Dr. sc. Lorena Škuflić
Redovita profesorica
Ekonomski fakultet Sveučilišta u Zagreb, Hrvatska
E-mail: lskuflic@efzg.hr
Orcid: https://orcid.org/0000-0002-2978-2902

Dr. sc. Maja Bašić
Znanstvena savjetnica
Institut za javne financije, Zagreb, Hrvatska
E-mail: maja.basic@ijf.hr
Orcid: https://orcid.org/0000-0002-1842-7091

OKOLIŠNA KUZNETSOVA KRIVULJA ZA EMISIJE STAKLENIČKIH PLINOVA U ZEMLJAMA ČLANICAMA EUROPSKE UNIJE: SEKTORSKI PRISTUP

UDK / UDC: 330.43:330.15:504(4-67EU)
JEL klasifikacija / JEL classification: Q53, Q56, O44, C23
https://doi.org/10.17818/EMIP/2026/27
Izvorni znanstveni rad / Original scientific paper
Primljeno / Received: 16. ožujka 2026. / March 16, 2026
Prihvaćeno / Accepted: 18. svibnja 2026. / May 18, 2026

Sažetak

Rad istražuje povezanost emisija stakleničkih plinova i dohotka po stanovniku u 27 zemalja članica Europske unije u razdoblju od 1995. do 2023. godine primjenom hipoteze okolišne Kuznetsove krivulje (EKC). Primjenom kvadratnih, kubnih i dinamičkih panel-modela analizirane su agregatne i sektorske emisije u razvijenijim i manje razvijenim zemljama članicama. Rezultati upućuju na strukturne razlike među skupinama zemalja. Obrnuta U-krivulja potvrđena je u ukupnim emisijama, sektoru zgradarstva i izgaranju goriva u razvijenijim zemljama, dok manje razvijene zemlje uglavnom bilježe rastuće i konveksne obrasce kretanja emisija i dohotka. Smanjenje emisija ponajprije je povezano s vremenskim učincima i javnim politikama, a ne isključivo s rastom dohotka. Povećanje udjela obnovljivih izvora energije i smanjenje energetskog intenziteta dodatno pridonose smanjenju emisija, potvrđujući važnost tehnološke tranzicije i regulatorne potpore u tranzicijskim gospodarstvima.

Ključne riječi: okolišna Kuznetsova krivulja, GHG, emisije CO_2, BDP per capita, Europska unija.

This work is licensed under a Creative Commons Attribution 4.0 International License.

1. UVOD

Povijesno gledano, rastuća važnost pitanja zaštite okoliša pratila je razvoj teorija gospodarskog rasta i njihov postupni prelazak prema konceptu održivog gospodarskog razvoja. Rani pristupi ekonomskom rastu i razvoju bili su pretežito usmjereni na akumulaciju kapitala, rad i podjelu rada, pri čemu se nedovoljna raspoloživost prirodnih resursa smatrala ograničavajućim čimbenikom gospodarskog prosperiteta, a to je stajalište snažno povezano s klasičnom ekonomskom teorijom. Daljnjim razvojem ekonomske teorije čimbenici rasta postupno su se preispitivali, pa tako neoklasična teorija rasta, koja se najčešće povezuje sa Solowom, objašnjava dugoročni rast BDP-a po stanovniku egzogenim tehnološkim napretkom, uz pretpostavku opadajućih prinosa na kapital.

Nakon toga razvijene su teorije endogenog rasta, pri čemu Romer ističe ulogu znanja, inovacija te istraživanja i razvoja, dok Lucas naglašava važnost kvalitete ljudskog kapitala. Ovi pristupi temelje se na pretpostavci da zemlje mogu ostvariti tehnološki napredak endogeno, kroz kontinuirana ulaganja u obrazovanje, razvoj znanja i inovacije (Škuflić & Vlahinić-Dizdarević, 2003). Suvremene teorije rasta dodatno naglašavaju važnost kvalitete proizvodnih čimbenika, institucionalnog okvira, te sposobnosti zemalja da stvaraju i šire nova znanja, inovacije i digitalne tehnologije. U tom kontekstu, institucionalna teorija rasta stavlja kvalitetu institucija u središte istraživanja, prepoznajući je kao temeljni preduvjet održivog i dugoročnog gospodarskog rasta.

Proces gospodarskog rasta i razvoja uključuje značajne strukturne promjene, obilježene najprije prijelazom iz poljoprivrede u industriju, a potom sve većom dominacijom uslužnog sektora. S ubrzanom industrijalizacijom, koja korespondira sa povećanjem BDP-a, postalo je jasno da pojedine industrije predstavljaju ozbiljnu prijetnju prirodnom okolišu, dok druge uzrokuju manju štetu budućim generacijama. Kao odgovor na te izazove, koncept održivog razvoja dobio je na važnosti tijekom 1980-ih godina, te je formalno definiran u Brundtlandovom Izvješću Ujedinjenih naroda iz 1987. godine. Održivi razvoj definira se kao razvoj koji zadovoljava potrebe sadašnje generacije bez ugrožavanja mogućnosti budućih generacija da zadovolje vlastite potrebe (Ujedinjeni narodi, 1987). Taj je okvir označio prvu sustavnu integraciju gospodarskog rasta, socijalne pravednosti i zaštite okoliša u jedinstveni konceptualni pristup.

Grossman i Krueger prvi su ekonomisti koji su empirijski i sustavno uspostavili vezu između kvalitete okoliša i gospodarskog rasta. Njihov rad predstavlja značajan doprinos analizi odnosa između bruto domaćeg proizvoda (BDP-a) i okolišnih pokazatelja, odnosno između gospodarskog rasta i onečišćenja okoliša, s posebnim naglaskom na ulogu međunarodne trgovine. Taj je odnos u literaturi poznat kao hipoteza okolišne Kuznetsove krivulje (eng. *Environmental Kuznets Curve* ili EKC) (Grossman & Krueger, 1991). Nakon te pionirske studije provedena su brojna istraživanja. Neka su potvrdila „U-oblikovani" odnos između gospodarskog rasta i onečišćenja, dok su drugi autori utvrdili monoton rastući ili kubični odnos.

Središnje istraživačko pitanje ovoga rada usmjereno je na utvrđivanje slijede li emisije stakleničkih plinova (GHG) obrazac okolišne Kuznetsove krivulje (EKC) u odnosu na BDP na uzorku svih zemalja Europske unije (EU), uz kontrolu dinamike stanovništva. Analiza u ovom radu pristupa tom pitanju kroz ispitivanje triju hipoteza:

Hipoteza 1. Ukupne emisije stakleničkih plinova pokazuju EKC-tip odnosa s gospodarskim rastom: emisije najprije rastu, a zatim opadaju kako BDP po stanovniku raste (obrnuta U-krivulja).

Hipoteza 2. Emisije CO_2 iz pojedinih izvora (poljoprivreda, zgradarstvo, izgaranje goriva, industrijsko izgaranje, energetika, industrijski procesi, promet, otpad) slijede EKC-tip odnosa s BDP-om.

Hipoteza 3. Odnos dohotka i emisija razlikuje se između razvijenijih i manje razvijenih država članica EU.

Rad je organiziran u pet cjelina. Uz uvod i zaključak, donosi sveobuhvatan pregled relevantne literature o odnosu gospodarskog rasta i okoliša, temeljen na prethodnim empirijskim istraživanjima, prikazuje metodološki okvir, te iznosi i raspravlja rezultate empirijske analize.

2. TEORIJSKA RAZMATRANJA ODNOSA GOSPODARSKOG RASTA I OKOLIŠA

Središnje pitanje koje se pojavilo u ekonomskoj literaturi odnosi se na to može li se dugoročni gospodarski rast i razvoj uskladiti s očuvanjem okoliša ili su ta dva cilja inherentno suprotstavljena. S jedne strane, neki autori tvrde da kontinuirani rast proizvodnje i potrošnje može dovesti do iscrpljivanja prirodnih resursa i degradacije okoliša, dok, s druge strane, zagovornici alternativnog stajališta smatraju da je gospodarski rast preduvjet poboljšanja kvalitete okoliša. Naime, rast razine BDP-a povećava i potražnju za čišćim okolišem i sposobnost društva da financira mjere zaštite okoliša raste.

U ranim fazama razvoja obično se intenzivira degradacija okoliša jer siromašnije zemlje nemaju dovoljno financijskih resursa, niti institucionalnih kapaciteta za ulaganja u zaštitu okoliša. Kada se dosegne određeni prag dohotka, degradacija se može stabilizirati i naposljetku smanjiti kao rezultat tehnološkog napretka, strukturnih promjena u gospodarstvu i jačanja okolišnih politika. U ekonomskoj literaturi ne postoji konsenzus o razini dohotka na kojoj dolazi do preokreta i ovisi o vrsti onečišćivača koji se promatra i raspon točke preokreta je u omjeru 1:7. Ova varijabilnost upućuje na nepostojanje jedinstvenog obrasca u odnosu između dohotka i okoliša. Relativno visok dohodovni prag tada je bio, a i danas je, nedostižan za velik broj zemalja. Stoga, za mnoge zemlje, gospodarski rast i dalje ima negativne posljedice za okoliš i buduće generacije.

Zemlje članice Europske unije znatno se razlikuju prema razini dostignutog razvoja i povijesnim obrascima rasta. Dok su pojedine današnje članice Europske unije imale dugotrajna razdoblja centralno planiranih

gospodarstava obilježena snažnom industrijalizacijom, zemlje sjeverne i srednje Europe znatno su ranije prošle proces tranzicije prema postindustrijskim gospodarskim strukturama. Nasuprot tome, južnoeuropska gospodarstva pokazuju relativno visoku ovisnost o turizmu i uslužnim djelatnostima. Te strukturne razlike, zajedno s heterogenim razinama dohotka i izraženim sezonskim fluktuacijama stanovništva povezanim s turizmom, stvaraju neujednačene pritiske na okoliš među državama i regijama. Nadalje, neujednačena razina životnog standarda među državama članicama EU, također rezultira različitim utjecajima na okoliš. Luksemburg, s pretežno uslužnom gospodarskom strukturom i iznadprosječnim BDP-om po stanovniku, ima potpuno drukčiji okolišni otisak od Bugarske, najmanje razvijene članice Unije sa izrazito emisijki intenzivnim inudstrijskim sektorom.

Uz strukturne i razvojne odrednice, institucionalni i regulatorni čimbenici imaju središnju ulogu u oblikovanju dinamike onečišćenja. Od sredine 1980-ih, Europska unija postupno je jačala svoj okolišni okvir, u početku kroz ciljane mjere poput direktiva o kvaliteti zraka, a kasnije kroz sveobuhvatne regulatorne sustave koji obuhvaćaju industrijska postrojenja. Direktiva o integriranom sprječavanju i kontroli onečišćenja (IPPC) (96/61/EZ), kasnije ojačana Direktivom o industrijskim emisijama (2010/75/EU), uvela je jedinstveni sustav izdavanja dozvola temeljen na primjeni najboljih raspoloživih tehnika. Ovi regulatorni razvojni koraci vjerojatno su utjecali na kretanje onečišćenja tijekom vremena, te bi ih trebalo izričito uključiti u empirijske analize odnosa između dohotka i okoliša.

2.1. Hipoteza okolišne Kuznetsove krivulje

Odnos između kvalitete okoliša i gospodarskog razvoja prvi su sustavno istražili Grossman i Krueger (1991), koji su taj odnos formalizirali kroz koncept okolišne Kuznetsove krivulje. Njihov značajan doprinos, temeljen na podacima za 42 zemlje, analizira povezanost između dohotka po stanovniku i različitih pokazatelja onečišćenja zraka, uključujući sumporni dioksid (SO_2), dim i lebdeće čestice. Rezultati istraživanja upućuju na odnos u obliku obrnute U-krivulje, pri čemu degradacija okoliša raste pri nižim razinama dohotka, a opada nakon dosezanja točke preokreta procijenjene na približno 4.000–5.000 USD po stanovniku (u stalnim cijenama iz 1985.), a navedena prijelomna točka kreće se i do 35.000 USD ili više u nekim drugim istraživanjima (Holtz-Eakin & Selden, 1995). Nadalje, Grossman i Krueger, u svojoj analizi, identificirali su tri glavna kanala putem kojih liberalizacija trgovine utječe na okolišne ishode, a to su učinak opsega, učinak strukture i tehnološki učinak.

Učinak opsega odnosi se na povećanje ukupne proizvodnje kao rezultat viših razina gospodarske aktivnosti, što, uz nepromijenjene proizvodne strukture i tehnologije, dovodi do povećanja onečišćenja okoliša. Primjerice, širenje industrija temeljenih na fosilnim gorivima rezultira višim emisijama CO_2, SO_2 i drugih onečišćivača. Učinak strukture proizlazi iz promjena u sektorskoj strukturi gospodarstva i obrascima međunarodne trgovine. Komparativne prednosti u industrijama onečišćivačima mogu se pojaviti u manje razvijenim zemljama, s relativno slabijom okolišnom regulativom, što ima implikacije za alokaciju stranih

izravnih ulaganja. Međutim, smjer učinka strukture ovisi o konkretnom obrascu gospodarske specijalizacije i ne mora nužno podrazumijevati povećanje onečišćenja. Tehnološki učinak općenito se smatra pozitivnim, jer liberalizacija trgovine i rast BDP-a olakšavaju usvajanje čišćih, učinkovitijih i tehnološki naprednijih proizvodnih procesa. Istodobno, viši životni standard u pravilu potiče veću svijest o zaštiti okoliša, što dovodi do strožih regulatornih okvira. Ovi učinci promatrani zajedno upućuju na to da učinak opsega uglavnom povećava onečišćenje, tehnološki učinak ga smanjuje, dok učinak strukture može djelovati u oba smjera.

Na temelju opsežnih statističkih i ekonometrijskih analiza Grossman i Krueger pokazali su da odnos između gospodarskog razvoja, mjerenog BDP-om po stanovniku, i onečišćenja okoliša često slijedi obrazac obrnute U-krivulje (Grossman & Krueger, 1991). U ranim fazama industrijalizacije, obilježenima niskim okolišnim standardima, razine onečišćenja imaju tendenciju rasta. S porastom dohotka, povećana svijest o okolišu, strukturna transformacija gospodarstva prema uslužnim djelatnostima i uvođenje strožih regulatornih okvira zajednički doprinose naknadnom smanjenju onečišćenja. Taj se preokret događa oko tzv. točke preokreta u razvojnome procesu. Empirijska istraživanja pokazala su različite procjene razine dohotka pri kojoj se ta točka javlja, a prag znatno varira ovisno o vrsti onečišćivača koji se promatra. Stoga rezultate EKC-a treba tumačiti s velikim oprezom. Arrow i sur. (1995) dodatno naglašavaju da sam gospodarski rast ne jamči poboljšanje kvalitete okoliša, osobito u slučaju globalnih i dugoročnih izazova poput klimatskih promjena, te ističu ključnu ulogu institucija, okolišne politike i očuvanja otpornosti ekosustava u postizanju održivog razvoja.

Nadovezujući se na taj okvir, Shafik i Bandyopadhyay (1992) proveli su jedno od najopsežnijih ranih empirijskih testiranja hipoteze EKC-a. Koristeći podatke za 149 zemalja u razdoblju 1960.–1990., analizirali su širok skup okolišnih pokazatelja u državama različite dohodovne razine. Njihovi rezultati pokazuju da okolišni ishodi ne slijede jedinstveni obrazac povezan s dohotkom. Pokazatelji poput pristupa sigurnoj pitkoj vodi i sanitarnim uslugama monotono se poboljšavaju s rastom dohotka, dok se odnos obrnute U-krivulje javlja prvenstveno kod lokalnih onečišćivača zraka, osobito lebdećih čestica i sumpornog dioksida. Suprotno tome, kod globalnih ili lako eksternaliziranih okolišnih problema, poput emisija ugljikova dioksida (CO_2) po stanovniku i stvaranja komunalnog otpada, ne nalazi se dokaz o smanjenju pri višim razinama dohotka. Naime, ti pokazatelji pokazuju kontinuirano pogoršanje s rastom dohotka. Slično tome, pokazatelji kvalitete riječnih voda pokazuju slabe ili nedosljedne odnose s dohotkom, te ne slijede jasan EKC obrazac. Istodobno, Shafik i Bandyopadhyay (1992) su utvrdili snažnu povezanost između cijena energije i emisija CO_2, što upućuje na to kako ekonomski poticaji i regulatorni instrumenti imaju odlučujuću ulogu u smanjenju globalnih emisija, više nego sam rast dohotka.

U posebnim povijesnim okolnostima, poput prvog i drugog naftnog šoka, nagli rast cijena nafte doveo je do smanjenja gospodarske aktivnosti u mnogim zemljama, što je bilo praćeno privremenim padom razine onečišćenja, a isto se desilo i za vrijeme COVID pandemije. Ti su događaji naglasili važnost cijena

energije kao značajne odrednice dinamike emisija. U tom je kontekstu Tucker (1995) istaknuo potrebu uključivanja energetskih varijabli u empirijske analize odnosa dohotka i okoliša, pristup koji su kasnije preuzeli Suri i Chapman (1998), koji su izričito analizirali ulogu potrošnje energije i strukturnih promjena unutar EKC okvira. Osim cijena energije i otvorenosti trgovine, literatura je razmatrala širok raspon dodatnih objašnjavajućih varijabli. Međutim, potreban je oprez kako bi se izbjegla prekomjerna parametrizacija modela, jer uključivanje prevelikog broja regresora može oslabiti identifikaciju modela i narušiti robusnost empirijskih rezultata. U novije vrijeme, značajan pad razina onečišćenja tijekom zatvaranja uzrokovanih pandemijom bolesti COVID-19, nakon čega su uslijedile djelomične postpandemijske prilagodbe, dodatno je naglasio potrebu uzimanja u obzir strukturnih lomova u empirijskim modelima, primjerice uključivanjem odgovarajućih varijabli.

Nadalje, rad Panayotou (2000) je pružio sveobuhvatan pregled empirijske i teorijske literature o odnosu gospodarskog rasta i kvalitete okoliša, ističući da su istraživači primjenjivali EKC okvir na različite okolišne pokazatelje, uključujući analize onečišćenja zraka i voda, te druge oblike okolišnog pritiska (npr. Cropper & Griffiths, 1994). Dokazi upućuju na to da ne postoji jedinstveni, univerzalni obrazac te da odnos obrnute U-krivulje nije potvrđen u svim slučajevima, niti se dosljedno pojavljuje zajednička točka preokreta u različitim istraživanjima. Brojni radovi također su se usredotočili na potrošnju energije kao ključni pokretač degradacije okoliša, s obzirom na njezinu središnju ulogu u generiranju različitih oblika onečišćenja.

U novijim istraživanjima Farhani i Shahbaz (2014) su na uzorku od 10 bliskoistočnih i afričkih zemalja i razdoblju od 1990.-2010. u ocjeni CO_2 emisija uključili BDP per capita, kvadrirani BDP per capita, energetsku potrošnju, trgovinsku otvorenost, industrijsku strukturu i ljudski razvoj. A istraživanjem je potvrđena obrnuta U-krivulja (EKC). Potrošnja energije predstavlja najjači faktor rasta emisija CO_2, a pozitivna veza je utvrđena i kod rasta industrije i kod rasta trgovine. Kasman i Duman (2015) analiziraju uzročnu povezanost između potrošnje energije, emisija CO_2, gospodarskog rasta, trgovinske otvorenosti i urbanizacije. Rezultati empirijske analize pružaju dokaze u prilog hipotezi okolišne Kuznetsove krivulje, potvrđujući postojanje obrnutog U-oblikovanog odnosa između gospodarskog rasta i onečišćenja okoliša. Zhigolli i Fetai (2024) istraživali su odnos između emisija CO_2 i dohotka per capita na primjeru zemalja Zapadnog Balkana i utvrdili negativan odnosu u vremenskom intervalu od 2011.-2022., dok su Srdelić i Barišić (2025) ispitivali EKC na sektorskoj razini na primjeru Hrvatske u periodu od 1995.-2021. te utvrdili postojanje obrnute U krivulje u energetsko intenzivnim sektorima i sektoru zgradarstva. Autori koji su uključili velik broj varijabli između kojih i populaciju i urbanizaciju (primjerice, Gravina & Lanzafame, 2024) pokazali su da odnos između ekonomskog rasta i okolišnog opterećenja slijedi obrnuti N-oblik, a ne klasičnu EKC krivulju, pri čemu postoje dvije ključne prijelomne točke: minimum na približno 1.300 USD BDP-a po stanovniku i maksimum na oko 40.000 USD**.** Između tih točaka ekonomski rast dovodi do povećanja emisija, dok tek na vrlo visokim razinama dohotka dolazi do njihovog smanjenja. Osim BDP-a po stanovniku (u linearnom, kvadratnom i

kubnom obliku), rezultati identificiraju niz ključnih determinanti emisija: potrošnju fosilnih goriva, industrijsku strukturu, međunarodni turizam, financijski razvoj (kreditiranje), nejednakost dohotka i urbanizaciju kao faktore koji povećavaju emisije, dok alternativni i nuklearni izvori energije, šumske površine, udio uslužnog i poljoprivrednog sektora, izvoz te politička polarizacija djeluju u smjeru njihovog smanjenja. Iako su uključene i socio-demografske varijable poput gustoće populacije, rezultati pokazuju da je dinamika emisija primarno određena kombinacijom ekonomskog rasta, energetskog miksa i strukturnih karakteristika gospodarstva. Većina zemalja u razvoju nalazi se na uzlaznom dijelu krivulje, dok su razvijene zemlje pretežno u fazi smanjenja emisija. Istaknuti autori dokazali su da oblik EKC krivulje ovisi o izboru varijabli i samom modelu.

2.2. Vrsta onečišćenja kao determinanta EKC odnosa

Empirijska istraživanja s kraja prošlog stoljeća dodatno naglašavaju razliku između lokalnih i globalnih onečišćivača u analizama EKC-a. Selden i Song (1994), analizirajući podatke za 47 do 68 zemalja u razdoblju 1979.–1990., identificiraju odnose u obliku obrnute U-krivulje za nekoliko lokalnih onečišćivača zraka, uz relativno visoke procijenjene razine dohotka na točki preokreta. Međutim, njihovi nalazi upućuju na to da se takvi obrasci ne mogu jednostavno generalizirati na globalne onečišćivače poput CO_2. Slično tome, Holtz-Eakin i Selden (1995), koristeći panel podataka za 130 zemalja koje obuhvaćaju približno 74 % globalnih emisija CO_2 iz fosilnih goriva i proizvodnje cementa, utvrđuju da se elastičnost emisija u odnosu na dohodak smanjuje kako dohodak raste, ali se ukupne emisije CO_2 i dalje projiciraju u rastu zbog kontinuiranog povećanja stanovništva i dohotka, osobito u zemljama s nižim razinama dohotka.

Shafik (1994) u svojim istraživanjima je došao do zaključka o obrnutoj U-krivulji tipičnoj za EKC isključivo za lokalne okolišne indikatore, poput sumpornog dioksida i lebdećih čestica, koji imaju neposredne i lokalizirane učinke, dok, nasuprot tome, kod globalnih onečišćivača, osobito emisije ugljikova dioksida, nije pronašao točku preokreta, što upućuje na to da degradacija okoliša povezana s globalnim eksternalijama ne opada s rastom dohotka.

Cole, Rayner i Bates (1997) su dodatno doveli u pitanje univerzalnost hipoteze EKC-a, pokazujući da su procijenjene točke preokreta osobito za globalne onečišćivače vrlo visoke i uz visoku statističku nesigurnost, te se često nalaze izvan promatranog raspona dohotka. Njihovi rezultati sugeriraju da su EKC-odnosi robusniji za određene lokalne onečišćivače nego za globalne, čime se dovodi u pitanje stajalište da će gospodarski rast sam po sebi automatski riješiti okolišne probleme.

Stern (2004) u pregledu hipoteze okolišne Kuznetsove krivulje identificira nekoliko važnih slabosti ranijih istraživanja, poput izostavljanja relevantnih varijabli, neprikladnih specifikacija modela i nedovoljnog uvažavanja međudržavnih razlika. Primjenom unaprijeđenih panel-tehnika nalazi ograničenu potporu obrnutoj U-krivulji u slučaju pojedinih lokalnih onečišćivača zraka, poput

sumpornog dioksida, dok odbacuje postojanje stabilne EKC za globalne onečišćivače, osobito ugljikov dioksid. Stern je zaključio da su dugoročna poboljšanja kvalitete okoliša primarno rezultat tehnološkog napretka, promjena u energetskoj strukturi i politici zaštite okoliša, a ne samog rasta dohotka.

Lieb (2003) je ponudio teorijsko objašnjenje zašto je pojava okolišne Kuznetsove krivulje manje vjerojatna u slučaju globalnih onečišćivača. Njegovo istraživanje pokazuje da su, za razliku od lokalnih okolišnih problema, globalni onečišćivači poput ugljikova dioksida obilježeni snažnim poticajima "slobodnog jahača", što smanjuje nastojanja pojedinih zemalja da provode politike smanjenja emisija kako dohodak raste. Posljedično, sam rast dohotka može biti nedostatan za generiranje EKC točke preokreta, što naglašava važnost koordiniranog međunarodnog djelovanja u rješavanju globalnih okolišnih eksternalija.

2.3. Nelinearnost odnosa okoliša i dohotka kroz slučajeve pojedinih država

Analize na razini pojedinih zemalja pružaju dodatne uvide u složenost odnosa između dohotka i okoliša. Friedl i Getzner (2003), fokusirajući se na Austriju u razdoblju 1960.–1999., identificiraju kubični (N-oblikovani) odnos između BDP-a i emisija CO_2, uz strukturni lom sredinom 1970-ih povezan s naftnim šokom. Njihova specifikacija uključuje otvorenost trgovine (mjerenu udjelom uvoza) radi testiranja hipoteze o utočištu za zagađivače, kao i udio tercijarnog sektora radi obuhvaćanja strukturne transformacije gospodarstva. Slične nelinearne dinamike razmatraju Dinda (2004) te Kijima, Nishide i Ohyama (2010). Nadalje, Lieb (2003) tvrdi da su za zagađivače zaliha, poput CO_2, monotone ili N-oblikovane putanje teorijski vjerojatnije od obrasca obrnute U-krivulje, koji se obično povezuje sa zagađivačima toka.

Dvije utjecajne studije usmjerene na Francusku, Ang (2007) te Iwata, Okada i Samreth (2010), daju vrijedan doprinos raspravi o EKC-u za emisije ugljikova dioksida. Ang (2007) istražuje dugoročnu vezu između emisija CO_2, potrošnje energije i gospodarskog rasta u Francuskoj u razdoblju 1960.–2000., te pronalazi stabilan dugoročni odnos među varijablama. Rezultati pokazuju da su gospodarski rast i potrošnja energije pozitivno povezani s emisijama CO_2, pružajući ograničenu potporu hipotezi obrnute U-krivulje. Umjesto potvrde točke preokreta, istraživanje naglašava ključnu ulogu obrazaca potrošnje energije u objašnjavanju dinamike emisija. Slično tome, Iwata, Okada i Samreth (2010) također ispituju EKC hipotezu za emisije CO_2 u Francuskoj, izričito uključujući energetsku strukturu zemlje u analizu. Njihovi rezultati sugeriraju da, iako se mogu pojaviti određeni nelinearni obrasci, smanjenje emisija, u velikoj je mjeri, posljedica strukturnih promjena u energetskom miksu, osobito širenja nuklearne energije, a ne samog rasta dohotka. Istraživanje naglašava da su tehnološke promjene i energetska politika ključne odrednice okolišnih ishoda.

Navedene studije, promatrane zajedno, pokazuju da se u slučaju Francuske smanjenje emisija ne može objasniti isključivo rastom dohotka. Umjesto toga, presudnu ulogu imaju strukturne promjene u energetskom sektoru i proaktivne javne politike. Ovi nalazi dodatno podupiru tvrdnju da hipoteza EKC-a, osobito u slučaju globalnih onečišćivača poput CO_2, nije automatska niti univerzalno primjenjiva.

Na temelju prikazanih teorijskih mehanizama, empirijski model u ovom radu operacionalizira ključne determinante okolišnog opterećenja kroz odabrane varijable. Tehnološki i strukturni učinci obuhvaćeni su kroz razinu BDP-a po stanovniku i njegov kvadratni oblik, dok se energetski učinci reflektiraju kroz emisije stakleničkih plinova po sektorima. Demografski pritisci na okoliš uključeni su putem varijable stanovništva, koja odražava potencijalni utjecaj rasta populacije na potražnju za energijom i resursima. Na taj način empirijski model omogućuje testiranje teorijskih pretpostavki EKC-a u kontekstu zemalja Europske unije.

3. METODOLOGIJA I REZULTATI

Ovaj rad koristi uravnotežene panel podatke koji obuhvaćaju 27 zemalja članica Europske unije u razdoblju od 1995. do 2023. godine (T = 29, N = 27). Iako su prethodni radovi analizirali postojanje Kuznetsove krivulje na primjeru pojedinih sektora (primjerice, Mazzanti & Zoboli, 2009; Konat et al., 2024) ili odnose između emisija različitih vrsta stakleničkih plinova i dohotka (Madaleno & Moutinho, 2021), većina radova temelji se na ispitivanju odnosa gospodarskog razvoja i emisija stakleničkih plinova kao početne teze EKC (primjerice, Lapinskiene et al., 2015; Mohammed et al., 2023). U ovom radu teži se pružiti komparativan pristup analizi emisija plinova u raznim sektorima, a kako bi se pokazala nužnost heterogenog pristupa javnoj politici smanjenja istih.

Vizualna analiza dinamike razdvajanja gospodarskog rasta i emisija stakleničkih plinova po zemljama (Prilog 1) ukazuje na snažan trend razdvajanja u razvijenijim zemljama, te volatilniji trend u manje razvijenijim zemljama. Zemlje Srednje i Istočne Europe, primjerice, prati relativno razdvajanje u kojem emisije počinju stagnirati unatoč gospodarskom rastu. S druge strane, u mediteranskim zemljama emisije do kasnih 2000-ih ostaju vezane uz razinu dohotka po stanovniku. Kako bi se ispitao utjecaj dohotka na emisije stakleničkih plinova i postojanje Kuznetsove krivulje, a s obzirom na razlike u gospodarskom razvoju unutar Europske unije, zemlje članice podijeljene su u dvije skupine, razvijenije i manje razvijene s obzirom na razinu medijana prosječnog dohotka mjerenog aritmetičkom sredinom u periodu 1995.-2023. godine. Skupinu razvijenijih zemalja čine zemlje stare jezgre Europske unije, koje obilježava trajno viša razina dohotka po stanovniku u odnosu na prosjek Europske unije: Austrija, Belgija, Cipar, Danska, Finska, Francuska, Njemačka, Irska, Italija, Malta, Nizozemska, Španjolska i Švedska. Preostale zemlje, svrstane se u skupinu manje razvijenih u odnosu na prethodne jer njihov prosječni dohodak po stanovniku ne doseže razinu razvijenijih, te u literaturi pokazuju obilježja slabije konvergencije i sporijeg rasta produktivnost. Skupinu manje razvijenih zemalja čine Bugarska, Hrvatska, Češka, Estonija, Grčka, Mađarska, Latvija, Litva, Poljska, Portugal , Rumunjska, Slovačka i Slovenija.

Prije procjene modela proveden je niz dijagnostičkih testova kako bi se ispitala svojstva podataka i identificirao i specificirao ekonometrijski model. Svi podaci preuzeti su iz baza Eurostat, World Development Indicators (WDI) i Svjetske banke. Testovi jediničnog korijena pokazali su kako postoje razlike u varijablama u stacionarnosti na razinama, ali je većina njih stacionarna u prvoj diferenciji, I(1) (Prilog 2). Nadalje, Pesaranov (2004) i Friedmanov (1937) test međuovisnosti poprečnih presjeka upućuje na prisutnost znatne međuovisnosti među varijablama, što je odraz gospodarske integracije i zajedničkog regulatornog okruženja karakterističnog za zemlje članice Europske unije (Prilog 4). S obzirom na nestacionarnost i međuovisnost poprečnih presjeka, analizirala se i kointegracija panela koristeći tri komplementarna pristupa: Kaov (1999) test temeljen na rezidualima, Pedronijev (1999, 2004) test kointegracije te Westerlundov (2007) test temeljen na mehanizmu korekcije pogreške. Rezultati sva tri postupka ukazuju na postojanje kointegracije između emisija stakleničkih plinova i dohotka po stanovniku, potvrđujući sličan trend u podacima. Iako analiza koeficijenata korelacije za sve promatrane varijable ne prelazi 0,8, osim za koeficijent korelacije između populacije i emisija stakleničkih plinova (te emisija CO_2 iz poljoprivrede i otpada), kako bi se ublažila multikolinearnost između dohotka po stanovniku i njegove kvadratne vrijednosti, varijabla dohodak centrirana je i izražena kao odstupanja od uzorkovanog prosjeka, a što smanjuje multikolinearnost bez narušavanja zaključaka u pogledu valjanosti modela i interpretacije koeficijenata. Faktor inflacije varijance (VIF) pokazuje da najveći VIF iznosi 5,66 za BDP p.c., dok je sljedeća vrijednost VIF-a 3,28, a prosječna 2,56, prema čemu je zaključeno kako problem multikolinearnosti među varijablama u modelu ne predstavlja problem.

Ekonometrijski model ima sljedeći oblik:

$$y_{it} = \alpha_i + \lambda_t + \beta_1 x_{it} + \beta_2 x_{it}^2 + \gamma z_{it} + \mu_{it} \quad (1)$$

gdje y_{it} predstavlja emisije stakleničkih plinova za zemlju *i* u godini *t*. Ukupne emisije stakleničkih plinova (GHG) za cijelu ekonomiju uključuju emisije ugljičnog dioksida (CO_2), metana (CH_4) i dušikovog oksida (N_20) koje nastaju izgaranjem fosilnih goriva te uzrokuju globalno zatopljenje. Pri izradi sektorske analize koristila se emisija CO_2 koja se učestalo koristi pri izražavanju ekvivalentnih usporedba utjecaja emisija stakleničkih plinova u raznim sektorima[1]. α_i označava fiksne učinke po zemlji koji zahvaćaju vremenski nepromjenjivu heterogenost između država članica, λ_t predstavlja fiksne vremenske učinke (godišnje *dummy* varijable) koji kontroliraju zajedničke vremenske šokove i promjene politika koje utječu na sve zemlje; x_{it} je prirodni logaritam realnog BDP-a po stanovniku (centriran na prosjeku uzorka); x_{it}^2 je njegova kvadratna vrijednost uključena kako bi obuhvatila potencijalne nelinearne odnose između dohotka i emisija stakleničkih plinova ili CO_2 u skladu s hipotezom EKC-a, z_{it} predstavlja vektor kontrolnih varijabli, a μ_{it} je idiosinkratična pogreška modela.

U model su uključeni fiksni vremenski učinci zato što koordinirane klimatske politike Europske unije, kao što su Sustav trgovanja emisijama i pojedini

[1] Za detalje pogledati objašnjenje statistike na mrežnim stranicama Eurostata.

klimatski paketi, generiraju zajedničke šokove u svim zemljama članicama, pri čemu godišnje *dummy* varijable apsorbiraju učinke interventnih politika, tehnoloških promjena i globalnih gospodarskih šokova (primjerice, recesije 2008. godine ili pandemije COVID-19) koji utječu na emisije neovisno o rastu dohotka specifičnom za pojedinu zemlju. Iako bi fiksni učinci po zemljama trebali apsorbirati heterogenost između zemalja članica, kako bi se izbjegao problem izostavljenih varijabli i izolirao učinak dohotka na emisije stakleničkih plinova, model koristi vektor kontrolnih varijabli koje obuhvaćaju strukturne, tehnološke i institucionalne karakteristike zemalja članica (Antweiler et al., 2001). Strukturne karakteristike uključuju: i) udio dodane vrijednosti industrije u BDP-u pri čemu veći udio industrije vodi do viših emisija stakleničkih plinova (Lamb et al., 2021), ii) trgovinsku otvorenost koja označava udio uvoza i izvoza u BDP-u (Islam et al., 2016), iii) urbanizaciju kao udio urbanog u ukupnom stanovništvu, a koja oblikuje potražnju za energijom (Lee et al., 2022; Luqman et al., 2023), iv) veličinu populacije kako bi se izolirao učinak ekonomije opsega s obzirom na to da rast stanovništva utječe na rast potražnje za proizvodima što vodi pritiscima na zagađenje okoliša (Holtz-Eakin & Selden, 1995, Lee et al., 2022), v) te razvijenost financijskog tržišta (Qin et al., 2021, Lu et al., 2022) koju zbog nedostatka konzistentnih vremenskih serija promatramo kao dug privatnog nebankarskog sektora vodeći se premisom da su snažnija financijska tržišta nužna za efikasnu alokaciju financijskog kapitala prema zelenim tehnologijama (de Haas & Popov, 2023). Tehnološke karakteristike mjerene su: a) razinom usvajanja zelenih tehnologija u proizvodnji energije za što koristimo pokazatelj udjela obnovljivih izvora energije u ukupnoj potrošnji (IEA u WDI, 2026; Squalli, 2017; Lu et al., 2022), te b) energetskim intenzitetom koji mjeri kilograme ekvivalentne potrošnje goriva u realnih $1000 BDP PPP (WDI, 2026). Tehnološki napredak u smjeru korištenja obnovljivih izvora energije (Bilgen & Sarikaya, 2016) i smanjenje energetskog intenziteta impliciraju korištenje učinkovitijih proizvodnih tehnologija (Fisher-Vanden et al., 2004) te vode smanjenju emisija stakleničkih plinova (Qin et al., 2021). Finalno, institucionalne varijable objašnjavaju kvalitetu upravljanja i snagu državnog aparata u provođenju zakona za što smo koristili varijablu kvalitete institucija putem indeksa V-Dem koji mjeri kvalitetu institucija poput snažne vladavine prava ili neovisnog pravosuđa (Lau et al., 2014; Yameogo et al., 2021, Lee et al., 2022).

Varijable BDP p.c., populacija, trgovinska otvorenost, razvijenost financijskog tržišta, energetski intenzitet i emisije stakleničkih plinova u modelu su u logaritamskim vrijednostima. Varijable BDP p.c., BDP p.c.^{2}, BDP p.c.^{3} centrirane su na prosjeku uzorka kako bi se smanjila multikolinearnost, čime se ne mijenja utjecaj linearnog i kvadratnog (te eventualno kubnog) člana, te potvrđuje robustan odnos između dohotka i emisija stakleničkih plinova. Većina varijabli je nestacionarna u razinama (Prilog 2), a u radu se primjenjuje model u logaritamskim vrijednostima kako bi se procijenili dugoročni kointegracijski odnosi između emisija stakleničkih plinova i razine dohotka (Prilog 3).

Prisutnost međuovisnosti poprečnih presjeka (Prilog 4), potencijalna heteroskedastičnost i serijska korelacija u panel podacima zahtijevaju korištenje modela procijenjenog metodom najmanjih kvadrata s Driscoll-Kraayevim (1998)

standardnim pogreškama. Metoda najmanjih kvadrata s Driscoll-Kraayevim (1998) standardnim pogreškama daje konzistentne procjene koeficijenata, generirajući standardne pogreške robusne na prostorne i vremenske ovisnosti. Iako je model procijenjen dvosmjernim fiksnim efektima s Driscoll-Kraayevim (1998) standardnim pogreškama (Tablica 2 i Prilog 5), dodatni testovi robusnosti modela uključili su testiranje kubne funkcije, dinamičkog modela fiksnih efekata zbog postojanja dugoročnih kointegracijskih odnosa i modela standardiziranih procjenitelja (Prilog 6).

Deskriptivna statistika prikazana je u Tablici 1.

Tablica 1. Deskriptivna statistika

Varijabla	Izračun	Izvor podataka	Broj opažanja	Aritmetička sredina (μ)	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost
BDP p.c.	BDP p.c.	Eurostat	783	0,00	0,87	-2,72	1,86
BDP p.c.^{2}	BDP p.c.^{2}	Eurostat	783	0,75	1,17	0,00	7,43
BDP p.c.^{3}	BDP p.c.^{3}	Eurostat	783	-0,46	2,82	-20,23	6,45
Populacija	Broj stanovnika	Eurostat	756	0,00	0,01	-0,04	0,04
Urbanizacija	Udio urbanog u ukupnom stanovništvu	WB	783	0,71	0,12	0,50	0,96
Industrija	Udio dodane vrijednosti industrije u BDP-u	WDI	783	0,24	0,06	0,09	0,41
Trgovinska otvorenost	(Uvoz + izvoz) / BDP	WDI	783	0,73	0,24	0,31	1,63
Razvijenost financijskog tržišta	Udio duga privatnog nebankarskog sektora u BDP-u	Eurostat	783	4,67	0,59	2,39	5,85
Obnovljivi izvori energije	Udio obnovljivih izvora energije u ukupnoj potrošnji	WDI, Eurostat	756	0,01	0,01	-0,05	0,09
Energetski intenzitet	kilogram ekvivalentne potrošnje goriva u realnih $1000 BDP PPP iz 2021. godine	WDI	756	-0,03	0,05	-0,28	0,25
Kvaliteta institucija	v2x_liberal	V-Dem	756	0,00	0,02	-0,12	0,26
GHG	Emisija stakleničkih plinova	Eurostat	783	4,26	1,32	1,01	7,04
Poljoprivreda	CO_2 od poljoprivrede	Eurostat	696	0,30	0,37	0,00	1,64
Zgradarstvo	CO_2 od zgradarstva	Eurostat	783	2,20	1,32	0,08	5,39
Izgaranje goriva	CO_2 od izgaranja goriva	Eurostat	734	1,63	0,98	0	3,84
Industrijsko izgaranje	CO_2 od industrijskog izgaranja	Eurostat	775	2,18	1,17	0,01	4,77
Proizvodnja električne energije	CO_2 od proizvodnje električne energije	Eurostat	783	2,90	1,31	0,15	5,91
Industrijski procesi	CO_2 od industrijskih procesa	Eurostat	783	1,70	0,99	0,01	3,88
Promet	CO_2 od prometa	Eurostat	783	2,68	1,17	0,25	5,19
Otpad	CO_2 od otpada	Eurostat	653	0,17	0,36	0,00	1,65

Napomena: Svi podaci osim urbanizacije, industrije, obnovljivih izvora energije i kvalitete institucija su u logaritamskom obliku. Podaci za BDP su centrirani. Podaci za udio obnovljivih izvora energije u ukupnoj potrošnji s WDI dostupni su do 2021. godine, dok se metodologija izračuna podataka s Eurostata mijenjala 2003. Stoga su za ovaj pokazatelj korišteni podaci WDI, a za 2022. i 2023. godinu izračunala se godišnja stopa rasta te primijenila na podatke WDI.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Detaljni rezultati empirijske analize dani su u Prilogu 5, a sažetak rezultata prikazan je u Tablici 2.

Tablica 2. Sažetak rezultata analize EKC u zemljama članicama Europske unije

Sektor	Uzorak	BDP p.c.[2]	BDP p.c.	Vrem. trend	Strukturni efekti (Pop./Urb./Ind./Trg./Fin.)		Tehnološki efekti (Obn.en./En.int.)		Institucionalni	Oblik EKC
					Pozitivan	Negativan	Pozitivan	Negativan		
GHG	Cijeli uzorak	0,03***	0,43***	Neg. od 2003.	Pop. *** Trg. †	Urb. –***	En.int. ***	Obn.en. –***		Konveksan
	Razvijenije	–0,04***	0,45***	Neg. od 2008.	Pop. *** Ind. *** Trg. ***	Urb. –*** Fin. –***	En.int. ***	Obn.en. –***	Inst. –†	Obrnuto U
	Manje razv.	0,10***	0,45***	Neg. od 2003.	Ind. ** Fin. ***	Pop. –*** Urb. –***	En.int. ***	Obn.en. –***		Konveksan
Poljoprivreda	Cijeli uzorak	–0,01†	n.s.	Neg. od 1997.	Trg. **	Pop. –† Fin. –***	Obn.en. ***	En.int. –**	Inst. ***	Nije potvrđen
	Razvijenije	n.s.	n.s.	Neg. od 2006.	Trg. **	Fin. –***	Obn.en. ***		Inst. *	Nije potvrđen
	Manje razv.	–0,06*	n.s.	Neg. od 1998.		Urb. –*	Obn.en. *		Inst. ***	Obrnuto U
Zgradarstvo	Cijeli uzorak	n.s.	0,49***	Neg. od 2002.	Pop. ***	Urb. –† Ind. –***	En.int. ***	Obn.en. –***	Inst. **	Linearan
	Razvijenije	–0,17**	0,58***	Neg. od 2002.	Pop. *** Trg. *		En.int. **	Obn.en. –***	Inst. –†	Obrnuto U
	Manje razv.	0,05*	0,48***	Neg. od 1998.		Pop. –** Ind. –* Trg. –**		Obn.en. –**		Konveksan
Izgaranje goriva	Cijeli uzorak	0,12***	0,49***	Neg. od 2003.			Obn.en. ** En.int. ***		Inst. –**	Konveksan
	Razvijenije	–0,23***	1,12***	Neg. od 1996.	Urb. * Trg. †	Ind. –*	Obn.en. *	En.int. –†		Obrnuto U
	Manje razv.	0,23**	0,51**	Pozitivan	Ind. **	Trg. –†	Obn.en. *** En.int. *		Inst. –*	Konveksan
Industrijsko izgaranje	Cijeli uzorak	0,08***	0,27***	Neg. od 1998.				Obn.en. –***		Konveksan
	Razvijenije	n.s.	0,80***	Neg. od 2003.	Urb. *** Trg. ***	Pop. –*** Fin. –*	En.int. ***	Obn.en. –**		Linearan
	Manje razv.	0,15***	0,33**	Neg. od 1999.	Ind. *	Pop. –**		Obn.en. –**		Konveksan
Proizvodnje električne energije	Cijeli uzorak	n.s.	0,34**	Pozitivan	Pop. *** Ind. ***	Urb. –*	En.int. ***	Obn.en. –***		Linearan

	Razvijenije	n.s.	n.s.	Pozitivan	Pop. *** Ind. **	Fin. −***	En.int. ***	Obn.en. −***		Nije potvrđen
	Manje razv.	n.s.	0,57***	Neg. od 2004.	Pop. ** Ind. *** Fin. ***		En.int. ***	Obn.en. −***		Linearan
Industrijski procesi	Cijeli uzorak	n.s.	0,21*	Neg. od 2009.	Trg. **	Urb. −*** Ind. −*	Obn.en. *			Linearan
	Razvijenije	n.s.	0,51***	Neg. od 2008.	Trg. †	Ind. −* Fin. −*	Obn.en. *** En.int. ***			Linearan
	Manje razv.	0,07***	0,29**	Neg. od 1996.	Trg. *** Fin. ***	Pop. −** Urb. −*		Obn.en. −**		Konveksan
Promet	Cijeli uzorak	0,02*	0,56***	Pozitivan i n.s.	Trg. **	Urb. −***	En.int. **	Obn.en. −***	Inst. −*	Konveksan
	Razvijenije	0,06**	0,70***	Neg. od 2006.	Trg. * Fin. **	Urb. −*** Ind. −†	En.int. ***	Obn.en. −**	Inst. †	Konveksan
	Manje razv.	n.s.	0,38**	Pozitivan i n.s.	Pop. ** Trg. **	Urb. −**		Obn.en. −**	Inst. −†	Linearan
Otpad	Cijeli uzorak	n.s.	n.s.	Pozitivan	Pop. *	Urb. −*** Trg. −*	Obn.en. †		Inst. −*	Nije potvrđen
	Razvijenije	n.s.	−0,16†	Pozitivan	Pop. * Ind. *	Trg. −** Fin. −†			Inst. −*	Nije potvrđen
	Manje razv.	n.s.	n.s.	Pozitivan		Urb. −*	Obn.en. *** En.int. †			Nije potvrđen

Napomene: *** p-vrijednost < 0,001; ** p-vrijednost < 0,01; * p-vrijednost < 0,05; † p-vrijednost < 0,1. Prikazani su samo statistički značajni efekti ($p < 0,10$); varijable bez značajnog efekta izostavljene su iz ćelije. BDP p.c.[2] i BDP p.c. prikazani su kao koeficijenti na 2 decimalna mjesta; Pop. = logaritam populacije; Urb. = udio urbanog stanovništva u ukupnom stanovništvu; Ind. = udio dodane vrijednosti industrije u BDP-u; Trg. = logaritam trgovinske otvorenosti; Fin. razv. = logaritam duga (proxy za financijsku razvijenost); Obn. en. = udio obnovljivih izvora energije u ukupnoj potrošnji; En. int. = logaritam energetskog intenziteta; Kval. inst. = V-Dem liberalni indeks institucionalne kvalitete. „-" označava negativan odnos između nezavisne i zavisne varijable.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Empirijski rezultati pokazuju značajno razilaženje u putanjama emisija unutar Europske unije, što upućuje na to da odnos između gospodarskog rasta i degradacije okoliša ovisi o sektoru i razini razvoja. Ukupne emisije stakleničkih plinova u cijelom uzorku i manje razvijenim zemljama prate rastuću konveksnu putanju. Procijenjene vrijednosti koeficijenta dohotka i njegove kvadratne vrijednosti su pozitivne što ukazuje na to da u manje razvijenim zemljama emisije imaju tendenciju ubrzavanja kako dohodak raste. Nasuprot tome, razvijenije zemlje imaju potvrđen tradicionalni EKC oblik obrnutog slova U.

Analiza pojedinačnih sektora dodatno objašnjava razvojne asimetrije. Klasični obrazac EKC-a u obliku obrnutog slova U, prema kojem emisije CO_2 prvo rastu pa padaju s dohotkom, vidljiv je, osim u ukupnim emisijama razvijenijih zemalja, u ograničenom broju poduzoraka: i) u razvijenijim zemljama u sektorima zgradarstva i izgaranja goriva, te ii) u manje razvijenim zemljama u sektoru poljoprivrede. Empirijska analiza ukazuje na to kako za većinu promatranih sektora prevladavaju konveksni obrasci pri čemu hipoteza EKC ne vrijedi, a iz istog razloga u radu je izostavljen izračun točaka preokreta. U sektorima industrijskog izgaranja i prometa, emisije CO_2 pokazuju pretežno konveksne ili rastuće linearne obrasce, dok u sektoru proizvodnje električne energije u skupini razvijenih zemalja dohodak po stanovniku nije statistički značajan. Osobito je zanimljivo što nijedan poduzorak u sektoru otpada nije potvrdio povezanost između dohotka i emisija.

Kako bi se adresirao problem izostavljenih varijabli, u model je uključen prošireni vektor kontrolnih varijabli koji obuhvaća strukturne, tehnološke i institucionalne učinke koji mogu imati utjecaj na emisije stakleničkih plinova. Na agregatnoj razini, a vezano uz strukturne učinke, rast populacije dominantno povećava emisije, a rast udjela urbanog stanovništva vodi smanjenju emisija stakleničkih plinova (potonje, primjerice, u sektorima proizvodnje električne energije, industrijskih procesa, prometa i otpada). Rast udjela industrije u BDP-u na razini cijelog uzorka ima mješovit utjecaj na emisije. U sektorima zgradarstva i industrijskih procesa rast udjela industrije smanjuje emisije, dok ih u sektorima proizvodnje električne energije povećava. S druge strane, na agregatnoj razini trgovinska otvorenost povećava emisije, posebice u sektorima poljoprivrede, industrijskih procesa i prometa, a financijska razvijenost većinom nema učinka na emisije (osim u sektoru poljoprivrede gdje ih smanjuje). Vezano uz tehnološke učinke, udio obnovljivih izvora energije pokazuje mješovit učinak na emisije. U sektorima ukupnih emisija stakleničkih plinova, zgradarstva, industrijskog izgaranja, proizvodnje električne energije i prometa bilježi se značajan utjecaj na njihovo smanjenje, pri čemu zaključujemo kako tehnološka tranzicija izravno smanjuje emisije stakleničkih plinova. Međutim, na razini cijelog uzorka u poljoprivredi, izgaranju goriva, industrijskim procesima i otpadu obnovljivi izvori energije pozitivno utječu na emisije stakleničkih plinova. Energetski intenzitet pretežito ima pozitivan predznak (npr. ukupne emisije stakleničkih plinova, zgradarstvo, izgaranje goriva, proizvodnja električne energije i promet), potvrđujući da niska energetska učinkovitost izravno povećava razinu emisija. Naime, na razini ukupnog uzorka jedino u sektoru poljoprivrede energetski intenzitet vodi smanjenju emisija. Vezano uz institucionalne učinke, rast kvalitete institucija vodi

smanjenju stakleničkih plinova u sektoru izgaranja goriva, prometa i otpada, te povećanju u sektoru poljoprivrede i zgradarstva.

Finalno, fiksni vremenski učinci ukazuju na prisutnost negativnih vremenskih trendova tijekom 2000.-ih godina (npr. od 2002. do 2009.), ukazujući na učinak zajedničkih makroekonomskih i regulatornih šokova.

4. DISKUSIJA

Rezultati analize ispitivali su tezu o postojanju univerzalne okolišne Kuznetsove krivulje za emisije stakleničkih plinova u Europskoj uniji. Analiza je pokazala da poboljšanje kvalitete zaštite okoliša ne nastaje jednostavno, niti kao posljedica bogatstva zemalja (Horobet et al., 2024), ali produbljuje naše razumijevanje odnosa emisija stakleničkih plinova i dohotka.

Interpretacija dobivenih oblika krivulja ukazuje na razvojnu asimetriju. Razvijene i manje razvijene zemlje slijede različite putanje: razvijenije većinom smanjuju emisije i u pojedinim ključnim sektorima (GHG, zgradarstvo, izgaranje goriva) uspijevaju dosegnuti oblik obrnutog slova U, dok manje razvijene bilježe rast onečišćenja kako njihova gospodarstva rastu posebice u ukupnim emisijama te sektorima zgradarstva, izgaranja goriva, industrijskog izgaranja te industrijskih procesa (Horobet et al., 2024; Srdelić & Barišić, 2024; Ziberi et al., 2025). Istodobno, rast emisija i konveksnost uočeni u nekim manje razvijenim zemljama upućuju na „prljavi razvojni put“, postavljajući pitanje vrijedi li univerzalno oblik obrnute U-krivulje (Jóźwik et al., 2021; Ziberi et al., 2025).

Primjena kubne specifikacije modela objašnjava nelinearnu prirodu odnosa između dohotka i emisija stakleničkih plinova (Prilog 6). U cijelom uzorku, N-rastući oblik krivulje, u kojem su sva tri dohodovna člana pozitivna, vidljiv je u poljoprivredi. Kod manje razvijenih zemalja, ukupne emisije stakleničkih plinova također pokazuju rastući N-oblik, kao i s njima povezani sektori proizvodnje električne energije i otpada. Štoviše, u istim modelima linearni rastući oblik vidljiv je kod manje razvijenih zemalja u sektoru poljoprivrede, zgradarstva, izgaranja goriva, industrijskog izgaranja, industrijskih procesa i prometa. Navedeno implicira da emisije rastu i da ne postoji naznaka točke preokreta, vodeći ugljično intenzivnim obrascima. S druge strane, u cijelom uzorku vidljivo je smanjenje emisija ukupnih stakleničkih plinova, od izgaranja goriva i industrijskog izgaranja obrascem obrnutog slova N, te u razvijenijim državama u industrijskim procesima i prometu. Štoviše, u razvijenijim zemljama primjena kubne specifikacije potvrdila je da krivulja obrnutog U vrijedi u ukupnim emisijama stakleničkih plinova i zgradarstvu, upućujući na to da se emisije, nakon inicijalnog smanjenja, stabiliziraju na nižim razinama. Navedeno potvrđuje dekarbonizaciju prvenstveno razvijenijih zemalja.

Ovisnost „čiste“ proizvodnje o institucijama i regulaciji (Suzuki, 2015; Hagendorn et al., 2024) obuhvaćena je (strukturnim, tehnološkim i institucionalnim) kontrolnim varijablama čime je premošten jaz između teorijskog okvira i empirijskog

modela, a korištenje modela standardiziranih procjenitelja (Prilog 6) omogućilo je usporedbu ekonomske značajnosti procijenjenih elastičnosti. Analiza magnitude standardiziranih procjenitelja pokazuje da rast populacije ($\beta_{std} = 0{,}39$) i energetskog intenziteta ($\beta_{std} = 0{,}14$) povećavaju emisije ukupnih stakleničkih plinova, dok povećanje udjela obnovljivih izvora energije za jednu standardnu devijaciju smanjuje emisije za 0,11 standardnih devijacija ($\beta_{std} = 0{,}11$). Kada se u analizu uključe različiti sektori, vidljivo je kako su sektori poljoprivrede, otpada i proizvodnje električne energije, posebice u razvijenim zemljama uspješno razdvojili emisije od gospodarskog rasta (Morales-Lage et al., 2019). U razvijenijim zemljama Europske unije zabilježena je visoka i značajna standardizirana elastičnost obnovljivih izvora energije ($\beta_{std-Obn.en.} =$ -0,33) i energetskog intenziteta ($\beta_{std-En.int.} = 0{,}21$) u sektoru proizvodnje električne energije; financijske razvijenosti u sektoru poljoprivrede ($\beta_{std-Fin.} =$ -0,45); te kvalitete institucija u sektoru poljoprivrede ($\beta_{std-Ins.} = 0{,}30$) i otpada ($\beta_{std-Ins.} =$-0,31). S druge strane, u manje razvijenim zemljama uočavamo značajan utjecaj obnovljivih izvora energije i energetskog intenziteta u sektorima izgaranja goriva ($\beta_{std-Obn.en.} =$ 0,31, i $\beta_{std-En.int.} = 0{,}20$) i proizvodnje električne energije ($\beta_{std-Obn.en.} =$ -0,25 i $\beta_{std-En.int.} = 0{,}31$).

Analiza dugoročne dinamike putem DFE modela potvrđuje postojanje dugoročne ravnotežne veze između dohotka i emisija (Prilog 6). Značajni, negativni koeficijenti korekcije pogreške (ECT) u gotovo svim modelima pokazuju da se sustav postupno prilagođava ravnoteži nakon kratkoročnih šokova. Model pokazuje utjecaj povratak sustava u ravnotežu, njegovu dugoročnu putanju uslijed šoka promjene nezavisnih varijabli. Dugoročna putanja prikazana je vremenskim trendovima (Prilog 5 i Prilog 6) koji su uglavnom negativni, odnosno vidljivo je smanjenje emisija s vremenom. Najsporiji povratak sustava u ravnotežu uočen je kod ukupnih stakleničkih plinova ukazujući na to da se povratak u ravnotežu događa za otprilike 9 godina uslijed šoka promjene nezavisnih varijabli (ECT = - 0,11), dok je najbrži povratak sustava u ravnotežu primijećen u sektoru emisija CO_2 od otpada koji slijedi nakon 1,6 godina (ECT = - 0,63).

Financijska razvijenost pokazuje asimetrične učinke ovisno o stupnju razvijenosti. U razvijenijim zemljama, financijski razvoj uglavnom djeluje inhibitorno na emisije, što ukazuje na to da zreli financijski sustavi uspješno usmjeravaju kapital u „čiste“ tehnologije i energetsku učinkovitost. Učinak trgovinske otvorenosti u razvijenijim zemljama povećava emisije (iako ih jedinu u sektoru otpada smanjuje), dok u manje razvijenim zemljama trgovinska otvorenost smanjuje emisije CO_2 u sektorima zgradarstva, izgaranja goriva, a povećava u sektorima prometa i industrijskih procesa. Navedeno objašnjavamo činjenicom da u sektorima poput zgradarstva trgovinska otvorenost olakšava uvoz zelenih tehnologija iz razvijenih zemalja, ali u sektorima poput prometa utječe na jačanje logističkih tijekova. Značajno je što emisije reagiraju jače na efekte promjena politika, poput EU ETS-a i Zelenog plana, ili tehnološki napredak, u odnosu na postupne učinke dohotka koje predviđa teorija (Buelens, 2024; Europska komisija, 2019, 2023). Specifični vremenski učinci imaju veći utjecaj od dohotka, što upućuje na potrebu promatranja razlike između pasivnih i aktivnih promjena nametnutih političkim intervencijama (Horobet et al., 2024; Ziberi et al., 2025). Negativan vremenski trend nastupa ranije u razvijenijim nego u manje

razvijenim zemljama, a što ukazuje na usvajanje i početak implementacije Europskog zelenog plana, kao i ubrzane strategije napuštanja ugljena i plina. Ovakva dinamika vremenskih učinaka potvrđuje tezu da dekarbonizacija elektroenergetskog sektora u Europskoj uniji nije automatska posljedica rasta dohotka po stanovniku, već je potaknuta klimatskim politikama, regulatornim pritiscima i usvajanjem čistih tehnologija.

S druge strane, konveksan odnos između dohotka i emisija vidljiv u emisijama ukupnih stakleničkih plinova, industrijskom izgaranju i prometu, ukazuje na porast emisija usporedno s rastom proizvodnje, osobito u manje razvijenim članicama Europske unije (Horobet et al., 2024). Pozitivna standardizirana elastičnost udjela industrije u manje razvijenim zemljama u sektorima ukupnih emisija i industrijskog izgaranja pokazuje da je ovisnost o industrijskoj proizvodnji strukturni pokretač emisija (Prilog 6). Strukturni učinci očituju se i kroz urbanizaciju, koja u većini sektora (poput ukupnih emisija i prometa) pokazuje negativne utjecaje (Tablica 2), indicirajući postojanje ekonomije obujma u urbanim središtima. Veća gustoća naseljenosti omogućuje rast isplativosti i energetsku učinkovitost putem sustava grijanja, mreže javnog prijevoza te smanjenja prosječne dužine putovanja po stanovniku. Posljedično, prostorno planiranje i pametna urbanizacija očituju se kao instrumenti dekarbonizacije.

Rezultati analize impliciraju kako ostvarenje ciljeva Europskog zelenog plana nije moguće bez diferenciranih mjera. Naime, rastući obrasci emisija stakleničkih plinova u manje razvijenim članicama direktno ukazuju na navedeno. Kako ulaganja u zelene tehnologije postaju nužnost, kao i stroža regulacija, postizanje klimatskih ciljeva zahtijeva financijsku potporu manje razvijenim zemljama za prelazak na čiste tehnologije te mjere zaštite ranjivih kućanstava i poduzeća od troškova novonastalih određivanja cijena (Olmos et al., 2012). Fondovi za pravednu tranziciju trebali bi utjecati na korištenje čistih tehnologija, čime bi se izbjeglo njihovo dugotrajno zaključavanje u ugljično intenzivnim industrijama. Drugo, europske politike trebale bi koristiti sektorski prilagođene instrumente. Primjerice, politike određivanja cijena CO_2 (poput EU ETS-a) daju rezultate u energetskim sektorima. S druge strane, sektor prometa ostaje otporan na dosadašnje mjere jer njegove emisije konzistentno rastu s dohotkom u gotovo svim modelima, zahtijevajući infrastrukturne intervencije. Sektorska analiza pokazuje da je otpad jedini promatrani sektor u kojem su fiksni vremenski učinci konzistentno pozitivni u svim specifikacijama, slično kao i sektor proizvodnje električne energije (Prilog 6). Iako klimatske politike potiču negativne vremenske promjene u energetskim sektorima od početka 2000.-ih, javne politike ne utječu na smanjenje emisija CO_2 iz otpada. Ovaj trend sugerira da učinci masovne potrošnje, linearnih ekonomskih modela i rasta životnog standarda nadmašuju dosadašnje napore u implementaciji kružnog gospodarstva. Navedeno implicira da se dekarbonizacija ne može ostvariti isključivo tehnološkim rješenjima, već zahtijeva promjene u ponašanju potrošača s jedne strane, te proizvođača i dizajna proizvoda s druge strane. Konačno, kako bi se dodatno objasnili mehanizmi dekarbonizacije izvan postojećih kontrolnih varijabli, buduća istraživanja trebala bi obuhvatiti dodatne čimbenike poput istraživanja i razvoja te ispitati rizik ponovnog rasta emisija u razvijenijim zemljama uslijed visoke potrošnje.

5. ZAKLJUČAK

Sektorska analiza otkriva heterogenost u dinamici odnosa dohotka i emisija. Analiza sektorskih obrazaca emisija u EU27 potvrđuje da dekarbonizacija nije automatizam gospodarskog rasta, već rezultat interakcije između dohodovnih učinaka i institucionalnih intervencija. Ključni nalaz ovog istraživanja je strukturni rascjep u putanjama emisija: dok razvijenije članice potvrđuju EKC hipotezu, manje razvijene zemlje pokazuju konveksan (U-oblik) trend rasta emisija s rastom dohotka, vodeći riziku zaključavanja u „prljavi razvojni put".

Zanimljiv nalaz ovog istraživanja jest dominantna uloga vremenskih učinaka u objašnjenju dinamike emisija. Fiksni vremenski učinci upućuju na silazne trendove u emisijama u većini sektora od početka 2000.-ih, a što sugerira da su strukturne reforme, regulatorne intervencije, tehnološki napredak i klimatske politike na razini Europske unije značajniji za dekarbonizaciju od samog rasta dohotka. Usporedba razvijenijih i manje razvijenih zemalja članica Europske unije ukazuje na asimetrične putanje prilagodbe. Dok razvijenija gospodarstva pokazuju jasnije znakove potaknute politikama razdvajanja rasta dohotka od emisija stakleničkih plinova u pojedinim sektorima, manje razvijene zemlje bilježe konveksne ili ubrzavajuće trendove u sektorima osjetljivima na dohodak. Štoviše, utjecaj strukturnih, tehnoloških i institucionalnih efekata različit je u ovim dvjema skupinama zemalja. Primjerice, u sektoru izgaranja goriva udio industrije u dodanoj vrijednosti negativno utječe na emisije u razvijenim zemljama, a pozitivno u manje razvijenim. U sektorima proizvodnje električne energije i industrijskih procesa, financijska razvijenost negativno utječe na emisije u razvijenim zemljama, a pozitivno u manje razvijenim; dok u sektoru industrijskih procesa udio obnovljivih izvora energije u razvijenim zemljama pozitivno utječe na emisije, a u manje razvijenim negativno. Finalno, važna je razlika u utjecaju institucionalne kvalitete. Iako je u većini modela nesignifikantna, u sektoru prometa pozitivno utječe na emisije u razvijenim zemljama, a negativno u manje razvijenim. Obrnuto vrijedi za sektor otpada. Navedeno upućuje na to da konvergencija u razinama dohotka ne podrazumijeva i konvergenciju u uspješnosti zaštite okoliša. Bez ciljane institucionalne potpore, tehnološkog unaprjeđenja i učinkovitih regulatornih okvira, manje razvijene zemlje članice mogu ostati na emisijski intenzivnim putanjama rasta.

Ovim istraživanjem ponovno je dovedeno u pitanje EKC-a kao univerzalni zakon povezanosti gospodarskog razvoja i onečišćenja okoliša. Poboljšanja kvalitete okoliša u Europskoj uniji ovisi o sektoru, o stupnju razvoja te su uvjetovana politikama zaštite okoliša. Gospodarski rast može osigurati potrebne resurse za ulaganja, ali ne jamči smanjenje emisija bez koordinirane regulacije. Ograničenje ovog rada očituje se u korištenju agregiranih i nacionalnih makroekonomskih pokazatelja koji, iako korisni za prepoznavanje općih trendova u analizi panel podataka, ne mogu obuhvatiti specifične mikroekonomske mehanizme i ponašanje pojedinačnih poduzeća unutar analiziranih sektora. Buduća istraživanja trebala bi analizirati prelijevanje emisija između zemalja članica, ispitati potencijalne asimetrične šokove na mikrorazini, obuhvatiti čimbenike poput izravnih ulaganja u istraživanje i razvoj zelenih izvora energije i energetske

učinkovitosti te ispitati rizik ponovnog rasta emisija stakleničkih plinova u razvijenijim zemljama uslijed visoke razine potrošnje čime bi se doprinijelo preciznijem razumijevanju složenog odnosa između gospodarskog razvoja i okolišne održivosti u europskom kontekstu.

Doprinosi autora: Konceptualizacija, L. Š., M. B..; Metodologija, M. B.; Validacija, M. B.; Formalna analiza, M. B.; Istraživanje, L. Š., M. B..; Resursi, L. Š., M. B.; Čuvanje podataka, M. B.; Pisanje – priprema izvorne verzije, L. Š., M. B.; Pisanje – pregled i prireĎivanje, L. Š., M. B.; Vizualizacija, M. B.; Nadzor, L. Š.

Financiranje: Istraživanje prikazano u rukopisu nije dobilo nikakva sredstva iz vanjskih izvora financiranja.

Sukob interesa: Nema.

Priznanje korištenja umjetnom inteligencijom (UI) ili alatima temeljenima na umjetnoj inteligenciji: Tijekom pripreme ovog rada autor(i) su se koristili alatima UI kako bi generirali kodove za analizu podataka i vizualizaciju rezultata, za prijevod nekih izraza te lekturu rada. Nakon korištenja alatom, autori su pregledali i po potrebi uredili sadržaj te preuzimaju punu odgovornost za sadržaj objavljenog članka.

LITERATURA

Ang, J. B. (2007). CO_2 emissions, energy consumption, and output in France. *Energy Policy, 35*(10), 4772–4778. https://doi.org/10.1016/j.enpol.2007.03.032

Antweiler, W., Copeland, B. R., & Taylor, M. S. (2001). Is free trade good for the environment?. *American economic review, 91*(4), 877-908. http://dx.doi.org/10.1257/aer.91.4.877

Arrow, K., Bolin, B., Costanza, R., Dasgupta, P., Folke, C., Holling, C. S., Jansson, B.O., Levin, S., Mäler, K. G., Perrings, C., & Pimentel, D. (1995). Economic growth, carrying capacity, and the environment. *Ecological economics, 15*(2), 91-95. https://doi.org/10.1016/0921-8009(95)00059-3

Bilgen, S., & Sarikaya, I. (2016). Contribution of efficient energy use on economy, environment, and sustainability. *Energy Sources, Part B: Economics, Planning, and Policy, 11*(12), 1166-1172. http://dx.doi.org/10.1080/15567249.2016.1177622

Buelens, C. (2024). Climate change and its implications for prices and inflation, *Quarterly Report on the Euro Area (Directorate General Economic and Financial Affairs)*, *23*(1), 23–40. Preuzeto s: https://ec.europa.eu/economy_finance/publications/qr_euro_area/index_en.htm; RePEc:euf:qreuro: 0231-02 [20. prosinca 2025.]

Cole, M. A., Rayner, A. J., & Bates, J. M. (1997). The Environmental Kuznets Curve: An empirical analysis. *Environment and Development Economics*, *2*(4), 401–416. https://doi.org/10.1017/S1355770X97000211

Cropper, M. L., & Griffiths, C. (1994). The Interaction of Population Growth and Environmental Quality. *American Economic Review*, *84*(2), 250–254. https://www.econ.umd.edu/sites/www.econ.umd.edu/files/pubs/jc26.pdf

De Haas, R., & Popov, A. (2023). Finance and Green Growth. *The Economic Journal, 133*(650), 637-668. http://hdl.handle.net/10.1093/ej/ueac081; https://doi.org/10.1093/ej/ueac081

Dinda, S. (2004). Environmental Kuznets curve hypothesis: A survey. *Ecological Economics*, *49*(4), 431–455. https://doi.org/10.1016/j.ecolecon.2004.02.011

Driscoll, J. C., & Kraay, A. C. (1998). Consistent covariance matrix estimation with spatially dependent panel dana. *Review of Economics and Statistics*, *80*(4), 549-560, https://www.jstor.org/stable/2646837

Europska komisija (2019). *The European Green Deal*. Preuzeto s: https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal_en [1. prosinca 2025.]

Europska komisija (2023). *Energy and the Green Deal*. Preuzeto s: https://commission.europa.eu/topics/energy/energy-and-green-deal_en [1. prosinca 2025.]

Farhani, S., & Shahbaz, M. (2014). What role of renewable and non-renewable electricity consumption and output is needed to initially mitigate CO2 emissions in MENA region? *Renewable and Sustainable Energy Reviews, 40*, 80-90. https://doi.org/10.1016/j.rser.2014.07.170

Fisher-Vanden, K., Jefferson, G. H., Liu, H., & Tao, Q. (2004). What is driving China's decline in energy intensity?. *Resource and Energy economics, 26*(1), 77-97. https://doi.org/10.1016/j.reseneeco.2003.07.002

Friedl, B., & Getzner, M. (2003). *Determinants of CO_2 emissions in a small open economy, Ecological Economics*, *45*(1), 133–148. https://doi.org/10.1016/S0921-8009(03)00008-9

Friedman, M. (1937). The use of ranks to avoid the assumption of normality implicit in the analysis of variance. *Journal of the American Statistical Association*, *32*(200), 675-701. https://doi.org/10.2307/2279372

Gravina, A. F., & Lanzafame, M. (2024). 'What's your shape?'A data-driven approach to estimating the Environmental Kuznets Curve. Preuzeto s: https://ssrn.com/abstract=4779930 ili http://dx.doi.org/10.2139/ssrn.4779930

Grossman, G. M., & Krueger, A. B. (1991). Environmental Impacts of a North American Free Trade Agreement. *NBER Working Paper No. 3914*. Preuzeto s: https://www.nber.org/system/files/working_papers/w3914/w3914.pdf [2. veljače 2026.] https://doi.org/10.3386/w3914

Hagendorn, J. E., Hattemer, B., & Kalantzis, F. (2024). A positive trade-off: Emissions reduction and costs under Phase IV of the Emissions Trading System. *EIB Working Paper 2024/05*, European Investment Bank. https://doi.org/10.2867/8720105

Holtz-Eakin, D., & Selden, T. M. (1995). Stoking the fires? CO_2 emissions and economic growth. *Journal of Public Economics*, *57*(1), 85–101. https://www.sciencedirect.com/science/article/pii/004727279401449X; https://doi.org/10.1016/0047-2727(94)01449-X

Horobet, A., Belascu, L., Radulescu, M., Balsalobre-Lorente, D., Botoroga, C.-A., & Negreanu, C.-C. (2024). Exploring the Nexus between Greenhouse Emissions, Environmental Degradation and Green Energy in Europe: A Critique of the Environmental Kuznets Curve. *Energies*, *17*(20), 5109. RePEc:gam:jeners:v:17:y:2024:i:20:p:5109-:d:1498685; https://doi.org/10.3390/en17205109

Islam, M., Kanemoto, K., & Managi, S. (2016). Impact of trade openness and sector trade on embodied greenhouse gases emissions and air pollutants. *Journal of Industrial Ecology, 20*(3), 494-505. https://doi.org/10.1111/jiec.12455

Iwata, H., Okada, K., & Samreth, S. (2010). Empirical study on the Environmental Kuznets Curve for CO_2 in France: The role of nuclear energy*, Energy Policy*, *38*(8), 4057–4063. https://doi.org/10.1016/j.enpol.2010.03.031

Jóźwik, B., Gavryshkiv, A.-V., Kyophilavong, P., & Gruszecki, L. E. (2021). Revisiting the Environmental Kuznets Curve Hypothesis: A Case of Central Europe. *Energies*, *14*(12), 3415. https://doi.org/10.3390/en14123415

Kao, C. (1999). Spurious regression and residual-based tests for cointegration in panel data. *Journal of Econometrics*, *90*(1), 1-44. https://doi.org/10.1016/S0304-4076(98)00023-2

Kasman, A., & Duman, Y. S. (2015). CO2 emissions, economic growth, energy consumption, trade and urbanization in new EU member and candidate countries: a panel data analysis. *Economic modelling, 44*, 97-103. https://doi.org/10.1016/j.econmod.2014.10.022

Kijima, M., Nishide, K., & Ohyama, A. (2010). Economic models for the environmental Kuznets curve: A survey. *Journal of economic dynamics and control*, *34*(7), 1187-1201. https://doi.org/10.1016/j.jedc.2010.03.010

Konat, G., Dürrü, Z., & Han, A. (2024). Investigation of waste Kuznets curve hypothesis in selected OECD member EU countries: Panel data analysis. *Akademik Yaklaşımlar Dergisi*, *15*(2), 1028-1049. https://doi.org/10.54688/ayd.1473301

Lamb, W. F., Wiedmann, T., Pongratz, J., Andrew, R., Crippa, M., Olivier, J. G., Wiedenhofer, D., Mattioli, G., Khourdajie, A. A., & House, J. (2021). A review of trends and drivers of greenhouse gas emissions by sector from 1990 to 2018. *Environmental research letters, 16*(7), 073005. 10.1088/1748-9326/abee4e

Lapinskienė, G., Peleckis, K., & Radavičius, M. (2015). Economic development and greenhouse gas emissions in the European Union countries. *Journal of Business Economics and Management*, *16*(6), 1109-1123. https://doi.org/10.3846/16111699.2015.1112830

Lau, L. S., Choong, C. K., Eng, Y. K. (2014). Carbon dioxide emission, institutional quality, and economic growth: empirical evidence in Malaysia. *Renewable Energy, 68*, 276-281, 10.1016/j.renene.2014.02.013; https://doi.org/10.1016/j.renene.2014.02.013

Lee, H. S., Arestis, P., Chong, S. C., Yap, S., & Sia, B. K. (2022). The heterogeneous effects of urbanisation and institutional quality on greenhouse gas emissions in Belt and Road Initiative countries. *Environmental Science and Pollution Research, 29*(1), 1087-1105. https://doi.org/10.1007/s11356-021-15699-0

Lieb, C. M. (2003). The environmental Kuznets curve: A survey of the empirical evidence and of possible causes. *Discussion Paper Series No. 391*, University of Heidelberg. https://www.uni-heidelberg.de/md/awi/forschung/dp391.pdf

Lu, L., Zheng, H., Chen, M., & Najam, H. (2022). Tackling carbon intensity with green finance in the covid-19-era: recommendations for OECD economies. *Climate Change Economics, 13*(03), 2240014. https://doi.org/10.1142/S2010007822400140

Luqman, M., Rayner, P. J., & Gurney, K. R. (2023) On the impact of urbanisation on CO2 emissions. *Urban Sustainability, 3*(6), https://doi.org/10.1038/s42949-023-00084-2

Madaleno, M., & Moutinho, V. (2021). Analysis of the new kuznets relationship: Considering emissions of carbon, methanol, and nitrous oxide greenhouse gases—Evidence from EU countries. *International Journal of Environmental Research and Public Health*, *18*(6), 2907. https://doi.org/10.3390/ijerph18062907

Mazzanti, M., & Zoboli, R. (2009). Municipal waste Kuznets curves: evidence on socio-economic drivers and policy effectiveness from the EU. *Environmental and Resource Economics*, *44*(2), 203-230. https://doi.org/10.1007/s10640-009-9280-x

Mohammed, S., Gill, A. R., Ghosal, K., Al-Dalahmeh, M., Alsafadi, K., Szabó, S., Oláh, J., Alkerdi, A., Ocwa A., & Harsanyi E. (2024). Assessment of the environmental kuznets curve within EU-27: Steps toward environmental sustainability (1990–2019). *Environmental Science and Ecotechnology*, *18*, 100312. https://doi.org/10.1016/j.ese.2023.100312

Morales-Lage, R., Bengochea-Morancho, A., Camarero, M., & Martínez-Zarzoso, I. (2019). Club convergence of sectoral CO2 emissions in the European Union. *Energy Policy*, *135*, 111019. https://doi.org/10.1016/j.enpol.2019.111019

Olmos, L., Ruester, S., & Liong, S. J. (2012). On the selection of financing instruments to push the development of new technologies: Application to clean energy technologies. *Energy policy*, 43, 252-266. https://doi.org/10.1016/j.enpol.2012.01.001

Panayotou, T. (2000). Economic Growth and the Environment. *CID Working Paper Series No. 56*. Harvard University, Center for International Development. https://www.hks.harvard.edu/sites/default/files/centers/cid/files/publications/faculty-working-papers/056.pdf

Pedroni, P. (1999). Critical values for cointegration tests in heterogeneous panels with multiple regressors. *Oxford Bulletin of Economics and Statistics*, *61*(S1), 653-670. https://doi.org/10.1111/1468-0084.0610s1653

Pedroni, P. (2004). Panel cointegration: Asymptotic and finite sample properties of pooled time series tests with an application to the PPP hypothesis. *Econometric Theory*, *20*(3), 597-625. https://doi.org/10.1017/S0266466604203073

Pesaran, M. H. (2004). General diagnostic tests for cross section dependence in panels. *Cambridge Working Papers in Economics*, 0435. https://docs.iza.org/dp1240.pdf; https://doi.org/10.2139/ssrn.572504

Qin, L., Hou, Y., Miao, X., Zhang, X., Rahim, S., & Kirikkaleli, D. (2021). Revisiting financial development and renewable energy electricity role in attaining China's carbon neutrality target. *Journal of Environmental Management, 297*, 113335. https://doi.org/10.1016/j.jenvman.2021.113335

Selden, T. M., & Song, D. (1994). Environmental quality and development: Is there a Kuznets curve for air pollution emissions? *Journal of Environmental Economics and Management, 27*(2), 147–162. https://doi.org/10.1006/jeem.1994.1031

Shafik, N. (1994). Economic development and environmental quality: an econometric analysis. *Oxford Economic Papers*, 46(Supplement_1), 757-773. https://doi.org/10.1093/oep/46.Supplement_1.757

Shafik, N., & Bandyopadhyay, S. (1992). Economic Growth and Environmental Quality: Time-Series and Cross-Country Evidence. *Policy Research Working Paper Series from The World Bank.* Preuzeto s: https://econpapers.repec.org/RePEc:wbk:wbrwps:904 [2. veljače 2026.]

Shahbaz, M., Raghutla, C., Chittedi, K. R., Jiao, Z., & Vo, X. V. (2019). The effect of renewable energy consumption on economic growth: Evidence from the renewable energy country attractive index. *Energy*, *207*, 118162. https://doi.org/10.1016/j.energy.2020.118162

Squalli, J. (2017). Renewable energy, coal as a baseload power source, and greenhouse gas emissions: Evidence from US state-level data. *Energy, 127*, 479-488. https://doi.org/10.1016/j.energy.2017.03.156

Srdelić, L., & Barišić, R. (2025), Does economic growth reduce or increase pollution? An examination of Croatia's sector-specific Enviromental Kuznets Curve. *Ekonomska misao i praksa*, *34*(1), 85-105. https://doi.org/10.17818/EMIP/2025/9

Stern, D. I. (2004). The rise and fall of the environmental Kuznets curve. *World Development*, *32*(8), 1419–1439. https://steadystate,org/wp-content/uploads/Stern_Kuznets Curve,pdf; https://doi.org/10.1016/j.worlddev.2004.03.004

Suri, V., & Chapman, D. (1998). Economic growth, trade and energy: implications for the environmental Kuznets curve. *Ecological Economics*, *25*(2), 195–208. https://doi.org/10.1016/S0921-8009(97)00180-8

Suzuki, M. (2015). Identifying roles of international institutions in clean energy technology innovation and diffusion in the developing countries: matching barriers with roles of the institutions. *Journal of Cleaner Production*, 98, 229-240. https://doi.org/10.1016/j.jclepro.2014.08.070

Škuflić, L., & Vlahinić-Dizdarević, N. (2003). Koncept nove ekonomije i značaj informacijsko-komunikacijske tehnologije u Republici Hrvatskoj. *Ekonomski pregled*, *54*(5-6), 460-479. https://hrcak.srce.hr/25464

Tucker, M. (1995). Carbon dioxide emissions and global GDP. *Ecological Economics*, *15*(3), 215–223. https://doi.org/10.1016/0921-8009(95)00045-3

Ujedinjeni narodi (1987). *Our Common Future: Report of the World Commission on Environment and Development.* United Nations General Assembly document A/42/427. Preuzeto s: http://www.un-documents.net/our-common-future.pdf [1. prosinca 2025.]

Westerlund, J. (2007). Testing for error correction in panel dana. *Oxford Bulletin of Economics and Statistics*, *69*(6), 709-748. https://doi.org/10.1111/j.1468-0084.2007.00477.x

Yameogo, C.E.W., Omojolaibi, J.A., & Dauda, R.O.S. (2021). Economic globalisation, institutions and environmental quality in Sub-Saharan Africa. *Research in Globalization, 3*, 100035. https://doi.org/10.1016/j.resglo.2020.100035

Zhigolli, G., & Fetai, B. (2024). The relationships between CO2 emissions and GDP per capita, energy consumption, industrial production in the case of Western Balkan countries. *Ekonomska misao i praksa, 33*(2), 539-553. https://doi.org/10.17818/EMIP/2024/2.10

Ziberi, B. F., Ibraimi, X., Ahmad, N., & Vveinhardt, J. (2025). The EU Green Agenda legal framework and economic growth in developing countries: a panel EKC approach. *Business: Theory and Practice*, *26*(2), 305–322. https://doi.org/10.3846/btp.2025.23716

PRILOZI

Prilog 1. Odnos emisija stakleničkih plinova i dohotka po zemlji

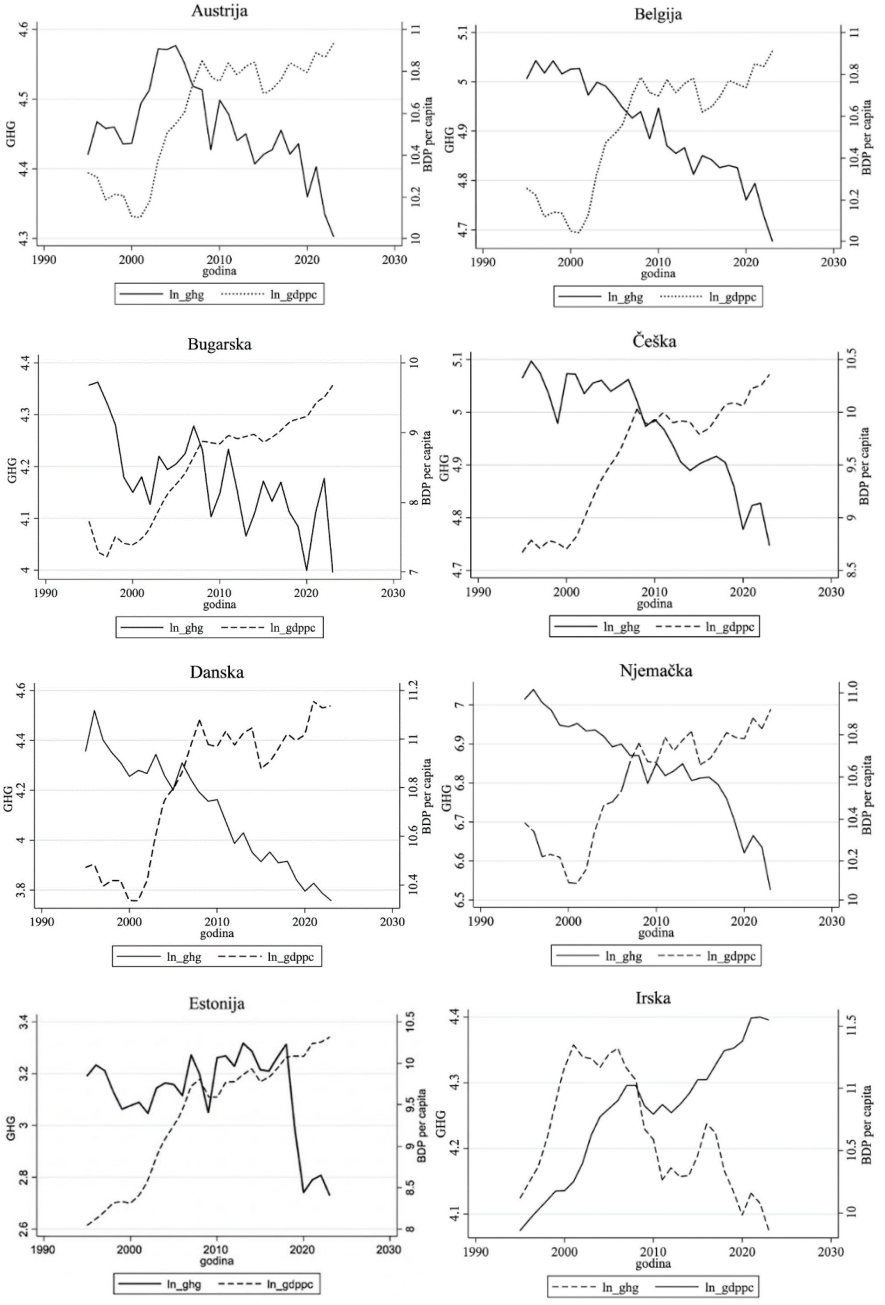

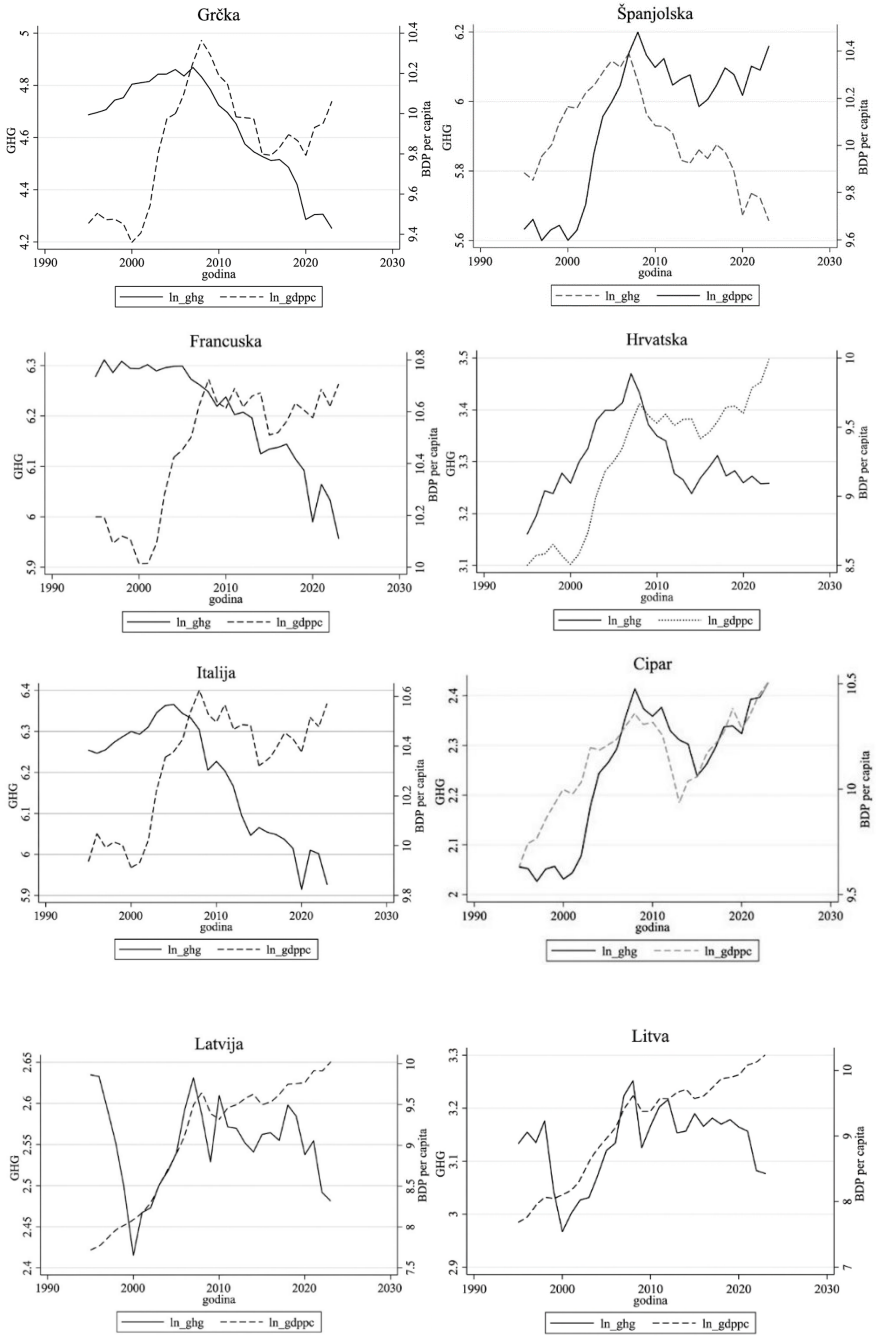
Grčka
Španjolska
Francuska
Hrvatska
Italija
Cipar
Latvija
Litva
GHG
BDP per capita
godina
1990
2000
2010
2020
2030
ln_ghg
ln_gdppc

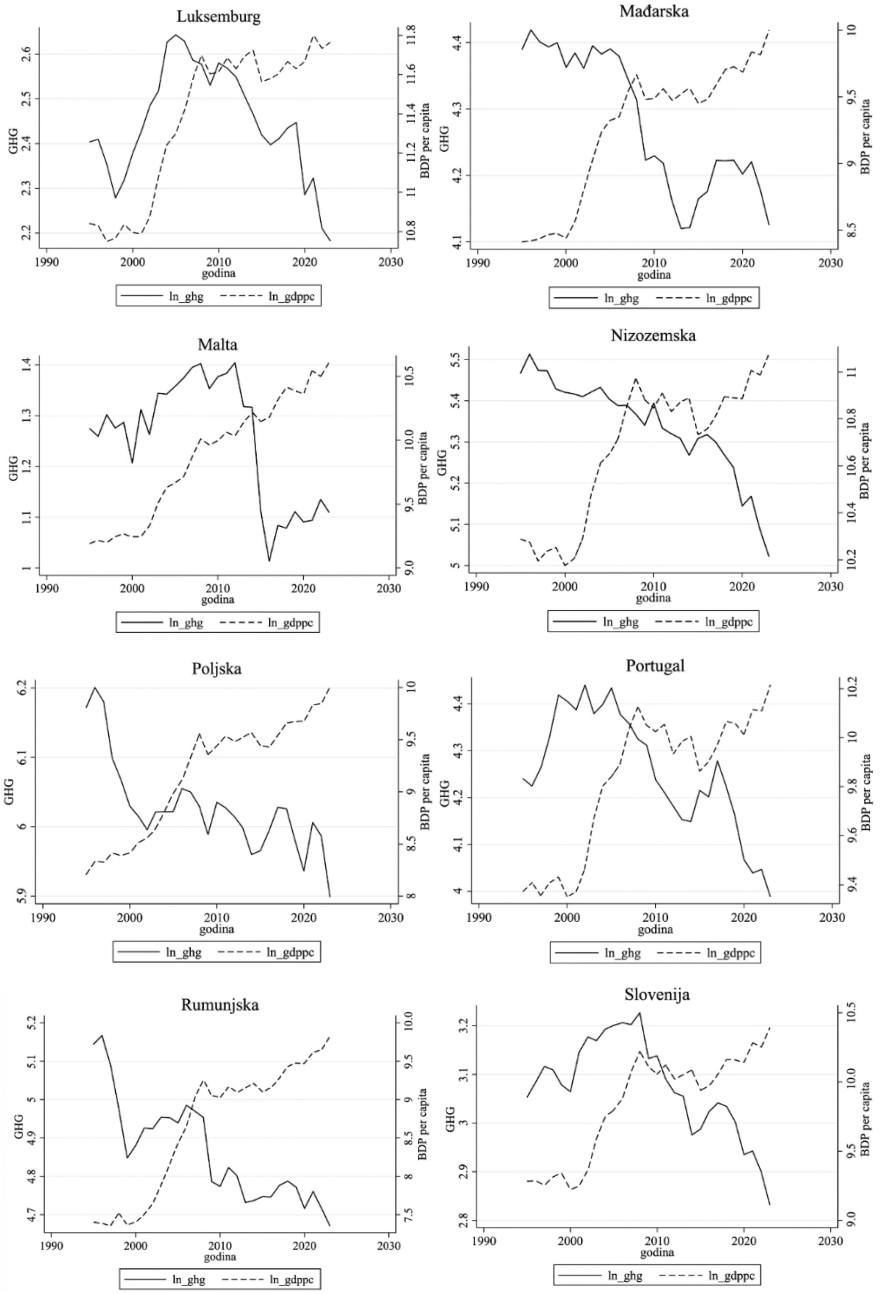
Luksemburg
Mađarska
Malta
Nizozemska
Poljska
Portugal
Rumunjska
Slovenija
GHG
BDP per capita
godina
ln_ghg
ln_gdppc

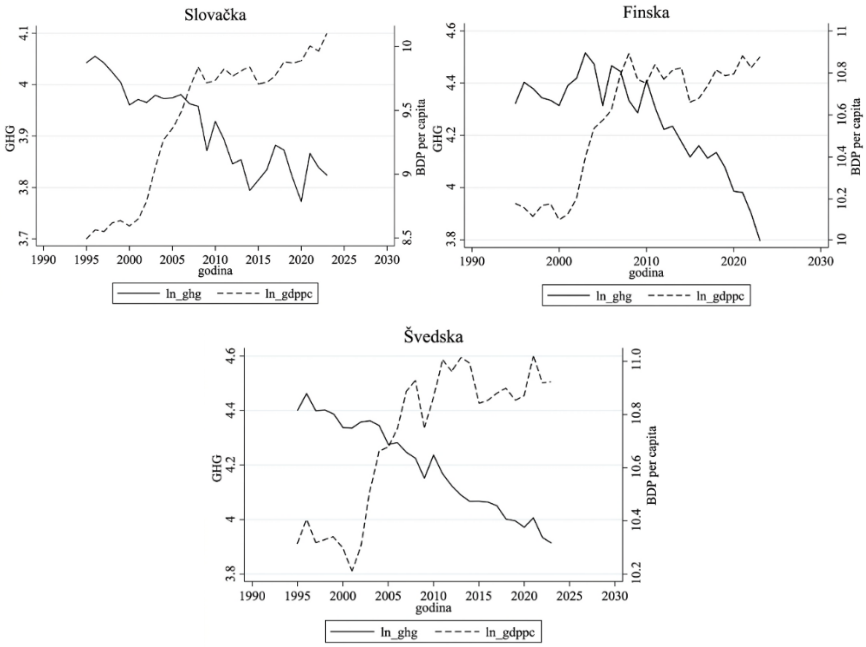

Varijabla ln_ghg označava ukupnu emisiju stakleničkih plinova, a varijabla ln_gdppc označava BDP p.c.

Izvor: izrada autora prema podacima Eurostata.

Prilog 2. Test jediničnog korjena

Varijabla		ADF – Fisher $\chi 2$	Im-Pesaran-Shin	Levin-Lin-Chu
BDP p.c.	Stacionarno oko konstante	1,000	1,000	0,013
	I(1)	0,000	0,000	0,000
Populacija	Stacionarno oko konstante	0,000	1,000	0,407
	I(1)	1,000	0,364	0,202
	I(2)	0,000	0,000	0,000
Urbanizacija	Stacionarno oko konstante	0,000	1,000	0,000
Industrija	Stacionarno oko konstante	0,111	0,190	0,000
	I(1)	0,000	0,000	0,000
Trgovinska otvorenost	Stacionarno oko konstante	0,931	0,593	0,000
	I(1)	0,000	0,000	0,000
Razvijenost financijskog tržišta	Stacionarno oko konstante	0,049	0,004	0,000
Obnovljivi izvori energije	Stacionarno oko konstante	1,000	1,000	1,000
	I(1)	0,000	0,000	0,000
Energetski intenzitet	Stacionarno oko konstante	1,000	1,000	0,997
	I(1)	0,000	0,000	0,000
Kvaliteta institucija	Stacionarno oko konstante	0,000	0,594	0,070
	I(1)	0,000	0,000	0,000
GHG	Stacionarno oko konstante	1,000	1,000	1,000
	I(1)	0,000	0,000	0,000
Poljoprivreda	Stacionarno oko konstante	0,133	0,439	-
	I(1)	0,000	0,000	-
Zgradarstvo	Stacionarno oko konstante	0,305	0,865	0,069
	I(1)	0,000	0,000	0,000
Izgaranje goriva	Stacionarno oko konstante	0,000	-	-
Industrijsko izgaranje	Stacionarno oko konstante	0,806	0,893	-
	I(1)	0,000	0,000	-
Proizvodnja električne energije	Stacionarno oko konstante	0,717	0,913	1,000
	I(1)	0,000	0,000	0,000
Industrijski procesi	Stacionarno oko konstante	0,138	0,219	0,008
	I(1)	0,000	0,000	0,000
Promet	Stacionarno oko konstante	0,762	0,880	0,112
	I(1)	0,000	0,000	0,000
Otpad	Stacionarno oko konstante	0,000	0,390	-
	I(1)		0,000	-

Varijable BDP p.c., populacija, trgovniska otvorenost, razvijenost financijskog tržišta, energetski intenzitet te ukupne emisije GHG i sektorske vrijednosti CO_2 emisija su u logaritamskim vrijednostima. Sektorske varijable pokazuju emisije CO_2. Za test ADF-Fisher prikazana je p-vrijednost obrnutog $\chi 2$, a za testove Im-Pesaran-Shin i Levin-Lin-Chu dana je p-vrijednost. Oznaka „-“ označava nemogućnost izračuna pojedinog testa zbog postojanja nebalansiranog panela podataka.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Prilog 3. Procjena kointegracije između varijabli

Varijable	Pedroni	Kao	Westerlund
GHG	0,000	0,022	0,396
Poljoprivreda	0,117	0,140	0,004
Zgradarstvo	0,000	0,000	0,100
Izgaranje goriva	-	0,207	-
Industrijsko izgaranje	0,000	0,001	0,297
Proizvodnja električne energije	0,000	0,000	0,094
Industrijski procesi	0,000	0,000	0,033
Promet	0,000	0,000	0,119
Otpad	0,001	0,000	0,065

U Pedronijev i Westerlundov test zbog ograničenja od 7 varijabli uključene su sljedeće varijable: zavisna (emisije GHG ili CO_2) te BDP p.c., populacija, industrija, trgovinska otvorenost, obnovljivi izvori energije, energetski intenzitet; dok su u Kaov test uključene i varijable BDP p.c.2, urbanizacija, financijska razvijenost, institucije. Rezultati prikazuju p-vrijednosti *modified* Phillips-Perron testa, te za Kaov test *modified* Dickey-Fuller. Trend uključen u testove prema Pedroni i Westerlundu. Oznaka „-" prikazuje nemogućnost izračuna testa zbog nebalansiranog panela.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Prilog 4. Test poprečnih presjeka

Varijabla	Pesaran	Friedman
GHG	12,259***	126,266***
Poljoprivreda	-	4,320
Zgradarstvo	5,504***	65,550***
Izgaranje goriva	-	26,889
Industrijsko izgaranje	2,775**	55,032***
Proizvodnja električne energije	6,565***	71,837***
Industrijski procesi	8,491***	96,405***
Promet	20,453***	161,700***
Otpad	4,680***	62,843***

*** p – vrijednost < 0,001 ** p – vrijednost < 0,01 * p – vrijednost < 0,05 † p – vrijednost < 0,1,

Test prosječnih prosjeka pokazuje odnos varijable od interesa s varijablama BDP p.c., BDP p.c.^{2}, populacija, urbanizacija, industrija, trgovinska otvorenost, financijska razvijenost, obnovljivi izvori energije, energetski intenzitet, kvaliteta institucija. Sektorske varijable pokazuju emisije CO_2.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Lorena Škuflić, PhD

Full Professor
University of Zagreb, Faculty of Economics and Business, Croatia
E-mail: lskuflic@efzg.hr
Orcid: https://orcid.org/0000-0002-2978-2902

Maja Bašić, PhD

Senior Research Fellow
Institute of Public Finance, Zagreb, Croatia
E-mail: maja.basic@ijf.hr
Orcid: https://orcid.org/0000-0002-1842-7091

THE ENVIRONMENTAL KUZNETS CURVE FOR GREENHOUSE GAS EMISSIONS IN EUROPEAN UNION MEMBER STATES: A SECTORAL APPROACH

Abstract

This paper examines the relationship between greenhouse gas emissions and per capita income in the 27 European Union member states from 1995 to 2023 using the Environmental Kuznets Curve (EKC) framework. Quadratic, cubic, and dynamic panel models are applied to aggregate and sectoral emissions in both more developed and less developed member states. The findings reveal a clear structural divide. An inverted U-shaped relationship is identified for total emissions, buildings, and fuel sectors in more developed countries, while less developed countries mainly exhibit convex and growing N-shaped emission-income patterns. Emission reductions are driven largely by time effects and public policies rather than income growth alone. Increased use of renewable energy sources and lower energy intensity also contribute to reduced emissions, highlighting the importance of technological transition in decarbonisation. More developed member states demonstrate stronger policy-driven decoupling of emissions from economic growth, while less developed states continue to record rising emissions in income-sensitive sectors.

Keywords: Environmental Kuznets Curve (EKC), GHG, CO2 emissions, GDP per capita, European Union

JEL classification: Q53, Q56, O44, C23

***Online* prilog 5.** Rezultati regresije na panel podacima s Driscoll-Kraayevim standardnim pogreškama

Sektor	Uzorak	BDP p.c.²	BDP p.c.	Vrem. trend	Pop.	Urb.	Ind.	Trg. otv.	Fin. razv.	Obn. en.	En. int.	Kval. inst.	Oblik EKC	N	Gr.	F-stat.	R^2
		$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)		$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)					
GHG	Cijeli uzorak	0,0336*** (0,0080)	0,4293*** (0,0288)	Neg. od 2003.	0,3797*** (0,0924)	-1,1198*** (0,1316)	n.s.	0,2364† (0,1325)	n.s.	-1,2145*** (0,0838)	0,5081*** (0,0352)	n.s.	Konveksan	783	27	3.278,21	0,7891
	Razvijenije	-0,0441*** (0,0111)	0,4522*** (0,0629)	Neg. od 2008.	1,1293*** (0,1352)	-0,8701*** (0,1555)	0,7378*** (0,1749)	0,3436*** (0,0428)	-0,0949*** (0,0234)	-1,2650*** (0,0831)	0,6964*** (0,0377)	-0,8042† (0,3978)	Obrnuto U	406	14	355,49	0,9382
	Manje razv.	0,1016*** (0,0088)	0,4543*** (0,0272)	Neg. od 2003.	-1,0670*** (0,0923)	-0,6793*** (0,1547)	0,7329** (0,1971)	n.s.	0,0911*** (0,0121)	-1,1540*** (0,2364)	0,3918*** (0,0402)	n.s.	Konveksan	377	13	171,04	0,8229
Poljoprivreda	Cijeli uzorak	-0,0134† (0,0074)	n.s.	Neg. od 1997.	-0,1697† (0,0843)	n.s.	n.s.	0,2629** (0,0875)	-0,0940*** (0,0110)	0,5083*** (0,0765)	-0,1715** (0,0578)	0,5607*** (0,0740)	Nije potvrđen	696	25	992,97	0,3317
	Razvijenije	n.s.	n.s.	Neg. od 2006.	n.s.	n.s.	n.s.	0,8348** (0,2227)	-0,2777*** (0,0411)	0,7118*** (0,1251)	n.s.	1,4150* (0,6771)	Nije potvrđen	332	12	1.030,81	0,4636
	Manje razv.	-0,0552* (0,0223)	n.s.	Neg. od 1998.	n.s.	-0,5462* (0,2583)	n.s.	n.s.	n.s.	0,2812* (0,1192)	n.s.	0,5063*** (0,0862)	Obrnuto U	364	13	98,57	0,5077
Zgradarstvo	Cijeli uzorak	n.s.	0,4948*** (0,0527)	Neg. od 2002.	0,8973*** (0,0924)	-0,3816† (0,1982)	-1,6843*** (0,2792)	n.s.	n.s.	-1,2552*** (0,3153)	0,3185*** (0,0716)	0,1472** (0,0502)	Linearan	783	27	1.397,69	0,6456
	Razvijenije	-0,1743** (0,0446)	0,5837*** (0,1325)	Neg. od 2002.	1,7022*** (0,1912)	n.s.	n.s.	0,4160* (0,1814)	n.s.	-1,3423*** (0,1592)	0,5962** (0,1639)	-0,7830† (0,4061)	Obrnuto U	406	14	449,42	0,7581
	Manje razv.	0,0541* (0,0219)	0,4767*** (0,1068)	Neg. od 1998.	-0,6902** (0,1836)	n.s.	-1,6614* (0,7142)	-0,3687** (0,1162)	n.s.	-1,3583** (0,4290)	n.s.	n.s.	Konveksan	377	13	699,74	0,6591
Izgaranje goriva	Cijeli uzorak	0,1227*** (0,0266)	0,4894*** (0,0715)	Neg. od 2003.	n.s.	n.s.	n.s.	n.s.	n.s.	0,8442** (0,2247)	0,4422*** (0,0710)	-0,5319** (0,1833)	Konveksan	734	27	124.600,13	0,2393
	Razvijenije	-0,2339*** (0,0439)	1,1153*** (0,2672)	Neg. od 1996.	n.s.	0,9420* (0,3539)	-2,8271* (1,0384)	0,5717† (0,2851)	n.s.	0,6552* (0,3025)	-0,1697† (0,0854)	n.s.	Obrnuto U	357	14	8.622,85	0,4203
	Manje razv.	0,2250** (0,0592)	0,5101** (0,1461)	Pozitivan	n.s.	n.s.	2,9145** (0,9193)	-0,8859† (0,4487)	n.s.	2,4770*** (0,6007)	0,5348* (0,2112)	-0,3730* (0,1582)	Konveksan	377	13	22,28	0,4307
Industrijsko izgaranje	Cijeli uzorak	0,0783*** (0,0141)	0,2706*** (0,0433)	Neg. od 1998.	n.s.	n.s.	n.s.	n.s.	n.s.	-0,9391*** (0,0833)	n.s.	n.s.	Konveksan	775	27	7.889,92	0,6731
	Razvijenije	n.s.	0,8002*** (0,1283)	Neg. od 2003.	-0,4032*** (0,1017)	0,6414*** (0,1449)	n.s.	0,7317*** (0,1236)	-0,1553* (0,0648)	-0,4783** (0,1475)	0,3716*** (0,0873)	n.s.	Linearan	398	14	318.392,49	0,7581
	Manje razv.	0,1508*** (0,0284)	0,3312** (0,0872)	Neg. od 1999.	-1,4726** (0,4226)	n.s.	1,0459* (0,4697)	n.s.	n.s.	-1,2706** (0,3864)	n.s.	n.s.	Konveksan	377	13	334,91	0,7107
Proizvodnja električne energije	Cijeli uzorak	n.s.	0,3355** (0,0874)	Pozitivan	1,1955*** (0,2148)	-0,4577* (0,1696)	1,1439*** (0,1534)	n.s.	n.s.	-3,1717*** (0,2765)	0,8087*** (0,0815)	n.s.	Linearan	783	27	1.425,22	0,8245
	Razvijenije	n.s.	n.s.	Pozitivan	1,5717*** (0,3574)	n.s.	1,3801** (0,3937)	n.s.	-0,2092*** (0,0511)	-3,5031*** (0,3006)	0,7406*** (0,1301)	n.s.	Nije potvrđen	406	14	177,39	0,8364
	Manje razv.	n.s.	0,5710*** (0,1255)	Neg. od 2004.	0,9509** (0,2474)	n.s.	1,5083*** (0,3604)	n.s.	0,2041*** (0,0392)	-2,7136*** (0,3508)	1,0890*** (0,1142)	n.s.	Linearan	377	13	22,93	0,8761
Industrijski procesi	Cijeli uzorak	n.s.	0,2052* (0,0827)	Neg. od 2009.	n.s.	-1,3302*** (0,1832)	-0,4142* (0,1949)	0,4169** (0,1182)	n.s.	0,3788* (0,1789)	n.s.	n.s.	Linearan	783	27	58,36	0,3104
	Razvijenije	n.s.	0,5053*** (0,1217)	Neg. od 2008.	n.s.	n.s.	-0,7487* (0,2785)	0,2404† (0,1367)	-0,1432* (0,0539)	1,2310*** (0,2280)	0,4318*** (0,1029)	n.s.	Linearan	406	14	106,76	0,4114
	Manje razv.	0,0740*** (0,0178)	0,2862** (0,0745)	Neg. od 1996.	-1,1227** (0,3103)	-1,4509* (0,6458)	n.s.	0,7868*** (0,1786)	0,0866*** (0,0164)	-0,9458** (0,3266)	n.s.	n.s.	Konveksan	377	13	259,28	0,4920
Promet	Cijeli uzorak	0,0221* (0,0103)	0,5578*** (0,0544)	Pozitivan i n.s.	n.s.	-1,7716*** (0,3252)	n.s.	0,5700** (0,1832)	n.s.	-1,0344*** (0,1566)	0,4043** (0,1130)	-0,4939* (0,2079)	Konveksan	783	27	261,41	0,7655
	Razvijenije	0,0627** (0,0221)	0,6961*** (0,0729)	Neg. od 2006.	n.s.	-1,5522*** (0,3232)	-0,5734† (0,3166)	0,3972* (0,1479)	0,0463** (0,0148)	-0,7181** (0,1878)	0,5290*** (0,0805)	0,6573† (0,3589)	Konveksan	406	14	1.466,01	0,7537
	Manje razv.	n.s.	0,3768** (0,0999)	Pozitivan i n.s.	0,5712** (0,1735)	-1,8314** (0,5131)	n.s.	0,6097** (0,1912)	n.s.	-1,1059** (0,2977)	n.s.	-0,3369† (0,1966)	Linearan	377	13	892,32	0,8180
Otpad	Cijeli uzorak	n.s.	n.s.	Pozitivan	0,2255* (0,0859)	-0,2453*** (0,0368)	n.s.	-0,1052* (0,0391)	n.s.	0,0744† (0,0402)	n.s.	-0,0444* (0,0191)	Nije potvrđen	653	23	457,29	0,1264
	Razvijenije	n.s.	-0,1563† (0,0796)	Pozitivan	1,0608* (0,3829)	n.s.	0,6687* (0,3022)	-0,2942** (0,1024)	-0,0553† (0,0305)	n.s.	n.s.	-1,4480* (0,6499)	Nije potvrđen	319	11	5,23	0,2582
	Manje razv.	n.s.	n.s.	Pozitivan	n.s.	-0,1985* (0,0757)	n.s.	n.s.	n.s.	0,1604*** (0,0326)	0,0280† (0,0139)	n.s.	Nije potvrđen	334	12	67,33	0,2030

Napomene: *** p-vrijednost < 0,001; ** p-vrijednost < 0,01; * p-vrijednost < 0,05; † p-vrijednost < 0,1; n.s. = nije statistički značajno. Standardne pogreške navedene su u zagradama ispod procijenjenog koeficijenta. Sve procjene koriste metodu fiksnih efekata (FE) s Driscoll-Kraay standardnim pogreškama (najveći vremenski pomak = 3) i uključuju konstantu. Vjerojatnost > F = 0,0000. N = broj opažanja. Gr. = broj grupa. BDP p.c.² = kvadratni član dohotka per capita; BDP p.c. = linearni član dohotka per capita; Vrem. trend = uzima u obzir signifikantni vremenski trend nekoliko godina zaredom; Pop. = logaritam populacije; Urb. = udio urbanog stanovništva u ukupnom stanovništvu; Ind. = udio dodane vrijednosti industrije u BDP-u; Trg. otv. = logaritam trgovinske otvorenosti; Fin. razv. = logaritam duga (proxy za financijsku razvijenost); Obn. en. = udio obnovljivih izvora energije u ukupnoj potrošnji; En. int. = logaritam energetskog intenziteta; Kval. inst. = V-Dem liberalni indeks institucionalne kvalitete.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Online **prilog 6.** Rezultati alternativnih procjena modela

Rezultati alternativnih EKC modela — Ukupne emisije stakleničkih plinova (GHG)

Model	Uzorak	ECT	BDP p.c.³	BDP p.c.²	BDP p.c.	Vrem. trend	Pop.	Urb.	Ind.	Trg. otv.	Fin. razv.	Obn. en.	En. int.	Kval. inst.	Oblik EKC	N	Gr.	F-stat.	R^2
		$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)					
Kubni model	Cijeli uzorak	–	−0,01* (0,00)	0,02** (0,01)	0,44*** (0,03)	Neg. od 2003.	0,42*** (0,10)	−1,00*** (0,17)	n.s.	0,24† (0,13)	0,03† (0,01)	−1,18*** (0,08)	0,50*** (0,04)	n.s.	Obrnuto N	783	27	2.465,94	0,79
	Razvijenije	–	n.s.	−0,08** (0,03)	0,44*** (0,06)	Neg. od 2008.	1,10*** (0,15)	−0,86*** (0,16)	0,81*** (0,14)	0,34*** (0,04)	−0,10*** (0,02)	−1,26*** (0,08)	0,69*** (0,04)	−0,77† (0,40)	Obrnuto U	406	14	1.556,15	0,94
	Manje razv.	–	0,02** (0,01)	0,15*** (0,02)	0,49*** (0,03)	Neg. od 2003.	−1,16*** (0,08)	−0,81*** (0,18)	0,75** (0,20)	n.s.	0,09*** (0,01)	−1,22*** (0,22)	0,39*** (0,03)	n.s.	N - rastući	377	13	627,66	0,83
Din. FE model	Cijeli uzorak	−0,11*** (0,02)	–	−0,06* (0,03)	n.s.	–	0,61* (0,28)	−1,99** (0,70)	1,30* (0,54)	0,86** (0,26)	n.s.	−1,88*** (0,36)	n.s.	n.s.	–	–	–	–	–
	Razvijenije	−0,23*** (0,04)	–	−0,06* (0,03)	0,16** (0,05)	–	1,26*** (0,20)	−1,07* (0,43)	1,19** (0,36)	0,70*** (0,18)	−0,11* (0,05)	−1,73*** (0,19)	0,58*** (0,09)	n.s.	–	–	–	–	–
	Manje razv.	−0,17*** (0,03)	–	n.s.	n.s.	–	−1,49*** (0,39)	−2,27** (0,80)	1,61* (0,68)	n.s.	0,08† (0,05)	−1,74*** (0,50)	n.s.	−0,42† (0,22)	–	–	–	–	–
Model standardiziranih procjenitelja	Cijeli uzorak	–	–	0,03*** (0,01)	0,28*** (0,02)	Neg. od 2003.	0,39*** (0,09)	−0,10*** (0,01)	n.s.	0,04† (0,02)	n.s.	−0,11*** (0,01)	0,14*** (0,01)	n.s.	Konveksan	783	27	2.814,94	0,79
	Razvijenije	–	–	−0,04*** (0,01)	0,30*** (0,04)	Neg. od 2008.	1,16*** (0,14)	−0,08*** (0,01)	0,03*** (0,01)	0,06*** (0,01)	−0,04*** (0,01)	−0,12*** (0,01)	0,20*** (0,01)	−0,05† (0,02)	Obrnuto U	406	14	329,35	0,94
	Manje razv.	–	–	0,09*** (0,01)	0,30*** (0,02)	Neg. od 2003.	−1,10*** (0,09)	−0,06*** (0,01)	0,03** (0,01)	n.s.	0,04*** (0,01)	−0,11*** (0,02)	0,11*** (0,01)	n.s.	Konveksan	377	13	185,06	0,82

Napomene: *** p < 0,001; ** p < 0,01; * p < 0,05; † p < 0,1; n.s. = nije statistički značajno; Oznaka „-“ = nije primjenjivo. Standardne pogreške navedene su u zagradama ispod koeficijenta. Kubni model i model standardiziranih procjenitelja s fiksnim efektima i Driscoll-Kraay standardnih pogreškama (najveći vremenski pomak = 3). Dinamički FE model: prikazani su dugoročni (LR) koeficijenti; ECT = kratkoročni koeficijent korekcije pogreške; R^2 i F-statistika nisu dostupni za procjenitelj DFE (koristi z-testove); N = broj opažanja. Pop. = logaritam populacije; Urb. = udio urbanog stanovništva u ukupnom stanovništvu; Ind. = udio dodane vrijednosti industrije u BDP-u; Trg. otv. = logaritam trgovinske otvorenosti; Fin. razv. = logaritam duga (proxy za financijsku razvijenost); Obn. en. = udio obnovljivih izvora energije u ukupnoj potrošnji; En. int. = logaritam energetskog intenziteta; Kval. inst. = V-Dem liberalni indeks institucionalne kvalitete.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Rezultati alternativnih EKC modela — Emisije CO_2 iz poljoprivrede

Model	Uzorak	ECT	BDP p.c.³	BDP p.c.²	BDP p.c.	Vrem. trend	Pop.	Urb.	Ind.	Trg. otv.	Fin. razv.	Obn. en.	En. int.	Kval. inst.	Oblik EKC	N	Gr.	F-stat.	R^2
		$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)					
Kubni model	Cijeli uzorak	–	0,02** (0,01)	0,04** (0,01)	n.s.	Neg. od 1998.	−0,26** (0,08)	n.s.	−0,42* (0,19)	0,33*** (0,07)	−0,09*** (0,01)	0,35* (0,13)	n.s.	0,48*** (0,08)	N - rastući	696	25	5.746,48	0,37
	Razvijenije	–	n.s.	n.s.	n.s.	Neg. od 2006.	n.s.	n.s.	n.s.	0,81** (0,24)	−0,29*** (0,04)	0,71*** (0,12)	n.s.	1,50* (0,61)	Nije potvrđen	332	12	38,19	0,47
	Manje razv.	–	n.s.	n.s.	0,07* (0,03)	Neg. od 1998.	n.s.	n.s.	n.s.	n.s.	n.s.	0,21† (0,11)	n.s.	0,48*** (0,10)	Linearan	364	13	78,56	0,51
Din. FE model	Cijeli uzorak	−0,15*** (0,02)	–	−0,06* (0,03)	−0,14† (0,07)	–	n.s.	n.s.	1,19* (0,58)	n.s.	n.s.	n.s.	n.s.	0,84** (0,28)	–	–	–	–	–
	Razvijenije	−0,18*** (0,04)	–	n.s.	n.s.	–	n.s.	n.s.	n.s.	n.s.	−0,18† (0,10)	n.s.	n.s.	n.s.	–	–	–	–	–
	Manje razv.	−0,19*** (0,03)	–	−0,07* (0,03)	−0,20** (0,08)	–	n.s.	n.s.	1,65* (0,74)	n.s.	n.s.	0,84† (0,50)	n.s.	0,73** (0,21)	–	–	–	–	–
Model standardiziranih procjenitelja	Cijeli uzorak	–	–	−0,04† (0,02)	n.s.	Neg. od 1997.	-0,63† (0,31)	n.s.	n.s.	0,17** (0,06)	−0,15*** (0,02)	0,17*** (0,03)	−0,18** (0,06)	0,12*** (0,02)	Nije potvrđen	696	25	2.071,03	0,33
	Razvijenije	–	–	n.s.	n.s.	Neg. od 2006.	n.s.	n.s.	n.s.	0,55** (0,15)	−0,45*** (0,07)	0,24*** (0,04)	n.s.	0,30* (0,14)	Nije potvrđen	332	12	103,72	0,46
	Manje razv.	–	–	−0,18* (0,07)	n.s.	Neg. od 1998.	n.s.	−0,17* (0,08)	n.s.	n.s.	n.s.	0,09* (0,04)	n.s.	0,11*** (0,02)	Obrnuto U	364	13	202,50	0,51

Napomene: *** p < 0,001; ** p < 0,01; * p < 0,05; † p < 0,1; n.s. = nije statistički značajno; Oznaka „-“ = nije primjenjivo. Standardne pogreške navedene su u zagradama ispod koeficijenta. Kubni model i model standardiziranih procjenitelja s fiksnim efektima i Driscoll-Kraay standardnih pogreškama (najveći vremenski pomak = 3). Dinamički FE model: prikazani su dugoročni (LR) koeficijenti; ECT = kratkoročni koeficijent korekcije pogreške; R^2 i F-statistika nisu dostupni za procjenitelj DFE (koristi z-testove); N = broj opažanja. Pop. = logaritam populacije; Urb. = udio urbanog stanovništva u ukupnom stanovništvu; Ind. = udio dodane vrijednosti industrije u BDP-u; Trg. otv. = logaritam trgovinske otvorenosti; Fin. razv. = logaritam duga (proxy za financijsku razvijenost); Obn. en. = udio obnovljivih izvora energije u ukupnoj potrošnji; En. int. = logaritam energetskog intenziteta; Kval. inst. = V-Dem liberalni indeks institucionalne kvalitete.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Rezultati alternativnih EKC modela — Emisije CO_2 iz zgradarstva

Model	Uzorak	ECT	BDP p.c.³	BDP p.c.²	BDP p.c.	Vrem. trend	Pop.	Urb.	Ind.	Trg. otv.	Fin. razv.	Obn. en.	En. int.	Kval. inst.	Oblik EKC	N	Gr.	F-stat.	R^2
		$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)					
Kubni model	Cijeli uzorak	–	n.s.	n.s.	0,51*** (0,05)	Neg. od 2002.	0,94*** (0,13)	n.s.	−1,62*** (0,29)	n.s.	n.s.	−1,21*** (0,28)	0,31*** (0,07)	0,17** (0,06)	Linearan	783	27	2.305,71	0,65
	Razvijenije	–	n.s.	−0,28*** (0,07)	0,54** (0,14)	Neg. od 2002.	1,62*** (0,24)	n.s.	n.s.	0,39* (0,17)	n.s.	−1,32*** (0,17)	0,58** (0,17)	−0,67† (0,39)	Obrnuto U	406	14	2.514,54	0,76
	Manje razv.	–	n.s.	n.s.	0,47** (0,14)	Neg. od 1998.	−0,67** (0,19)	n.s.	−1,67* (0,72)	−0,37** (0,12)	-0,04† (0,02)	−1,34** (0,40)	n.s.	n.s.	Linearan	377	13	542,63	0,66
Din. FE model	Cijeli uzorak	−0,17*** (0,02)	–	−0,09** (0,03)	n.s.	–	0,74* (0,35)	n.s.	n.s.	n.s.	−0,21** (0,07)	−1,96*** (0,46)	n.s.	n.s.	–	–	–	–	–
	Razvijenije	−0,16*** (0,03)	–	−0,19* (0,09)	n.s.	–	2,42*** (0,58)	n.s.	2,21* (1,08)	n.s.	n.s.	−1,98*** (0,55)	n.s.	n.s.	–	–	–	–	–
	Manje razv.	−0,27*** (0,03)	–	n.s.	n.s.	–	−1,33** (0,49)	−2,30* (0,98)	n.s.	−0,68* (0,27)	−0,16** (0,06)	−1,90** (0,62)	n.s.	n.s.	–	–	–	–	–
Model standardiziranih procjenitelja	Cijeli uzorak	–	–	n.s.	0,32*** (0,03)	Neg. od 2002.	0,92*** (0,10)	-0,03† (0,02)	−0,07*** (0,01)	n.s.	n.s.	−0,12*** (0,03)	0,09*** (0,02)	0,01** (0,00)	Linearan	783	27	941,27	0,65
	Razvijenije	–	–	−0,16** (0,04)	0,38*** (0,09)	Neg. od 2002.	1,75*** (0,20)	n.s.	n.s.	0,08* (0,03)	n.s.	−0,12*** (0,01)	0,17** (0,05)	−0,05† (0,02)	Obrnuto U	406	14	756,81	0,76
	Manje razv.	–	–	0,05* (0,02)	0,31*** (0,07)	Neg. od 1998.	−0,71** (0,19)	n.s.	−0,07* (0,03)	−0,07** (0,02)	n.s.	−0,13** (0,04)	n.s.	n.s.	Konveksan	377	13	205,61	0,66

Napomene: *** p < 0,001; ** p < 0,01; * p < 0,05; † p < 0,1; n.s. = nije statistički značajno; Oznaka „-“ = nije primjenjivo. Standardne pogreške navedene su u zagradama ispod koeficijenta. Kubni model i model standardiziranih procjenitelja s fiksnim efektima i Driscoll-Kraay standardnih pogreškama (najveći vremenski pomak = 3). Dinamički FE model: prikazani su dugoročni (LR) koeficijenti; ECT = kratkoročni koeficijent korekcije pogreške; R^2 i F-statistika nisu dostupni za procjenitelj DFE (koristi z-testove); N = broj opažanja. Pop. = logaritam populacije; Urb. = udio urbanog stanovništva u ukupnom stanovništvu; Ind. = udio dodane vrijednosti industrije u BDP-u; Trg. otv. = logaritam trgovinske otvorenosti; Fin. razv. = logaritam duga (proxy za financijsku razvijenost); Obn. en. = udio obnovljivih izvora energije u ukupnoj potrošnji; En. int. = logaritam energetskog intenziteta; Kval. inst. = V-Dem liberalni indeks institucionalne kvalitete.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Rezultati alternativnih EKC modela — Emisije CO_2 od izgaranja goriva

Model	Uzorak	ECT	BDP p.c.³	BDP p.c.²	BDP p.c.	Vrem. trend	Pop.	Urb.	Ind.	Trg. otv.	Fin. razv.	Obn. en.	En. int.	Kval. inst.	Oblik EKC	N	Gr.	F-stat.	R^2
		$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)					
Kubni model	Cijeli uzorak	–	−0,06*** (0,02)	n.s.	0,57*** (0,11)	Neg. od 2003.	0,35† (0,18)	1,27† (0,63)	n.s.	n.s.	n.s.	1,19*** (0,29)	0,30*** (0,07)	−0,32† (0,19)	Obrnuto N	734	27	37.326,98	0,32
	Razvijenije	–	−0,08† (0,04)	n.s.	1,08** (0,29)	Neg. od 2002.	n.s.	0,86* (0,38)	−2,87* (1,07)	0,59* (0,28)	n.s.	0,63* (0,30)	n.s.	n.s.	Linearan	357	14	7.141,31	0,42
	Manje razv.	–	n.s.	n.s.	0,38* (0,15)	Pozitivan	n.s.	n.s.	2,85** (0,90)	-0,94† (0,49)	n.s.	2,73*** (0,60)	0,55** (0,18)	n.s.	Linearan	377	13	25,44	0,44
Din. FE model	Cijeli uzorak	−0,14*** (0,02)	–	n.s.	0,28† (0,15)	–	n.s.	n.s.	n.s.	n.s.	n.s.	n.s.	0,56† (0,32)	−1,34* (0,61)	–	–	–	–	–
	Razvijenije	−0,21*** (0,04)	–	n.s.	n.s.	–	n.s.	n.s.	n.s.	n.s.	n.s.	−1,46† (0,75)	n.s.	n.s.	–	–	–	–	–
	Manje razv.	−0,15*** (0,03)	–	0,16† (0,09)	0,66** (0,23)	–	n.s.	n.s.	n.s.	n.s.	n.s.	n.s.	0,93† (0,49)	−1,14† (0,67)	–	–	–	–	–
Model standardiziranih procjenitelja	Cijeli uzorak	–	–	0,15*** (0,03)	0,43*** (0,06)	Neg. od 2003.	n.s.	n.s.	n.s.	n.s.	n.s.	0,11** (0,03)	0,17*** (0,03)	−0,04** (0,01)	Konveksan	734	27	4.897,87	0,24
	Razvijenije	–	–	−0,28*** (0,05)	0,98*** (0,23)	Neg. od 1998.	n.s.	0,11* (0,04)	−0,16* (0,06)	0,14† (0,07)	n.s.	0,08* (0,04)	-0,07† (0,03)	n.s.	Obrnuto U	357	14	8.593,47	0,42
	Manje razv.	–	–	0,27** (0,07)	0,45** (0,13)	Pozitivan	n.s.	n.s.	0,17** (0,05)	−0,22† (0,11)	n.s.	0,31*** (0,07)	0,20* (0,08)	−0,03* (0,01)	Konveksan	377	13	27,20	0,43

Napomene: *** p < 0,001; ** p < 0,01; * p < 0,05; † p < 0,1; n.s. = nije statistički značajno; Oznaka „-“ = nije primjenjivo. Standardne pogreške navedene su u zagradama ispod koeficijenta. Kubni model i model standardiziranih procjenitelja s fiksnim efektima i Driscoll-Kraay standardnih pogreškama (najveći vremenski pomak = 3). Dinamički FE model: prikazani su dugoročni (LR) koeficijenti; ECT = kratkoročni koeficijent korekcije pogreške; R^2 i F-statistika nisu dostupni za procjenitelj DFE (koristi z-testove); N = broj opažanja. Pop. = logaritam populacije; Urb. = udio urbanog stanovništva u ukupnom stanovništvu; Ind. = udio dodane vrijednosti industrije u BDP-u; Trg. otv. = logaritam trgovinske otvorenosti; Fin. razv. = logaritam duga (proxy za financijsku razvijenost); Obn. en. = udio obnovljivih izvora energije u ukupnoj potrošnji; En. int. = logaritam energetskog intenziteta; Kval. inst. = V-Dem liberalni indeks institucionalne kvalitete.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Rezultati alternativnih EKC modela — Emisije CO_2 od industrijskog izgaranja

Model	Uzorak	ECT	BDP p.c.³	BDP p.c.²	BDP p.c.	Vrem. trend	Pop.	Urb.	Ind.	Trg. otv.	Fin. razv.	Obn. en.	En. int.	Kval. inst.	Oblik EKC	N	Gr.	F-stat.	R^2
		$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)					
Kubni model	Cijeli uzorak	–	−0,02** (0,01)	0,05*** (0,01)	0,31*** (0,04)	Neg. od 1996.	n.s.	0,59* (0,25)	n.s.	n.s.	n.s.	−0,82*** (0,08)	n.s.	n.s.	Obrnuto N	775	27	7.950,58	0,68
	Razvijenije	–	n.s.	n.s.	0,80*** (0,13)	Neg. od 1996.	−0,34* (0,13)	0,61*** (0,14)	n.s.	0,74*** (0,13)	−0,16* (0,07)	−0,49** (0,15)	0,38*** (0,09)	n.s.	Linearan	398	14	1.954,68	0,76
	Manje razv.	–	n.s.	n.s.	0,30*** (0,06)	Neg. od 1999.	−1,38** (0,45)	n.s.	1,03* (0,47)	n.s.	n.s.	−1,20** (0,36)	n.s.	n.s.	Linearan	377	13	808,40	0,71
Din. FE model	Cijeli uzorak	−0,16*** (0,02)	–	n.s.	−0,20* (0,10)	–	n.s.	n.s.	n.s.	n.s.	n.s.	−1,52** (0,52)	n.s.	n.s.	–	–	–	–	–
	Razvijenije	−0,17*** (0,03)	–	0,21† (0,11)	−0,51** (0,19)	–	n.s.	n.s.	n.s.	n.s.	n.s.	−1,22* (0,56)	n.s.	n.s.	–	–	–	–	–
	Manje razv.	−0,16*** (0,03)	–	n.s.	n.s.	–	n.s.	−3,12† (1,75)	n.s.	n.s.	n.s.	n.s.	n.s.	n.s.	–	–	–	–	–
Model standardiziranih procjenitelja	Cijeli uzorak	–	–	0,08*** (0,01)	0,20*** (0,03)	Neg. od 1998.	n.s.	n.s.	n.s.	n.s.	n.s.	−0,10*** (0,01)	n.s.	n.s.	Konveksan	775	27	1.821,37	0,67
	Razvijenije	–	–	n.s.	0,59*** (0,09)	Neg. od 2003.	−0,47*** (0,12)	0,06*** (0,01)	n.s.	0,15*** (0,03)	−0,08* (0,03)	−0,05** (0,02)	0,12*** (0,03)	n.s.	Linearan	398	14	2.144,15	0,76
	Manje razv.	–	–	0,15*** (0,03)	0,24** (0,06)	Neg. od 1999.	−1,71** (0,49)	n.s.	0,05* (0,02)	n.s.	n.s.	−0,13** (0,04)	n.s.	n.s.	Konveksan	377	13	320,70	0,71

Napomene: *** p < 0,001; ** p < 0,01; * p < 0,05; † p < 0,1; n.s. = nije statistički značajno; Oznaka „-“ = nije primjenjivo. Standardne pogreške navedene su u zagradama ispod koeficijenta. Kubni model i model standardiziranih procjenitelja s fiksnim efektima i Driscoll-Kraay standardnih pogreškama (najveći vremenski pomak = 3). Dinamički FE model: prikazani su dugoročni (LR) koeficijenti; ECT = kratkoročni koeficijent korekcije pogreške; R^2 i F-statistika nisu dostupni za procjenitelj DFE (koristi z-testove); N = broj opažanja. Pop. = logaritam populacije; Urb. = udio urbanog stanovništva u ukupnom stanovništvu; Ind. = udio dodane vrijednosti industrije u BDP-u; Trg. otv. = logaritam trgovinske otvorenosti; Fin. razv. = logaritam duga (proxy za financijsku razvijenost); Obn. en. = udio obnovljivih izvora energije u ukupnoj potrošnji; En. int. = logaritam energetskog intenziteta; Kval. inst. = V-Dem liberalni indeks institucionalne kvalitete.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Rezultati alternativnih EKC modela — Emisije CO_2 od proizvodnje električne energije

Model	Uzorak	ECT	BDP p.c.³	BDP p.c.²	BDP p.c.	Vrem. trend	Pop.	Urb.	Ind.	Trg. otv.	Fin. razv.	Obn. en.	En. int.	Kval. inst.	Oblik EKC	N	Gr.	F-stat.	R^2
		$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)					
Kubni model	Cijeli uzorak	–	n.s.	n.s.	0,31** (0,10)	Pozitivan	1,13*** (0,23)	−0,67* (0,26)	1,04*** (0,16)	n.s.	n.s.	−3,24*** (0,30)	0,82*** (0,08)	n.s.	Linearan	783	27	2.050,50	0,83
	Razvijenije	–	n.s.	n.s.	n.s.	Pozitivan	1,54*** (0,37)	n.s.	1,47*** (0,30)	n.s.	−0,21*** (0,05)	−3,49*** (0,30)	0,74*** (0,12)	n.s.	Nije potvrđen	406	14	8.036,30	0,84
	Manje razv.	–	0,06*** (0,01)	0,23*** (0,04)	0,70*** (0,11)	Neg. od 2006.	0,58** (0,20)	n.s.	1,57*** (0,36)	n.s.	0,20*** (0,04)	−2,97*** (0,33)	1,08*** (0,12)	−0,15† (0,08)	N - rastući	377	13	1.794,48	0,88
Din. FE model	Cijeli uzorak	−0,22*** (0,03)	–	n.s.	0,16† (0,08)	–	1,70*** (0,35)	n.s.	1,96** (0,67)	0,65* (0,30)	0,14* (0,07)	−3,68*** (0,46)	0,86*** (0,18)	n.s.	–	–	–	–	–
	Razvijenije	−0,25*** (0,04)	–	n.s.	0,29* (0,14)	–	1,84** (0,57)	n.s.	n.s.	1,22* (0,49)	n.s.	−3,86*** (0,53)	1,08*** (0,26)	n.s.	–	–	–	–	–
	Manje razv.	−0,22*** (0,04)	–	n.s.	0,22† (0,13)	–	n.s.	n.s.	2,85* (1,17)	n.s.	0,26** (0,08)	−2,67** (0,84)	1,08*** (0,27)	n.s.	–	–	–	–	–
Model standardiziranih procjenitelja	Cijeli uzorak	–	–	n.s.	0,22** (0,06)	Pozitivan	1,24*** (0,22)	−0,04* (0,01)	0,05*** (0,01)	n.s.	n.s.	−0,30*** (0,03)	0,23*** (0,02)	n.s.	Linearan	783	27	102,96	0,82
	Razvijenije	–	–	n.s.	n.s.	Pozitivan	1,62*** (0,37)	n.s.	0,06** (0,02)	n.s.	−0,09*** (0,02)	−0,33*** (0,03)	0,21*** (0,04)	n.s.	Nije potvrđen	406	14	307,61	0,84
	Manje razv.	–	–	n.s.	0,38*** (0,08)	Neg. od 2004.	0,98** (0,26)	n.s.	0,06*** (0,02)	n.s.	0,09*** (0,02)	−0,25*** (0,03)	0,31*** (0,03)	n.s.	Linearan	377	13	118,90	0,88

Napomene: *** p < 0,001; ** p < 0,01; * p < 0,05; † p < 0,1; n.s. = nije statistički značajno; Oznaka „-“ = nije primjenjivo. Standardne pogreške navedene su u zagradama ispod koeficijenta. Kubni model i model standardiziranih procjenitelja s fiksnim efektima i Driscoll-Kraay standardnih pogreškama (najveći vremenski pomak = 3). Dinamički FE model: prikazani su dugoročni (LR) koeficijenti; ECT = kratkoročni koeficijent korekcije pogreške; R^2 i F-statistika nisu dostupni za procjenitelj DFE (koristi z-testove); N = broj opažanja. Pop. = logaritam populacije; Urb. = udio urbanog stanovništva u ukupnom stanovništvu; Ind. = udio dodane vrijednosti industrije u BDP-u; Trg. otv. = logaritam trgovinske otvorenosti; Fin. razv. = logaritam duga (proxy za financijsku razvijenost); Obn. en. = udio obnovljivih izvora energije u ukupnoj potrošnji; En. int. = logaritam energetskog intenziteta; Kval. inst. = V-Dem liberalni indeks institucionalne kvalitete.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Rezultati alternativnih EKC modela — Emisije CO_2 od industrijskih procesa

Model	Uzorak	ECT	BDP p.c.³	BDP p.c.²	BDP p.c.	Vrem. trend	Pop.	Urb.	Ind.	Trg. otv.	Fin. razv.	Obn. en.	En. int.	Kval. inst.	Oblik EKC	N	Gr.	F-stat.	R^2
		$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)					
Kubni model	Cijeli uzorak	–	n.s.	n.s.	0,22* (0,08)	Neg. od 2009.	n.s.	−1,15*** (0,23)	-0,33† (0,18)	0,42** (0,11)	n.s.	0,44* (0,19)	n.s.	n.s.	Linearan	783	27	173,50	0,31
	Razvijenije	–	−0,07** (0,03)	0,10** (0,04)	0,55*** (0,12)	Neg. od 2007.	n.s.	-0,39† (0,19)	−1,01** (0,31)	0,27* (0,12)	−0,14* (0,06)	1,20*** (0,23)	0,45*** (0,11)	n.s.	Obrnuto N	406	14	118,55	0,43
	Manje razv.	–	n.s.	n.s.	0,31** (0,09)	Neg. od 1996.	−1,19*** (0,29)	−1,54* (0,71)	n.s.	0,80*** (0,18)	0,09*** (0,01)	−0,99** (0,32)	n.s.	n.s.	Linearan	377	13	283,06	0,49
Din. FE model	Cijeli uzorak	−0,22*** (0,02)	–	−0,06* (0,03)	−0,19* (0,08)	–	n.s.	−1,83* (0,75)	n.s.	0,64* (0,25)	n.s.	n.s.	n.s.	n.s.	–	–	–	–	–
	Razvijenije	−0,15*** (0,03)	–	n.s.	−0,33* (0,16)	–	n.s.	n.s.	−1,96† (1,08)	n.s.	−0,27* (0,13)	n.s.	n.s.	n.s.	–	–	–	–	–
	Manje razv.	−0,33*** (0,04)	–	n.s.	−0,23* (0,10)	–	−1,25* (0,48)	−2,48* (0,96)	1,52† (0,84)	0,94** (0,27)	0,10† (0,06)	n.s.	n.s.	n.s.	–	–	–	–	–
Model standardiziranih procjenitelja	Cijeli uzorak	–	–	n.s.	0,18* (0,07)	Neg. od 2009.	n.s.	−0,16*** (0,02)	−0,02* (0,01)	0,10** (0,03)	n.s.	0,05* (0,02)	n.s.	n.s.	Linearan	783	27	69,71	0,31
	Razvijenije	–	–	n.s.	0,44*** (0,11)	Neg. od 2008.	n.s.	n.s.	−0,04* (0,02)	0,06† (0,03)	−0,09* (0,03)	0,15*** (0,03)	0,16*** (0,04)	n.s.	Linearan	406	14	163,34	0,41
	Manje razv.	–	–	0,09*** (0,02)	0,25** (0,07)	Negativan	−1,54** (0,43)	−0,17* (0,08)	n.s.	0,19*** (0,04)	0,05*** (0,01)	−0,12** (0,04)	n.s.	n.s.	Konveksan	377	13	235,24	0,49

Napomene: *** p < 0,001; ** p < 0,01; * p < 0,05; † p < 0,1; n.s. = nije statistički značajno; Oznaka „-“ = nije primjenjivo. Standardne pogreške navedene su u zagradama ispod koeficijenta. Kubni model i model standardiziranih procjenitelja s fiksnim efektima i Driscoll-Kraay standardnih pogreškama (najveći vremenski pomak = 3). Dinamički FE model: prikazani su dugoročni (LR) koeficijenti; ECT = kratkoročni koeficijent korekcije pogreške; R^2 i F-statistika nisu dostupni za procjenitelj DFE (koristi z-testove); N = broj opažanja. Pop. = logaritam populacije; Urb. = udio urbanog stanovništva u ukupnom stanovništvu; Ind. = udio dodane vrijednosti industrije u BDP-u; Trg. otv. = logaritam trgovinske otvorenosti; Fin. razv. = logaritam duga (proxy za financijsku razvijenost); Obn. en. = udio obnovljivih izvora energije u ukupnoj potrošnji; En. int. = logaritam energetskog intenziteta; Kval. inst. = V-Dem liberalni indeks institucionalne kvalitete.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Rezultati alternativnih EKC modela — Emisije CO_2 od prometa

Model	Uzorak	ECT	BDP p.c.³	BDP p.c.²	BDP p.c.	Vrem. trend	Pop.	Urb.	Ind.	Trg. otv.	Fin. razv.	Obn. en.	En. int.	Kval. inst.	Oblik EKC	N	Gr.	F-stat.	R^2
		$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)					
Kubni model	Cijeli uzorak	–	n.s.	0,02† (0,01)	0,57*** (0,05)	Mješovito	n.s.	−1,70*** (0,30)	n.s.	0,57** (0,18)	n.s.	−1,01*** (0,15)	0,40** (0,11)	−0,48* (0,20)	Linearan	783	27	8.973,91	0,77
	Razvijenije	–	−0,10** (0,03)	0,24** (0,06)	0,76*** (0,06)	Neg. od 2005.	n.s.	−1,63*** (0,25)	−0,94*** (0,17)	0,44* (0,16)	0,05* (0,02)	−0,76** (0,19)	0,55*** (0,07)	n.s.	Obrnuto N	406	14	404,82	0,79
	Manje razv.	–	n.s.	n.s.	0,38** (0,10)	Pozitivan	0,56** (0,19)	−1,84** (0,47)	n.s.	0,61** (0,19)	n.s.	−1,11** (0,29)	n.s.	−0,34† (0,20)	Linearan	377	13	2.072,88	0,82
Din. FE model	Cijeli uzorak	−0,21*** (0,02)	–	n.s.	0,13* (0,05)	–	−0,52* (0,22)	−2,30*** (0,55)	n.s.	0,52** (0,18)	n.s.	−1,31*** (0,29)	n.s.	−0,69** (0,23)	–	–	–	–	–
	Razvijenije	−0,21*** (0,03)	–	n.s.	0,15† (0,08)	–	n.s.	−1,54* (0,68)	n.s.	n.s.	n.s.	−0,98** (0,29)	n.s.	n.s.	–	–	–	–	–
	Manje razv.	−0,23*** (0,03)	–	n.s.	n.s.	–	n.s.	−1,81* (0,91)	1,89* (0,84)	0,56* (0,25)	n.s.	−1,68** (0,58)	−0,50** (0,19)	−0,54* (0,25)	–	–	–	–	–
Model standardiziranih procjenitelja	Cijeli uzorak	–	–	0,02* (0,01)	0,41*** (0,04)	Neg. od 2011.	n.s.	−0,18*** (0,03)	n.s.	0,12** (0,04)	n.s.	−0,11*** (0,02)	0,13** (0,04)	−0,03* (0,01)	Konveksan	783	27	98,12	0,77
	Razvijenije	–	–	0,06** (0,02)	0,51*** (0,05)	Neg. od 2006.	n.s.	−0,15*** (0,03)	-0,03† (0,02)	0,08* (0,03)	0,02** (0,01)	−0,08** (0,02)	0,17*** (0,03)	0,04† (0,02)	Konveksan	406	14	1.340,53	0,75
	Manje razv.	–	–	n.s.	0,28** (0,07)	Pozitivan	0,66** (0,20)	−0,18** (0,05)	n.s.	0,12** (0,04)	n.s.	−0,12** (0,03)	n.s.	−0,02† (0,01)	Linearan	377	13	763,50	0,82

Napomene: *** p < 0,001; ** p < 0,01; * p < 0,05; † p < 0,1; n.s. = nije statistički značajno; Oznaka „-“ = nije primjenjivo. Standardne pogreške navedene su u zagradama ispod koeficijenta. Kubni model i model standardiziranih procjenitelja s fiksnim efektima i Driscoll-Kraay standardnih pogreškama (najveći vremenski pomak = 3). Dinamički FE model: prikazani su dugoročni (LR) koeficijenti; ECT = kratkoročni koeficijent korekcije pogreške; R^2 i F-statistika nisu dostupni za procjenitelj DFE (koristi z-testove); N = broj opažanja. Pop. = logaritam populacije; Urb. = udio urbanog stanovništva u ukupnom stanovništvu; Ind. = udio dodane vrijednosti industrije u BDP-u; Trg. otv. = logaritam trgovinske otvorenosti; Fin. razv. = logaritam duga (proxy za financijsku razvijenost); Obn. en. = udio obnovljivih izvora energije u ukupnoj potrošnji; En. int. = logaritam energetskog intenziteta; Kval. inst. = V-Dem liberalni indeks institucionalne kvalitete.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.

Rezultati alternativnih EKC modela — Emisije CO_2 od otpada

Model	Uzorak	ECT	BDP p.c.³	BDP p.c.²	BDP p.c.	Vrem. trend	Pop.	Urb.	Ind.	Trg. otv.	Fin. razv.	Obn. en.	En. int.	Kval. inst.	Oblik EKC	N	Gr.	F-stat.	R^2
		$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)	$\hat{\beta}$ (S.E.)					
Kubni model	Cijeli uzorak	–	n.s.	n.s.	n.s.	Pozitivan	0,23* (0,09)	−0,24*** (0,05)	n.s.	−0,11* (0,04)	n.s.	n.s.	n.s.	−0,04* (0,02)	Nije potvrđen	653	23	1.553,37	0,13
	Razvijenije	–	n.s.	n.s.	−0,15† (0,08)	Pozitivan	1,08* (0,39)	n.s.	0,72* (0,32)	−0,30** (0,10)	-0,06† (0,03)	n.s.	n.s.	−1,49* (0,68)	Nije potvrđen	319	11	77,30	0,26
	Manje razv.	–	0,01*** (0,00)	0,04*** (0,01)	0,03* (0,01)	Pozitivan	n.s.	−0,28** (0,08)	n.s.	n.s.	n.s.	0,11*** (0,02)	0,03** (0,01)	n.s.	N - rastući	334	12	702,59	0,26
Din. FE model	Cijeli uzorak	−0,63*** (0,03)	–	n.s.	n.s.	–	0,13† (0,07)	n.s.	−0,20* (0,10)	n.s.	n.s.	n.s.	n.s.	n.s.	–	–	–	–	–
	Razvijenije	−0,70*** (0,05)	–	n.s.	n.s.	–	0,46* (0,19)	n.s.	n.s.	−0,23† (0,12)	n.s.	n.s.	n.s.	−0,99† (0,53)	–	–	–	–	–
	Manje razv.	−0,30*** (0,04)	–	0,01† (0,01)	n.s.	–	n.s.	−0,25† (0,15)	n.s.	n.s.	n.s.	n.s.	n.s.	n.s.	–	–	–	–	–
Model standardiziranih procjenitelja	Cijeli uzorak	–	–	n.s.	n.s.	Pozitivan	0,84* (0,32)	−0,08*** (0,01)	n.s.	−0,07* (0,03)	n.s.	0,03† (0,01)	n.s.	−0,01* (0,00)	Nije potvrđen	653	23	5.754,58	0,13
	Razvijenije	–	–	n.s.	-0,37† (0, 19)	Pozitivan	3,96* (1,43)	n.s.	0,10* (0,05)	−0,19** (0,07)	-0,09† (0,05)	n.s.	n.s.	−0,31* (0,14)	Nije potvrđen	319	11	15,98	0,26
	Manje razv.	–	–	n.s.	n.s.	n.s.	n.s.	−0,06* (0,02)	n.s.	n.s.	n.s.	0,05*** (0,01)	0,03† (0,01)	n.s.	Nije potvrđen	334	12	63,23	0,20

Napomene: *** p < 0,001; ** p < 0,01; * p < 0,05; † p < 0,1; n.s. = nije statistički značajno; Oznaka „-“ = nije primjenjivo. Standardne pogreške navedene su u zagradama ispod koeficijenta. Kubni model i model standardiziranih procjenitelja s fiksnim efektima i Driscoll-Kraay standardnih pogreškama (najveći vremenski pomak = 3). Dinamički FE model: prikazani su dugoročni (LR) koeficijenti; ECT = kratkoročni koeficijent korekcije pogreške; R^2 i F-statistika nisu dostupni za procjenitelj DFE (koristi z-testove); N = broj opažanja. Pop. = logaritam populacije; Urb. = udio urbanog stanovništva u ukupnom stanovništvu; Ind. = udio dodane vrijednosti industrije u BDP-u; Trg. otv. = logaritam trgovinske otvorenosti; Fin. razv. = logaritam duga (proxy za financijsku razvijenost); Obn. en. = udio obnovljivih izvora energije u ukupnoj potrošnji; En. int. = logaritam energetskog intenziteta; Kval. inst. = V-Dem liberalni indeks institucionalne kvalitete.

Izvor: izrada autora prema podacima Eurostata, WDI i Svjetske banke.