



Primljeno 27-11-2024
 Kl. ozn. 643-03/24-03/18
 Ur. br. 141-01-24-001
 Org. jed. 01

Trg braće Mažuranića 10 • 51 000 Rijeka • Croatia

T: (051) 406-500 • F: (051) 216-671; 216-091

W: www.uniri.hr • E: ured@uniri.hr

2. PRIJAVA TEME DOKTORSKE DISERTACIJE

Opći podaci i kontakt doktoranda/doktorandice	
Titula, ime i prezime doktoranda/doktorandice	Nikolina Blašković, univ. spec. oec. MBA
Nositelj/Nositelji studija	SVEUČILIŠTE U RIJECI, EKONOMSKI FAKULTET
Naziv studija	Poslijediplomski sveučilišni (doktorski) studij ekonomije i poslovne ekonomije
Matični broj doktoranda/doktorandice	221/19
Ime i prezime majke i/ili oca	Milka (rođ. Babić) i Nikola Peričić
Datum i mjesto rođenja	8. lipnja 1973. u Rijeci
Adresa	Braće Car Uračić 22, Crikvenica
Fiksni telefon/ mobilni telefon	+385 98 222 969
E-pošta	pansionberto@gmail.com
ŽIVOTOPIS DOKTORANDA/DOKTORANDICE	
Nikolina Blašković, rođena 1973. godine, udana je i majka dvoje odrasle djece. Dugogodišnja je poduzetnica iz Crikvenice s bogatim iskustvom u turističkoj industriji. Od 2003. do 2022. godine, kao osnivačica i vlasnica obiteljskog obrta Pansion Berto, vodila je sve ključne aspekte poslovanja. U ožujku 2022. godine, obiteljski posao prepustila je svojoj kćeri. Uz poduzetničke aktivnosti, aktivno je uključena u obrazovni sektor, gdje je radila kao nastavnica strukovnih predmeta iz ekonomije i turizma u Srednjoj školi dr. Antuna Barca u Crikvenici. Njezini profesionalni interesi obuhvaćaju turizam i ekonomiju, dok su njezini akademski interesi usmjereni na ekonomiju, energetiku i održivost. Od 2019. godine doktorandica je na Ekonomskom fakultetu Sveučilišta u Rijeci, gdje istražuje europsko energetske tržište, energetske učinkovitost i energetske neovisnost. Tijekom poslijediplomskog specijalističkog studija Ekonomija energetskega sektora (MBA) i doktorskog studija, kontinuirano se usavršava sudjelovanjem na brojnim međunarodnim seminarima i radionicama, što dodatno obogaćuje njezino znanje u području ekonomije i energetike te je motivira za daljnja istraživanja. Članica je nekoliko stručnih organizacija te aktivno sudjeluje u radu odbora i vijeća. Kao članica Nadzornog odbora EKO-MURVICA d.o.o., obnaša funkciju potpredsjednice. Također je uključena u Hrvatski ogranak Međunarodnog vijeća za velike energetske sustave (CIGRE), Alumni udrugu Ekonomskog fakulteta Sveučilišta u Rijeci, Školski odbor Srednje škole dr. Antuna Barca, Upravno vijeće Županijske lučke uprave Crikvenica te Mrežu za promicanje žena u energetske tranziciji (XEnergy). Govori engleski i njemački jezik, ljubiteljica je klasične glazbe, hard rocka i metala, a u slobodno vrijeme uživa u motociklizmu, putovanjima i druženju s obitelji.	

1. NASLOV PREDLOŽENE TEME

1.1. Hrvatski

Modeliranje maloprodajnih cijena električne energije: Kvantifikacija učinka dinamičke konvergencije i komponenti cijena na tržišnu konkurenciju i koncentraciju u zemljama Europske energetske zajednice

1.2. Engleski

Modelling Retail Electricity Prices: Quantifying the Effect of Dynamic Price Convergence and Price Components on Market Competition and Concentration in the Countries of the European Energy Community

1.3. Područje/polje
Društvene znanosti / ekonomija
1.4. Ključne riječi (minimalno pet riječi)
1. Cijene električne energije 2. Konvergencija 3. Tržišna otvorenost 4. Konkurencija 5. Komponente cijena 6. Europska energetska zajednica

2. PREDLOŽENI ILI POTENCIJALNI MENTOR/MENTORI

2.1. Mentor/i

Titula, ime i prezime	Ustanova, država	E-pošta
Prof.dr.sc., redoviti profesor u trajnom zvanju Nela Vlahinić	Ekonomski fakultet, Sveučilište u Rijeci, Hrvatska	nela.vlahinic@efri.uniri.hr

Minimalni opći kriteriji za odabir mentora:

- mora imati doktorat znanosti i biti izabran u znanstveno zvanje;
- mora imati najmanje dvije godine poslijedoktorskog iskustva;
- mora biti voditelj (suvoditelj ili partner) domaćeg ili međunarodnog projekta ili biti na drugi način u mogućnosti osigurati podršku za provedbu znanstvenih istraživanja;
- mora zadovoljavati minimalne kriterije izvrsnosti.

Ukoliko mentor nije zaposlenik Sveučilišta u Rijeci doktorandu se obavezno dodjeljuje komentor sa sastavnice Sveučilišta koja provodi doktorski studij.

2.2. Komentor

Titula, ime i prezime	Ustanova, država	E-pošta
Prof. dr. sc. Blanka Škrabić Perić	Ekonomski fakultet Sveučilišta u Splitu	bskrabic@efst.hr

3. OBRAZLOŽENJE TEME

3.1. Sažetak na hrvatskom jeziku (maksimalno 4000 znakova s praznim mjestima) U kontekstu globalnih energetske izazova i promjena tržišnih politika, analiza maloprodajnih cijena električne energije predstavlja ključnu temu, povezujući porezne politike, otvorenost tržišta i ekonomske varijable u zemljama Europske energetske zajednice (EEZ). Istraživanje obuhvaća 39 članica EEZ-a, uključujući EU-15 (prvih 15 članica Europske unije), EU-13 (zemlje koje su pristupile EU nakon 2004. godine) te Ugovorne strane i promatrače (Contracting Parties/Observers, CP/OB). Unatoč liberalizaciji tržišta koja ima za cilj smanjenje cjenovnih razlika i jačanje konkurencije, maloprodajne cijene značajno variraju među članicama EEZ-a, što utječe na stupanj otvorenosti tržišta. Istraživanje se fokusira na modeliranje učinka ključnih komponenti cijena električne energije na razinu konkurencije i stupanj koncentracije opskrbljivača u EEZ-u, u razdoblju od 2017. do 2023. godine. Glavna hipoteza istraživanja testira učinak ključnih komponenti cijena i dinamičke konvergencije ukupnih maloprodajnih cijena električne energije na tržišnu konkurenciju i koncentraciju u zemljama EEZ-a. Uz glavnu hipotezu, četiri pomoćne hipoteze ispituju različite aspekte međupovezanosti čimbenika s ciljem njihove identifikacije i kvantifikacije. Metodološki okvir istraživanja uključuje različite pristupe za analizu učinaka ključnih čimbenika na tržišnu otvorenost i konvergenciju cijena u EEZ-u. Kvalitativna komparativna analiza (QCA) koristi se za identifikaciju ključnih čimbenika (regulirane cijene, dekarbonizacija, energetska miks) koji utječu na otvorenost tržišta, dok logički modeli temeljeni na Booleovoj analizi pružaju uvid u logičke povezanosti između uvjeta i ishoda. Ekonometrijska analiza primjenjuje metode konvergencije (sigma, beta, delta, uzlazno-silazna i dinamička personalizirana konvergencija) kako bi se procijenila usklađenost nacionalnih cijena s prosjekom EEZ-a.
--

Panel modeli koriste se za testiranje postavljenih hipoteza o učinku ključnih komponenti cijena i dinamičke personalizirane konvergencije na stupanj otvorenosti tržišta i konkurenciju.. Ove varijable djeluju kao primarni prediktori zavisne varijable, definirane kroz kumulativni udio glavnih opskrbljivača i/ili ukupan broj opskrbljivača, uz mogućnost kreiranja sintetičkog indeksa iz dostupnih pokazatelja. Modeli uključuju dodatne nezavisne varijable definirane Booleovom logikom te kontrolne varijable koje pružaju širi ekonomski kontekst. Za model će se odabrati ključne prediktorske varijable iz svake skupine nezavisnih i kontrolnih varijabli, dok će se ostale varijable koristiti za testiranje modela.

Teorijski ciljevi istraživanja obuhvaćaju analizu regulatornih i institucionalnih čimbenika koji utječu na konvergenciju cijena i otvorenost tržišta. Aplikativni ciljevi usmjereni su na identificiranje prepreka koje potiču ili usporavaju tržišnu otvorenost te na pružanje preporuka za oblikovanje politika.

Doprinos istraživanja proizlazi iz sveobuhvatnog pristupa u modeliranju maloprodajnih cijena električne energije kroz raščlambu na komponente, uz usporedbu nominalnih cijena i cijena izraženih prema PPS-u. Ovaj pristup omogućava preciznu usporedbu stvarnih troškova električne energije u zemljama EEZ-a, popunjavajući prazninu u literaturi koja se uglavnom fokusira na nominalne cijene. Uvođenjem varijable dinamičke konvergencije proširuje se analitički okvir za praćenje promjena cijena unutar nacionalnih tržišta, što doprinosi boljem razumijevanju procesa konvergencije i divergencije cijena. Osim znanstvenog doprinosa, istraživanje ima praktičnu vrijednost kroz identifikaciju ključnih čimbenika koji utječu na troškove i tržišnu strukturu. Time se pružaju uvjeti za kreiranje politika koje potiču tržišnu otvorenost, konkurenciju i integraciju, s ciljem smanjenja razlika u cijenama između razvijenih i manje razvijenih članica EEZ-a.

3.2. *Sažetak na engleskom jeziku* (maksimalno 4000 znakova s praznim mjestima)

In the context of global energy challenges and shifting market policies, the analysis of retail electricity prices represents a crucial topic, linking tax policies, market openness, and economic variables across the countries of the European Energy Community (EEC). This study encompasses 39 EEC member states, including the EU-15 (the first 15 European Union member states), the EU-13 (countries that joined the EU after 2004), as well as the Contracting Parties and Observers (CP/OB). Despite market liberalisation aiming to reduce price disparities and enhance competition, significant variations in retail electricity prices persist among EEC member states, influencing the degree of market openness.

This research focuses on modelling the impact of key electricity price components on the level of competition and supplier concentration within the EEC from 2017 to 2023. The primary hypothesis examines the impact of key price components and dynamic convergence of overall retail electricity prices on the degree of market competition and concentration across the EEC. In addition to the primary hypothesis, four auxiliary hypotheses explore various aspects of interrelations between factors to identify and quantify their effects.

The methodological framework incorporates various approaches to analysing the impact of key factors on market openness and price convergence in the EEC. Qualitative Comparative Analysis (QCA) is employed to identify key factors (regulated prices, decarbonisation, and energy mix) influencing market openness, while logical models based on Boolean analysis provide insights into the logical connections between conditions and outcomes. Econometric analysis applies convergence methods (sigma, beta, delta, upward and downward convergence, and dynamic personalised convergence) to assess the alignment of national prices with EEC averages.

Panel models are utilised to test hypotheses concerning the impact of key price components and dynamic personalised convergence on market openness and competition. These variables serve as primary predictors of the dependent variable, defined through the cumulative share of major suppliers and/or the total number of suppliers, with the potential to construct a synthetic index from available indicators. The models also include additional independent variables defined by Boolean logic and control variables that provide a broader economic context. Key predictor variables will be selected from each group of independent and control variables, while the remaining variables will be used to validate the model.

Theoretical objectives of the research include analysing regulatory and institutional factors that influence price convergence and market openness. Applied objectives aim to identify barriers that facilitate or hinder market openness and provide policy recommendations.

The contribution of this research lies in its comprehensive approach to modelling retail electricity prices through the decomposition of their components, alongside a comparison of nominal prices and prices expressed in Purchasing Power Standards (PPS). This approach enables a precise comparison of actual electricity costs across EEC countries, addressing a gap in the literature, which primarily focuses on nominal prices. The introduction of the dynamic convergence variable expands the analytical framework for tracking price changes within national markets, contributing to a deeper understanding of price convergence and divergence processes. Beyond its scientific contribution, the research has practical value by identifying key

factors that influence costs and market structure. This provides the foundation for developing policies that foster market openness, competition, and integration, with the goal of reducing price disparities between developed and less developed EEC member states.

3.3. Uvod i pregled dosadašnjih istraživanja

(preporučeno 7000 znakova s praznim mjestima)

Uvod i analiza izazova energetskog tržišta

Tranzicija europskog energetskog tržišta prema potpunoj liberalizaciji i integraciji ima za cilj stvaranje jedinstvenog tržišta koje potiče konkurenciju i konvergenciju cijena. Međutim, tržište električne energije unutar Europske energetske zajednice (EEZ) suočeno je s izazovima koji proizlaze iz regulatornih razlika, napora u procesu dekarbonizacije i socio-ekonomskih uvjeta. EU-15 zemlje pružaju stabilnije uvjete za konkurenciju, dok EU-13 i CP/OB članice trebaju dodatno ojačati regulaciju i privući investicije. Dekarbonizacija je također naprednija u EU-15 zemljama, dok CP/OB članice trebaju intenzivirati ulaganja u obnovljive izvore energije kako bi potaknule konkurenciju i smanjile cjenovne razlike.

Europski energetski sektor, obilježen dinamičnim tržišnim promjenama i stalnim prilagođavanjem regulatornih okvira, suočava se s brojnim izazovima u integraciji i postizanju jedinstvenog tržišta električne energije. Ključni pojmovi koji se koriste u ovoj analizi su:

- **Konvergencija cijena:** Proces smanjenja razlika u cijenama električne energije među različitim državama članicama kroz harmonizaciju tržišnih uvjeta.
- **Tržišna koncentracija:** Stanje u kojem mali broj velikih sudionika dominira tržištem, ograničavajući konkurenciju.
- **Liberalizacija tržišta:** Proces otvaranja tržišta za nove sudionike i smanjenja državne regulacije kako bi se potaknula konkurencija.

Unatoč implementaciji brojnih reformi, uključujući Treći energetski paket i paket "Čista energija za sve Europljane" iz 2019. godine, proces stvaranja otvorenog i konkurentnog tržišta ostaje nedovršen. Dosadašnja istraživanja jasno ukazuju na značajne razlike među državama u pogledu konvergencije cijena i stupnja konkurencije, osobito između razvijenih zemalja zapadne Europe (EU-15), novih članica iz srednje i istočne Europe (EU-13), te Ugovornih strana Energetske zajednice (EEZ).

Reforme i liberalizacija

Prema izvješćima ACER-a i CEER-a (2023), liberalizacija tržišta električne energije postigla je djelomične uspjehe. Treći energetski paket, koji se fokusira na razdvajanje aktivnosti proizvodnje, prijenosa i distribucije energije, ima za cilj povećati transparentnost i otvorenost tržišta za nove konkurente. Međutim, u zemljama EU-13, tržišna koncentracija ostaje visoka, a broj opskrbljivača relativno malen, što upućuje na ograničenu otvorenost tržišta i nedostatak konkurencije. Primjerice, u Poljskoj i Mađarskoj, tržišna koncentracija je i dalje visoka unatoč reformama, što ukazuje na potrebu za dodatnim mjerama za poticanje konkurencije.

Regulatorni okviri

Regulatorni okviri igraju ključnu ulogu u oblikovanju tržišnih performansi i zaštiti potrošača. U zemljama EEZ, usklađivanje zakonodavnih okvira s europskim pravilima nije uvijek uspješno, s obzirom na suočavanje s administrativnim i političkim izazovima. Razlike u poreznim politikama i regulatornim okvirima doprinose divergenciji cijena električne energije među državama članicama Europske unije. Na primjer, Njemačka i Danska koriste visoke poreze i subvencije za obnovljive izvore energije, što rezultira višim maloprodajnim cijenama unatoč smanjenju veleprodajnih cijena (Bublitz et al., 2017; Mihut & Popp, 2018).

Sažetak ključnih točaka

Na kraju ovog uvoda, ističu se ključni izazovi koje istraživanje nastoji adresirati:

- **Razlike u regulatornim okvirima:** Varijacije u zakonodavstvu i poreznim politikama među državama članicama EEZ-a.
- **Visoka tržišna koncentracija:** Dominacija malog broja opskrbljivača na tržištima EU-13 i CP/OB zemalja.
- **Ovisnost o fosilnim gorivima:** Veća ovisnost o uvozu energije u nekim zemljama EEZ-a.

- **Varijacije u poreznim politikama:** Različiti porezni režimi koji utječu na konačne cijene električne energije.

Ovi izazovi predstavljaju temelj za daljnju analizu tržišne integracije, liberalizacije i regulacije unutar Europske energetske zajednice, s ciljem stvaranja jedinstvenog, konkurentnog i održivog tržišta električne energije.

Teorijski okvir za istraživanje maloprodajnih cijena električne energije

Istraživanje se temelji na nekoliko ključnih teorijskih okvira koji pružaju osnovu za analizu procesa konvergencije cijena i tržišne dinamike. Kroz ove teorije, istražuju se interakcije između različitih ekonomskih, regulatornih i političkih čimbenika te njihov utjecaj na liberalizaciju tržišta i konvergenciju cijena. Sljedeća tablica pruža pregled ključnih teorijskih okvira koji oblikuju analizu procesa konvergencije cijena i otvorenosti tržišta u energetsom sektoru.

Tablica 1: Pregled teorijskih okvira i njihove primjene u istraživanju

Teorija	Autori	Ključni koncept	Primjena u istraživanju
Teorija ekonomske integracije	Balassa (1961), Pelkmans (2016)	Uklanjanje tržišnih barijera radi stvaranja jedinstvenog tržišta i postizanja konvergencije cijena.	Analizira konvergenciju cijena električne energije izraženih u nominalnim eurocentima po kilovatsatu (cent/kWh) i prema paritetu kupovne moći (PPS/kWh) tijekom razdoblja 2017.–2023. u kontekstu liberalizacije tržišta u Europskoj energetskoj zajednici (EEZ), kako bi se ocijenila postignuća jedinstvenog tržišta u konvergenciji cijena, povećanju otvorenosti tržišta i konkurencije, što doprinosi integraciji tržišta.
Teorija konvergencije	Barro & Sala-i-Martin (1992), Erdinç & Yaşar (2020)	Smanjenje razlika u ekonomskim varijablama među zemljama. Sigma (σ) konvergencija mjeri smanjenje varijabilnosti među zemljama, beta (β) konvergencija mjeri brzinu smanjenja razlika, dok uzlazno-silazna konvergencija/divergencija istražuje smjer i dinamiku konvergencije cijena.	Mjeri stupanj konvergencije cijena u zemljama EEZ-a, istražuje usklađivanje cijena kroz liberalizaciju i utjecaj regulatornih promjena na dinamiku cijena, identificirajući u kojoj mjeri razlike među članicama postaju manje izražene s vremenom.
Teorija institucionalne ekonomije i javnog izbora	North (1990), Buchanan (1965), Glachant & Ruester (2014), Hirth (2018)	Institucije i političke odluke oblikuju tržišne ishode kroz regulatorne mjere i politike koje utječu na tržište.	Koristi se kvalitativna komparativna analiza (QCA) kao metodološki okvir za identifikaciju ključnih čimbenika koji utječu na otvorenost tržišta i konvergenciju cijena unutar EEZ-a. Primjenjuju se logički modeli iz Booleove analize kako bi se povezali uvjeti (npr. regulirane cijene, dekarbonizacija, energetski miksi) s ishodima (otvorenost tržišta), omogućavajući razumijevanje logičkih odnosa među varijablama i pružajući preporuke za poticanje konkurencije.
Teorija pariteta kupovne moći	Cassel (1920)	Prilagodba cijena među zemljama prema kupovnoj moći za postizanje tržišne ravnoteže.	Prilagodba cijena prema PPS-u omogućava analizu stvarnog troškovnog opterećenja među članicama EEZ-a, pružajući detaljniji uvid u razlike između nominalnih cijena i onih prilagođenih kupovnoj moći. Time se preciznije ocjenjuju pritisci na kupovnu moć potrošača te otkrivaju slučajevi u kojima nominalno niže cijene, zbog ograničene kupovne moći u

Teorija industrijske organizacije	Bain (1956), Scherer & Ross (1990)	Analiza tržišne strukture, tržišne moći i regulatornih intervencija za poticanje konkurencije i regulaciju cijena.	manje razvijenim zemljama, zapravo usporavaju konkurenciju. Istražuje kako struktura tržišta i regulatorne mjere utječu na otvorenost tržišta u EEZ-u, definiranu konkurencijom i koncentracijom opskrbljivača, te na procese konvergencije cijena. Mjerenje učinaka ključnih komponenti cijena omogućava razumijevanje uvjeta koji potiču ili ograničavaju tržišnu konkurenciju.
Teorija regulacije	Stigler (1971), Laffont & Tirole (1993), Joskow (2007)	Vladine regulacije usmjerene su na konvergenciju cijena i promicanje održivih izvora energije.	Ekonometrijska analiza procjenjuje utjecaj regulatornih mjera na otvorenost tržišta u EEZ-u kroz procese konvergencije cijena i kontrolu troškova. Analiza ispituje u kojoj mjeri regulatorne mjere podržavaju otvorenost tržišta i konkurenciju, fokusirajući se na njihove dugoročne učinke u tržišnom okruženju EEZ-a.

Pregled literature

Dosadašnja istraživanja u području tržišne integracije i dinamike tržišta električne energije u Europi naglašavaju složenost odnosa između tržišne koncentracije, konkurencije, regulatornih reformi i konvergencije cijena. Razumijevanje tržišnih dinamika, uključujući koncentraciju tržišta, formiranje cijena, liberalizaciju i ulogu regulatornih okvira, ključno je za analizu suvremenih trendova u energetsom sektoru. Osobit se naglasak stavlja na konvergenciju, koja igra središnju ulogu u tranziciji prema održivijim energetske sustavima.

Ovaj pregled literature pokriva nekoliko ključnih tematskih područja, uključujući:

- tržišnu koncentraciju i konkurenciju,
- dinamiku tržišta i implikacije na cijene,
- učinke reformi i liberalizacije u energetsom sektoru,
- ulogu regulacije i institucionalnih okvira,
- integraciju obnovljivih izvora energije,
- izazove i buduće perspektive razvoja tržišta.

Pregled je strukturiran kako bi odražavao ova područja, pružajući sveobuhvatan uvid u trenutno stanje istraživanja, dok istovremeno identificira nedostatke koje bi buduća istraživanja mogla ispuniti.

Tablica 2: Ključni nalazi iz literature povezani s područjima istraživanja

Područje istraživanja	Autori	Ključni nalazi
Tržišna konkurencija i koncentracija	Brown et al. (2020); Kirschen et al. (2000); Littlechild (2018, 2019); Jamasb et al. (2005, 2017); Akkemik i Oguz (2011); Ndebele, Marsh & Scarpa (2019); Lucila de Almeida et al. (2022)	Tržišna struktura, regulatorne reforme i ponašanje potrošača ključni su faktori koji oblikuju dinamiku maloprodajnih tržišta električne energije. Povećanje koncentracije tržišta, inercija potrošača i nedostaci u regulatornim okvirima ograničavaju konkurenciju. Međutim, neke reforme su dovele do povećane konkurencije u određenim uvjetima.
Dinamika tržišta i implikacije na cijene	Bublitz, Keles i Fichtner (2017); Mihać i Popp (2018); Liu, Zhang, Chen i Dou (2019); Hartley, Medlock i Jankovska (2019); Lilian, Houllier i Tamvakis (2016); Kopsakangas Savolainen (2004); de Menezes i Houllier (2016); Panos i Densing (2019); Kuik et al. (2022); Schweng (2022); Phillips i Sul (2009); Batalla et al. (2019);	Integracija obnovljivih izvora energije i regulatorne promjene imaju složene učinke na tržišne cijene. Deregulacija može povećati cijene, dok integracija obnovljivih izvora smanjuje veleprodajne cijene, ali maloprodajne cijene rastu zbog subvencija. Konvergencija cijena električne energije među kućanstvima i industrijskim potrošačima u EU razlikuje se zbog regulatornih intervencija i

	Ciferri et al. (2019); Pollitt (2019); Schreck et al. (2020)	nacionalnih politika. Različiti pristupi također oblikuju različite putanje konvergencije u liberaliziranim tržištima.
Učinci reformi i liberalizacije	Erdodgu (2011); Glashant i Ruester (2014); Hattori i Tsutsui (2004); Nagayama (2009); Esplin et al. (2020); Fiorio i Florio (2013); Imura i Cross (2018); Nwaeze (2000); Dormady et al. (2019); Streimikiene et al. (2013); Upadhyaya, Raymond i Mixon (1997); Stagnaro et al. (2020); Meeus (2020); Magnani et al. (2023)	Liberalizacija i reforme ne donose uvijek smanjenje cijena, a u nekim slučajevima dovode do porasta cijena. Učinci reformi variraju među zemljama ovisno o potrošnji energije i specifičnim nacionalnim uvjetima. Liberalizacija tržišta električne energije uz volatilnost cijena, posebno nakon pandemije i energetske krize, oblikuje tržišnu dinamiku.
Uloga regulacije	Varhade et al. (2018); Kaller et al. (2018); Polemis (2016); Tsai i Tsai (2018); ACER/CERR (2023); Moreno, López i García-Alvarez (2012); Poudineh (2019); Pepermans (2018)	Regulacija je ključna za oblikovanje tržišnih performansi i zaštitu potrošača. Snažni institucionalni okviri i transparentni sustavi cijena neophodni su za osiguranje konkurencije i poboljšanje učinkovitosti tržišta električne energije. Nedostaci u regulativnim okvirima mogu dovesti do tržišne koncentracije i ograničenja konkurencije.
Integracija obnovljivih izvora energije	Trujillo-Baute, del Río, i Mir-Artigues (2018); Hirth (2018); Cambini et al. (2016); Pezzutto et al. (2018); Silva i Cerqueira (2017); Breitschopf i Wachsmuth (2017); Nepal et al. (2018); Child et al. (2019); Rokicki i Perkowska (2020); Halkos i Tsiirivis (2023)	Integracija obnovljivih izvora energije doprinosi konkurenciji i inovacijama, no također povećava maloprodajne cijene. Pristupi tržišnoj liberalizaciji i poticanju obnovljivih izvora moraju biti prilagođeni svakoj zemlji zbog različitih uvjeta.
Izazovi i buduće perspektive	Pollitt (2017); Sampson i Longe (2021); ACER/CERR (2021); Tucki et al. (2019); Chomać-Pierzecka, Sobczak i Soboń (2022); Cambini et al. (2016); Siksnelyte-Butkiene et al. (2022); Ambec et al. (2023); Kuik et al. (2022); Schweng (2022)	Budući izazovi uključuju prilagodbu tržišnih struktura, integraciju obnovljivih izvora i dekarbonizaciju. Potrebne su prilagođene politike za poticanje održivih energetskih sustava i stabilnih tržišnih uvjeta, kako ističu Pollitt (2017) i Sampson i Longe (2021). Identificirane prepreke zahtijevaju dodatno istraživanje i prilagodbu politika koje bi uzimale u obzir specifične ekonomske i institucionalne uvjete na nacionalnoj i regionalnoj razini.

Ovaj pregled istraživanja ističe ključne izazove i potencijale europskog energetskog sektora u kontekstu tržišne integracije, konkurencije i regulacije. Liberalizacija i integracija obnovljivih izvora energije mogu pridonijeti integraciji i otvorenosti tržišta, ali zahtijevaju ciljano usmjerene politike kako bi se potaknula konvergencija cijena i tržišna konkurencija u zemljama EEZ-a.

Prepreke poput visoke tržišne koncentracije i raznolikih regulatornih pristupa zahtijevaju daljnja istraživanja i prilagodbu politika koje bi uvažavale specifične ekonomske i institucionalne uvjete pojedinih zemalja članica EEZ-a.

Prepoznavanje nedostataka u prethodnim istraživanjima

Iako brojna istraživanja istražuju utjecaj reformi, regulatornih okvira i integracije obnovljivih izvora energije na tržišnu dinamiku i cijene električne energije, većina njih ne povezuje ključne komponente cijena s analizom utjecaja konvergencije cijena električne energije i njezinih komponenti na tržišnu konkurenciju i koncentraciju. Osim toga, nedostaju istraživanja koja primjenjuju napredne metode analize dinamičke konvergencije kao prediktora u kontekstu stupnja otvorenosti tržišta u zemljama Europske energetske zajednice (EEZ). Istovremeno, ograničen je broj studija koje integriraju kvalitativne i kvantitativne pristupe za razumijevanje složenih uzroka i posljedica regulacije cijena.

Na temelju ovih uvida, buduća istraživanja trebala bi se usmjeriti na identificiranje konkretnih mjera za tranziciju prema održivim energetskim modelima. Pri tome je važno uzeti u obzir međusobnu povezanost tržišnih, regulatornih i političkih čimbenika te razviti rješenja koja potiču konkurentnost energetskih tržišta.

PRIJEDLOG DISPOZICIJE DOKTORSKE DISERTACIJE

1. UVOD

- 1.1. Predmet i problem istraživanja
- 1.2. Ciljevi istraživanja
- 1.3. Hipoteze istraživanja
- 1.4. Metode istraživanja
- 1.5. Očekivani znanstveni doprinos
- 1.6. Obrazloženje sadržaja i strukture doktorske disertacije

2. KONTEKSTUALNI OKVIR EUROPSKOG TRŽIŠTA ELEKTRIČNE ENERGIJE

- 2.1. Zakonodavni okvir, reformski paketi i ciljevi liberalizacije tržišta električne energije
- 2.2. Pregled kretanja i tržišnih trendova u europskom maloprodajnom tržištu električne energije
 - 2.2.1. Otvorenost tržišta električne energije
 - 2.2.2. Sastavnice cijena i struktura

3. PREGLED PRETHODNIH ISTRAŽIVANJA I TEORIJSKI OKVIR

- 3.1. Tržišna konkurencija i koncentracija
- 3.2. Dinamika tržišta i implikacije na cijene
- 3.3. Učinci reformi i liberalizacije
- 3.4. Uloga regulacije
- 3.5. Integracija obnovljivih izvora energije
- 3.6. Izazovi i buduće perspektive
- 3.7. Teorijski okvir; Ključni koncepti i primjena u istraživanju
 - 3.7.1. Teorija ekonomske integracije
 - 3.7.2. Teorija konvergencije
 - 3.7.3. Teorija institucionalne ekonomije i javnog izbora
 - 3.7.4. Teorija pariteta kupovne moći (PPS)
 - 3.7.5. Teorija industrijske organizacije
 - 3.7.6. Teorija regulacije

4. METODOLOGIJA ISTRAŽIVANJA

- 4.1. Istraživački cilj
- 4.2. Pregled metoda korištenih u istraživanju
 - 4.2.1. Kombinacija kvalitativnih i ekonometrijskih metoda
 - 4.2.2. Teorijska osnova kvalitativne i kvantitativne analize
 - 4.2.3. Odabir kombinacije metoda za analizu tržišta energije
 - 4.2.4. Opravdanost metodološkog pristupa integracije QCA, panel modela i analize konvergencije u analizi tržišta električne energije u EEZ-u

5. EMPIRIJSKA ANALIZA UČINKA MALOPRODAJNIH CIJENA ELEKTRIČNE ENERGIJE NA KONVERGENCIJU, OTVORENOST I KONKURENCIJU NA TRŽIŠTIMA ELEKTRIČNE ENERGIJE U ZEMLJAMA EUROPSKE ENERGETSKE ZAJEDNICE

- 5.1. Kvalitativna komparativna analiza (QCA); Primjena u ovom istraživanju
 - 5.1.1. Identifikacija ključnih institucionalnih i regulatornih uvjeta
 - 5.1.2. Kreiranje matrica ocjenjivanja prema ključnim kriterijima
- 5.2. Istraživanje konvergencije
 - 5.2.1. Pregled prethodnih istraživanja konvergencije u energetske sektoru
 - 5.2.2. Obrazloženje metoda konvergencije korištenih u istraživanju
- 5.3. Ekonometrijska analiza panel podataka
 - 5.3.4. Pregled prethodnih istraživanja tržišta električne energije na panel podacima
 - 5.3.5. Prikaz i prilagodba relevantnih ekonometrijskih metoda za analizu učinka komponenti cijena na otvorenost tržišta i konkurenciju
- 5.4. Ekonometrijska analiza konvergencije
 - 5.4.1. Definiranje dinamička (personalizirana) konvergencija
 - 5.4.2. Analiza sigma (σ) konvergencije
 - 5.4.3. Analiza beta (β) konvergencije
 - 5.4.4. Analiza delta (δ) konvergencije
 - 5.4.5. Analiza i modeliranje uzlazne i silazne konvergencije/divergencije
- 5.5. Opis uzorka i podataka

5.5.1. Definicija uzorka i izvori podataka

5.5.2. Prikupljanje kvalitativnih i kvantitativnih podataka iz izvješća regulatora od 2017.–2023.

5.5.3. Definiranje i deskriptivna statistika varijabli

5.6. Formulacija modela

5.6.1. Dikotomizacija odabranih uvjeta

5.6.2. Izrada istinitosne tablice

5.6.3. Booleov logički model s odabranim ishodom

5.6.4. Panel modeli; Modeliranje učinka komponenti cijena, dinamičke (personalizirane) konvergencije i odabranih varijabli na tržišnu konkurenciju i koncentraciju

5.6.5. Ograničenja modela

6. PRIKAZ I INTERPRETACIJA REZULTATA ISTRAŽIVANJA

6.1. Odabrani ključni kriteriji QCA analize

6.2. Primijenjene analize konvergencije maloprodajnih cijena električne energije

6.3. Ishod Booleovog logičkog modela

6.3. Rezultati panel modela analize učinka komponenti cijena, dinamičke (personalizirane) konvergencije i odabranih varijabli na tržišnu konkurenciju i koncentraciju

7. ZAKLJUČNA RAZMATRANJA

7.1. Diskusija o nalazima

7.2. Utjecaj regulatornih i fiskalnih politika na tržišne dinamike

7.3. Zaključak

7.4. Implikacije istraživanja na politiku regulacije cijena

7.5. Očekivani znanstveni doprinos

7.6. Ograničenja istraživanja i prijedlozi za buduća istraživanja

3.4. Cilj i hipoteze istraživanja (preporučeno 700 znakova s praznim mjestima)

Problem istraživanja

Maloprodajno tržište električne energije u EEZ-u suočeno je sa značajnim razlikama u cijenama među državama članicama, koje postaju još izraženije kada se nominalne cijene u eurima usporede s cijenama izraženima u standardima kupovne moći (PPS-u). Naime, zemlje EU-15, iako nominalno imaju više cijene, u cijenama izraženima u PPS-u pokazuju povoljniji položaj, dok manje razvijene zemlje, unatoč nižim nominalnim cijenama, bilježe veće stvarne cijene električne energije kada se izraze u PPS-u. Ove razlike među zemljama, izražene kroz njihove komponente, otežavaju postizanje konvergencije cijena unutar EEZ-a. Posljedično, one izravno utječu na tržišnu koncentraciju, konkurenciju i stupanj otvorenosti tržišta, stvarajući izazove za integraciju i liberalizaciju tržišta električne energije.

Nominalne cijene električne energije među zemljama EEZ-a često ne konvergiraju, čak ni uz liberalizirano tržište. Ovu divergenciju uzrokuju brojni faktori, uključujući poreze, inflaciju, lokalne valute i troškove distribucije, koji stvaraju različite tržišne uvjete među zemljama i otežavaju potpunu deregulaciju cijena. Iako cijene izražene u PPS-u pokazuju veću sličnost među državama, nominalne cijene i dalje predstavljaju ključnu prepreku tržišnoj integraciji i liberalizaciji. Ovaj izazov posebno pogađa zemlje s nižom kupovnom moći koje podnose relativno veći teret cijena.

Razlike između nominalnih cijena električne energije i cijena prilagođenih standardima kupovne moći (PPS) predstavljaju značajnu prepreku tržišnoj integraciji. Zemlje EU-15, zahvaljujući višoj kupovnoj moći i manjim relativnim razlikama u cijenama izraženima u PPS-u, pokazuju veću uspješnost u procesima postupne deregulacije cijena i tržišne liberalizacije. Nasuprot tome, manje razvijene zemlje, s nižom kupovnom moći i većim relativnim opterećenjem cijena u PPS-u, suočene su s izazovima poput povećane osjetljivosti tržišta na promjene cijena i sporije prilagodbe regulatornim reformama.

Izvještaji Europske komisije navode kako su razlike u porezima, naknadama i energetske politikama među članicama glavni izvori razlika u maloprodajnim cijenama. Iako je tržišna liberalizacija omogućila određeni stupanj konkurencije, postojeće razlike u fiskalnim politikama i regulacijama i dalje ometaju integraciju tržišta. Stoga će se ovo istraživanje fokusirati na analizu ključnih komponenti cijena koje pridonose divergenciji cijena među članicama EEZ-a te istražiti prepreke tržišnoj liberalizaciji.

Predmet istraživanja

Predmet istraživanja su dinamička konvergencija maloprodajnih cijena električne energije i ključne komponente cijena – troškovi energije, mrežni troškovi, porezi i naknade – oblikovane različitim fiskalnim politikama, te njihov utjecaj na tržišnu konkurenciju i koncentraciju u EEZ-u.

Objekti istraživanja

- **Kvalitativni čimbenici:** regulatorne politike, institucionalni kapaciteti, socio-ekonomski uvjeti i energetske standardi među EU-15, EU-13 i CP/OB zemljama.
- **Dinamika konvergencije cijena:** analizirana kroz metode sigma, beta, delta i uzlazno-silazne konvergencije.
- **Nominalne cijene električne energije:** za kućanstva i ne-kućanstva, izražene u eurima po kWh.
- **Cijene izražene u PPS-u:** pokazatelj kupovne moći potrošača u različitim članicama EEZ-a.
- **Komponente maloprodajnih cijena:** uključuju troškove energije, mrežne troškove, ostale poreze i naknade.
- **Tržišna konkurencija i koncentracija:** mjerena brojem opskrbljivača i njihovim tržišnim udjelima.

Svrha istraživanja

Svrha ovog istraživanja je teorijski i empirijski utvrditi stupanj konvergencije maloprodajnih cijena električne energije i njihovih ključnih komponenti (izraženih u eurima i PPS-u) te modelirati njihov utjecaj na tržišnu konkurenciju i koncentraciju u zemljama Europske energetske zajednice. Istraživanje nastoji utvrditi kako razlike u cijenama i njihovim komponentama otežavaju tržišnu liberalizaciju i oblikuju tržišne dinamike, s ciljem pružanja preporuka za unaprijeđenje tržišne integracije i liberalizacije.

Ciljevi i hipoteze istraživanja

Radna hipoteza:

Dinamička konvergencija ukupnih maloprodajnih cijena električne energije i ključne komponente cijena imaju signifikantan učinak na tržišnu konkurenciju i koncentraciju u zemljama Europske energetske zajednice.

Glavni cilj istraživanja:

Glavni cilj istraživanja je utvrditi značaj i kvantificirati učinak dinamičke konvergencije ukupnih maloprodajnih cijena električne energije i njihovih ključnih komponenti (troškova energije, mrežnih troškova, PDV-a i ostalih naknada) na tržišnu konkurenciju i koncentraciju u zemljama Europske energetske zajednice.

Rezultati istraživanja omogućit će:

1. Identifikaciju ključnih čimbenika koji oblikuju dinamiku cijena i procese tržišne integracije te doprinose konkurenciji i koncentraciji na tržištima električne energije.
2. Pružanje uvida u integracijske i liberalizacijske procese energetskog tržišta s ciljem jačanja tržišne konkurentnosti.

Specifični ciljevi istraživanja i pomoćne hipoteze:

1. Modelirati učinak komponenti maloprodajnih cijena električne energije (mrežnih troškova, troškova energije, poreza i naknada) i dinamičke (personalizirane) konvergencije na tržišnu konkurenciju i koncentraciju na maloprodajnom tržištu električne energije. Modeliranje u ovom kontekstu obuhvaća primjenu ekonometrijskih i kvalitativnih metoda za kvantifikaciju i testiranje odnosa između ključnih čimbenika i tržišnih ishoda.
 - **PH1:** Komponente cijena (mrežni troškovi, trošak energije, porezi, naknade) i dinamička (personalizirana) konvergencija imaju signifikantan učinak na tržišnu konkurenciju i koncentraciju.
2. Usporediti nominalne cijene električne energije s cijenama izraženim prema paritetu kupovne moći (PPS) kako bi se prikazali i bolje razumijeli stvarni troškovi električne energije u različitim socio-ekonomskim kontekstima.
 - **PH2:** Cijene prilagođene paritetu kupovne moći (*Purchasing Power Standard, PPS*) doprinose boljem razumijevanju stvarnih troškova električne energije u zemljama EEZ-a.
3. Istražiti stupanj i dinamiku konvergencije cijena električne energije među zemljama EEZ-a primjenom metoda sigma, beta, delta i uzlazno-silazne konvergencije, kako bi se ocijenio utjecaj liberalizacije tržišta na stupanj konvergencije i varijabilnost cijena.
 - **PH3:** Liberalizacija tržišta nije dovela do potpune konvergencije cijena niti do značajnijeg smanjenja varijabilnosti cijena među zemljama EEZ-a.
4. Identificirati ključne institucionalne, regulatorne i socio-ekonomske uvjete koji utječu na otvorenost tržišta i regulaciju cijena u EEZ-u korištenjem QCA metode, te ih integrirati u ekonometrijsku panel analizu kako bi se kvantificirao njihov učinak na stupanj otvorenosti tržišta u zemljama EEZ-a.
 - **PH4:** Regulacija cijena, dekarbonizacija, energetsko siromaštvo, diverzifikacija energetskog miksa i kvaliteta regulatornog okvira ključni su čimbenici koji utječu na stupanj otvorenost tržišta u zemljama EEZ-a.

Postavljanje hipoteza o učinku komponenti cijena, dinamičke konvergencije, cijena prilagođenih paritetu kupovne moći (PPS) te institucionalnih i regulatornih uvjeta na tržišnu koncentraciju, otvorenost tržišta i konkurenciju proizlazi iz opažanja da porezne politike, regulatorni okviri i socio-ekonomski čimbenici značajno utječu na tržišnu dinamiku u zemljama EEZ-a.

Za sveobuhvatnu analizu tržišta električne energije unutar EEZ-a definirani su teorijski i aplikativni ciljevi. Teorijski ciljevi usmjereni su na analizu institucionalnih i regulatornih faktora koji oblikuju tržišnu stabilnost i otvorenost, dok aplikativni ciljevi teže praktičnim preporukama za jačanje konkurencije i smanjenje razlika u cijenama. Slijedi tablica s definiranim ciljevima istraživanja.

Tablica 3: Teorijski i aplikativni ciljevi istraživanja

Teorijski ciljevi	Aplikativni ciljevi
Modeliranje učinka dinamičke personalizirane konvergencije i komponenti maloprodajnih cijena električne energije (mrežni troškovi, troškovi energije, porezi, naknade) na tržišnu konkurenciju i koncentraciju u zemljama EEZ-a. Cilj je kvantificirati utjecaj konvergencije i komponenti cijena koristeći metode za mjerenje konvergencije, temeljem teorija industrijske organizacije i tržišne učinkovitosti.	Smanjenje barijera ulasku novih opskrbljivača kroz smanjenje udjela reguliranih komponenti i povećanje transparentnosti cijena. Cilj je omogućiti fleksibilnost cijena koja potiče otvorenost tržišta i konkurenciju, smanjujući rigidnost cijena i stvarajući uvjete za razvoj konkurencije na tržištu električne energije u EEZ-u.
Istraživanje utjecaja nominalnih cijena i cijena izraženih u PPS-u na analizu stvarnih troškova električne energije u zemljama EEZ-a. Cilj je utvrditi kako cijene izražene u PPS-u omogućavaju preciznije razumijevanje troškovnih razlika među zemljama EEZ-a, temeljem teorije pariteta kupovne moći i teorije konvergencije.	Poboljšanje pristupa tržišnim cijenama putem fiskalnih politika usmjerenih na smanjenje razlika u nominalnim cijenama i poticanje ulaganja u obnovljive izvore energije kroz ciljane subvencije. Cilj je olakšati energetske prijelaz u manje razvijenim zemljama EEZ-a, smanjujući ovisnost o fosilnim gorivima te potaknuti tržišno usklađeni sustav cijena koji doprinosi konkurenciji.
Analiza konvergencije cijena električne energije među zemljama EEZ-a. Cilj je primijeniti metode sigma, beta, delta, uzlazno-silazne te dinamičke (personalizirane) konvergencije kako bi se ocijenili smjer, brzina, intenzitet i dinamika konvergencije cijena među zemljama. Analizirat će se i uspješnost tržišne liberalizacije u smanjenju varijabilnosti cijena, temeljem teorije ekonomske integracije i teorije konvergencije.	Razvoj infrastrukture i fiskalnih olakšica za poticanje konvergencije cijena. Cilj je dugoročno podržati razvoj zajedničke infrastrukture za obnovljive izvore energije i smanjenje regulatornih barijera kako bi se olakšao ulazak novih opskrbljivača i podržala otvorenost tržišta.
Kvalitativna analiza ključnih regulatornih i institucionalnih čimbenika (korištenjem QCA metode) kako bi se identificirali uvjeti koji doprinose otvorenosti tržišta i konvergenciji cijena. Cilj je ispitati utjecaj regulatornog okvira, politike dekarbonizacije, diverzifikacije energetskog miksa i mjera protiv energetskog siromaštva na tržišnu dinamiku u EEZ-u, prema teoriji institucionalne ekonomije i javnog izbora.	Identifikacija uvjeta koji podržavaju konkurenciju. Cilj je prilagoditi regulatorne pristupe kako bi odgovarali nacionalnim uvjetima, uz promicanje standardiziranih smjernica za liberalizaciju i diverzifikaciju izvora energije, čime se podržava dugoročna otvorenost tržišta i ujednačenost cijena u EEZ-u.

Tablica u nastavku prikazuje istraživačka pitanja, zaključke i preporučena rješenja za svaku pomoćnu hipotezu definiranu ciljevima istraživanja. Pitanja su usmjerena na razumijevanje strukture maloprodajnih cijena, institucionalnih uvjeta i fiskalnih politika koji oblikuju cijene i posljedično otvorenost tržišta i konkurenciju u zemljama EEZ-a.

Tablica 4.: Istraživačka pitanja, zaključci i rješenja

Istraživačka pitanja	Zaključci	Rješenja
Kako ključne komponente maloprodajnih cijena električne energije, kao što su troškovi energije, mreže, porezi, naknade i dinamička personalizirana konvergencija, utječu na tržišnu konkurenciju i koncentraciju?	Visoki udio reguliranih komponenti maloprodajnih cijena stvara rigidnost u cijenama i predstavlja prepreku za nove ulaske na tržište, smanjujući time stupanj otvorenosti tržišta i konkurenciju.	Smanjiti udio reguliranih komponenti gdje je to izvedivo te povećati transparentnost u strukturi cijena kako bi se smanjila rigidnost i omogućujući lakši ulazak novih opskrbljivača i jačanje konkurencije.
Kako nominalne cijene i cijene izražene u PPS-u odražavaju razlike u troškovima električne energije među zemljama EEZ-a i kako fiskalni i regulatorni pristupi utječu na tržišnu konkurenciju i koncentraciju?	Nominalne cijene i cijene izražene u PPS-u imaju značajan učinak na analizu tržišnih troškova. Nominalne cijene pokazuju više vrijednosti u razvijenim zemljama, dok cijene izražene u PPS-u bolje odražavaju relativne troškovne razlike među manje razvijenim zemljama. Fiskalni i regulatorni pristupi dodatno utječu na tržišnu konkurenciju i koncentraciju i posljedično ograničavaju integraciju tržišta.	Divergenciju nominalnih cijena smanjiti usmjeravanjem fiskalnih politika prema smanjenju razlika kroz poticanje obnovljivih izvora i ubranu tranziciju. Ciljanim subvencijama i pojednostavljenjem administrativnih postupaka smanjiti energetske ovisnost i potaknuti konkurenciju na tržištu.
Postoji li konvergencija cijena među zemljama EEZ-a i kako	Nominalne cijene i cijene prilagođene standardima kupovne moći (PPS)	Poduprijeti konvergenciju cijena kroz razvoj zajedničke infrastrukture za

cijene izražene u PPS-u utječu na tu konvergenciju?	omogućavaju bolje razumijevanje stvarnih troškova na maloprodajnom tržištu električne energije. Dok nominalne cijene ukazuju na više razine u razvijenim zemljama, cijene prilagođene PPS-u bolje reflektiraju relativne razlike u troškovima među manje razvijenim zemljama. Različiti fiskalni i regulatorni pristupi dodatno pridonose razlikama u cijenama, istovremeno otežavajući njihovu konvergenciju.	obnovljive izvore energije i smanjenje ovisnosti o fosilnim gorivima putem ciljane energetske tranzicije. Smanjiti administrativne prepreke i poticati konkurenciju kroz fleksibilan regulatorni okvir i ulaganje u infrastrukturu.
Koji su ključni institucionalni, regulatorni i socio-ekonomski uvjeti koji utječu na otvorenost tržišta i regulaciju cijena unutar EEZ-a?	Razlike u institucionalnim kapacitetima, regulatornim okvirima i socio-ekonomskim uvjetima među zemljama EEZ-a otežavaju jedinstveni pristup liberalizaciji i konvergenciji tržišta. Čimbenici kao što su regulacija cijena, dekarbonizacija, energetska neovisnost i kvaliteta regulatornih institucija značajno utječu na otvorenost tržišta i konkurenciju.	Prilagoditi regulatorne pristupe nacionalnim uvjetima i poticati diverzifikaciju izvora energije. Razviti smjernice koje uključuju politike liberalizacije, socio-ekonomski kontekst i regulatorni okvir kako bi se prepoznali uvjeti koji podržavaju otvorenost tržišta i konkurenciju u zemljama EEZ-a.

Istraživačka pitanja, zaključci i preporuke u ovoj tablici pružaju ključne uvide u institucionalne i regulatorne uvjete te tržišne razlike u zemljama EEZ-a, usmjerene prema jačanju otvorenosti maloprodajnog tržišta, konkurencije i konvergencije cijena.

Sljedeći dio rada predlaže metodološki okvir koji obuhvaća kvalitativne i kvantitativne metode. Kroz kombinaciju ovih pristupa istraživanje će nastojati odgovoriti na definirane ciljeve, istraživačka pitanja i postavljene hipoteze, pružajući sveobuhvatan uvid u tržišnu dinamiku unutar EEZ-a.

3.5. Materijal, metodologija i plan istraživanja (preporučeno 6500 znakova s praznim mjestima)

1. Metodološki okvir

• Istraživački cilj

- Cilj istraživanja je testirati učinak dinamičke konvergencije i komponenti maloprodajnih cijena električne energije (troškova energije, mrežnih troškova, poreza i naknada) na tržišnu koncentraciju i konkurenciju u 39 zemalja Europske energetske zajednice (EEZ) tijekom razdoblja 2017. – 2023. Istraživanje kombinira kvalitativne i ekonometrijske metode kako bi se omogućila sveobuhvatna analiza utjecaja cijena izraženih u eurima i standardima kupovne moći (PPS) na dinamiku tržišta, s posebnim fokusom na procese konvergencije.

• Kombinacija kvalitativnih i ekonometrijskih metoda

- **Kvalitativna komparativna analiza (QCA)** koristi skupovnu logiku i Booleovu algebru za analizu složenih društvenih fenomena (Ragin, 1987; Schneider & Wagemann, 2012). Ova metoda omogućava identifikaciju specifičnih kombinacija uvjeta koji dovode do određenih ishoda, što je čini posebno korisnom za istraživanje utjecaja regulatornih politika, dekarbonizacije i tržišnih reformi u energetsom sektoru.
- **Ekonometrijska analiza** primjenjuje višestruku regresiju na panel podacima kroz statičke i dinamičke modele. Statički panel modeli procjenjuju osnovne utjecaje, dok dinamički panel modeli, koristeći GMM metodu, analiziraju vremenske i uzročne odnose među ključnim varijablama, uključujući dinamičku (personaliziranu) konvergenciju koja prati prilagodbu nacionalnih cijena prema prosjeku EEZ-a.
- **Analiza konvergencije** Za procjenu dinamike konvergencije cijena električne energije među zemljama Europske energetske zajednice (EEZ), koristi se nekoliko mjera konvergencije: dinamička (personalizirana) konvergencija, sigma (σ) konvergencija, beta (β) konvergencija, delta (δ) konvergencija te uzlazna i silazna konvergencija/divergencija. Svaka od ovih mjera pruža komplementarne uvide u širinu, smjer, brzinu i intenzitet procesa približavanja ili udaljavanja cijena u odnosu na prosječne ili referentne vrijednosti.

2. Definiranje varijabli

Tablica 5 prikazuje pregled odabranih i definiranih varijabli koje se koriste za kvantitativnu analizu u panel modelima, kategoriziranih prema zavisnim, nezavisnim, regulatornim, okolišnim, energetske, kontrolnim i pomoćnim varijablama. Ove varijable osmišljene su kako bi omogućile preciznu analizu utjecaja različitih čimbenika na stupanj otvorenosti i konkurentnost na maloprodajnom tržištu električne energije u Europskoj energetskoj zajednici (EEZ).

Tablica 5: Varijable za kvantitativnu analizu u panel podacima

Oznaka	Opis	Modelira
Zavisne varijable		
CMS_MAIN5	Kumulativni tržišni udio glavnih opskrbljivača (s udjelom barem 5% ukupne potrošnje električne energije)	Mjeri tržišnu koncentraciju i otvorenost maloprodajnog tržišta električne energije.
MS_LARGEST	Tržišni udio najvećeg opskrbljivača na tržištu električne energije (%)	Mjeri udio tržišta koji drži najveći opskrbljivač.
TOTAL_RET	Ukupan broj opskrbljivača koji opskrbljuju krajnje potrošače	Broj opskrbljivača koji djeluju na tržištu krajnje opskrbe.
NUM_MAIN5	Broj glavnih opskrbljivača (s udjelom $\geq 5\%$ ukupne potrošnje električne energije)	Broj glavnih opskrbljivača koji drže značajan tržišni udio.
Primarne prediktorske varijable		
FIN_ELEC	Cijena električne energije za kućanstva i ne-kućanstva, uključujući sve poreze i naknade (u EUR i PPS po kWh)	Pokazuje ukupnu cijenu energije uz sve poreze i naknade.
EN_ELEC	Troškovi energije i opskrbe za kućanstva i ne-kućanstva (u EUR i PPS po kWh)	Prati komponente cijena povezane s energijom i opskrbom.
NET_ELEC	Troškovi mreže za kućanstva i ne-kućanstva (u EUR i PPS po kWh)	Prikazuje troškove mrežne infrastrukture unutar cijene energije.
VAT_ELEC	Porez na dodanu vrijednost (PDV) na električnu energiju za kućanstva i ne-kućanstva (u EUR i PPS po kWh)	Dio cijene povezan s PDV-om na električnu energiju (ispitat će se multikolinearnost sa sličnim varijablama).
CAPT_ELEC	Kapacitetni porezi na električnu energiju za kućanstva i ne-kućanstva (u EUR i PPS po kWh)	Dodatni porezi na kapacitet vezani uz električnu energiju.
OTH_ELEC	Ostali porezi, naknade i troškovi za kućanstva i ne-kućanstva (u EUR i PPS po kWh)	Svi ostali dodatni porezi i naknade unutar cijene energije.
CONV_DP	Dinamička konvergencija (godišnja promjena u logaritamskom omjeru između specifične nacionalne cijene i prosjeka cijena EEZ)	Prikazuje postaje li cijena električne energije u zemlji skuplja ili jeftinija u odnosu na prosjek EEZ-a.
Regulacija cijena (A)		
REG_PRICE	Indikator regulacije cijena (1 = da, 0 = ne)	Pokazuje postojanje regulacije cijena na tržištu.
Dekarbonizacija (B)		
SHR_RES	Udio obnovljivih izvora energije u ukupnoj potrošnji električne energije	Indikator ciljeva održivog razvoja EU (SDG).
ENV_ELEC	Ekološki porezi na električnu energiju za kućanstva i ne-kućanstva (u EUR i PPS po kWh)	Prikazuje dodatne ekološke poreze unutar cijene energije.
RET_ELEC	Porezi za obnovljive izvore energije za kućanstva i ne-kućanstva (u EUR i PPS po kWh)	Prikazuje poreze usmjerene na obnovljive izvore energije.
GHG_EMIS	Emisije stakleničkih plinova u sektoru električne energije, plina, pare i klimatizacije	Indikator ciljeva održivog razvoja EU (SDG).
Energetsko siromaštvo (C)		
EN_POW	Postotak populacije koja nije u mogućnosti adekvatno zagrijati dom zbog siromaštva	Indikator energetske siromaštva u skladu s ciljevima održivog razvoja EU (SDG).
Diverzifikacija energetske miksa (D)		

DVI_ES	Indeks diverzifikacije izvora energije	Indikator ciljeva održivog razvoja EU (SDG).
DVI_FEC	Indeks diverzifikacije konačne potrošnje energije po sektorima	Indikator ciljeva održivog razvoja EU (SDG).
Regulatorni okvir (E)		
RISE_SC_ENEFF	RISE indeks energetske učinkovitosti	Pokazuje regulatorne indikatore za energetske učinkovitost.
RISE_SC_RES	RISE indeks obnovljivih izvora	Pokazuje regulatorne indikatore za obnovljive izvore energije.
RQ_EST	Procjena kvalitete regulatornog okvira (RQ_EST)	Prikazuje kvalitetu regulatornog okvira.
CPI	Indeks percepcije korupcije	Indikator ciljeva održivog razvoja EU (SDG).
Kontrolne varijable		
EN_INT_PPS	Energetska intenzivnost BDP-a u PPS	Mjeri koliko energije koristi gospodarstvo po jedinici BDP-a.
EN_PROD	Energetska produktivnost u EUR i u PPS	Omjer između BDP-a i potrošnje energije.
EN EFFIC	Energetska učinkovitost	Mjeri učinkovitost korištenja energije.
R_GDP_PC	Realni BDP po stanovniku u EUR i u PPS	Indikator ciljeva održivog razvoja EU (SDG).
GDP_PC	BDP po stanovniku u EUR i u PPS (u tržišnim cijenama)	Indikator ciljeva održivog razvoja EU (SDG).
SWITCH_RATE	Stopa promjene pružatelja usluga na tržištu električne energije	Mjeri spremnost potrošača na promjenu opskrbljivača.
Pomoćne varijable		
HS_NET	Pokrivenost širokopojsnim internetom po vrsti područja	Indikator ciljeva održivog razvoja EU (SDG).
I_NET_USE	Učestalost korištenja interneta (dnevno)	Indikator ciljeva održivog razvoja EU (SDG).

Napomena: Od svake skupine ostalih nezavisnih i kontrolnih varijabli koristit će se ključna prediktorska varijabla, dok će se ostale varijable koristiti za testiranje modela. Predlaže se formiranje sintetičkog indeksa iz dostupnih zavisnih varijabli za detaljnu analizu tržišne konkurencije i koncentracije.

3. Formiranje sintetičkih indeksa koncentracije i konkurencije kao zavisne varijable

Na temelju raspoloživih podataka, predlaže se oblikovanje sintetičkih indeksa koncentracije i konkurencije radi precizne analize otvorenosti tržišta električne energije. Ovi indeksi definiraju se kao zavisne varijable koje omogućavaju kvantitativnu procjenu

Indeks koncentracije

Indeks koncentracije osmišljen je kako bi reflektirao dominaciju glavnih tržišnih aktera i njihovu tržišnu moć. Kombinacija pokazatelja kumulativnog tržišnog udjela glavnih opskrbljivača (*CMS_MAIN5*), tržišnog udjela najvećeg opskrbljivača (*MS_LARGEST*) te broja glavnih opskrbljivača (*NUM_MAIN5*) omogućuje preciznu procjenu dominantnosti ključnih tržišnih subjekata. Ova kombinacija omogućuje:

- **Kumulativni utjecaj glavnih opskrbljivača** (*CMS_MAIN5*), što odražava strukturu i distribuciju tržišne moći.
- **Tržišnu dominaciju najvećeg opskrbljivača** (*MS_LARGEST*), važnu za razumijevanje monopolističkih ili oligopolističkih učinaka na tržišnu dinamiku.
- **Širinu konkurencije među glavnim opskrbljivačima** (*NUM_MAIN5*), čime se procjenjuje konkurentski pritisak među vodećim tržišnim igračima.

Formula za indeks koncentracije

$$\text{Indeks koncentracije} = 0,4 \times \frac{CMS_MAIN5}{NUM_MAIN5} + 0,6 \times MS_LARGEST \quad (1)$$

Objašnjenje: Ova formula kombinira prosječni tržišni udio glavnih opskrbljivača po trgovcu $\frac{CMS_MAIN5}{NUM_MAIN5}$ i tržišni udio najvećeg opskrbljivača ($MS_LARGEST$), što omogućava precizno mjerenje koncentracije i naglašava prisutnost dominantnog aktera na tržištu.

Ponderi u formuli sintetičkog indeksa koncentracije odabrani su kao $w_1=0,4$ za prosječni tržišni udio glavnih opskrbljivača i $w_2=0,6$ za tržišni udio najvećeg opskrbljivača. Takav izbor pondera osigurava fleksibilnost i konzistentnost u analizi tržišne strukture i omogućava istovremeno mjerenje širine dominacije i moći ključnog aktera. Ovakva metodologija prilagođava se specifičnim karakteristikama sektora poput tržišta električne energije i odgovara teorijskim osnovama poput HHI , CR_n i GRS indeksa (Ukav, 2017; Ginevičius i Čirba, 2009; Peleckis, 2022). Osim toga, provedena je analiza osjetljivosti kako bi se utvrdila robusnost dodijeljenih pondera, čime se osigurava konzistentnost i stabilnost rezultata u različitim tržišnim uvjetima. Metodologija je utemeljena na regulatornim izvješćima i empirijskim istraživanjima čime se prilagođava specifičnostima tržišta električne energije i omogućava sveobuhvatno mjerenje koncentracije i konkurencije.

Analitički i teorijski kontekst izbora pondera u formuliranju ondeksa koncentracije

Analiza tržišne koncentracije ističe ključnu ulogu pondera u kvantificiranju tržišne dinamike, posebno u uvjetima kompleksnih distribucijskih obrazaca i specifičnih tržišnih karakteristika. Ponderi se koriste kao osnovni alat za prilagodbu metoda mjerenja koncentracije različitim tržišnim strukturama, osiguravajući da rezultati odražavaju stvarne uvjete tržišta. Na primjer, Herfindahl-Hirschmanov indeks (HHI) kvadrira tržišne udjele, čime implicitno daje veći značaj dominantnim sudionicima, dok metoda koncentracijskih omjera (CR_n) pruža kumulativni uvid u udjele vodećih firmi. Obje metode, međutim, pokazuju ograničenja u detektiranju promjena u distribuciji udjela, posebno među manjim sudionicima. Kao odgovor, naprednije tehnike, poput Maurel-Sédillot i GRS indeksa, uvode prilagodljive konstante kako bi osigurale osjetljivost na različite distribucije i tržišne uvjete, balansirajući utjecaj velikih i malih tržišnih sudionika (Ginevičius i Čirba, 2009; Maasoumi i Slottje, 2003). Pravila ponderiranja dodatno se usklađuju s karakteristikama tržišta kako bi reflektirala specifične ciljeve analize i ograničila maksimalne udjele dominantnih aktera, čime smanjuju koncentraciju i potiču diverzifikaciju, dok raznoliko ponderiranje interpolira između jednakih i kapitalizacijskih pondera kako bi omogućilo fleksibilniju analizu. Simulacije pokazuju da takvi pristupi značajno povećavaju širinu indeksa (Goldberg et al., 2023).

Indeks konkurencije

Indeks konkurencije usmjeren je na broj i aktivnost manjih tržišnih aktera izvan kruga glavnih opskrbljivača, omogućavajući procjenu potencijalnog prostora za konkurenciju. Za izračun se koriste:

- **Ukupan broj opskrbljivača** ($TOTAL_RET$), koji pruža uvid u širinu tržišta i prilike za nove ulaske.
- **Preostali (rezidualni) tržišni udio** ($1 - CMS_MAIN5$), koji predstavlja prostor izvan kontrole glavnih opskrbljivača i djelovanje manjih sudionika.

Formula za indeks konkurencije

$$\text{Indeks konkurencije} = \frac{TOTAL_RET - NUM_MAIN5}{1 - CMS_MAIN5} \quad (2)$$

Objašnjenje: Ova formula mjeri broj manjih opskrbljivača ($TOTAL_RET - NUM_MAIN5$) u odnosu na preostali (rezidualni) tržišni prostor ($1 - CMS_MAIN5$). Jasna definicija omogućava razumijevanje doprinosa manjeg broja opskrbljivača u preostalom tržišnom prostoru, čime se izbjegava dvosmislenost u tumačenju.

Interpretacija: Indeks konkurencije daje informacije o potencijalnom prostoru za nove ulaske i aktivnosti manjih aktera, ključnom za procjenu stupnja otvorenosti tržišta. Viša vrijednost sugerira veći broj konkurenata i veći preostali prostor na tržištu, što ukazuje na viši stupanj otvorenosti tržišta.

Prednosti i primjena u panel analizi

- **Sveobuhvatna procjena tržišne dinamike:** Indeksi koncentracije i konkurencije omogućavaju precizno kvantificiranje ključnih elemenata tržišne strukture, a panel analiza omogućava promatranje tih elemenata kroz vrijeme i među različitim tržištima. Ovim pristupom dobiva se dinamički prikaz promjena u koncentraciji i konkurenciji, bitnih za razumijevanje tržišnih trendova.
- **Kontrola za specifične učinke:** Panel analiza omogućava kontrolu specifičnih tržišnih karakteristika koje mogu utjecati na koncentraciju i konkurenciju, poput regulatornih promjena ili ekonomskih uvjeta. Time se bolje uočavaju uzroci i posljedice učinaka na indekse, što pridonosi točnosti rezultata.
- **Integracija s nezavisnim varijablama:** Korištenje indeksa u panel modelu omogućava ispitivanje kako određene nezavisne varijable utječu na tržišnu koncentraciju i konkurenciju. To doprinosi bogatijem razumijevanju tržišne dinamike i identifikaciji ključnih faktora koji pridonose održivoj konkurenciji.
- **Konzistentnost s teorijskim okvirom:** Pristup je usklađen s ekonomskom teorijom o tržišnoj koncentraciji i konkurenciji, što je važno za analizu tržišta električne energije gdje su promjene u regulaciji i strukturi cijena definirane kao ključni čimbenici utjecaja.

Predloženi sintetički indeksi kao zavisne varijable, precizno kvantificiraju razine koncentracije i konkurencije, čime se olakšava procjena utjecaja komponenti cijena na otvorenost tržišta i omogućava jasnije razumijevanje odnosa između tržišnih struktura i cijena električne energije, čineći rezultate primjenjivima za regulatore i strateške odluke.

4. Odabrani uvjeti (varijable) za Booleov logički model

Tablica 6 pruža pregled odabranih uvjeta (varijabli) i njihovih definicija koji se koriste u sklopu Booleovog logičkog modela. U okviru analize, otvorenost tržišta (*O*) definirana je kao zavisni ishod koji mjeri razinu liberalizacije energetskeg tržišta u promatranim zemljama. Pretpostavlja se da odabrani uvjeti doprinose otvorenosti tržišta te čine osnovu za daljnju analizu njihovih međusobnih odnosa i utjecaja.

Tablica 6: Odabrani uvjeti (varijable) za Booleov logički model

Oznaka	Uvjet	Definicija	Izvor
O	Otvorenost tržišta	Zavisni ishod koji odražava stupanj liberalizacije energetskeg tržišta u pojedinoj zemlji.	-
A	Regulacija cijena	Prisutnost ili odsutnost regulacije maloprodajnih cijena energije.	Eurostat, 2023
B	Dekarbonizacija	Stupanj prelaska na niskougljične ili obnovljive izvore energije u energetskeg miksu zemlje.	International Energy Agency, 2023
C	Energetsko siromaštvo	Udio stanovništva s poteškoćama u zadovoljavanju osnovnih energetskeg potreba.	European Energy Poverty Observatory, 2023
D	Diverzifikacija energetskeg miksa	Raznolikost izvora energije u zemlji, što utječe na sigurnost opskrbe i otpornost energetskeg sustava.	European Commission, 2023a
E	Regulatorni okvir i mjere	Učinkovitost i transparentnost regulatornog okvira te politike i inicijative za poboljšanje energetske učinkovitosti i smanjenje emisija.	World Bank, 2023; European Environment Agency, 2023
F	Konvergencija prema naprednim zemljama	Stupanj usklađenosti regulatornih politika zemalja EU13 i CP/OB s politikama naprednih zemalja.	European Commission, 2023b

5. Pristupi istraživanju i metodološki koraci

Primjena **QCA analize** (*Qualitative Comparative Analysis*) u kontekstu energetskeg politika i energetskeg tranzicije omogućava analizu kombinacija regulatornih i institucionalnih uvjeta koji utječu na liberalizaciju tržišta, tržišnu koncentraciju i konvergenciju maloprodajnih cijena električne energije. Ova metoda, temeljena na teorijama ekonomske integracije, konvergencije i tržišne učinkovitosti, doprinosi identifikaciji ključnih politika koje ubrzavaju energetskeg tranziciju u zemljama Europske energetskeg zajednice (EEZ).

Tablica 7 prikazuje ključne kriterije koji se koriste u QCA analizi za mjerenje napretka u energetskeg politikama. Svaki kriterij ocjenjuje se na skali od 1 do 5, pri čemu se procjenjuje napredak pojedinih zemalja EEZ-a u kontekstu postizanja ciljeva energetskeg tranzicije i konvergencije cijena.

Tablica 7: Ključni kriteriji QCA analize

Kriterij	Definicija	Ocjena (1-5)
Dekarbonizacija	Napredak u smanjenju emisija stakleničkih plinova i integraciji obnovljivih izvora energije	1 - Minimalan napredak; 5 - Potpuni napredak
Liberalizacija tržišta	Stupanj otvorenosti i konkurentnosti na energetsom tržištu	1 - Minimalna otvorenost; 5 - Potpuna liberalizacija
Sigurnost opskrbe	Diverzifikacija energetske miksa i otpornost na poremećaje u opskrbi	1 - Visoka ovisnost o uvozu; 5 - Potpuna sigurnost
Institucionalna efikasnost	Učinkovitost regulatornih okvira i institucija te usklađenost s EU standardima	1 - Slaba provedba; 5 - Učinkovita usklađenost
Utjecaj na regulaciju cijena	Utjecaj politika na formiranje cijena i pristupačnost električne energije	1 - Visoke cijene zbog regulacija; 5 - Pristupačne cijene
Socio-ekonomski kontekst	Učinak energetske politike na društvo (npr., energetska siromaštvo) i ekonomski rast	1 - Visoka razina siromaštva; 5 - Visoka pristupačnost

Metodologija i proces Booleove analize

U okviru QCA metodologije, Booleova analiza uključuje niz konkretnih koraka za operacionalizaciju ključnih uvjeta.

1. Dihotomizacija: Prvi korak uključuje pretvaranje ordinalnih ocjena uvjeta u binarne vrijednosti 0 i 1. Ocjene 4 i 5 na ljestvici od 1 do 5 smatraju se visokim vrijednostima (1), što označava prisutnost određenog uvjeta. Ocjene 1, 2 i 3 smatraju se niskim vrijednostima (0), što označava odsutnost uvjeta (Ragin, 1987).

2. Izrada istinitosne tablice: Nakon dihotomizacije ocjena Likertove skale (1-3 kao 0, 4-5 kao 1), izrađuje se istinitosna tablica koja prikazuje relevantne kombinacije binarnih vrijednosti uvjeta za svaku promatranu zemlju, s pripadajućom vrijednošću zavisnog ishoda (otvorenost tržišta). Odabrani pragovi omogućavaju jasnu diferencijaciju između niskih i visokih razina uvjeta, usklađujući se s teorijskim smjericama QCA metodologije, koje naglašavaju važnost razlikovanja prisutnih i odsutnih uvjeta radi osiguravanja konzistentnosti i validnosti analize

3. Formulacija minimalnih uvjeta (minterma)

Za svaku zemlju gdje je $O = 1$ (otvorenost tržišta postignuta), identificiraju se minimalni uvjeti (*mintermi*). Ovi uvjeti predstavljaju najmanje skupove binarnih vrijednosti koji opisuju kombinacije ključnih faktora potrebnih za postizanje zavisnog ishoda. Na primjeru za Zemlju 1:

- Vrijednost uvjeta: $A=1, B=1, C=1, D=0, E=1, F=1$
- Minterm: $A \wedge B \wedge C \wedge \neg D \wedge E \wedge F$

Ova formulacija ilustrira kako određena kombinacija prisutnih (1) i odsutnih (0) uvjeta (u ovom slučaju $D=0$ rezultira otvorenosti tržišta ($O=1$)).

Booleov logički model

Nakon konstrukcije istinitosne tablice i identifikacije svih minterma za slučajeve gdje je $O=1$, primjenjuje se **Booleova algebra** radi pojednostavljenja kombinacija uvjeta i identifikacije **minimalnih skupova uvjeta**. Ovi minimalni skupovi opisuju ključne uvjete koji su dovoljni za postizanje zavisnog ishoda. Kroz postupak minimizacije dolazi se do jednadžbe koja predstavlja najjednostavnije kombinacije uvjeta.

Formula kao teorijska osnova:

Booleov logički model koristi sljedeću jednadžbu za opisivanje kombinacija uvjeta koji dovode do liberalizacije tržišta:

$$O = (A \wedge B) \vee (C \wedge D) \vee (E \wedge F)$$

Primijećena razlika

1. U mintermu za Zemlju 1:

- Vidljiva je odsutnost uvjeta D ($\neg D$), što znači da u ovom konkretnom slučaju $D=0$ nije relevantno za postizanje otvorenosti tržišta.

2. U teorijskoj jednadžbi:

- Varijabla D ponovno se pojavljuje kao dio drugog člana ($C \wedge D$).
- To je zato što teorijska jednadžba predstavlja **generalizirani** oblik koji sažima različite kombinacije uvjeta za sve slučajeve gdje je $O=1$ Kombinacija ($C \wedge D$) može biti relevantna za druge zemlje, gdje je $D=1$.

Objašnjenje formule:

Jednadžba pokazuje kako različite kombinacije uvjeta ($A - F$) mogu rezultirati otvorenosti tržišta (O)

gdje je:

1. Prvi član: ($A \wedge B$)

- **Tumačenje:** Otvorenost tržišta je rezultat minimalne regulacije cijena (A) i visokog stupnja dekarbonizacije (B).
- **Teorijska osnova:** Uklanjanje regulatornih prepreka i prelazak na obnovljive izvore energije potiče tržišnu dinamiku i inovacije.

2. Drugi član: ($C \wedge D$)

- **Tumačenje:** Liberalizacija se postiže smanjenjem energetske siromaštva (C) i diverzifikacijom energetske miksa (D).
- **Teorijska osnova:** Smanjenje energetske siromaštva povećava potražnju i smanjuje potrebu za intervencijama, dok diverzifikacija osigurava sigurnost opskrbe.

3. Treći član: ($E \wedge F$)

- **Tumačenje:** Učinkovit regulatorni okvir (E) i konvergencija prema naprednim zemljama (F) stvaraju povoljne uvjete za otvaranje i integraciju tržišta.
- **Teorijska osnova:** Učinkovite politike i prilagodba najboljim praksama smanjuju administrativne prepreke i olakšavaju ulazak novih sudionika na tržište.

Alternativna formula primjer:

$$O = (A \wedge B \wedge E \wedge F) \vee (\neg A \wedge C \wedge E \wedge F)$$

gdje je:

1. Prvi član: ($A \wedge B \wedge E \wedge F$)

- **Tumačenje:** Postiže se otvorenost tržišta uz minimalnu regulaciju cijena.

2. Drugi član: ($\neg A \wedge C \wedge E \wedge F$)

- **Tumačenje:** Regulacija cijena može biti prisutna ako je energetska siromaštvo nisko, a regulatorni okvir i konvergencija su osigurani.

Interpretacija logičkih operacija

Konjunkcija ($\wedge$): Uvjeti moraju biti istovremeno prisutni npr. ($A \wedge B$).

Disjunkcija ($\vee$): Dovoljna je prisutnost bilo koje kombinacije npr. ($A \wedge B$) $\vee$ ($C \wedge D$).

Negacija ($\neg$): Nepostojanje uvjeta, što u alternativnim jednadžbama omogućava identificiranje različitih puteva do ishoda.

Povezanost uvjeta s teorijama

Tržišna dinamika i konkurencija

- **Varijable A i D :**

- **A** (minimalna regulacija cijena): Ova varijabla ukazuje na važnost smanjenja državne intervencije u formiranju cijena, što omogućuje dinamičnije tržište.
- **D** (diversifikacija energetskeg miksa): Diverzifikacija izvora energije povećava otpornost tržišta i osigurava stabilnost opskrbe.
- **Primjer:** Zemlje s visokom diversifikacijom energetskeg miksa imaju manje volatilne cijene i niže ulazne barijere za nove sudionike.

Socio-ekonomski pristup

- **Varijable B i C :**

- **B** (dekarbonizacija): Naglašava smanjenje ovisnosti o fosilnim gorivima i prijelaz na obnovljive izvore energije.
- **C** (smanjenje energetskeg siromaštva): Ukazuje na potrebu za pristupačnošću energije za ranjive skupine, što potiče potrošačku participaciju.
- **Primjer:** Zemlje koje uspješno smanjuju energetske siromaštvo omogućuju veću participaciju potrošača u tržišnim procesima.

Teorija regulatorne konvergencije

- **Varijable E i F :**

- **E** (učinkovit regulatorni okvir): Kvalitetni regulatorni okviri smanjuju administrativne prepreke i povećavaju transparentnost tržišta.
- **F** (konvergencija prema naprednim zemljama): Usmjerenost na prilagodbu nacionalnih politika prema najboljim praksama razvijenih zemalja.
- **Primjer:** Usklađivanje s EU direktivama omogućuje jednostavnije integriranje u zajedničko energetske tržište.

Teorijska i empirijska osnova

1. **Tržišna dinamika:**

- Varijable A , B i D odražavaju ključne elemente tržišne konkurencije i sigurnosti opskrbe.
- **Primjer:** Liberalizacija tržišta u EU-15 potaknula je inovacije i smanjila troškove integracijom obnovljivih izvora energije.

2. **Socio-ekonomski pristup:**

- Varijable B i C naglašavaju povezanost socio-ekonomskih faktora s energetske politikama.
- **Primjer:** Smanjenje energetskeg siromaštva povećava potrošačku participaciju i podržava tržišnu liberalizaciju.

3. **Teorija regulatorne konvergencije:**

- Varijable E i F reflektiraju važnost usklađivanja politika i institucionalne učinkovitosti u liberalizaciji tržišta.
- **Primjer:** Prilagodba regulatornih okvira EU-13 i CP/OB (osim Norveške, koja je primjer najbolje prakse a nalazi se u skupini CP/OB) zemalja prema standardima EU-15.

Preporuke za politike

Na temelju odabranih varijabli i njihovih teorijskih osnova, formuliraju se preporuke za politike koje bi mogle unaprijediti liberalizaciju tržišta i energetske tranzicije. Konačne preporuke temeljit će se na rezultatima testiranja.

1. **Regulacija cijena (A):**

- Postupno ukidanje regulacija cijena radi poticanja tržišne konkurencije, uz primjenu zaštitnih mehanizama za ranjive skupine.

2. **Dekarbonizacija (B):**

- Poticanje ulaganja u obnovljive izvore energije i infrastrukturu kroz subvencije i fiskalne olakšice, s naglaskom na smanjenje emisija stakleničkih plinova.

3. Energetsko siromaštvo (C):

- Provođenje programa za povećanje energetske učinkovitosti u kućanstvima s niskim primanjima te osiguranje pristupačne energije za ranjive skupine.

4. Diversifikacija energetskog miksa (D):

- Promicanje raznolikosti izvora energije radi povećanja otpornosti na poremećaje opskrbe i smanjenja ovisnosti o uvozu energije.

5. Regulatorni okvir (E):

- Jačanje regulatornih tijela za povećanje transparentnosti, učinkovitosti i provedbe politika, s naglaskom na usklađivanje s najboljim praksama unutar EEZ-a.

6. Konvergencija (F):

- Usklađivanje nacionalnih politika i regulatornih okvira s praksama naprednih zemalja EU-15 kako bi se smanjile administrativne prepreke i omogućila veća integracija u zajedničko tržište.

Analiza je usmjerena na primjenu praksi iz skupine EU-15, koja služi kao uzor za liberalizaciju tržišta i provedbu energetskih politika unutar Europske energetske zajednice (EEZ). Mintermi su definirani na temelju izvješća nacionalnih i nadnacionalnih regulatora te empirijskih podataka o regulatornim, institucionalnim i socio-ekonomskim uvjetima zemalja EU-15 i prilagođeni za članice skupina EU-13 i CP/OB.

Sve navedene varijable predstavljaju ključne aspekte koji mogu pridonijeti liberalizaciji tržišta i energetske tranziciji. Konačne preporuke bit će određene na temelju rezultata analize, pri čemu će se fokus staviti na varijable koje imaju značajan utjecaj na otvorenost tržišta i konkurenciju.

6. Ekonometrijska analiza višestruke regresije na panel podacima

Odabir panel modela u modeliranju učinka maloprodajnih cijena električne energije na tržišnu konkurenciju i koncentraciju omogućava preciznu analizu složenih tržišnih učinaka, kao i utjecaj regulatornih i ekonomskih čimbenika na tržišta kroz vrijeme. Statički panel modeli pružaju osnovne procjene kratkoročnih povezanosti između cijena i tržišnih karakteristika, što omogućava jasan pregled trenutnih učinaka. S druge strane, dinamički panel modeli omogućavaju analizu dugoročnih prilagodbi i odgođenih učinaka koji su ključni za analizu tržišta.

Primjena System GMM metode u dinamičkim modelima, kao što su prikazali Halkos i Tsiirivis (2023), rješava problem endogenosti, gdje se cijene ili tržišni faktori mogu istodobno pojavljivati kao uzroci i posljedice. Nadalje, metode poput copula GARCH modela (Ly et al., 2022) omogućavaju praćenje zavisnosti između tržišta u vremenu. Osim toga, radovi poput onih Sirina i Ertena (2022) te Csereklyei (2019) koriste statičke modele za procjenu kratkoročnih učinaka regulatornih mjera i elastičnosti potražnje. U kontrastu, dinamički modeli, kao kod Rosa (2017), omogućavaju preciznu analizu sporijih prilagodki kod komercijalnih i industrijskih korisnika.

Zajednički, ovi modeli omogućavaju detaljno i diferencirano razumijevanje tržišnih dinamika, prilagodbe na promjene cijena te njihovog učinka na stupanj otvorenosti tržišta i konkurenciju. Stoga, korištenje kombinacije statičkih i dinamičkih panel modela predstavlja sveobuhvatan pristup za modeliranje učinka komponenti maloprodajnih cijena električne energije na stupanj otvorenosti tržišta i konkurenciju.

Statički panel model

Svrha: Statički panel model procjenjuje utjecaj specifičnih komponenti cijena na tržišnu konkurenciju i koncentraciju u zemljama EEZ-a. Uključivanje varijabli iz Booleovog modela omogućava analizu učinaka regulatornih i strukturnih čimbenika. Model analizira prostorne i vremenske dimenzije bez uzimanja u obzir vremenske dinamike zavisne varijable kroz vremenske periode.

Statički panel model s fiksnim efektima ima oblik:

$$y_{it} = \alpha_i + \beta_1 \text{Konvergencija}_{it} + \beta_2 \text{Energija}_{it} + \beta_3 \text{Mreža}_{it} + \beta_4 \text{Porezi}_{it} + \beta_5 \text{Naknade}_{it} + \beta_6 \text{BM}_{it} + Z_{it} \gamma + \varepsilon_{it}; i = 1, 2, \dots, 39, t = 2017, 2018, \dots, 2023 \quad (1)$$

gdje je:

y_{it} : Zavisna varijabla koja mjeri otvorenost tržišta i konkurenciju,

α_i : Fiksni efekt za zemlju i , koji hvata sve nepromatrane karakteristike specifične za zemlju koje ne mijenjaju tijekom vremena

β_1 : Koeficijent za varijablu dinamičke (personalizirane) konvergencije koja mjeri godišnje promjene u omjeru cijena u pojedinoj zemlji prema prosjeku EEZ-a

$\beta_2...5$: Koeficijenti za varijable koje opisuju komponente maloprodajnih cijena električne energije

BM_{it} : Matrica varijabli odabranih prema Booleovom modelu (npr. regulatorni okvir, diverzifikacija, dekarbonizacija)

β_6 : Vektor koeficijenata uz varijable odabrane Booleovim modelom

Z_{it} : Matrica kontrolnih varijabli, poput BDP-a po glavi stanovnika

γ : Vektor koeficijenata uz kontrolne varijable

ε_{it} : Slučajna pogreška specifična za zemlju i godinu t

Statički panel model sa slučajnim efektima ima oblik:

$$y_{it} = \mu + \beta_1 \text{Konvergencija}_{it} + \beta_2 \text{Energija}_{it} + \beta_3 \text{Mreža}_{it} + \beta_4 \text{Porezi}_{it} + \beta_5 \text{Naknade}_{it} + BM_{it} \beta_6 + \gamma Z_{it} + \alpha_i + \varepsilon_{it}; i=1, 2...39, t=2017, 2018,...2023 \quad (2)$$

gdje je:

y_{it} : Zavisna varijabla koja mjeri otvorenost tržišta i konkurenciju

μ : Zajednički konstantni član za sve jedinice promatranja

β_1 Koeficijent za varijablu dinamičke (personalizirane) konvergencije koja mjeri godišnje promjene u omjeru cijena u pojedinoj zemlji prema prosjeku EEZ-a,

$\beta_2...5$: Koeficijenti za varijable koje opisuju komponente maloprodajnih cijena električne energije

BM_{it} : Matrica varijabli odabranih prema Booleovom modelu (npr. regulatorni okvir, diverzifikacija, dekarbonizacija)

β_6 : Vektor koeficijenata uz varijable odabrane Booleovim modelom

Z_{it} : Matrica kontrolnih varijabli, poput BDP-a po glavi stanovnika

γ : Vektor koeficijenata uz kontrolne varijable

α_i : Slučajni efekt za zemlju i , koji predstavlja nepromatrane varijable specifične za zemlju, pretpostavljene da su neovisne od objašnjavajućih varijabli.

ε_{it} : Slučajna pogreška specifična za zemlju i i godinu t

Odabir između fiksnih i slučajnih efekata:

- **Fiksni efekti:** Koriste se kad nepromatrane varijable među zemljama mogu biti povezane s objašnjavajućim varijablama, čime kontroliraju stalne karakteristike svake zemlje.
- **Slučajni efekti:** Primjenjuju se kada nepromatrane varijable nisu povezane s objašnjavajućim varijablama, omogućavajući efikasnije procjene pod tim uvjetom.

Testiranje modela:

- **F test-** Određuje opravdanost korištenja modela sa fiksnim efektom; p-vrijednost < 0.05 sugerira da se odbacuje nulta hipoteza o jednakosti konstantnih članova za sve jedinice promatranja te da je upotreba modela sa fiksnim efektom opravdana
- **LM Test (Breusch-Pagan):** Ispituje opravdanost korištenja modela sa slučajnim efektima; p-vrijednost < 0.05 sugerira heterogenost i preporučuje model sa slučajnim efektima.
- **Hausmanov test:** Određuje preferenciju između fiksnih i slučajnih efekata. Ako je p-vrijednost < 0.05 , koristi se model s fiksnim efektima u protivnom model sa slučajnim efektima

Interpretacija rezultata:

- Koeficijenti β prikazuju očekivanu promjenu u zavisnoj varijabli za promjenu objašnjavajuće varijable, uz kontrolu ostalih varijabli.

Prednosti i nedostaci modela:

- **Slučajni efekti:** Omogućavaju procjenu varijabli neovisnih o vremenu, pružajući efikasnije procjene za velike uzorke.
- **Nedostaci:** Ako je slučajna greška povezana s objašnjavajućom varijablom, GLS procjena postaje pristrana, čime su fiksni efekti prikladniji.

Wooldridgeov test za autokorelaciju:

- Testira autokorelaciju u rezidualima panela. Ako je p-vrijednost < 0.05, prisutna je autokorelacija.

Dinamički panel model (GMM)

Svrha: Dinamički panel model koristi se za procjenu modela kojima vrijednost zavisne varijable ovisi o svojim vrijednostima iz prethodnih razdoblja. Primjenom Generalizirane metode momenata (GMM) kontroliraju se endogenost i povratne veze među ključnim varijablama, čime se omogućava bolja analiza dinamičkih prilagodbi cijena u zemljama EEZ-a.

Dinamički panel koji sadrži zavisnu varijablu s jednim vremenskim pomakom unatrag ima oblik:

$$y_{it} = \mu + \gamma y_{it-1} + \beta_1 \text{Konvergencija}_{it} + \beta_2 \text{Energija}_{it} + \beta_3 \text{Mreža}_{it} + \beta_4 \text{Porezi}_{it} + \beta_5 \text{Naknade}_{it} + BM_{it} \beta_6 + \gamma Z_{it} + \alpha_i + \varepsilon_{it}; i = 1, 2, \dots, 39, t = 2017, 2018, \dots, 2023 \quad (3)$$

pri čemu se podrazumijeva da su greške relacije ε_{it} nezavisno i identično distribuirane slučajne varijable sa sredinom 0 i varijancom σ_ε^2 .

gdje je:

y_{it-1} : Vrijednost zavisne varijable iz prethodnog razdoblja koja omogućava procjenu dinamike prilagodbe u tržišnoj otvorenosti.

μ : Zajednički konstantni član za sve jedinice promatranja

γ : vrijednost koeficijenta uz vrijednost zavisne varijable iz prethodnog razdoblja

β_1 : Koeficijent za varijablu dinamičke (personalizirane) konvergencije koja mjeri godišnje promjene u omjeru cijena u pojedinoj zemlji prema prosjeku EEZ-a,

$\beta_2, \dots, \beta_5$: Koeficijenti za varijable koje opisuju komponente maloprodajnih cijena električne energije

BM_{it} : Matrica varijabli odabranih prema Booleovom modelu (npr. regulatorni okvir, diverzifikacija, dekarbonizacija)

β_6 : Vektor koeficijenata uz varijable odabrane Booleovim modelom

Z_{it} : Matrica kontrolnih varijabli, poput BDP-a po glavi stanovnika

γ : Vektor koeficijenata uz kontrolne varijable

α_i : Specifični efekt za svaku zemlju i koji hvata karakteristike specifične za svaku zemlju, a koje ostaju konstantne tijekom vremena (npr., institucionalni faktori, geografske karakteristike).

ε_{it} : greška koja uključuje specifične učinke za zemlju i i godinu t .

Objašnjenje:

GMM metodom model uključuje vrijednost zavisne varijable iz prethodnog razdoblja i druge povezane varijable kako bi riješio problem endogenosti, omogućavajući procjenu dinamike tržišne dinamike u promatranim zemljama. Regulatorne varijable, komponente cijena, energetska učinkovitost i dekarbonizacija, doprinose testiranju učinka regulatornog okvira na tržišnu konkurenciju i koncentraciju.

Dijagnostički testovi:

- Sarganov ili Hansenov test: Testira valjanost instrumenata korištenih u GMM procjeni, potvrđujući da instrumenti adekvatno kontroliraju endogenost bez stvaranja pristranosti.

- Arellano-Bond test za autokorelaciju: Testira autokorelaciju u diferenciranim greškama modela; dopuštena je autokorelacija prvog reda, ali ne i drugog reda (AR(2)), što bi ukazivalo na neodgovarajuće instrumente.

Ovaj model i dijagnostički testovi omogućavaju pouzdane procjene dinamičkih prilagodbi na tržištu električne energije, uzimajući u obzir utjecaj cijena, regulatornog okvira, diverzifikacije energetske potrošnje i energetske učinkovitosti na tržišnu otvorenost i koncentraciju.

7. Ekonometrijska analiza konvergencije

Dinamička (personalizirana) konvergencija

Praćenje konvergencije cijena električne energije među zemljama članicama Europske energetske zajednice (EEZ) ključno je za razumijevanje tržišnih trendova i donošenje učinkovitih energetske politika. U ovom se istraživanju primjenjuje metodologija koja koristi varijablu *CONV_DP* kao nezavisnu varijablu u modelu za analizu učinka na konkurenciju i koncentraciju na maloprodajnom tržištu električne energije. Varijabla *CONV_DP* izračunava se na temelju podataka *FIN_ELEC*, koji predstavljaju cijene električne energije za kućanstva i ne-kućanstva, uključujući sve poreze i naknade, izražene u eurima i u standardima kupovne moći (PPS) po kWh.

Dinamička, ili personalizirana konvergencija, mjeri godišnju promjenu omjera između nacionalne maloprodajne cijene električne energije i prosjeka EEZ-a, te omogućava praćenje prilagodbi cijena u pojedinoj zemlji u odnosu na regionalni prosjek. Korištenjem varijable *CONV_DP*, moguće je utvrditi približava li se određena zemlja prosječnim vrijednostima EEZ-a ili se od njih udaljava, čime se dobiva precizan uvid u relativne promjene cijena tijekom vremena.

Formula za izračun Dinamičke (personalizirane) konvergencije:

$$CONV_DP = \ln \left(\frac{price_ratio}{lag_price_ratio} \right) \quad (1)$$

Komponente formule:

1. *price_ratio*

$$price_ratio = \frac{FIN_ELEC_{i,t}}{FIN_ELEC_{EEZ,t}} \quad (2)$$

gdje su:

$FIN_ELEC_{i,t}$: Maloprodajna cijena električne energije u specifičnoj zemlji (*i*) u godini (*t*)

$FIN_ELEC_{EEZ,t}$: Prosječna maloprodajna cijena električne energije za sve zemlje EEZ-a u godini (*t*)

2. *lag_price_ratio*:

$$lag_price_ratio = \frac{FIN_ELEC_{i,t-1}}{FIN_ELEC_{EEZ,t-1}} \quad (3)$$

gdje su:

$FIN_ELEC_{i,t-1}$: Maloprodajna cijena električne energije u specifičnoj zemlji (*i*) u prethodnoj godini (*t-1*)

$FIN_ELEC_{EEZ,t-1}$: Prosječna maloprodajna cijena električne energije za sve zemlje EEZ-a u prethodnoj godini (*t-1*)

Iz čega se definira konačna formula kao:

$$CONV_DP = \ln \left(\frac{FIN_ELEC_{i,t} \times FIN_ELEC_{EEZ,t-1}}{FIN_ELEC_{EEZ,t} \times FIN_ELEC_{i,t-1}} \right) \quad (4)$$

gdje su:

$FIN_ELEC_{i,t} \times FIN_ELEC_{EEZ,t-1}$: Kombinacija maloprodajne cijene u godini (*t*) zemlje (*i*) i prosječne cijene iz prethodne godine (*t-1*) u EEZ-u.

$FIN_ELEC_{EEZ,t} \times FIN_ELEC_{i,t-1}$: Kombinacija maloprodajne prosječne cijene u godini (t) EEZ-a i cijene zemlje (i) iz prethodne godine ($t-1$).

Interpretacija rezultata:

- **Pozitivan rezultat ($CONV_DP > 0$):** Nacionalne cijene električne energije rastu brže od prosječne cijene u EEZ-u, što ukazuje na divergenciju.
- **Negativan rezultat ($CONV_DP < 0$):** Nacionalne cijene električne energije rastu sporije ili padaju u odnosu na prosječnu cijenu u EEZ-u, što ukazuje na konvergenciju.
- **Vrijednost blizu nule ($CONV_DP \approx 0$):** Nacionalne cijene električne energije prate prosječne trendove cijena u EEZ-u.

Istraživački pristupi za optimizaciju procesa konvergencije

Metodološki okvir analize konvergencije utemeljen je na korištenju logaritamskih omjera, koji omogućavaju praćenje relativnih promjena cijena tijekom vremena. Ovaj pristup podržava teorija konvergencije u ekonomiji, koja koristi logaritamske omjere za usporedbu prilagodbi cijena među zemljama i njihov odnos prema kolektivnom prosjeku (Barro & Sala-i-Martin, 1992; Crespo Cuaresma & Wörz, 2005).

Uvođenje vrijednosti iz prethodnog razdoblja kroz varijablu *lag_price_ratio* dodatno olakšava analizu dinamike cijena u višegodišnjem kontekstu, omogućavajući preciznije praćenje promjena tijekom vremena. Takav pristup zasnovan je na literaturi koja naglašava važnost vrijednosti iz prethodnog razdoblja u modeliranju dugoročnih tržišnih trendova (Greene, 2003; Arellano & Bond, 1991; Engle & Granger, 1987; Hamilton, 1994).

Metodološki okvir dinamičke (personalizirane) konvergencije dodatno podržavaju istraživanja o metodama ubrzanja konvergencije. Na primjer, Smith i Ford (1979) uspoređuju različite algoritme za ubrzanje konvergencije, uključujući Brezinskijev *θ-algoritam*, dok Homeier (1999) predlaže interpolaciju za transformaciju logaritamski konvergentnih nizova u linearne, čime se povećava učinkovitost konvergenijskih metoda. Sidi (1995) koristi Generalizirani Richardsonov Ekstrapolacijski Proces (GREP) za stabilizaciju konvergencije u oscilirajućim logaritamskim nizovima, dok Sedogbo (1990) istražuje algoritme kao što su modificirani Aitkenov Δ^2 proces i *θ-algoritam*, s ciljem poboljšanja brzine konvergencije.

Kombinacija agregiranih pokazatelja i raščlanjenih troškovnih komponenti pruža sveobuhvatan pregled tržišnih odnosa. Agregirani pokazatelji omogućavaju praćenje općih trendova konvergencije ili divergencije, dok raščlanjene varijable daju uvid u specifične doprinose troškovnih elemenata, što je osobito važno za analizu dinamičkih prilagodbi na tržištu. Takav pristup potvrđuje i Baltagi (2008), koji naglašava važnost kombiniranja različitih varijabli kako bi se dobila cjelovita slika ekonomskih procesa u panel podacima. Barro i Sala-i-Martin (1992) ističu važnost agregiranih pokazatelja za opće praćenje trendova konvergencije, ali i potrebu za raščlambom čimbenika prilagodbe kako bi se razumjele specifične tržišne prilagodbe. Arellano (2003) dodaje da panel podaci omogućavaju analizu dinamičkih odgovora i kontrolu heterogenosti, što je ključno za razumijevanje složenih ekonomskih procesa.

Ovaj sveobuhvatni pristup, koji integrira logaritamske omjere, vrijednosti iz prethodnog razdoblja, agregirane pokazatelje i raščlanjene troškovne komponente, pruža robusnu osnovu za analizu tržišnih obrazaca u Europskoj energetske zajednici, omogućavajući precizno praćenje dinamike među zemljama i razumijevanje prilagodbi na tržištu.

Sigma (σ) konvergencija

Sigma konvergencija mjeri smanjenje varijabilnosti cijena kroz vrijeme koristeći standardnu devijaciju ili koeficijent varijacije, što omogućava procjenu homogenizacije cijena među zemljama (Eurofound, 2018).

Formula za sigma konvergenciju

$$CV_t = \frac{\sigma_t}{\mu_t} \times 100 \quad (1)$$

gdje su:

CV_t : koeficijent varijacije

$$\sigma_t = \sqrt{\frac{\sum_{i=1}^N (x_{i,t} - \mu_t)^2}{N}} \quad (2)$$

σ_t : standardna devijacija cijena u vremenu t

$$\mu_t = \frac{1}{N} \sum_{i=1}^N x_{i,t} \quad (3)$$

μ_t : prosječna cijena u zemljama EEZ-a u vremenu t

N : broj zemalja

$x_{i,t}$: cijena u zemlji i u vremenu t

Pad koeficijenta varijacije (CV_t) kroz vrijeme ukazuje na sigma konvergenciju, dok porast sugerira divergenciju među zemljama.

Beta (β) konvergencija

Beta konvergencija istražuje postoji li proces "sustizanja", gdje zemlje s nižim početnim cijenama rastu brže u odnosu na zemlje s višim početnim cijenama. To se procjenjuje kroz regresijsku analizu (Eurofound, 2018).

Formula za beta konvergenciju:

$$\ln(\Delta_{y,t}) = \alpha + \beta \ln(y_{i,t-1}) + \epsilon_{i,t} \quad (1)$$

gdje su:

$y_{i,t}$: razina cijena u zemlji i u vremenu t

$\Delta_{y,t} = y_{i,t} - y_{i,t-1}$: stopa rasta cijena

α i β : parametri za procjenu

$\epsilon_{i,t}$: slučajna pogreška.

Negativna vrijednost koeficijenta β sugerira konvergenciju jer zemlje s nižim početnim cijenama brže rastu prema prosječnim vrijednostima.

Delta (δ) konvergencija

Delta konvergencija mjeri razmak između cijena u pojedinoj zemlji i najbolje performirajuće zemlje unutar EEZ-a. Ovo omogućuje analizu približavanja ili udaljavanja od predvodnika (Eurofound, 2018).

Formula za delta konvergenciju:

$$\delta_t = \sum_{i=1}^N (MAX(x_{i,t}) - x_{i,t}) \quad (1)$$

gdje je:

- $MAX(x_{i,t})$: najviša cijena među zemljama u vremenu t ,
- $x_{i,t}$: cijena u zemlji i u vremenu t ,
- δ_t : ukupni razmak od vodeće zemlje.

Smanjenje vrijednosti δ_t kroz vrijeme ukazuje na delta konvergenciju, dok povećanje sugerira divergenciju.

Uzlazna i silazna konvergencija/divergencija

Ovo istraživanje, osim analize standardnih konvergencijskih mjera, procjenjuje i specifične obrasce uzlazne i silazne konvergencije/ divergencije maloprodajnih cijena električne energije među zemljama Europske energetske zajednice (EEZ). Cilj je razumjeti približavaju li se zemlje EEZ-a u pogledu cijena ili se kroz vrijeme udaljavaju. Metodologija je inspirirana izvješćem Eurofound-a (2018), koje naglašava potrebu za preciznim praćenjem smjera i intenziteta promjena među zemljama. Praćenje ovih obrazaca ključno je za informirano donošenje politika EEZ-a, jer omogućava uvid u to kako se performanse zemalja mijenjaju te smanjuju li se ili povećavaju razlike među njima. U analizi se tako razmatraju različiti scenariji konvergencije i divergencije, ovisno o tome približavaju li se ili udaljavaju nacionalne cijene zemalja u odnosu na prosjek EEZ-a i u kojem se smjeru kreću njihove međusobne razlike.

Prvi korak u ovoj analizi uključuje izračun koeficijenta varijacije (*CV*), koji mjeri relativnu varijabilnost cijena među zemljama u odnosu na prosječnu vrijednost u različitim vremenskim točkama *t*. Koeficijent varijacije (*CV*) daje osnovu za praćenje promjena u varijabilnosti cijena kroz vrijeme, a formula je prikazana u okviru praćenja Sigma konvergencije u ovoj metodologiji.

Ključne formule za praćenje odstupanja i varijabilnosti

- Razlika u cijeni (odstupanje cijene zemlje od prosjeka EEZ-a):

$$diff_{i,t} = x_{i,t} - EEZmean_t \quad (1)$$

- Kvadrat razlike (apsolutna mjera odstupanja svake zemlje od prosjeka EEZ-a):

$$sqdiff_{i,t} = (diff_{i,t})^2 = (x_{i,t} - EEZmean_t)^2 \quad (2)$$

- Promjena prosječne cijene zemlje između godina:

$$\Delta MSmean_i = MSmean_{i,2023} - MSmean_{i,2017} \quad (3)$$

- Promjena prosjeka EEZ-a:

$$\Delta EEZmean = EEZmean_{2023} - EEZmean_{2017} \quad (4)$$

- Promjena kvadratne razlike (mjerenje promjene varijabilnosti između zemalja):

$$\Delta sqdiff_i = sqdiff_{i,2023} - sqdiff_{i,2017} \quad (5)$$

Klasifikacija konvergencijskih i divergencijskih obrazaca s dodatnim kriterijima

Na temelju vrijednosti $\Delta EEZmean$, $\Delta MSmean$, i $\Delta sqdiff$, definiraju se sljedeći obrasci:

- **Uzlazna konvergencija (*Upward Convergence*):** Rastući trend prosječnih performansi uz smanjenje varijabilnosti među zemljama.
- **Kriterij:** Prosječna cijena na razini EEZ raste ili ostaje na istoj razini uz istovremeno smanjenje varijabilnosti

$$\Delta EEZmean \geq 0 \quad \text{ i } \quad \Delta sqdiff < 0 \quad (6)$$

- **Dodatni uvjet:** Promjena prosječne cijene pojedine zemlje premašuje promjenu prosječne cijene EEZ-a

$$\Delta MS_{mean} > \Delta EEZ_{mean} \quad (7)$$

- **Uzlazna divergencija (Upward Divergence):** Rastući trend prosječnih performansi uz povećanje varijabilnosti među zemljama.

- **Kriterij:** Prosječna cijena na razini EEZ raste ili ostaje na istoj razini uz istovremeno povećanje varijabilnosti

$$\Delta EEZ_{mean} \geq 0 \quad i \quad \Delta sqdiff > 0 \quad (8)$$

- **Dodatni uvjet:** Promjena prosječne cijene pojedine zemlje zaostaje za promjenom prosječne cijene EEZ-a

$$\Delta MS_{mean} < \Delta EEZ_{mean} \quad (9)$$

- **Silazna konvergencija (Downward Convergence):** Opadajući trend prosječnih performansi uz smanjenje varijabilnosti među zemljama

- **Kriterij:** Prosječna cijena na razini EEZ opada uz istovremeno smanjenje varijabilnosti

$$\Delta EEZ_{mean} < 0 \quad i \quad \Delta sqdiff < 0 \quad (10)$$

- **Dodatni uvjet:** Promjena prosječne cijene pojedine zemlje zaostaje za promjenom prosječne cijene EEZ-a

$$\Delta MS_{mean} < \Delta EEZ_{mean} \quad (11)$$

- **Silazna divergencija (Downward Divergence):** Opadajući trend prosječnih performansi uz povećanje varijabilnosti među zemljama.

- **Kriterij:** Prosječna cijena na razini EEZ opada uz istovremeno povećanje varijabilnosti

$$\Delta EEZ_{mean} < 0 \quad i \quad \Delta sqdiff > 0 \quad (12)$$

- **Dodatni uvjet:** Promjena prosječne cijene pojedine zemlje premašuje promjenu prosječne cijene EEZ-a

$$\Delta MS_{mean} > \Delta EEZ_{mean} \quad (13)$$

Dodatni Obrasci Konvergencije i Divergencije

Uz osnovne obrasce konvergencije i divergencije, u analizi su razmotreni i dodatni obrasci:

- **Paralelni trendovi (Parallel Trends):** označava situaciju u kojoj su promjene u prosječnoj cijeni EEZ-a i pojedine zemlje jednake, uz konstantnu varijabilnost.

- **Kriterij:**

$$\Delta EEZ_{mean} = \Delta MS_{mean} \quad i \quad \Delta sqdiff = 0 \quad (14)$$

- **Presijecanje trendova (Crossing Trends):** označava situaciju kada su godišnje promjene u prosječnoj cijeni EEZ-a i pojedine zemlje suprotne, uz promjenu varijabilnosti.
- **Kriterij:**

$$(\Delta EEZ_{mean} > 0 \text{ i } \Delta MS_{mean} < 0) \text{ ili } (\Delta EEZ_{mean} < 0 \text{ i } \Delta MS_{mean} > 0), \Delta sqdiff \neq 0 \quad (15)$$

Ovaj pristup omogućava detaljnu analizu varijabilnosti maloprodajnih cijena električne energije u EEZ-u i služi kao alat za praćenje konvergencije i divergencije među zemljama članicama.

8. Plan istraživanja

Plan istraživanja prikazan je u Tablici 8 gdje su detaljno opisani koraci istraživanja, od proučavanja relevantnih teorija i prikupljanja literature do formulacije regulatornih preporuka.

Tablica 8: Plan istraživanja

Hodogram	Opis	Izvedba u modelu
Prikupljanje i analiza literature	Proučavanje relevantnih teorija (npr., teorije konvergencije, institucionalne ekonomije, industrijske organizacije) za izgradnju teorijskog okvira istraživanja o; konvergenciji cijena, otvorenosti tržišta i konkurenciji u EEZ-u.	Omogućava formulaciju istraživačkih hipoteza temeljenih na prethodnim radovima o tržišnim i regulatornim čimbenicima.
Prikupljanje podataka za kvalitativnu analizu	Podaci se prikupljaju kroz pregled nacionalnih energetskih strategija, izvještaja međunarodnih organizacija (IEA, Europska komisija) te relevantnih izvještaja nacionalnih regulatora EEZ-a. Zemlje su grupirane kao EU-15, EU-13 i CP/OB. Definirani su ključni uvjeti potrebni za provođenje QCA.	Osigurava potrebne regulatorne i institucionalne podatke za QCA, uključujući regulatorni okvir, politike liberalizacije, subvencije i socio-ekonomski kontekst.
Prikupljanje kvantitativnih podataka	Podaci se prikupljaju iz Eurostat baze podataka i izvještaja ACER-a i CEER-a za razdoblje 2017.–2023. Obuhvaćaju cijene električne energije i njihove komponente te makroekonomske i regulatorne varijable za zemlje EEZ-a.	Priprema varijabli za ekonometrijsku analizu i definiciju komponenti cijena električne energije.
Kvalitativna komparativna analiza (QCA)	Identificira institucionalne i regulatorne čimbenike koji doprinose otvorenosti tržišta i konvergenciji cijena u EEZ-u.	Koristi kvalitativne metode za identifikaciju uvjeta koji olakšavaju ili usporavaju konvergenciju.
Ekonometrijska analiza konvergencije	Koristeći metode sigma (σ), beta (β) i delta (δ) konvergencije te dinamike konvergencije, analiza procjenjuje u kojoj mjeri dolazi do smanjenja razlika u cijenama električne energije među zemljama EEZ-a. Primjenjuje se metodologija iz studije "Upward Convergence in the EU".	Primjena metoda konvergencije za procjenu smanjenja varijabilnosti cijena i brzine ujednačavanja cijena među zemljama.
Definiranje dinamičke personalizirane konvergencije	Varijabla dinamičke personalizirane konvergencije mjeri godišnju promjenu u omjeru između specifične cijene električne energije u zemlji i prosjeka EEZ-a, omogućujući praćenje kretanja cijena u odnosu na EEZ prosjek. Prati postaje li zemlja skuplja ili jeftinija u odnosu na prosjek.	Varijabla se računa kao razlika između logaritma omjera nacionalne i prosječne cijene u EEZ-u za trenutnu i prethodnu godinu, čime se prati trend prilagodbe cijena.
Ekonometrijska analiza na panel podacima	Statički i dinamički panel modeli omogućavaju kvantifikaciju utjecaja komponenti cijena na otvorenost tržišta i konkurenciju. Dinamički modeli koriste generaliziranu metodu momenata (GMM) za procjenu uzročnih i vremenskih učinaka.	Statički panel modeli procjenjuju početne učinke, dok GMM pristup omogućava analizu vremenskih i uzročnih odnosa među ključnim tržišnim i regulatornim čimbenicima.
Interpretacija rezultata	Rezultati se tumače u kontekstu teorijskog okvira i prethodnih istraživanja o tržišnoj integraciji i konvergenciji,	Usporedba nalaza s relevantnim teorijama i istraživanjima o

	omogućavajući uvid u ulogu regulatornih mjera u dinamici cijena i koncentraciji u EEZ-u.	konvergenciji cijena i otvorenosti tržišta u EEZ-u
Izrada preporuka	Na temelju rezultata, donose se preporuke za regulatorne politike s ciljem smanjenja tržišnih barijera, poticanja konkurencije i održive energetske tranzicije u EEZ-u.	Usmjerenje regulatornih preporuka prema poticanju konvergencije cijena i poboljšanju tržišne dinamike u EEZ-u

9. Ograničenja modela

- **Nebalansirani podaci:** Iako neki podaci nisu dostupni za sve zemlje u svakom promatranom razdoblju, panel modeli prilagođeni su radu s nebalansiranim podacima, čime omogućavaju sveobuhvatnu analizu ključnih tržišnih varijabli unatoč djelomičnim nedostacima u podacima.
- **Endogenost:** Mogući problem endogenosti testirat će se provođenjem testova za provjeru njezine prisutnosti (npr., Hausmanov test) i valjanosti instrumenata (npr., Hansenov test) a pokušat će se riješiti korištenjem instrumentalnih varijabli, metode fiksnih učinaka i generalizirane metode momenata (GMM). Time će se osigurati kontrola obostrane kauzalnosti varijabli i pouzdane procjene.
- **Multikolinearnost:** Kod nekih varijabli može postojati problem multikolinearnosti, što otežava točnu procjenu utjecaja pojedinih komponenti cijena. Primijenit će se odgovarajući testovi kako bi se otkrile i eliminirale potencijalne korelacije među varijablama.
- **Ograničeno vremensko razdoblje:** Razdoblje od 2017. do 2023., zbog nedostatka podataka o komponentama cijena prije 2017. godine, predstavlja ograničenje istraživanja jer bi dulji vremenski okvir pridonio boljem razumijevanju dugoročnih trendova. Ipak, detaljna raščlamba maloprodajnih cijena električne energije na pojedinačne komponente omogućava precizniju analizu utjecaja tih komponenti na stupanj otvorenosti tržišta i konkurenciju, što doprinosi razumijevanju aktualnih tržišnih dinamika.
- **Relevantnost podataka iz nacionalnih regulatornih izvještaja:** Podaci prikupljeni iz izvještaja nacionalnih regulatora mogu varirati u točnosti i ažurnosti, što može utjecati na konzistentnost i usporedivost rezultata između zemalja.

10. Zaključak o metodološkom okviru

Predloženi metodološki okvir prati definirane ciljeve i hipoteze, pružajući temelje za analizu ključnih čimbenika koji oblikuju tržišnu dinamiku električne energije u EEZ-u. Primjenom panel modela omogućava se sveobuhvatno razumijevanje tržišnih trendova i regulatornih učinaka, uz uvažavanje vremenskih i strukturnih aspekata. Ovaj pristup doprinosi znanstvenim istraživanjima i praktičnim preporukama za unaprjeđenje tržišne liberalizacije i energetske tranzicije.

Unatoč ograničenjima, rezultati pružaju ključne uvide u dinamiku tržišta električne energije i nude osnovu za daljnje istraživanje i donošenje politika.

3.6. Očekivani znanstveni doprinos predloženog istraživanja (preporučeno 500 znakova s praznim mjestima)

Očekivani znanstveni doprinos predloženog istraživanja očituje se u razvoju sveobuhvatnog i metodološki integriranog pristupa u modeliranju maloprodajnih cijena električne energije, koji kombinira ekonometrijske metode panel analize, testiranja konvergencije (sigma, beta, delta, uzlazno-silazna i dinamička konvergencija) i kvalitativnu komparativnu analizu (QCA). Ovakva metodologija omogućava detaljnu analizu učinaka ključnih komponenti cijena i konvergencije na tržišnu konkurenciju i koncentraciju, pružajući uvid u smjer, brzinu, intenzitet i stupanj konvergencije maloprodajnih cijena među zemljama Europske energetske zajednice (EEZ).

Posebnu vrijednost predstavlja dinamička (personalizirana) konvergencija kao nezavisna varijabla, koja doprinosi preciznom praćenju nacionalnih cjenovnih razlika i njihovih promjena tijekom vremena. Uz to, integracija QCA omogućava oblikovanje scenarija i preporuka temeljenih na kombinacijama uvjeta poput dekarbonizacije, energetskog siromaštva i diverzifikacije energetskog miksa, čime se istraživanje usmjerava na praktične implikacije politika.

Dodatno, znanstveni doprinos obuhvaća sveobuhvatan pristup za modeliranje maloprodajnih cijena električne energije, uključujući raščlambu cijena na ključne komponente – troškove energije, mrežne troškove, poreze i ostale naknade – te njihovo izražavanje u nominalnim vrijednostima i standardima kupovne moći (PPS). Ovaj pristup omogućava preciznu usporedbu stvarnih troškova električne energije među zemljama EEZ-a i popunjava prazninu u literaturi koja se uglavnom fokusira na nominalne cijene.

Panel analiza modelira učinke dinamičke konvergencije i komponenti maloprodajnih cijena na tržišnu konkurenciju i koncentraciju, pridonoseći razumijevanju čimbenika koji potiču ili usporavaju proces integracije maloprodajnog tržišta električne energije u EEZ-u.

Očekivani praktični doprinos predloženog istraživanja sadržan je u oblikovanju scenarija i preporuka za politike koje potiču otvorenost tržišta, konkurenciju i integraciju. Kvalitativna komparativna analiza (QCA) omogućava analizu kombinacija ključnih uvjeta poput razine dekarbonizacije, mjera protiv energetskog siromaštva i diverzifikacije energetskog miksa. Nalazi istraživanja pružit će smjernice i preporuke za razvoj konkretnih mjera koje smanjuju razlike u cijenama između razvijenih i manje razvijenih članica EEZ-a te pridonose integraciji tržišta i održivoj energetskej tranziciji.

Buduća istraživanja mogu se usmjeriti na:

- **Istraživanje utjecaja pametnih brojlara i digitalizacije** na tržišnu transparentnost i integraciju te analizu troškova njihove implementacije.
- **Praćenje ulaganja u mrežnu infrastrukturu** radi smanjenja troškova energije i otvaranja tržišta, posebno u manje razvijenim zemljama EEZ-a.
- **Istraživanje učinaka mjera protiv energetskog siromaštva** na tržišnu otvorenost, što bi moglo pomoći zemljama s nižom kupovnom moći.
- **Razvoj metodologije za praćenje ekonomske učinkovitosti dekarbonizacije**, što bi pružilo uvid u njezin utjecaj na otvorenost i integraciju tržišta.
- **Analizu dugoročnih učinaka geopolitičkih rizika** na cijene energije i prilagodbu regulatornih mjera u EEZ-u, što bi pružilo dodatne smjernice za otvorenost tržišta i konkurenciju.

3.1. Popis citirane literature
(maksimalno 30 referenci)

1. ACER - CEER. (2023). *Energy Retail and Consumer Protection 2023 Market Monitoring Report*. [online] Available at: <https://acer.europa.eu/electricity/market-monitoring-report#135>.
2. Ambec, S., Banal, A., Cantillon, E., Crampes, C., Creti, A., Decarolis, F., Fabra, N., Gerlagh, R., Kneuhoff, K., Landais, C., Liski, M., Llobet, G., Newbery, D., Polo, M., Reguant, M., Schwenen, S. and Vehviläinen, I. (2023). Electricity market design: Views from European economists. *research.aalto.fi*. [online] Available at: <https://research.aalto.fi/en/publications/electricity-market-design-views-from-european-economists> [Accessed 19 Feb. 2024].
3. Batalla, J., Paniagua, J. and Trujillo-Baute, E. (2019). Energy Market Integration and Electricity Trade. *Economics of Energy & Environmental Policy*, 8(2). doi:<https://doi.org/10.5547/2160-5890.8.2.jbat>.
4. Breitschopf, B. and Wachsmuth, J. (2017). What is the impact of the EU Energy Union on electricity prices? Results for selected member states. doi:<https://doi.org/10.1109/eem.2017.7982025>.
5. Brown, D.P., Zamikau, J., Adib, P., Tsai, C.H. and Woo, C.K. (2020). Rising market concentration in Texas's retail electricity market. *The Electricity Journal*, 33(8), p.106848. doi:<https://doi.org/10.1016/j.tej.2020.106848>.
6. Bublitz, A., Keles, D. and Fichtner, W. (2017). An analysis of the decline of electricity spot prices in Europe: Who is to blame? *Energy Policy*, [online] 107, pp.323–336. doi:<https://doi.org/10.1016/j.enpol.2017.04.034>.
7. Cambini, C., Caviggioli, F. and Scellato, G. (2016). Innovation and market regulation: evidence from the European electricity industry. *Industry and Innovation*, 23(8), pp.734–752. doi:<https://doi.org/10.1080/13662716.2016.1206464>.
8. Cassetta, E., Nava, C.R. and Zoia, M.G. (2022). EU electricity market integration and cross-country convergence in residential and industrial end-user prices. *Energy Policy*, 165, p.112934. doi:<https://doi.org/10.1016/j.enpol.2022.112934>.
9. Child, M., Kemfert, C., Bogdanov, D. and Breyer, C. (2019). Flexible electricity generation, grid exchange and storage for the transition to a 100% renewable energy system in Europe. *Renewable Energy*, 139, pp.80–101. doi:<https://doi.org/10.1016/j.renene.2019.02.077>.
10. Chomać-Pierzecka, E., Sobczak, A. and Soboń, D. (2022). The Potential and Development of the Geothermal Energy Market in Poland and the Baltic States—Selected Aspects. *Energies*, 15(11), p.4142. doi:<https://doi.org/10.3390/en15114142>.
11. Ciferri, D., D'Errico, M.C. and Polinori, P. (2019). Integration and convergence in European electricity markets. *Economia Politica*, 37(2), pp.463–492. doi:<https://doi.org/10.1007/s40888-019-00163-7>.
12. de Menezes, L.M. and Houllier, M.A. (2016). Reassessing the integration of European electricity markets: A fractional cointegration analysis. *Energy Economics*, 53, pp.132–150. doi:<https://doi.org/10.1016/j.eneco.2014.10.021>.
13. Dormady, N., Hoyt, M., Roa-Henriquez, A. and Welch, W. (2019). Who Pays for Retail Electric Deregulation? Evidence of Cross-Subsidization from Complete Bill Data. *The Energy Journal*, 40(2). doi:<https://doi.org/10.5547/01956574.40.2.ndor>.
14. Esplin, R., Davis, B., Rai, A. and Nelson, T. (2020). The impacts of price regulation on price dispersion in Australia's retail electricity markets. *Energy Policy*, 147, p.111829. doi:<https://doi.org/10.1016/j.enpol.2020.111829>.
15. Eurofound. (2018) Upward convergence in the EU: Concepts, measurements and indicators. Luxembourg: Publications Office of the European Union. Available at: <http://eurofound.link/ef18003>
16. Halkos, G.E. and Tsirivis, A.S. (2023). Electricity Prices in the European Union Region: The Role of Renewable Energy Sources, Key Economic Factors and Market Liberalization. *Energies*, 16(6), p.2540. doi:<https://doi.org/10.3390/en16062540>.

17. Hartley, P.R., Medlock, K.B. and Jankovska, O. (2019). Electricity reform and retail pricing in Texas. *Energy Economics*, 80, pp.1–11. doi:<https://doi.org/10.1016/j.eneco.2018.12.024>.
18. Hirth, L. (2018). What caused the drop in European electricity prices? A factor decomposition analysis. *The Energy Journal*, 39(1). doi:<https://doi.org/10.5547/01956574.39.1.lhir>.
19. Iimura, A. and Cross, J.S. (2018). The impact of renewable energy on household electricity prices in liberalized electricity markets: A cross-national panel data analysis. *Utilities Policy*, 54, pp.96–106. doi:<https://doi.org/10.1016/j.jup.2018.08.003>.
20. Jamasb, T., Nepal, R. and Timilsina, G.R. (2017). A Quarter Century Effort Yet to Come of Age: A Survey of Electricity Sector Reform in Developing Countries. *The Energy Journal*, 38(3). doi:<https://doi.org/10.5547/01956574.38.3.tjam>.
21. Kaller, A., Bielen, S. and Marneffe, W. (2018). The impact of regulatory quality and corruption on residential electricity prices in the context of electricity market reforms. *Energy Policy*, 123, pp.514–524. doi:<https://doi.org/10.1016/j.enpol.2018.09.008>.
22. Lucila de Almeida, Esposito, F. and Josephine van Zeben (2022). When indicators fail electricity policies: Pitfalls of the EU's retail energy market Barrier Index. *Energy Policy*, [online] 165, p.112892. doi:<https://doi.org/10.1016/j.enpol.2022.112892>.
23. M. Erdiñç Telatar and Nermin Yaşar (2020). The Convergence of Electricity Prices for European Union Countries. *Springer eBooks*, pp.55–63. doi:https://doi.org/10.1007/978-3-030-32296-0_4.
24. Mihuț, I.S. & Pop, L.N. (2018) 'Convergence vs. divergence: the path of the European Union', *Managerial Challenges of the Contemporary Society*, 11(2), pp. 89-95. Available at: <https://www.europub.co.uk/articles/-A-444297>
25. Ndebele, T., Marsh, D. and Scarpa, R. (2019). Consumer switching in retail electricity markets: Is price all that matters? *Energy Economics*, 83, pp.88–103. doi:<https://doi.org/10.1016/j.eneco.2019.06.012>.
26. Pepermans, G. (2018). European energy market liberalization: experiences and challenges. *International Journal of Economic Policy Studies*, 13(1), pp.3–26. doi:<https://doi.org/10.1007/s42495-018-0009-0>.
27. Pollitt, M.G. (2017). The economic consequences of Brexit: energy. *Oxford Review of Economic Policy*, 33(suppl_1), pp.S134–S143. doi:<https://doi.org/10.1093/oxrep/grx013>.
28. Sampson, E.M. and Longe, O.M. (). Review of the Role of Energy Pricing Policies in Electricity Retail Market. In: *2021 IEEE PES/IAS PowerAfrica*. pp.1–5. doi:<https://doi.org/10.1109/PowerAfrica52236.2021.9543429>
29. Tsai, C.-H. and Tsai, Y.-L. (2018). Competitive retail electricity market under continuous price regulation. *Energy Policy*, 114, pp.274–287. doi:<https://doi.org/10.1016/j.enpol.2017.12.012>.
30. Varhade, P., Kumar, A., Dhingra, D.T. and Navalkar, P. (2018). Study of introducing competition in retail supply of electricity across developed countries and its framework for india. *International Journal of Management Studies*, 5, p.109. doi:[http://dx.doi.org/10.18843/ijms/v5i1\(2\)/15](http://dx.doi.org/10.18843/ijms/v5i1(2)/15)

3.2. Procjena ukupnih troškova predloženog istraživanja (u kunama)			
3.3. Predloženi izvori financiranja istraživanja			
Vrsta financiranja	Naziv projekta	Voditelj projekta	Potpis
Nacionalno financiranje			
Međunarodno financiranje			
Ostale vrste projekata			
Samostalno financiranje			
3.4. Sjednica Etičkog povjerenstva na kojoj je odobren prijedlog istraživanja (po potrebi)			

SUGLASNOST PREDLOŽENOG MENTORA I DOKTORANDA S PRIJAVOM TEME Izjavljujem da sam suglasan s temom koja se prijavljuje. Potpis  Prof.dr.sc., redoviti profesor u trajnom zvanju Nela Vlahinić Potpis  Prof. dr. sc. Blanka Škrabić Perić
--

IZJAVA Izjavljujem da nisam prijavila/o doktorski rad s istovjetnom temom ni na jednom drugom sveučilištu. U Rijeci, 26. 11. 2024. Potpis  Nikolina Blašković M.P.
