



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Atsinaujinančių energetikos išteklių poreikio Lietuvoje prognozavimas

Baigiamasis magistro studijų projektas

Dominykas Dzingelevičius

Projekto autorius

Prof. Dr. Daiva Dumčiuvienė

Vadovė

Dr. Vilma Petrauskienė

Vadovė

Kaunas, 2025



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Atsinaujinančių energetikos išteklių poreikio Lietuvoje prognozavimas

Baigiamasis magistro studijų projektas

Didžiųjų verslo duomenų analitika (6213AX001)

Dominykas Dzingelevičius
Projekto autorius

Prof. Dr. Daiva Dumčiuvienė
Vadovė

Dr. Vilma Petrauskienė
Vadovė

Prof. Dr. Vytautas Snieška
Recenzentas

Doc. Dr. Loreta Saunorienė
Recenzentė

Kaunas, 2025



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Dominykas Dzingelevičius

Atsinaujinančių energetikos išteklių poreikio Lietuvoje prognozavimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Dominykas Dzingelevičius

Patvirtinta elektroniniu būdu

Dzingelevičius Dominykas. Atsinaujinančių energetikos išteklių poreikio Lietuvoje prognozavimas. Magistro studijų baigiamasis projektas / vadovė prof. dr. Daiva Dumčiuvienė; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Taikomoji matematika (Matematikos mokslai).

Reikšminiai žodžiai: atsinaujinanti energetika; poreikio prognozavimas; vartojimo prognozavimas.

Kaunas, 2025. 68 p.

Santrauka

Įgyvendinant žaliajo kurso susitarimus ES valstybėse, tarp jų ir Lietuvoje, stebimas atsinaujinančios energijos suvartojimo augimas. Tokie pokyčiai esmingai keičia valstybių energetikos sektorių struktūrą, lemia nacionalinių įstatymų leidžiamosios ir vykdomosios valdžios institucijų prioritetus, kuria naujas galimybes valstybėms narėms ir keičia jų santykinius pranašumus. Lietuvai ši iniciatyva taip pat suteikia galimybę tapti strateginės reikšmės valstybe, žaliosios energijos eksportuotoja. Todėl svarbu žinoti, kokia yra bendra atsinaujinančių išteklių poreikio valstybėje tendencija ir kokia ji bus ateinančiais metais.

Šios ateities tendencijos prognozuojamos taikant įvairius matematinius metodus: laiko eilučių modelius, ekonometrinius modelius, ARIMA šeimos modelius, pilkuosius modelius ir giluminio mokymosi modelius. Modelių tikslumui vertinti naudojamas išorinis kryžminis patikrinimas, hiperparametrai nustatomi vidinio kryžminio tikrinimo pagalba. Kiekvienos šeimos modeliai atrenkami eksperimentuojant su įvairiomis alternatyvomis ir modifikacijomis pagal vienodus paklaidų matus. Geriausiu modeliu turimų duomenų prognozavimui pripažintas eksponentinis pilkasis modelis EXGM (1,1).

Dzingelevičius Dominykas. Forecasting the Demand for Renewable Energy Resources in Lithuania. Master's Final Degree Project / supervisor prof. dr. Daiva Dumčiuvienė; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology.

Study field and area (study field group): Applied Mathematics (Mathematical Sciences).

Keywords: renewable energy; demand forecasting; consumption forecasting.

Kaunas, 2025. 68 pages.

Summary

With the implementation of the European Green Deal in EU member states, including Lithuania, consumption of renewable energy is on the rise. Such shifts fundamentally transform the structure of national energy sectors, shape the priorities of legislative and executive authorities, create new opportunities for member states and alter their relative advantages. For Lithuania, this initiative also presents the opportunity to become a strategically important country, a net exporter of green energy. Therefore, it is crucial to understand the overall trend in the demand for renewable energy resources within the country and how it will evolve in the upcoming years.

Future trends are forecasted using various mathematical methods: time-series models, econometric models, ARIMA-family models, grey models and deep-learning models. External cross-validation is employed to assess model accuracy, while hyperparameters are tuned via internal cross-validation. Models within each family are selected by experimenting with different alternatives and modifications according to uniform error metrics (MAPE, MAE, RMSE). The exponential grey model EXGM (1,1) proved to be the best model for forecasting the available dataset.

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Įvadas	9
1. Atsinaujinančios energetikos tendencijos ir prognozavimo galimybės	10
1.1. Atsinaujinančios energetikos svarba ir plėtra	10
1.1.1. Atsinaujinančios energetikos reikšmė	10
1.1.2. Pasaulinės ir Lietuvos tendencijos	12
1.1.3. Branduolinės energijos ateitis	13
1.1.4. Atsinaujinančios energetikos reguliavimas ir politiniai aspektai	14
1.2. Atsinaujinančios energetikos poreikio prognozavimo problematika	16
1.2.1. Poreikio prognozavimas energetikos sektoriuje	16
1.2.2. Pagrindiniai iššūkiai ir problemos	17
1.3. Atsinaujinančios energetikos poreikio prognozavimui naudojami modeliai	17
1.3.1. Laiko eilučių modeliai	17
1.3.2. Ekonometriniai modeliai	18
1.3.3. ARIMA modeliai	20
1.3.4. Pilkieji (angl. <i>grey</i>) modeliai	21
1.3.5. Giluminio mokymosi modeliai	22
1.4. Programinės įrangos ir įrankių analizė	24
1.4.1. Specializuoti įrankiai ir jų taikymas	24
1.4.2. Programinė įranga ir algoritmai prognozavimui	25
1.4.3. Reikalavimai modeliams ir programinei įrangai	25
2. Duomenų parinkimas ir žvalgomoji analizė	27
2.1. Duomenų šaltiniai ir statistinė analizė	27
2.2. Duomenų apdorojimas ir paruošimas	28
3. Modelio sudarymas ir prognozavimas	38
3.1. Poreikio prognozavimo modelio sudarymas	38
3.1.1. Laiko eilutės modelis	38
3.1.2. Ekonometrinis modelis	42
3.1.3. ARIMA modelis	47
3.1.4. Pilkasis modelis	50
3.1.5. Giluminio mokymosi modelis	54
3.2. Darbo rezultatai	57
3.3. Siūlymai ir rekomendacijos	62
Išvados	63
Literatūros sąrašas	64

Lentelių sąrašas

1 lentelė. Laiko eilučių modelių tikslumas pagal prognozavimo periodą.....	40
2 lentelė. Vidutinis laiko eilučių modelių tikslumas	41
3 lentelė. Reguliarizavimo metodų tikslumas	45
4 lentelė. Elastinio tinklo modelio rezultatai	46
5 lentelė. ARIMA modelio tikslumas	48
6 lentelė. ELNET-ARIMAX(1,1,0) ($t-4$) modelio tikslumas	48
7 lentelė. ELNET-ARIMAX(1,1,0) modelio tikslumas.....	49
8 lentelė. ARIMA šeimos modelių tikslumas	49
9 lentelė. GM (1,1) modelio tikslumas.....	52
10 lentelė. GM modelių tikslumas	53
11 lentelė. EXGM (1,1) modelio tikslumas	53
12 lentelė. Giluminio mokymosi modelių tikslumas	55
13 lentelė. Modifikuotų LSTM modelių tikslumas.....	56
14 lentelė. Dvikrypčio LSTM modelio tikslumas.....	56
15 lentelė. Modelių tikslumas pagal šeimas.....	58
16 lentelė. EXGM (1,1) modelio ateities prognozės.....	59

Paveikslų sąrašas

1 pav.	Pradinio duomenų masyvo žvalgomoji analizė.....	29
2 pav.	Atrinkto duomenų rinkinio žvalgomoji analizė	31
3 pav.	Atsinaujinančių išteklių dalis bendrame energijos vartojime.....	32
4 pav.	Atsinaujinančios energijos vartojimas Lietuvoje	33
5 pav.	Skirtingų atsinaujinančios energijos rūšių vartojimas Lietuvoje	34
6 pav.	Atsinaujinančių išteklių vartojimo struktūra Lietuvoje.....	35
7 pav.	Atsinaujinančios energijos rūšių vartojimo koreliacija	36
8 pav.	Prognozavimo periodo įtaka tikslumo rezultatams	40
9 pav.	Struktūrinio laiko eilučių modelio rezultatai.....	42
10 pav.	Nepriklausomų kintamųjų kryžminė koreliacija su priklausomu kintamuoju	43
11 pav.	Stacionarių nepriklausomų kintamųjų kryžminė koreliacija su priklausomu kintamuoju ...	44
12 pav.	Elastinio tinklo modelio rezultatai	47
13 pav.	ELNET-ARIMAX(1,1,0) modelio rezultatai	50
14 pav.	GM (1,1) modelio rezultatai	51
15 pav.	EXGM (1,1) modelio rezultatai	54
16 pav.	Dvikrypčio LSTM modelio rezultatai	57

Ivadas

Pagal apibrėžimą, atsinaujinanti energija yra tokia energijos rūšis, kurios „išteklių gamtoje laikui bėgant atsinaujina (natūraliai pasipildo).“ (VZ žodynas) Apie tokios atsinaujinančios energetikos ir tiesiog bendrai apie aplinkosaugos reformų poreikį Europos viešojoje erdvėje plačiai diskutuojama jau ne vieną dešimtmetį, tai pasireiškia tiek per įvairias aktyvių piliečių iniciatyvas, tiek ir per mokslinius tyrimus, analizuojančius ateities klimatą, užterštumą ir kitas gamtines sąlygas. Šios diskusijos ypač suaktyvėjo XX a. 8-ajame dešimtmetyje, kartu su tiek Europoje, tiek ir likusio pasaulio demokratinėse valstybėse besiformuojančiais ekologijos, moterų teisių ir pacifizmo judėjimais.

Pastaruoju laikotarpiu tokio pobūdžio diskusijos yra tapusios kur kas rezultatyvesnėmis ir neabejotinai ryškios to pavyzdys, ypač kalbant apie Europą, yra Europos žaliasis kursas – 2019 metų gruodį Europos Komisijos paskelbtas politinių iniciatyvų ir susitarimų rinkinys, kurio esminis ir galutinis tikslas yra per 30 metų, t.y. iki 2050 metų, užtikrinti poveikio klimatui neutralumą Europos Sąjungoje. Pačiame susitarime yra ir daug įvairių tarpinių tikslų ir terminų, bet apibendrinant visa ši nauja strategija reiškia, kad turi būti peržiūrimos ir pagal poreikį reformuojamos transporto, pramonės, žemės ūkio, aplinkos, klimato ir kitos sritys, įskaitant, be abejo, ir energetikos sritį. O tai savo ruožtu reiškia, kad šie susitarimai nulems reikšmingus pokyčius kiekvienoje valstybėje, paveiks jų ekonomikas, tame tarpe, žinoma, ir Lietuvos ekonomiką. Dėl to yra svarbu analizuoti šiuos būsimus pokyčius ir numatyti jų poveikį iš anksto.

Darbo tikslas: suprognozuoti atsinaujinančios energijos poreikį Lietuvoje.

Tiriamas objektas: metinis atsinaujinančios energijos vartojimas Lietuvoje 1990–2024 m.

Darbo uždaviniai:

1. išnagrinėti ir aptarti atsinaujinančios energetikos sektorių Lietuvoje;
2. apžvelgti praeityje atliktų tyrimų rezultatus ir taikytus matematinius modelius;
3. atrasti tinkamiausią modelį atsinaujinančios energijos poreikio Lietuvoje prognozavimui;
4. suprognozuoti atsinaujinančios energijos poreikį 2024–2027 metais.

1. Atsinaujinančios energetikos tendencijos ir prognozavimo galimybės

Prieš pradėdant nagrinėti aktualius duomenis ir stengiantis išvelgti juose kokius nors dėsningumus, visų pirma derėtų išsiginčinti ne tik geriausią šiai analizei ir prognozavimui taikytiną metodiką, bet ir aptarti pačios atsinaujinančios energetikos subtilumus.

1.1. Atsinaujinančios energetikos svarba ir plėtra

Siekiant aiškumo, pradėti atsinaujinančios energetikos analizavimą reikėtų nuo detalesnio aptarimo, kaip galima suvokti pačią atsinaujinančią energetiką ir jos išteklius. Tiek mokslinėje aplinkoje, tiek ir bendrai žiniasklaidoje, viešojoje erdvėje ši sąvoka yra nagrinėjama įvairiais pjūviais, skirstoma pagal vienokius ar kitokius savo bruožus, kurie, priklausomai nuo konteksto, gali padėti geriau suprasti šį reiškinį ar bent jau aiškiau suformuluoti turimą problemą. Aptarus skirtingas atsinaujinančios energetikos rūšis bus lengviau aptarti ir šios energijos rūšies tendencijas, raidą, taip pat ir teisinio reglamentavimo aspektus.

1.1.1. Atsinaujinančios energetikos reikšmė

Kaip jau minėta, pati atsinaujinančios energetikos išteklių sąvoka yra ganėtinai plati, ją galima skaidyti įvairiais pjūviais, vienas iš kurių, pavyzdžiui, galėtų būti atsinaujinančios energijos kilmė ar susiformavimo šaltinis. Tokį sąrašą, priklausomai nuo siekiamo detalumo, galima sudaryti iš daugybės įvairių energijos rūšių, tačiau įvairioje literatūroje ir moksliniuose darbuose yra nusistovėjęs skaidymas į kelias pagrindines kategorijas, kurios esmingai nulemia atsinaujinančios energijos išteklių gavybą, panaudojimo galimybes ir kitus parametrus:

- saulės energija;
- vėjo energija;
- geoterminė energija;
- hidroenergija;
- biokuro energija;
- įvairių pramoninių ir komunalinių atsinaujinančių atliekų energija.

Svarbu iškart paminėti, kad bendrai vertinant nei vienos iš šių aukščiau paminėtų ar daugelio kitokių energijos rūšių nebūtų galima objektyviai išskirti kaip geriausios, ar tos, į kurią visoms atsinaujinančia energetika besirūpinančioms valstybėms labiausiai reikėtų orientuotis, nes visų pirma kiekvienoje valstybėje itin svarbus veiksnys, nulemiantis atsinaujinančios energetikos vartojimo struktūrą, yra gamtinės sąlygos ir geografinė padėtis.

Šis egzogeninis veiksnys tiesiogiai nulemia valstybės turimų atsinaujinančios energijos išteklių pobūdį ir, per tai, galimus pasirinkimus norint didinti atsinaujinančių išteklių vartojimą. Vienas iš pavyzdžių galėtų būti Šiaurės Europos valstybės, tokios kaip Švedija, kuri pagal 2022 metų Eurostato pateiktą ataskaitą suvartoja santykinai daugiausiai atsinaujinančios energijos visoje ES, virš 65% viso kiekio. Didžiąją dalį šio kiekio sudaro vandens energija tiesiog dėl natūraliai tose teritorijose susiformavusių krioklių. Kitas pavyzdys galėtų būti Islandija, kuri, nors ir nėra Europos Sąjungos valstybė, bet pagal Pasaulio Banko duomenis net virš 82% visos energijos gauna iš atsinaujinančių šaltinių, o konkrečiau elektros energijos atveju šis rodiklis siekia jau 100% - tokį kiekį padeda užtikrinti tiek gausūs vandens energijos ištekliai, visai kaip Norvegijos atveju, tiek ir geoterminė - žemės gelmių šilumos – energija, dėl kurios Islandija turi unikalų kraštovaizdį, garsinantį ją visame pasaulyje.

Grįžtant prie atsinaujinančios energetikos skirstymo, galima išskirti dar vieną pjūvį, kuriuo dažnai yra skaidoma ši energijos rūšis. Jei anksčiau jau aptarėme skaidymą pačios energijos šaltinių prasme, tai atsinaujinančią energetiką taip pat galima skaidyti ir panaudojimo kryptių prasme. Šiuo atveju tokias pačias išskiriamas kategorijas galime rasti tiek oficialiuose teisiniuose Europos Komisijos nutarimuose, tiek įvairiuose moksliniuose tyrimuose, tiek ir oficialiosios statistikos duomenų bazėse. Žinoma, kaip ir išteklių kilmės atveju, esant poreikiui šią energijos rūšį galima skaidyti į daugybę subkategorijų, tačiau pagrindinės šakos yra trys:

- atsinaujinančių išteklių suvartojimas transporto sektoriuje;
- atsinaujinančių išteklių suvartojimas elektros gamybai;
- atsinaujinančių išteklių suvartojimas šildymo ir aušinimo reikmėms.

Būtent toks skirstymas atsirado dėl jau minėtų Europos Komisijos nutarimų, kuriuose yra nustatomos tiek bendro atsinaujinančios energetikos išteklių suvartojimo ribos ir siektini tikslai, tiek ir įvairūs smulkesni pagal panaudojimo pobūdį išskaidyti tikslai, kuriuos turėtų pasiekti kiekviena ES narė valstybė.

Prieš detaliau aptariant skirtingas atsinaujinančios energetikos rūšis svarbu paminėti, kad, kaip pastebi Tsai ir kiti (2016) ar Brodny, Tutakas ir Saki (2020), pati atsinaujinanti energetika savaime nėra jokia panacėja, atnešanti visapusišką gerovę – viena vertus, ji turi akivaizdžių privalumų prieš konvencinio iškastinio kuro energiją dėl savo ekologinės švaros, minimalaus poveikio gamtai ir, svarbiausia, nesibaigiančių resursų, kita vertus, tokios energijos išgavimas pasižymi didelių investicijų poreikiu, aukštais kaštais ir, bent trumpuoju laikotarpiu, žemu efektyvumu. Dėl šių bruožų, anot Brodny, Tutakas ir Saki (2020), valstybėse, kuriose energetikos sektorius yra paremtas iškastinio kuro, tokio kaip anglis ar dujos, naudojimu, perėjimas prie žaliosios energetikos gali būti itin sunkus ir reikalauti ne tik tvirtos politinės valios, bet ir visuomenės daugumos pritarimo.

Kalbant apie neigiamus aspektus, atskirai reikėtų panagrinėti biokuro energiją, kuri nuo pat nepriklausomybės atkūrimo Lietuvos energetikos sektoriuje užima didžiausią naudojamą išteklių dalį. Įprastai biokurui yra priskiriamos įvairios gamtoje ir kasdienėje buityje susidarančios atliekos, kurios vis dar gali būti naudingai panaudotos, pavyzdžiui dumblas, susidarantis valant nuotekas, popierius, pjuvenų briketai, kartonas, sodo atliekos, mediena, parkų ir kitokių želdynų atliekos, gyvulininkystės ir augalininkystės atliekos, ir įvairios likusios komunalinės, gamybinės ir žemės ūkio atliekos. Ši energija yra gaunama sąlyginai nesudėtingai, lyginant su kitomis atsinaujinančios energetikos rūšimis, todėl jos vartojimas paprastai buvo siejamas su besivystančiomis valstybėmis (Acheampongas ir kt., 2016). Kadangi iškastinis kuras yra ribotas gamtinis išteklius, Jungtinių Tautų analitikų prognozėmis jo vartojimo bus visiškai atsisakyta jau šio amžiaus pabaigoje, t.y. po maždaug 75 metų, kuomet jo vietą didžiąja dalimi pakeis atsinaujinanti energetika, o konkrečiau būtent biokuras (Hallas ir Scrase, 1998). Ši energijos rūšis yra išgaunama sąlyginai nesudėtingai, kitaip tariant, lyginant su alternatyviomis atsinaujinančios energijos rūšimis ji nėra tokia imli technologijoms, tačiau pagrindiniai biokuro šaltiniai, tokie kaip miškininkystė – medienos ir pjuvenų briketų šaltinis, ar žemdirbystė – biodyzelino šaltinis, reikalauja didelių laisvų žemės plotų, ūkio veiklai tinkamų gamtinių sąlygų, o taip pat ir trąšų, kurios gali savo ruožtu daryti žalą aplinkai (Acheampongas ir kt., 2016, Ajanovic, 2013, Maradinas, 2020). Atlikti vakarų Europos, JAV ir Pietų Amerikos duomenų tyrimai rodo, kad biokuro energijos vartojimas turi teigiamą tiesinį priežastingumo ryšį valstybių bendrojo vidaus produkto augimui, tačiau nepasižymi statistiškai reikšmingu priežastiniu ryšiu su CO₂ emisijų mažėjimu ir tuo pačiu sukelia reikšmingą žemės ūkio produktų kainų paaugimą (Al-Mulalis, 2014, Apergis ir Payne, 2009, Aslanas, 2015).

Vėjo energija, kita populiari atsinaujinančios energijos rūšis, iš vienos pusės yra itin draugiška aplinkai, nes, anot jau anksčiau atliktų tyrimų, pasižymi mažiausiomis šiltnamio dujų emisijomis per visą jėgainės gyvavimo ciklą (Donesas ir kt., 2004), taip pat, norint šį išteklių panaudoti galutinio produkto gavybai, pvz. elektros gamybai, yra nereikalingas joks kuras, priešingai nei tiek įprasto iškastinio kuro naudojime, tiek ir jau aptarto atsinaujinančio biokuro naudojime (Tarjanne ir Aija, 2008). Iš kitos pusės, vėjo jėgainės pasižymi didžiausiais veiklos ir priežiūros kaštais, didžiausiu imlumu kapitalui, sudėtingomis aukštos kvalifikacijos žinių reikalaujančiomis technologijomis ir yra itin priklausomos nuo gamtos sąlygų – norint įrengti vėjo jėgainę reikia rasti tam palankią vietą, kuri pasižymi stipriais vėjo gūsiomis, kurios neplanuojama urbanizuoti ir uždengti dirbtinėmis kliūtimis, ir galų gale net ir tai negarantuoja pastovios elektros gamybos, nes pats gamybos procesas vis tiek lieka visiškai priklausomas nuo kasdinių oro sąlygų.

Saulės energija, taip pat populiari atsinaujinančios energijos rūšis, yra pakankamai plačiai aptarinėjama mokslininkų ir dažnai vertinama, kaip daug potencialo turintis energijos išgavimo metodas, tačiau taip pat pasižymintis tam tikrais unikaliais bruožais. Kaip pastebi Sampaio ir Gonzalezas (2016), tyrinėjantys saulės jėgaines iš inžinerinės ir konstrukcinės pusės, saulės energijos išgavimo sritis yra apskritai viena iš labiausiai vystomų, prioritetinių gamybos sričių visame pasaulyje, nes, nepaisant turimo potencialo, pasižymi ir keliais neigiamais aspektais, kurie gali nulemti alternatyvių energijos išgavimo metodų pasirinkimą. Iš teigiamos pusės, visų pirma, žinoma, saulės jėgainės, priešingai nei iškastinio kuro naudojimas, energijos generavimo metu neteršia aplinkos, neskatina klimato kaitos, globalaus atšilimo ir nekelia kitokios žalos gamtai. Taip pat iš saulės spindulių išgaautos energijos nebereikia perdirbti, transportuoti, o tai supaprastina patį energijos naudojimo procesą (Razykov ir kt., 2011). Lyginant su kitomis atsinaujinančios energijos jėgainėmis, saulės energija yra išgaunama daug tyčiau už vėjo jėgaines, kur besisukančios turbinos kelia didelį triukšmą, todėl saulės baterijas galima montuoti tiesiog gyvenamosiose zonose, ant pastatų stogų, o taip pat energijos išgavimas yra pigesnis už hidroelektrinių gavybą, nereikalauja keisti aplinkos – keistu upių tėkmės, užtvindyti galimai naudingų teritorijų. Kita vertus, saulės jėgainės vienam išgautam elektros vienetui sunaudoja 64 kartus daugiau materialių resursų, 7 kartus daugiau žmogiškųjų resursų ir 10 kartų daugiau kapitalo, nei branduolinė jėgainė (Sampaio ir Gonzalezas, 2016). Galimą saulės jėgainių neefektyvumą rodo ir pats gamybos principas, visiškai priklausomybė nuo gamtinių sąlygų ir debesuotumo – jei dienos trukmė neilga, o ir pati diena debesuota, išgaunami energijos kiekiai bus minimalūs. Kaip galimą nepatogumą vartotojams Sampaio ir Gonzalezas (2016) įžvelgia ir nuolatinės priežiūros būtinybę – dulkėms ar kitokiems nešvarumams patekus ant saulės modulių, šių našumas krenta, todėl juos reikia valyti, taip pat naudojimas karštame klimate gali reikalaus papildomų investicijų, nes nors saulės baterijoms reikia tiesioginių saulės spindulių, aukšta temperatūra turi neigiamą poveikį jų efektyvumui, todėl gali reikėti papildomai įrengti aušinimo ar kitokias karščio panaudojimo sistemas.

1.1.2. Pasaulinės ir Lietuvos tendencijos

Prieš tęsiant teisinio reglamentavimo aptarimą vertėtų atskirai pažvelgti į atsinaujinančios energetikos naudojimo raidą. Žinoma, svarbiausia šiuo atveju yra aptarti Lietuvos duomenis, tačiau norint geriau suvokti kontekstą ir gebėti objektyviai palyginti rezultatus ne vien laiko ašies, bet ir skerspjuvio prasme, vertėtų kartu panagrinėti pasaulines ar europines tendencijas.

Šioje vietoje dar kartą atsiskleidžia nagrinėjamos temos svarba ir aktualumas – reikiamos informacijos paieškas gali palengvinti tiek įvairios valstybinės institucijos, pavyzdžiui nacionalinės

statistikos institucijos ar ministerijos, tiek ir tarptautinės institucijos ar organizacijos, tokios kaip Eurostatas, Tarptautinė energijos agentūra ar Tarptautinė atsinaujinančios energijos agentūra. Šios institucijos ar organizacijos turi savo analitikų ir ekspertų komandas, kurios rengia įvairaus periodiškumo apžvalgas su ekspertiniais paaiškinimais, leidžiančias geriau suprasti nagrinėjamą temą.

2021 metais Tarptautinės energijos agentūros atliktoje Lietuvos apžvalgoje pastebima, kad 2004 m. ir 2009 m. uždarius abu Ignalinos atominės elektrinės reaktorius Lietuva iš elektros eksportuotojos tapo importuotoja, šį energijos trūkumą didžiąja dalimi užpildydama dujų ir biokuro energija. Tai leido užsitikrinti palankesnę situaciją ilguoju laikotarpiu, nes, kaip pastebi analitikai, jau 2014 metais Lietuva pasiekė savo 2020 metams iškeltus atsinaujinančios energijos vartojimo tikslus ir perteklinio atsinaujinančių išteklių vartojimo kreditus pardavinėjo Liuksemburgui. 2024 metais bendras Lietuvos energetikos agentūros ir JAV Nacionalinės atsinaujinančios energetikos laboratorijos specialistų atliktas tyrimas parodė, kad iš esmės Lietuva yra pajėgi pasiekti 100% atsinaujinančios energijos naudojimą jau 2030 metais. Svarbu paminėti, kad kurdami skirtingus 2030 metų scenarijus energetikos ekspertai akcentuoja palankias sąlygas saulės ir vėjo energijos gavybai Lietuvoje ir taip pat pastebi, kad tęsiant atsinaujinančios energetikos gamybos plėtrą pagal numatytus terminus Lietuva vėl turėtų tapti šalimi eksportuotoja, išgaunančia daugiau energijos, nei reikia vidiniam vartojimui.

Kalbant apie globalias tendencijas, į energetikos sritį orientuoto analitinio centro (angl. think-tank) Ember ekspertų Rosslowe ir Petrovich (2025) atlikta 2024 metų analizė rodo, kad nepaisant politinių ir ekonominių iššūkių ES energetikos sektorius tvirtai žengia atsinaujinančios energetikos link – saulės jėgainių sukuriamas energijos kiekis pirmą kartą pranoko anglies energiją, iš dujų gaunamos energijos kiekis nuolat mažėja jau penktus metus ir, kartu su anglies energija, savo apimtimi siekia tik pusę ankstesnio 2007 metų piko dydžio ir yra istorinėse žemumose. Didžiąja dalimi šis energijos kiekis yra kompensuojamas atsinaujinančios energetikos šaltiniais, o tai viena vertus leidžia įgyvendinti politinius ES tikslus – nepriklausomybę nuo Rusijos Federacijos iškastinių išteklių eksporto – ir, kartu, teikia ekonominę naudą – ekspertų skaičiavimu, per pirmąją Ursulos von der Leyen Europos Komisijos kadenciją 2019-2024 m. Europos valstybės sutaupė apie 59 mlrd. eurų, iš kurių 53 milijardai būtų buvę skirti iškastinių dujų importui ir likę 6 milijardai anglies importui.

1.1.3. Branduolinės energijos ateitis

Apžvelgus atsinaujinančios energijos rūšis, jų ypatybes ir tendencijas, vertėtų atskirai aptarti branduolinę energiją ir jos problematiką. Kaip jau minėta, pagal apibrėžimą atsinaujinančia yra vadinama tokia energija, kurios ištekliai gamtoje laikui bėgant atsinaujina, todėl pagal šį apibrėžimą branduolinę energiją reikėtų priskirti prie įprastų iškastinio kuro energijos rūšių. Kita vertus, jei prioritetu laikytume ne pačią naudojamą energijos šaltinio kilmę, bet galutinį rezultatą, t.y. sukuriamą energijos kiekį ir dėl jo į aplinką išskiriamą teršalų kiekį, tokiu atveju branduolinę energiją galėtume laikyti turinčia panašumų su atsinaujinančiais energijos ištekliais.

Kaip pastebi McCombie ir Jeffersonas (2016), branduolinė energija yra ženkliai pranašesnė už kitas iškastinio kuro energijos rūšis. Šie autoriai lygino įvairių atsinaujinančių šaltinių – vėjo, saulės, vandens, biokuro – poveikį aplinkai ir lygino jį su branduoline energija. Mokslininkų teigimu, vertinant visą energijos gamybos procesą nuo pat jėgainės statybų iki proceso pabaigoje susidariusių atliekų tvarkymo, išmetamų anglies dvideginio emisijų kiekis branduolinių jėgainių ir saulės ar vėjo elektrinių atveju yra pakankamai panašus, o gali būti net mažesnis. Autoriai pastebi, kad visuomenėse

vyrauja neigiamas emocijomis paremtas požiūris į branduolinę energiją dėl galimų pasekmių avarijos atveju, tačiau realybėje ši rizika yra daug labiau kontroliuojama. Kaip esminį šios energijos rūšies privalumą autoriai išskiria stabilumą – jau minėta, kad atsinaujinančių išteklių panaudojimas priklauso nuo gamtinių ir geografinių sąlygų, klimato, tuo tarpu branduolinės energijos atveju ši problema yra kur kas mažiau aktuali ir jėgainėse galima užtikrinti nuolatinį, nepertraukiamą energijos tiekimą reikiamais kiekiais. Šių metų sausį Tarptautinės energetikos agentūros ekspertų atliktoje branduolinės energijos perspektyvų analizėje (IEA, 2025) teigiama, kad branduolinės energijos ignoruoti tikrai nederėtų – pasaulinis elektros suvartojimas dėl modernių technologijų vystymosi yra itin greitai augantis, per pastarąjį dešimtmetį padvigubėjęs, todėl ir branduolinės energijos vartojimas yra aukščiausias nuo pat naftos krizės XX a. 8-ajame dešimtmetyje. Ekspertai atkreipia dėmesį, kad naujų reaktorių statyba yra koncentruota Kinijoje ir Rusijoje ir pagal dabartines tendencijas Kinija aplenkė JAV ir Europą pagal savo branduolinės energijos pajėgumus jau 2030 metais. Tačiau ekspertai akcentuoja, kad tai gali lemti strateginį Kinijos pranašumą energetikos srityje, nes, pagal autorių prognozes, bent jau iki 2040 metų tiek Europoje, tiek Jungtinėse Amerikos Valstijose, tiek Kinijoje branduolinė energija išliks pačia pigiausia energijos rūšimi.

Jau minėtų Tarptautinės energetikos komisijos ekspertų teigimu, taip pat ir Hongo ir kt. (2017) ar Thellufseno ir kt. (2024), reikšmingu technologiniu proveržiu branduolinės energetikos srityje galima laikyti mažuosius modulinius reaktorius (angl. *small modular reactor, SMR*). Šios rūšies reaktoriai, kaip jau sufleruoja pavadinimas, yra mažesnės galios, generuojantys nuo 10 iki 350 megavatų energijos (palyginimui, vienas Ignalinos atominės elektrinės reaktorius RBMK-1500 generuodavo 1500 megavatų energijos), atitinkamai mažesni ir dydžio prasme, o tai išsprendžia kelis dažniausiai keliamus branduolinių jėgainių trūkumus – sumažinama net ir itin mažą tikimybę turinčios avarijos sukeliama žala, sumažinamas imlumas investicijoms, nes mažų modulių reaktorių statyba yra atitinkamai pigesnė, nei įprastų atominės elektrinės reaktorių, taip pat užtikrinamas patogesnis energijos tiekimas – nedideli reaktoriai gali būti statomi, pavyzdžiui, prie pat duomenų centrų, taip užtikrinant nuolatinį ir nepriklausomą nuo bendro tinklo trikdžių energijos tiekimą.

Žvelgiant į anksčiau aptartas atsinaujinančios energetikos tendencijas reikėtų pastebėti, kad šios ekspertų vertinimu patraukliai atrodančios technologijos yra dar vystymo stadijoje. Tarptautinės energetikos komisijos ekspertai pastebi, kad didžiausią finansavimą šios srities moksliniams tyrimams ir eksperimentinei plėtrai skiria Jungtinės Amerikos Valstijos, nuo kurių ne itin atsilieka tiek Kinija, tiek ir pavienės Europos šalys, tokios kaip Prancūzija, Čekija, Lenkija ar Rumunija. Prognozuojama, kad pirmieji mažieji moduliniai reaktoriai savo pilną operacinį pajėgumą galėtų pasiekti 2030 metais ir tai galėtų būti viena iš priemonių, padedančių ES valstybėms mažinti išmetamų teršalų kiekį ir užtikrinti žaliojo kurso tikslų įgyvendinimą. Tai atsispindi ir Europos Komisijos požiūryje – dar 2023 metais buvo paskelbta mažųjų modulių reaktorių deklaracija, kurioje numatoma remti šios srities mokslinius tyrimus. Iš kitos pusės, Lietuvoje ši technologija taip pat galėtų būti panaudojama priklausomybės nuo importuojamos energijos mažinimui – Energetikos ministerijos atstovai periodiškai pamini, kad domisi šios srities progresu, galimybėmis ir galimu mažųjų reaktorių panaudojimu šalyje.

1.1.4. Atsinaujinančios energetikos reguliavimas ir politiniai aspektai

Jau minėta, kad pagrindinis viso žaliojo kurso susitarimas yra iki 2050 metų užtikrinti poveikio klimatui neutralumą, tačiau kitas, artimesnis ir ne mažiau svarbus atskaitos taškas yra 2030 metai, kuriems keli iš Europos Komisijos nutartų tikslų yra šie:

- sumažinti išmetamų teršalų ir šiltnamio efektą sukeliančių dujų kiekį visoje Europos Sąjungoje bent 55%, lyginant su 1990 metų lygiu;
- išplėsti saugomas teritorijas tiek sausumoje, tiek jūrose;
- sumažinti žemės ūkyje naudojamų pesticidų kiekį ir jų daromą žalą, taip atstatant nualintas ekosistemas;
- plėsti miškingų teritorijų plotus, pasodinant juose 3 milijardus naujų medžių;
- optimizuoti geležinkelių naudojimą, paversti jį patrauklesniu krovinių gabenimams;
- sumažinti naujų automobilių išmetamų teršalų kiekį 55%, o naujų furgonų išmetamų teršalų kiekį 50%;
- pasiekti 45% atsinaujinančių išteklių energijos suvartojimą.

Visų šių išvardytų ir likusių tikslų pasiekimui Europos Komisija ir Europos Vadovų Taryba yra numačiusios kelias į skirtingas kryptis orientuotas strategijas, tokias kaip prisitaikymo prie klimato kaitos strategiją, kurioje numatoma užtikrinti geresnį duomenų rinkimą ir dalijimąsi, priimamus sprendimus grįsti gamtos procesais, taip didinant atsparumą klimato kaitai, ir pačio prisitaikymo prie klimato kaitos integravimą į makrofiskalinę politiką. Kita strategija yra vadinama biologinės įvairovės strategija, ji yra orientuota į gamtai sukeliamos žalos mažinimo iniciatyvas, žemės ūkio pertvarkas. Taip pat yra strategija „Nuo ūkio iki stalo“, kurios esmė yra užtikrinti tvarų maisto naudojimą visame šio proceso cikle, pradedant jau paminėtu žemės ūkiu, tačiau taip pat skatinant ir tvarų vartojimą, sveikesnę mitybą ir mažesnį išmetamo nesuvartoto maisto kiekį. Aktualiausios nagrinėjamai temai yra dvi, pramonės ir žiedinės ekonomikos strategijos, kurios siekia kartu sustiprinti aplinkos apsaugą, tvarumą ir žiediskumą, šiuo atveju reiškiantį žiedinių gamybos ir vartojimo sistemų veikimą, arba, dar kitaip, visuose gamybos ir vartojimo ciklo žingsniuose susidarančių atliekų perdirbimą ir bendrą atliekų kiekio mažinimą.

Grįžtant prie pačios atsinaujinančios energetikos, šioje srityje nubrėžtus tikslus pakeitė ir pastarųjų metų geopolitiniai įvykiai. 2022 metų vasario pabaigoje prasidėjus plataus masto Rusijos invazijai Ukrainoje, jau tų pačių metų gegužę buvo priimti sprendimai atsisakyti priklausomybės nuo rusiško iškastinio kuro ir teikti papildomą paramą įvairiems atsinaujinančios energetikos skatinimo projektams. Šis veiksmų planas, pavadintas „REPowerEU“, anot Europos Komisijos, tuo pačiu metu yra orientuotas iškart į du tikslus – viena vertus, skatinti švarios, atsinaujinančios energijos gamybą ir turėti įvairius tokios energijos tiekimo šaltinius, kita vertus, mažinti Rusijos eksporto pajamas, o per tai karo Ukrainoje finansavimą, ir taip pat, kaip jau minėta, bendrai mažinti Europos valstybių priklausomybę nuo Rusijos gamtinių išteklių importo.

Ankstesniame skyriuje paminėti Ember analitinio centro ekspertai 2019-2024 m. periodą išskiria ne veltui – tai yra pirmoji Ursulos von der Leyen vadovaujamos Europos Komisijos kadencija. Įprastai išrinkus naujus EK narius būna pristatomi būsimų penkerių metų prioritetai ir kaip tik ši Europos Komisijos kadencija iškėlė Europos žaliąjį kursą kaip esminį prioritetą, nustatantį būsimų darbų kryptis. Esminiai šios iniciatyvos tikslai buvo iki 2030 m. sumažinti ES šiltnamio dujų emisijas bent 55%, lyginant su 1990 m. lygiu ir iki 2050 m. tapti pirmu klimatui neutraliu kontinentu. Ankstesniame skyriuje jau glaustai aptarta, kaip šiuos įsipareigojimus pavyksta įgyvendinti praktiškai, bet reikia pastebėti, kad politiniai ir ekonominiai veiksniai gali pakeisti minėtus susitarimus.

2024 m. pabaigoje Ursula von der Leyen buvo perrinkta antrai pirmininkavimo Europos Komisijoje kadencijai, o tai iš pirmo žvilgsnio turėtų suponuoti darbų tęstinumą ir tolimesnį pirmos kadencijos

susitarimų laikymąsi. Tačiau, 2025 m. pradžioje, pristačius pagrindines būsimos kadencijos darbų kryptis ir tikslus, paaiškėjo, kad žaliasis kursas nebėra esminis prioritetas. Prioritetiniais darbais šioje kadencijoje numatytas gynybos pramonės ir saugumo stiprinimas, ES valstybių konkurencingumo stiprinimas ir demokratinų vertybių puoselėjimas. Žinoma, tai nereiškia visiško žaliojo kurso idėjų atsisakymo, tačiau, kaip pastebi Maly (2024), Lilkovas (2023), Mišikas (2024) ar Almeida ir kt. (2023), Europos žaliasis kursas trumpuoju laikotarpiu gali turėti neigiamų pasekmių ES valstybėms ir dėl to būti keičiamas – dėl griežtinamų iškastinio kuro naudojimo sąlygų nuo tokio kuro priklausomos valstybės ar aukšta energijos paklausa pasižymintys jų verslo sektoriai gali nukentėti. Autorių teigimu, valstybėms atsiranda skubus poreikis investuoti į atsinaujinančios energijos gavybą, o tai gali nulemti aukštesnes gamybos kainas pramonės įmonėms ir taip silpninti jų tarptautinį konkurencingumą. Vienas ryškiausių to pavyzdžių, anot Mišiko (2024), būtų Slovakija – ši valstybė nuo pat Rusijos Federacijos plataus masto invazijos į Ukrainą pradžios 2022 metais nesiėmė esminių pokyčių savo energetikos sektoriuje ir išlaikė itin stiprią priklausomybę nuo Rusijos eksportuojamo iškastinio kuro. Dėl to ši valstybė skeptiškai vertina žaliojo kurso susitarimus ir yra sulaukusi priekaištų iš Europos Komisijos ir kitų ES institucijų dėl nepakankamai vykdomų įsipareigojimų.

Kita vertus, 2025 m. vasario pabaigoje Europos Komisija paskelbė Švarios pramonės kursą, iš esmės tiesiogiai atliepiantį konkurencingumo užtikrinimo prioritetą ir jį detalizuojanti. Dokumente aiškinama, kad esminis veiksnys, neigiamai veikiantis ES valstybių konkurencingumą, yra priklausomybė nuo iškastinio kuro importo. Skatinti įmonių konkurencingumą siūloma dvejomis esminėmis kryptimis – skiriant iki 100 mlrd. eurų aukštą energijos paklausą turintiems verslo sektoriams palaikyti ir papildomai investuojant į atsinaujinančios energijos gavybą, taip dar labiau mažinant priklausomybę nuo iškastinio kuro importo ir užtikrinant didesnę atsinaujinančios energijos išgavimą pačioje ES. Nors ir neturėdamas konkrečių laiko ašyje apibrėžtų tikslų šis priemonių paketas rodo, kad atsinaujinanti energetika vis dar yra laikoma Europos Sąjungos stiprybe, kuri ilguoju laikotarpiu atneš naudą, tačiau trumpuoju laikotarpiu yra jautri geopolitiniais iššūkiams.

1.2. Atsinaujinančios energetikos poreikio prognozavimo problematika

Jau aptarėme, kad atsinaujinančios energetikos poreikį tiek Lietuvoje, tiek visoje ES veikia globalūs veiksniai ir didelė dalimi ateities poreikis yra politinio apsisprendimo klausimas. Nepaisant to, ateities poreikio prognozavimas yra būtinas, siekiant numatyti galimus iššūkius ar problemas, taip pat ir identifikuoti valstybių stiprybes. Be prognozių, rodančių įsipareigojimų užtikrinimo rezultatus, energetikos sektorius gali susidurti su tiekimo nestabilumu, energijos deficitu ir ekonominiais nuostoliais.

1.2.1. Poreikio prognozavimas energetikos sektoriuje

Kaip pastebi Teixeira ir kt. (2024), visas energetikos sektorius yra sunkiai prognozuojamas, nes gali būti priklausomas nuo įvairių globalių ir vidinių procesų, tokių kaip jau paminėti geopolitiniai procesai, socialiniai pokyčiai, politinių pažiūrų kaita, tarptautiniai konfliktai, taip pat didelė dalimi gali pasižymėti nepastovumu dėl įvairių ekonominių veiksnių, pavyzdžiui makroekonominės aplinkos. Ruhnau ir kt. (2020) teigimu, toks nagrinėjamo proceso kompleksiskumas lemia, kad norint iš prognozių gauti apčiuopiamos naudos, dažnai reikia bendrų matematiko ir ekonomisto kompetencijų, reikia analizuoti procesų tarpusavio ryšius taikant sudėtingus matematinius modelius, dažnai net individualiam nagrinėjamam atvejui kuriant atskiras modelių variacijas ir patobulinimus.

1.2.2. Pagrindiniai iššūkiai ir problemos

Prieš detaliau aptariant ir palyginant prognozavimui naudojamus modelius galima panagrinėti bendrus iššūkius, su kuriais susiduria mokslininkai, modeliuodami energetikos rodiklių poreikį. Remiantis įvairių autorių (Dingo ir kt. (2022), Inmano ir kt. (2013), Aslamo ir kt. (2021) pastebėjimais, agreguoto poreikio, t.y. apimančio kelias skirtingas energetikos rūšis, prognozavimas gali turėti dideles paklaidas dėl jau paminėto procesų kompleksiskumo. Pavyzdžiui, įvairios mokestinės lengvatos ar kitokių formų valstybinės subsidijos gali būti nepastovios laike, nuolat kintančios, turinčios skirtingą poveikį skirtingoms energetikos šakoms, todėl gali atsirasti būtinybė skaidyti nagrinėjamą procesą į atskiras energetikos šakas ir tik tuomet tęsti tolimesnį modeliavimą. Iš kitos pusės, toks smulkinimas gali sukelti papildomų duomenų prieinamumo problemų – gali būti sunku rasti pakankamą imtį stebėjimų, kurie leistų kurti sudėtingus, daug kintamųjų apimančius modelius. Dingas ir kt. (2022) pastebi, kad neturint pakankamos apimties duomenų rinkinio tyrėjai gali būti apriboti modelių pasirinkime ir turėti pasirinkimą tik iš specialių mažoms imtims skirtų modelių, o tai, savo ruožtu, taip pat gali kelti problemų ir nulemti nepakankamai aukštą modelių tikslumą.

1.3. Atsinaujinančios energetikos poreikio prognozavimui naudojami modeliai

Nagrinėjant ankstesnių mokslininkų tyrimų problematiką galima pastebėti, kad nėra visiškai universalių iššūkių, su kuriais susidurtų visi tyrėjai. Nagrinėdami tą patį procesą mokslininkai modelių kūrimo metu renkasi skirtingus kelius, susiduria su skirtingomis problemomis ir priima skirtingus sprendimus joms spręsti. Todėl, apžvelgus teorinę dalį ir prieš pradedant nagrinėti pačius duomenis, būtų pravartu detaliau panagrinėti jau anksčiau atliktus tyrimus – apžvelgti ir palyginti ankstesnių tyrimų autorių pasirinktus duomenis ir pritaikytus modelius, palyginti juos tarpusavyje įvairiais tikslumo kriterijais, pasigilinti į jų specifiką ir galimas problemas. Tokia mokslinės literatūros analizė leistų ne tik identifikuoti potencialiai geriausius prognozavimo modelius šio tyrimo duomenims, bet taip pat ir suteiktų galimybę palyginti būsimus rezultatus ir jų tikslumo įverčius su kitų valstybių rezultatais, kitaip tariant platesniame kontekste.

Viename tokių straipsnių Indijos mokslininkai Suganthi ir Samuelis (2011) pastebi, kad prieš du ir daugiau dešimtmečių buvo paplitęs metodas prognozuoti energijos poreikius remiantis apklausomis. Tyrėjai atlikdavo reprezentatyvias visuomenės apklausas, kuriose aiškindavosi namų ūkių energijos vartojimo įpročius, ateities lūkesčius, taip pat bendro pobūdžio rodiklius, tokius kaip namų ūkio finansinė padėtis, amžius, užimtumas, šeimyninis statusas ir kiti, o atlikę apklausas prognozuodavo ateities paklausą remiantis šiais atsakymais. Kaip pastebi ir kiti autoriai, pvz. Aslamas ir kt. (2021), tokie metodai taikomi vis rečiau ir pirmenybė yra teikiama matematiniams prognozavimo modeliams, kuriuos galima išskaidyti pagal rūšis ir aptarti detaliau.

1.3.1. Laiko eilučių modeliai

Šiai rūšiai priskiriami modeliai pasižymi pakankamai nesudėtinga matematine konstrukcija, pvz. primityviausi vidurkių arba naivių lūkesčių modeliai, atsitiktinio klaidžiojimo su poslinkiu, naivių lūkesčių su sezoniškumu modeliai, ar santykinai sudėtingesnės konstrukcijos eksponentinio glodinimo modelis. Nors, kaip pastebi Nafilas ir kt. (2020) ar Inmanas ir kt. (2013), tokie modeliai susilaukia kritikos dėl savo paprastumo ir, numanoma, žemo tikslumo, tačiau praktika rodo, kad analizuojamiems duomenims gali nepavykti pritaikyti sudėtingų modelių ir tuomet šie modeliai tampa geriausiais įmanomais – tokius modelius savo tyrimuose naudoja Aras, H. ir Aras, N. (2010),

Turkijos mokslininkai, dujų suvartojimo tyrimui pritaikę pirmos eilės autoregresijos modelį, taip pat ir Izraelio energijos suvartojimą tyrinėję Barguras ir Mandelis (1981), kurie ateities reikšmes prognozavo remiantis tiesiniu laiko eilutės tendencija.

Žvelgiant į panašaus pobūdžio tyrimus galima matyti, kad iš šios rūšies modelių neabejotinai populiariausias yra eksponentinio glodinimo modelis. Nafilas ir kt. (2020) savo tyrime pastebi, kad toks modelis pasižymi geromis paaiškinamumo savybėmis, kuomet yra analizuojami istoriniai duomenys, tačiau pašalinus dalį stebėjimų ir atlikus kryžminį patikrinimą šio modelio prognozavimo tikslumas buvo menkesnis už lygiagrečiai išbandytus sudėtingesnius matematinius modelius, todėl galutiniam prognozavimui jis buvo atmestas. Kita vertus, kaip ir anksčiau aptartų modelių atveju, ne visada pavyksta pritaikyti sudėtingus ir aukštesnį tikslumą pasiekiančius modelius, tokiu atveju eksponentinis glodimas tampa geriausiu pasirinkimu – tiek Arroyo ir kt. (2007), tiek Badri ir kt. (1997) savo tyrimuose pasirinko būtent šį modelį.

1.3.2. Ekonometriniai modeliai

Šiai rūšiai priskiriami modeliai visų pirma pasižymi aukštesniais reikalavimais – jei paprastiems laiko eilučių modeliams tereikia vieno nagrinėjimui pasirinkto priklausomo kintamojo, kuris modelio pagalba yra analizuojamas ir prognozuojamas pagal savo paties savybes, tokias kaip tiesinio augimo tendą, sezoniškumą, ankstesnių laikotarpių reikšmes ir kt., tai ekonometrinių modelių esminis skirtumas pasireiškia papildomai į modelį įtraukiant egzogeninius nepriklausomus kintamuosius. Toks papildomų duomenų įtraukimas į modelį gali padėti geriau paaiškinti priklausomą kintamąjį, o per tai ir geriau prognozuoti jo ateities reikšmes. Tai ypač aktualu šios nagrinėjamos temos kontekste, nes net ir be papildomų tyrimų galima numanyti, kad atsinaujinančios energetikos vartojimas nėra visiškai atskiras, su kitais ekonominiais ar energetiniais procesais nesusijęs reiškinys. Vien tai, kad kelis pastaruosius metus viešojoje erdvėje vis daugėja diskusijų apie privačių saulės elektrinių įsirengimą, sufleruoja, kad bendras atsinaujinančios energetikos vartojimas gali priklausyti net ir nuo valstybės ekonomikos lygio ar gyventojų ekonominės gerovės. Namų ūkiai, gaunantys didesnes pajamas ir turintys daugiau santaupų, ko gero galėtų būti labiau suinteresuoti skirti dalį savo išteklių tokių saulės elektrinių įsirengimui ir ilguoju laikotarpiu patrauklesnės atsinaujinančios energetikos vartojimui.

Nagrinėjant jau atliktus tyrimus visų pirma verta paminėti, kad šios rūšies modeliams rasti praktinių pavyzdžių yra pastebimai lengviau. Kaip teigia O’Neillas ir Desai (2005), JAV valstybinių institucijų atliekamos energijos poreikio prognozės paprastai remiasi dviejų egzogeninių kintamųjų reikšmėmis - valstybės bendrojo vidaus produkto ir energijos naudojimo intensyvumu. Iš jų pirmasis įprastai būna perprognozuojamas, o energijos naudojimo intensyvumas – priešingai – prognozuojamas mažesnis, nei vėliau iš tiesų stebima. Dėl šių netikslumų ir energijos suvartojimas dažniausiai būna prognozuojamas žemesnis, nei iš tiesų. Tokie modeliai taikomi ir siauresnėms sritims, pvz. vien tik elektros energijos suvartojimui prognozuoti, kur galima rasti tiek ilgojo laikotarpio poreikio prognozavimo pavyzdžių (Al-Hamadi ir Solimanas, 2005), tiek ir trumpojo laikotarpio tyrimų, atliktų Haida ir Muto (1994) ar Charytoniuko ir kt. (1998).

Konkrečiau nagrinėjant pasirenkamus išorinius kintamuosius galima matyti, kad su energetika susiję procesai yra pasirenkami pakankamai dažnai ir yra naudingi energijos vartojimui prognozuoti – Honkongo mokslininkų Lamo ir kt. (2007) tyrime buvo nagrinėjamas atskirai namų ūkių ir verslo sektoriaus energijos suvartojimas 1979–2006 metais, o į tyrimą buvo įtraukti penki nepriklausomi

fizikiniai kintamieji – saulės radiacija, oro užterštumo indeksas, vėjo greitis, aplinkos temperatūra ir temperatūra, fiksuojama atsižvelgiant į aplinkos drėgnumą. Atlikus pagrindinių komponentų analizę buvo nustatyta, kad šių kintamųjų įtraukimas leidžia paaiškinti 66–84% namų ūkių sunaudojamos energijos variacijos ir net 78–96% verslo sektoriaus sunaudojamos energijos variacijos.

Toliau apžvelgiant tyrimuose naudojamus egzogeninius kintamuosius galima pastebėti, kad modelių sudarymas įtraukiant įvairius makroekonominis procesus kaip nepriklausomus kintamuosius taip pat yra pakankamai populiarus ir, sprendžiant pagal ankstesnių tyrimų rezultatus, suteikia naudos užtikrinant sudaromų modelių tikslumą. Pavyzdžiui, Turkijos mokslininkai Tunc ir kt. (2006), taip pat ir Yumurtaci ir Asmaz (2004) nagrinėjo ir prognozavo Turkijos elektros energijos suvartojimą, savo regresiniuose modeliuose remdamiesi tokiais nepriklausomais egzogeniniais kintamaisiais kaip energijos suvartojimas vienam gyventojui, gyventojų skaičius ir gyventojų prieaugis. Papildomai verta paminėti, kad statistiškai reikšmingas ryšys su į modelį įtrauktu nepriklausomu kintamuoju gali pasireikšti ne vien tiesine forma – pavyzdžiui, prancūzų mokslininkai Bessec ir Fouquau (2008), tyrinėdami elektros paklausos ir aplinkos temperatūros tarpusavio ryšius 15-oje pasirinktų Europos Sąjungos valstybių, nustatė, kad tarp šių dviejų procesų egzistuoja statistiškai reikšmingas netiesinis ryšys, kuris ypač pasireiškia šiltesniu klimatu pasižyminčiose pietinės Europos valstybėse. Rezultatų interpretavimo prasme toks netiesinio ryšio egzistavimas atrodo pakankamai logiškas, nes teigia, kad nagrinėjama elektros vartojimo paklausa bendrai priklauso ne vien nuo nominalaus temperatūros pokyčio, bet ir nuo temperatūros lygio, kuriame pokytis įvyksta.

Galima rasti ir daugiau egzogeninių kintamųjų, kurie skirtinguose tyrimuose yra nustatomi kaip statistiškai reikšmingai susiję su energijos vartojimu:

- valstybės bendrasis vidaus produktas (Intarpravich ir kt., (1996), Shahbaz ir kt. (2020), Troster ir kt. (2018);
- užsienio prekybos balansas (Intarpravich ir kt., (1996), Adebayo ir kt. (2021), Kilinc-Ata (2016);
- energijos išteklių kaina (Intarpravich ir kt., (1996), Arsenault ir kt. (1995), Shahbaz ir kt. (2020), Fumo ir Biswas (2015), Troster ir kt. (2018), Ghalehkhondabi ir kt. (2016);
- gyventojų pajamos (Arsenault ir kt. (1995), Fumo ir Biswas (2015), Adebayo ir kt. (2021), Kilinc-Ata (2016);
- gyventojų skaičius (Shahbaz ir kt. (2020), Fumo ir Biswas (2015);
- vidutinė aplinkos temperatūra (Fumo ir Biswas (2015), Ghalehkhondabi ir kt. (2016);
- investicijos į mokslinius tyrimus ir eksperimentinę plėtrą (Przychodzen ir Przychodzen (2020);
- energijos subsidijos (Przychodzen ir Przychodzen (2020), Kilinc-Ata (2016);
- kainų reguliavimo indeksai (Przychodzen ir Przychodzen (2020);
- urbanizacijos rodikliai (Ghalehkhondabi ir kt. (2016).

Dalies šių straipsnių autoriai pastebi, kad, kaip jau aptarta ankstesniame skyriuje, nagrinėjant individualių valstybių duomenis išskyla įvairių specifinių iššūkių – skirtingose valstybėse tiek atsinaujinančios, tiek bendros energetikos poreikį gali lemti visiškai skirtingi procesai ir veiksniai, nebūdingi kitoms valstybėms, todėl vieno universalaus modelio ar regresorių rinkinio, kuris tiktų daugeliui valstybių, nėra. Šiuo atveju galima tik spėti, kad artimiausi Lietuvos duomenims modeliai gali būti taikomi kaimyninėse valstybėse, tokiose kaip Lenkija, Latvija ar Estija, tiek dėl bendro Europos Sąjungos teisinio reglamentavimo, tiek ir dėl pačių valstybių panašumo gyventojų socialinių, kultūrinių įpročių prasme, valstybių raidos, išsivystymo ir ekonomikos lygio prasme.

1.3.3. ARIMA modeliai

Abiejų anksčiau aptartų rūšių – laiko eilučių ir ekonometrinių – modelių apibendrinimu galime laikyti šiuos ARIMA modelius. Savo populiariausiu autoregresiniu integruotu slankiųjų vidurkių (angl. *autoregressive integrated moving average*) pavadinimu ši modelių šeima tarsi atspindi tik paprastesnių laiko eilučių modelių dalį, kur pagal savo paties atributus (ilgalaikę augimo tendenciją, autoregresiškumą ir kt.) yra nagrinėjamas vienintelis priklausomas kintamasis. Kita vertus, praplėtę modelį iki SARIMA kartu įvertiname ir sezoniškumo komponentės svarbą laiko eilutėje, o papildomai pridėję egzogeninių kintamųjų matricą, gauname SARIMAX modelį, kuris leidžia nagrinėjamą laiko eilutę įvertinti visais aspektais – tiek atsižvelgti į pačią eilutę būdingas savybes, tiek ir įvertinti ryšius, nebūtinai tiesinius, su kitais egzogeniniais veiksniais.

Anot Suganthi ir Samuelio (2011) ar Chavezo ir kt. (1999), dėl šio universalumo modelis yra pakankamai populiarus mokslinėje literatūroje ir vertinamas kaip vienas iš paprastesnių metodų pasiekti aukštus tikslumo įverčius. Turkijos mokslininkai Volkanas ir kt. (2006) pritaikė paprastą tiesinės regresijos, ARIMA ir SARIMA modelius iškastinio kuro poreikiui nagrinėti ir gauti rezultatai parodė, kad prognozuojant pagal atskiras iškastinio kuro rūšis geriausiai pasirodė ARIMA šeimos modeliai – naftos gavybai nustatytas reikšmingas sezoniškumas, todėl modelis buvo praplėstas į SARIMA. Edigeris ir kt. (2005) taip pat pritaikė ARIMA modelius Turkijos energetikai tyrinėti ir savo tyrime nustatė, kad nagrinėjant atskiras energetikos šakas gaunami modeliai pasižymi didesnėmis paklaidomis, nei bendros energijos paklausos modelis, tačiau apibendrinto modelio tikslumas jau buvo patenkinamas ir ARIMA modeliai pripažinti tinkami tokiems procesams prognozuoti. Šios šeimos modeliai gali būti naudojami ne vien tik poreikiui, bet ir energetikos išteklių kainoms ir jų elastingumui prognozuoti, kaip tai atliko tiek Erdogdu (2010), tiek ir Conejo ir kt. (2005), ar tiesiog elektros apkrovai prognozuoti, kaip Cho ir kt. (2002) ar Pappas ir kt. (2008) tyrimuose.

Kita vertus, Nafilo ir kt. (2020) atliktame Maroko energijos paklausos tyrime buvo išbandyti trys modeliai – eksponentinio glodinimo, laikino priežastingumo ir ARIMA. Šio tyrimo metu ARIMA modelis, kaip ir eksponentinio glodinimo, nepasižymėjo aukštais tikslumo rezultatais ir buvo pripažintas netinkamu. Tačiau, kaip pastebi patys autoriai, žemas modelio tikslumas pasireiškė tik Maroko duomenų kontekste ir, reikia atkreipti dėmesį, kuriant šį modelį nebuvo įtraukti jokie egzogeniniai kintamieji, kurie galėtų pagerinti modelio tikslumą. Čia verta paminėti Alharbi ir Csala (2022) tyrimą, kuriame buvo nagrinėjamas vėjo greitis ir saulės radiacija. Tyrimas buvo pradėtas nuo paprasto ARIMA modelio, tačiau identifikavus ir reikšmingą sezoniškumą, ir kelis reikšmingus oro sąlygas apibūdinančius išorinius kintamuosius, buvo sudarytas galutinis SARIMAX modelis, kuris pasiekė aukštesnius tikslumo rezultatus. Panašūs rezultatai gauti ir nagrinėjant Pietų Korėjos saulės radiaciją – Alsharifas ir kt. (2019) lygindami ARIMA ir SARIMA modelių rezultatus dar kartą patvirtino, kad sezoniškumas yra būdingas tokio pobūdžio duomenims ir šiuo atveju SARIMA modelis pasiekė aukštesnį tikslumą. Tokių rezultatų galima rasti ne vien saulės ar vėjo energijos sektoriuose – JAV dujų gamybą ir suvartojimą nagrinėję Manigandanas ir kt. (2021) prognozavimui pritaikė SARIMA ir SARIMAX modelius ir lyginant tikslumo rezultatus paaiškėjo, kad egzogeninių veiksnių, tokių kaip oro sąlygų duomenys ar makroekonominiai rodikliai, įtraukimas į modelį leido pasiekti aukštesnius įverčius.

Trumpai apibendrinant, šie skirtingų mokslinių tyrimų pavyzdžiai rodo, kad ARIMA modelių šeima turi potencialo pagerinti tiek laiko eilučių modelių, tiek ir ekonometrinių modelių tikslumo rezultatus,

tačiau tam reikia skirti daugiau pastangų – atskirai įvertinti sezoniskumą, jei jis būdingas analizuojamiems duomenims, taip pat atidžiau paieškoti tarpusavio priežastingumo ryšių su kitais ekonominiais ar energetiniais procesais ir įtraukti juos į modelį.

1.3.4. Pilkieji (angl. *grey*) modeliai

Ankstesniuose skyriuose aptartus modelius galima vadinti tradiciniais, jie yra plačiai aptarinėjami ir sėkmingai taikomi įvairiose srityse, tačiau pasižymi vienu bendru trūkumu – reikalauja pakankamo kiekio istorinių duomenų, kurie ne visada gali būti prieinami. Nors šiame darbe nagrinėjamas energetikos sektorius savo ruožtu yra itin svarbus valstybės funkcionavimui ir paprastai valstybinės institucijos kaupia istorinius duomenis, tačiau, kaip pastebi Teixeira ir kt. (2024), specifinio pobūdžio duomenų rinkimas gali būti per brangus tiek laiko, tiek kaštų prasme, gali būti sunku surinkti patikimus duomenis. Dėl šių priežasčių mokslininkams savo tyrimuose kartais tenka naudoti pilkuosius modelius (GM), kurių pagrindinis privalumas, kaip pastebi Zhou ir Dingas (2020), ir yra galimybė prognozuoti turint ne visą informaciją ar nedidelį jos kiekį, arba tiesiog nežinant tyrinėjamų duomenų skirstinio.

Kaip pastebi Liu ir kt. (2016), pats modelių pavadinimas pilkieji (angl. *grey*) atskleidžia modelių vietą ar savotišką kompromisą tarp juodųjų (angl. *black*), reiškiančių visišką informacijos trūkumą ar nepatikimumą, ar baltųjų (angl. *white*), kuriuose yra prieinama visa reikalinga informacija. Tokių ne visiškai apibrėžtų procesų nagrinėjimas ir modelių taikymas gali būti laikomas atskira duomenų mokslo kryptimi, vadinama pilkąja teorija (angl. *grey theory*). Šią kryptį, anot Tsai ir kt. (2016), galima skaidyti į kelis pilkuosius procesus, kuriuos dar galima pavadinti veiksmų seka: generavimą (t. y. duomenų kaupimą, aproksimavimą ir išskleidimą), tarpusavio santykių analizę, modelio kūrimą, prognozavimą, sprendimų priėmimą ir kontrolę.

Kalbant apie pačių modelių kūrimą, mokslininkai (Ding ir kt. (2017), Zhou ir kt. (2020) išskiria tris pagrindines pilkųjų modelių, arba tiesiog GM, rūšis:

- GM(1,1) – pagrindinis pilkasis modelis, skirtas vienai laiko eilutei prognozuoti, rezultatui gauti pakanka vos 4 stebėjimų;
- GM(1,N) – pirminis modelis su papildomai įtrauktais nepriklausomais kintamaisiais;
- GM(0,N) – modelis neskirtas prognozuoti, o tik ryšiui tarp įtrauktų kintamųjų nustatyti.

Žinoma, kaip ir anksčiau aptartų ARIMA šeimos modelių atveju, pilkieji modeliai taip pat retai yra taikomi savo pradinėje formoje ir jiems egzistuoja daug įvairių modifikacijų, kurias tyrėjai individualiai parenka nagrinėjamoms laiko eilutėms siekdami gauti aukštesnius tikslumo rezultatus.

Liu ir Wu (2020) nagrinėdami Austrijos, Čekijos, Vengrijos ir Lenkijos atsinaujinančios energijos suvartojimo duomenis išbandė kelis skirtingus modelius: Holt – Winters eksponentinio glodinimo, GM modelį, taip pat ir kelias jo modifikacijas CFDGM – atitinkantį trupmeninį diskretųjį pilkąjį modelį (angl. *conformable fractional discrete grey model*), FGM – trupmeninį pilkąjį modelį (angl. *fractional grey model*) ir savo pačių sukurtą ANDGM – gretutinį nehomogenišką diskretųjį pilkąjį modelį (angl. *adjacent non-homogeneous discrete grey model*). Pastarajame modelyje yra pakeičiamas duomenų kaupimo procesas, sukuriant naują akumuliuoto generavimo operatorių, kuris, autorių nuomone, geriau įvertiną duomenų neapibrėžtumą ir netiesiškumą, ir dėl to pasižymi geresniais tikslumo įverčiais prognozuojant ateities rezultatus. Reikia atkreipti dėmesį, kad šiuo atveju GM modeliai buvo taikomi dėl pasirinkto 2008 – 2016 metus apimančio periodo ir metinės reikšmės turinčio kintamojo, nulemiančio tik 8 turimus stebėjimus. Panašias išvadas pateikė Liu ir kt.

(2014) tyrimas, kuriame trims skirtingiems Kinijos ir Taivano ekonomikos procesams prognozuoti buvo taikomas tradicinis GM(1,1) modelis ir jo modifikacijos RM-GM – slenkančio mechanizmo pilkasis modelis (angl. *rolling-mechanism grey model*) ir PRGM – PSO paremtas slenkančio mechanizmo pilkasis modelis (angl. *PSO-based rolling-mechanism grey model*). Pastarasis pačių autorių sukurtas modelis pasižymėjo pastebimai aukštesniais tikslumo įverčiais, nes, kaip teigia autoriai, geba geriau įvertinti tiek ilgalaikes procesų tendencijas, tiek ir trumpalaikius svyravimus. Kita vertus, tokia modelyje parametrai gaunami iteracijų pagalba, taikant euristinius metodus, todėl ir patys autoriai pripažįsta, kad egzistuoja galimybė pakliūti į lokalaus ekstremumo spąstus ir negauti optimalių parametru.

Kita vertus, galima pažvelgti į tyrimus, kuriuose pagrindiniai GM(1,1) modeliai lyginami su tradiciniais regresiniais modeliais, pvz. ARIMA. Wangas ir kt. (2017), nagrinėdami ketvirtinius Kinijos hidroelektrinių generacijos duomenis ateičiai prognozuoti, išbandė paprastą GM(1,1) modelį, SARIMA modelį ir modifikuotą DGGM(1,1) – duomenų grupavimu paremtą pilkąjį modelį (angl. *data grouping based grey model*). Rezultatai parodė, kad su 2011 m. 1 ketv. – 2015 m. 4 ketv. periodo imtimi, sudarančia 20 stebėjimų, SARIMA ir GM(1,1) modelių vidutinė absoliuti procentinė paklaida siekia 22,1% ir 22,2%, kitaip tariant, esminio skirtumo tarp jų nėra. Pasiūlytas DGGM(1,1) patobulinimas išskaidė laiko eilutę į 4 dalis pagal kiekvieną ketvirtį ir tuomet kiekvienai grupei atliko GM(1,1) prognozavimą, o tai jau nulėmė MAPE rodiklio sumažėjimą iki 16,2%. Reikia atkreipti dėmesį, kad SARIMA modelio autoriai patobulinti nebandė, pvz. įtraukiant papildomus išorės veiksnius. Kita vertus, žvelgiant į šio tyrimo rezultatus galima susidaryti nuomonę, kad turint jau šiek tiek didesnę duomenų imtį, nei minimalūs 4 stebėjimai, pagrindinis GM modelių pranašumas nebetenka svarbos ir tradicinių regresinių modelių taikymas taip pat gali būti tinkamas sprendimas. Kitas pavyzdys galėtų būti Yuano ir kt. (2016) tyrimas, kuriame Kinijos energijos suvartojimui prognozuoti vėl buvo išbandyti GM(1,1) ir ARIMA modeliai. Gauti tikslumo rezultatai ir vėl buvo pakankamai panašūs, tačiau autoriai atkreipė dėmesį, kad jų pritaikytas ARIMA(2,1,1) modelis labiau linkęs laikytis ilgalaikės tendencijos ir mažiau svyruoja pagal trumpalaikius nukrypimus, tuo tarpu GM(1,1) modelis lengviau paveikiamas trumpalaikių svyravimų ir todėl gali būti labiau tinkamas trumpalaikiam prognozavimui. Siekdami pagerinti tikslumo įverčius autoriai dar pritaikė hibridinį GM-ARIMA modelį, abiejų modelių prognozėms paprasčiausiai suteikdami 0,5 koeficiento svorį ir sudėdami gautus rezultatus. Tokia nesudėtinga modifikacija leido pagerinti prognozavimo tikslumą ir yra pavyzdys, kad tradicinių regresinių modelių ir GM šeimos modelių nereikėtų laikyti konkuruojančiais tarpusavyje, jie gali būti sujungti ir tinkamai papildyti vienas kitą.

1.3.5. Giluminio mokymosi modeliai

Nagrinėjant su energetika susijusius mokslinius tyrimus, ypač pastarojo dešimtmečio, nesunku pastebėti, kad dalyje tyrimų vienokia ar kitokia forma yra panaudojamas dirbtinis intelektas ir neretai yra pabrėžiama mašininio mokymosi modelių svarba. Dalis tokių modelių yra skirta klasterizavimui ir kategorizavimui, todėl šiuo atveju nėra svarbūs, įvairūs regresiniai modeliai jau buvo aptarti ankstesniuose skyriuose, tačiau ne mažiau svarbią ir ypač šiuo metu populiarią mašininio mokymosi dalį užima giluminis mokymasis. Paprastai ši sąvoka reiškia juodosios dėžės (angl. *black box*) modelius, kurių sandara nėra iki galo išreikšta ir tiksliai žinoma. Tokie modeliai, kaip paaiškėja lyginant juos su įprastais regresiniais modeliais, turi ir savitų privalumų, ir kartu trūkumų. Esminis trūkumas, nulemtas pačios juodosios dėžės konstrukcijos, yra neaiškūs sąryšiai tarp nagrinėjamų kintamųjų. Jei tradiciniame regresijos modelyje, pvz. ARIMA, gavus lygties koeficientus galima aiškiai pasakyti, kaip nepriklausomas kintamasis veikia priklausomą kintamąjį, tai taikant giluminio

mokymosi atvejus interpretacija yra kur kas sudėtingesnė ir tiksliai įvardinti poveikio nepavyksta. Kita vertus, kaip pastebi Wangas ir kt. (2019), toks interpretuojamumo paaukojimas suteikia galimybę pasiekti geresnius tikslumo įverčius prognozuojant ateities reikšmes, nes modelis, pvz. neuroninių tinklų, pats mokosi pagal pateiktus istorinius duomenis, lengviau prisitaiko prie sudėtingesnių netiesinių tarpusavio sąryšių.

Teixera ir kt. (2024) apžvelgdami neuroninių tinklų modelių taikymą atsinaujinančios energetikos prognozavimui išskiria keturis ANN – dirbtinių neuroninių tinklų (angl. *artificial neural network*) pritaikymo etapus: istorinių duomenų rinkimą ir sutvarkymą; duomenų normalizavimą; išskaidymą į mokymo, validavimo ir testavimo imtis; modelio struktūros parinkimą. Aslamas ir kt. (2021) atkreipia dėmesį, kad modelio struktūros parinkimas yra itin svarbus žingsnis, savo ruožtu priklausantis nuo turimų duomenų kiekio ir nulemiantis būsimo modelio tikslumą. Inmanas ir kt. (2013) pabrėžia, kad patys dirbtinio intelekto modeliai nėra naujiena, nes buvo pradėti kurti dar 1950-ųjų pradžioje, tačiau iki pat 1980-ųjų išliko santykinai nepopuliarūs dėl savo skaičiavimo sudėtingumo, kurį buvo sunku atlikti tuometiniais kompiuteriais. Vėliau, net ir tobulėjant kompiuterių pajėgumams, ANN modeliai išliko pakankamai paprasti – neuronų tinklą be įėjties ir išeities sluoksnių paprastai sudarydavo tik vienas paslėptas sluoksnis, nes daugiau sluoksnių turinčius modelius pritaikyti tuometinėmis technologijomis vis dar buvo sudėtinga.

Nagrinėjant pastarojo laikotarpio tyrimų rezultatus, pvz. Alpackaya ir kt. (2024), kur atsinaujinančios energetikos poreikio prognozavimui buvo pritaikytas tradicinis ARIMA modelis ir du neuroninių tinklų modeliai – CNN – konvoliucinis neuroninių tinklų modelis (angl. *convolutional neural network*) ir RNN – rekurentinis neuroninių tinklų modelis (angl. *recurrent neural network*), galima įsitikinti, kad sudėtingesni savo sandara neuroninių tinklų modeliai tikrai gali pralenkti tradicinius regresinius modelius. Viena vertus, neuroninių tinklų modeliai pasiekė net keliolika procentų geresnius tikslumo rezultatus, kita vertus autorių taikytas ARIMA modelis nebuvo visiškai pritaikytas nagrinėjamai laiko eilutei, pvz. įtraukiant sezoniskumą ar praplečiant modelį egzogeniniais kintamaisiais, o tai, kaip jau įsitikinome anksčiau, gali lemti prastesnius ARIMA tikslumo rezultatus.

Bentis ir kt. (2023), nagrinėję atsinaujinančios energetikos generavimą taikant mašininio ir giluminio mokymosi modelius dar kartą pabrėžia neuroninių tinklų taikymo dvipusiškumą – iš vienos pusės geriau atpažįstamus sudėtingus netiesinius tarpusavio ryšius duomenyse ir tikslesnius prognozavimo rezultatus, iš kitos pusės sudėtingą interpretavimą ir duomenų trūkumo problemą. Šie mokslininkai atkreipia dėmesį, kad norint pritaikyti sudėtingesnius neuroninių tinklų modelius, t.y. turinčius daugiau paslėptų sluoksnių tarp įėjties ir išeities, yra reikalingi dideli kiekiai duomenų, nes kitaip gaunami rezultatai gali būti nestabilūs ir pasižymėti didelėmis paklaidomis. Tai reiškia, kad neuroninių tinklų modeliai yra tarsi savotiška anksčiau aptartų GM modelių priešingybė, kurie kaip tik išsiskyrė savo gebėjimu atlikti laiko eilutės prognozavimą turint vos 4 stebėjimus.

Reikia taip pat paminėti, kad neuroninių tinklų modeliai gali būti įvairių formų – jau anksčiau buvo paminėti RNN ir CNN modeliai, kurie skiriasi nuo bendrojo ANN modelio savo skaičiavimo metodu, bet tokių alternatyvų galima išskirti ir dar daugiau. Khortsriwongas ir kt. (2023) nagrinėdami Tailando saulės energijos generavimo duomenis išbandė po kelis paprastus ir hibridinius neuroninių tinklų modelius, tokius kaip jau minėti RNN ir CNN, o taip pat LSTM – ilgos trumpalaikės atminties modelį (angl. *long short-term memory*), GRU – blokuojančių rekurentinių vienetų modelį (angl. *gated recurrent units*), BiLSTM – dvikryptį ilgos trumpalaikės atminties modelį (angl. *bidirectional long short-term memory*), BiGRU – dvikryptį blokuojančių rekurentinių vienetų modelį (angl.

bidirectional gated recurrent units) ir jų junginius CNN-LSTM, CNN-BiLSTM, CNN-GRU. Pritaikius visus modelius ir lyginant tikslumo rezultatus paaiškėjo, kad trumpalaikėms vienos dienos prognozėms šiuo atveju geriausiai tinka hibridinis CNN-BiGRU modelis, tuo tarpu ilgesnėms vienos savaitės prognozėms paprastas BiLSTM modelis išlaikė aukščiausią tikslumą. Iš vienos pusės tai rodo, ką pabrėžia ir autoriai, kad su šiandieniniais kompiuteriais nebėra sudėtinga taikyti įvairius neuroninių tinklų modelius, todėl galima išmėginti daug skirtingų rūšių, iš kitos pusės sudėtingesni hibridiniai metodai nebūtinai suteikia aukštesnį tikslumą ir gali užtekti vieno paprasto modelio.

Kalbant apie hibridinius modelius, Kumaris ir Toshniwalas (2021) saulės energijos gavybos procesui pritaikė paprastus CNN, LSTM, GRU, RNN ir DNN modelius ir finale palygino jų tikslumą su hibridinio CNN-LSTM modelio tikslumu. Rezultatai parodė, kad aukščiausiais tikslumo rezultatais pasižymi būtent hibridinis CNN-LSTM, pasiekdamas apie 20% aukštesnius tikslumo rezultatus nei likę modeliai. Autoriai nagrinėdami visų modelių veikimą pastebi, kad hibridinis modelis apjungia kelių modelių privalumus, pvz. CNN gebėjimą tiksliau išgauti duomenų erdvines savybes ir LSTM gebėjimą geriau identifikuoti duomenyse esančias ilgalaikes tendencijas, tačiau paprastai dėl to nukenčia skaičiavimo greitis – tokių modelių įvertinimas tampa sunkesnis, reikalauja daugiau laiko ir galingesnės įrangos, o didžiųjų duomenų nagrinėjimas gali būti pernelyg brangus tiek kaštų, tiek reikalaujamo laiko prasme. Dar atskirai galima paminėti Karakano (2024) atliktą atsinaujinančios energetikos gamybos prognozavimo tyrimą, kuriame buvo pritaikyti ir paprasti LSTM ir GRU neuroninių tinklų modeliai, ir hibridiniai CNN-LSTM, CNN-RNN, LSTM-GRU, CNN-GRU, ir tradicinis SARIMA modelis. Šio tyrimo rezultatai vėlgi parodė, kad hibridiniai modeliai pasižymi aukštesniais tikslumo įverčiais, šiuo atveju geriausią rezultatą parodė CNN-GRU modelis, pasiekęs apie 30% geresnį tikslumą nei SARIMA. Kita vertus, reikia paminėti, kad autorius šiuo atveju SARIMA modelio neišplėtė egzogeniniais kintamaisiais, kurie, tikėtina, būtų sumažinę tikslumo atotrūkį.

1.4. Programinės įrangos ir įrankių analizė

Apžvelgus skirtingas tyrimuose taikytas metodikas ir prieš pereinant prie duomenų analizės dalies būtų naudinga trumpai aptarti programinę įrangą, kuri taikoma energetikos prognozavimo tyrimuose. Nagrinėjant jau minėtus tyrimus galima pastebėti, kad įprastai mokslininkai savo darbuose nesigilina į programinės įrangos pritaikymo detales ar problematiką, tačiau galima rasti užuominų ar komentarų, kurie padeda nusimatyti galimas technines problemas tyrinėjant artimą sritį.

1.4.1. Specializuoti įrankiai ir jų taikymas

Visų pirma galima atkreipti dėmesį, kad tam tikriems panašaus pobūdžio darbams gali būti pritaikomi ir specifiniai, konkrečiam tikslui sukurti įrankiai. Paprastai tokie įrankiai palengvina ir paspartina atliekamą tyrimą, tačiau sukelia papildomų apribojimų. Galima išskirti 3 populiarius įrankius:

- **LEAP** – žemų emisijų analizės platforma (angl. Low Emissions Analysis Platform), sukurta Stokholmo aplinkos instituto tyrėjų. Šis įrankis skirtas energetikos politikos pokyčių analizei, klimato kaitos tyrinėjimams. Įrankio pagalba galima kurti skirtingus scenarijus ir analizuoti galimą šiltnamio dujų taršą, iškastinių išteklių gavybą, energijos gamybą. Autorių teigimu (SEI, 2025) modelis leidžia intuityviai kurti energetikos sistemas ir atlikti makroekonominį modeliavimą ir yra skirtas vidutinio ir ilgo periodo prognozėms, siekiančioms 20–50 metų.
- **HOMER** – hibridinis kelių energijos resursų optimizavimas (angl. Hybrid Optimization of Multiple Energy Resources) – yra įrankis, kurio pagalba galima optimizuoti skirtingų

atsinaujinančių energijos šaltinių panaudojimą tame pačiame tinkle. Įrankis leidžia identifikuoti ir iš anksto numatyti galimas problemas dėl tiekimo svyravimų, pvz. numatyti energijos trūkumus, jei dėl gamtos sąlygų svyruotų vėjo ar saulės energijos generavimas. Įrankio pagalba identifikuojant problemines vietas galima ne tik užtikrinti reikiamo kiekio energijos tiekimą, bet ir pasiekti mažiausius energijos generavimo kaštus, tinkamomis proporcijomis naudojant atsinaujinančius išteklius.

- **PLEXOS** – įrankis skirtas modeliuoti energetikos sistemas sujungiant visų rūšių energiją, tiek atsinaujinančią, tiek paremtą iškastiniu kuru, į vieną tinklą. Kuriant skirtingas simuliacijas įrankio pagalba taip pat galima identifikuoti problemines ir stipriąsias sritis, optimaliai paskirstyti išteklių naudojimą ir planuoti ateities plėtrą ar taršos mažinimą. Šis įrankis leidžia kurti ne tik ilgalaikes prognozes, kaip LEAP atveju, bet ir trumpalaikius valandinius scenarijus.

Visi trys aptarti įrankiai yra pažangūs, modernūs ir jų aktualumas ypatingai atsiskleidžia Europos žaliojo kurso kontekste, kuomet reikia rasti optimalius sprendimus mažinant išskiriamų teršalų kiekį. Iš kitos pusės, šie įrankiai yra skirti iš esmės energetikos ekspertams ir sprendimų priėmėjams, nes leidžia be rimtų programavimo žinių gilintis ir modeliuoti technines energetikos sektoriaus detales, politinių sprendimų įtaką, suteikia informacijos, kaip optimaliai paskirstyti energetikos išteklių vartojimą, kad sektorius būtų subalansuotas. Taip pat, iš praktinės pusės, šie specializuoti įrankiai yra mokami, jiems reikalingos licencijos, o tai papildomai apriboja jų panaudojimą moksliniuose darbuose.

1.4.2. Programinė įranga ir algoritmai prognozavimui

Turint omenyje, kad specializuoti energetikos nagrinėjimo įrankiai yra mokami ir gali būti naudojami tik pakankamai siauros srities problemoms spręsti, nenuostabu, kad pastarųjų metų tyrimuose dominuoja iš esmės trys platesnio profilio įrankiai: atviro šaltinio R ir Python programavimo kalbos, taip pat MATLAB platforma.

Galima rasti bet kurio iš trijų paminėtų įrankių sėkmingų pritaikymo atvejų pavyzdžių, pvz. Cabrerros ir kt. (2020) ar Kolentino ir kt. (2009) energetikos sektoriaus tyrimai taikant MATLAB, Upadhyay ir kt. (2024) tyrimas apjungiant MATLAB ir Python, ar Ulazios ir Ibarra-Berastegui (2016) vėjo ir hidroenergijos tyrimas taikant R. Atskirai paminėti verta Nanfacko ir kt. (2022) paskelbtą apžvalgą, kurioje kaip tik nagrinėjamas programavimo kalbų pritaikomumas energetikos sektoriaus problemoms spręsti. Autoriai pastebi, kad pastaruoju metu Python yra dažniausiai naudojama programavimo kalba energetikos tyrimuose, tačiau neįvardija jos kaip geriausios, visoms populiariausioms programinėms įrangoms atranda tiek savitų privalumų, tiek trūkumų, ir iš esmės teigia, kad taikoma programinė įranga turėtų būti laisvas paties autoriaus pasirinkimas.

1.4.3. Reikalavimai modeliams ir programinei įrangai

Taigi kalbant apie programinę įrangą galime daryti išvadą, kad nėra svarbu, kuri laisvai prieinama programavimo kalba bus taikoma, nes konkrečios programinės įrangos pasirinkimas tyrimo eigai esminės įtakos neturės. Šioje vietoje svarbu tik apsibrėžti universalius reikalavimus, kurie tyrimo metu būtų taikomi nepriklausomai nuo pasirinkto įrankio: gaunami rezultatai, tiek kokios nors vizualizacijos, tiek skaitiniai įverčiai turėtų būti aiškūs, suprantami ir interpretuojami, galutinis sudarytas prognozavimo modelis turėtų būti korektiškas ir tenkinti teorines prielaidas bei reikalavimus, modelių pagalba gaunami rezultatai turėtų būti tarpusavyje palyginami universaliais

tikslumo matais ir galiausiai pageidautina, kad galutinio modelio pagalba gautos ateities prognozės pasižymėtų patenkinamais tikslumo rezultatais, lyginant su anksčiau atliktais kitų valstybių tyrimais.

2. Duomenų parinkimas ir žvalgomoji analizė

Prieš kuriant prognozavimo modelį reikėtų atlikti žvalgomąją duomenų analizę, kurios pagalba būtų galima geriau suprasti turimus duomenis, identifikuoti jų savybes ir charakteristikas. Tam visų pirma reikia pasirinkti konkretų duomenų rinkinį, nes šiuo atveju pasirinkimas yra pakankamai platus – įvairių su nagrinėjama tema susijusių duomenų galima rasti tiek Valstybės duomenų agentūros (iki 2023 m. Lietuvos statistikos departamentas) ar Energetikos ministerijos, tiek Eurostato, tiek ir įvairių kitų tarptautinių organizacijų, tokių kaip Tarptautinė energetikos agentūra ar Tarptautinė atsinaujinančios energetikos agentūra, duomenų bazėse. Nemaža dalimi šie pateikiami duomenys persidengia, ypač Eurostato ir Valstybės duomenų agentūros atveju, tačiau galima rasti ir ganėtinai specifinių, siauroje srityje detalizuotų duomenų, pvz. analitinio centro Ember duomenų bazėje.

2.1. Duomenų šaltiniai ir statistinė analizė

Visą viešai prieinamų duomenų imtį iš esmės galima skirstyti pusiau pagal dvi savybes – prasmę ir periodiškumą. Pastaruoju atveju prieinami duomenys yra arba metiniai, arba, elektros energijos atveju, valandiniai – dažniausiai naudojami elektros rinkos kainai ir apkrovai prognozuoti. Prasmės atveju, nors ir galima rasti importo ir eksporto duomenų, kurie, beje, prieinami ir mėnesinio periodiškumo formoje, didžioji dalis duomenų daugiausiai skirstoma į energijos gamybą ir energijos sunaudojimą. Žinoma, formaliai abu dydžiai yra itin susiję, tačiau nagrinėjamos temos atveju derėtų rinktis energijos sunaudojimą, nes, pagal Valstybės duomenų agentūros pateikiamą metodologijos paaiškinimą, šis rodiklis rodo „kurą ir energiją, pateiktą galutiniams vartotojams: pramonės, statybos, žemės ūkio, kitų ekonominės veiklos rūšių įmonėms ir namų ūkiams“. Kitaip tariant, matematine prasme, šis rodiklis atspindi ne tik gamybą, bet ir importo bei eksporto santykį, ir valstybės teritorijoje sukauptų energijos atsargų panaudojimą.

Būtent dėl atsargų kaupimo dalies šį vartojimo rodiklį galime laikyti savotiška realizuota paklausa – pats gamybos procesas dar nerodo tikslios paklausos, importo pridėjimas ir eksporto atėmimas suteikia jau kiek tikslesnį vaizdą, bet rodo labiau galutinę pasiūlą, kuri nėra tas pats, kas rinkos paklausa, tačiau įvertinus sukauptų atsargų pasikeitimą gauname realų energijos poreikio valstybėje kiekį – jei valstybėje pagaminama ir importuojama per mažai energijos, nei rinkoje pageidaujama įsigyti – panaudojami valstybėje sukaupti rezervai ir vartotojų paklausa patenkinama, iš kitos pusės, jei valstybėje pagamintas ir importuotas energijos kiekis yra per didelis, o eksportu turimų resursų sumažinti nepavyksta, perteklius paprasčiausiai lieka atsargomis.

Aptarę, kad tikslių energijos paklausos duomenų viešose duomenų bazėse nėra pateikiama ir šiuo atveju energijos suvartojimo duomenys būtų geriausi, tiksliausiai apibūdinantys nagrinėjamą reiškinį, galime dar pastebėti, kad kituose panašaus pobūdžio tyrimuose yra taip pat nagrinėjamas energijos suvartojimas – tokius duomenis rinkosi pvz. Turkijos duomenis nagrinėję Yucesanas ir kt. (2021), Kinijos rinką nagrinėję Tsai ir kt. (2016) ar Manigandanas ir kt. (2021), nagrinėję JAV energetikos sektoriaus duomenis.

Lietuvos atveju detalūs suvartojimo duomenys yra pateikiami tiek Valstybės duomenų agentūros, tiek Eurostato duomenų bazėse, tačiau dėl patogumo pasiekiant duomenis patogiau šaltiniu pasirinkti Eurostatą – kai kuria programine įranga, pvz. R, galima pasiekti Eurostato duomenų bazę tiesiogiai, išvengiant laiką užimančio duomenų atsisiaunimo ir rankinio formatavimo įkėlimui į R aplinką. Šiai konkrečiai temai patogiausias duomenų rinkinys yra „Pilnas energijos balansas“ (angl. „*Complete energy balances*“), vidiniu Eurostato kodu žymimas kaip „nrg_bal_c“. Šiame rinkinyje talpinama

įvairi informacija – valstybių energijos duomenys, tokie kaip gamyba ar vartojimas, importas, eksportas, atsargų pasikeitimas, taip pat gamyba ir vartojimas gali būti nagrinėjami detaliau, išskaidant rodiklius į smulkesnes dalis pagal ištekliaus gamybos ar vartojimo paskirtį. Pagal standartizuotą tarptautinį energijos produktų klasifikatorių taip pat galima rinktis skirtingas energijos išteklių rūšis, apimančias tiek įvairų iškastinį kurą, pvz. įvairių rūšių anglį, dujas, taip pat atsinaujinančius išteklius, tokius kaip vėjo ar vandens energija. Kaip jau minėta anksčiau, duomenys yra metinio periodiškumo, o stebėjimai pateikiami nuo pat 1990 m.

2.2. Duomenų apdorojimas ir paruošimas

Jau aptarėme, kad svarbus Eurostato duomenų bazių privalumas yra galimybė pasiekti duomenis tiesiogiai per programinę įrangą. Šiuo atveju duomenų analizei bus naudojama R programa, todėl reikiamus energijos balanso duomenis galime pasiekti pačių duomenų mokslo specialistų, tyrėjų sukurto „eurostat“ paketo pagalba. Pats duomenų įkėlimas užtrunka porą minučių, o gautą duomenų rinkinį sudaro 7 stulpeliai ir virš 38 milijonų eilučių:

Data Frame Summary

nrg_bal_c

Dimensions: 38329986 x 7

Duplicates: 0

No	Variable	Stats / Values	Freqs (% of Valid)	Graph	Valid	Missing
1	freq [character]	1. A	38329986 (100.0%)		38329986 (100.0%)	0 (0.0%)
2	nrg_bal [character]	1. AFC 2. GAE 3. GIC 4. NRGSUP 5. TI_E 6. TI_EHG_E 7. STATDIFF 8. NRG_E 9. TI_EHG_APE_E 10. TI_EHG_MAPE_E [132 others]	279288 (0.7%) 279288 (0.7%) 279288 (0.7%) 279288 (0.7%) 279288 (0.7%) 279288 (0.7%) 279084 (0.7%) 278676 (0.7%) 278676 (0.7%) 278676 (0.7%) 35539146 (92.7%)		38329986 (100.0%)	0 (0.0%)
3	siec [character]	1. TOTAL 2. BIOE 3. FE 4. O4000XBIO 5. RA000 6. O4630 7. O4640 8. O4661XR5230B 9. O4669 10. O4671XR5220B [62 others]	538998 (1.4%) 538590 (1.4%) 538590 (1.4%) 534918 (1.4%) 534918 (1.4%) 534102 (1.4%) 534102 (1.4%) 534102 (1.4%) 534102 (1.4%) 534102 (1.4%) 32973462 (86.0%)		38329986 (100.0%)	0 (0.0%)
4	unit [character]	1. GWH 2. KTOE 3. TJ	12776662 (33.3%) 12776662 (33.3%) 12776662 (33.3%)		38329986 (100.0%)	0 (0.0%)
5	geo [character]	1. AL 2. AT 3. BE 4. BG 5. CY 6. CZ 7. DE 8. DK 9. EE 10. EL [31 others]	1020816 (2.7%) 1020816 (2.7%) 1020816 (2.7%) 1020816 (2.7%) 1020816 (2.7%) 1020816 (2.7%) 1020816 (2.7%) 1020816 (2.7%) 1020816 (2.7%) 1020816 (2.7%) 28121826 (73.4%)		38329986 (100.0%)	0 (0.0%)
6	TIME_PERIOD [Date]	min : 1990-01-01 med : 2007-01-01 max : 2023-01-01 range : 33y 0m 0d	34 distinct values		38329986 (100.0%)	0 (0.0%)
7	values [numeric]	Mean (sd) : 14437.8 (385475.4) min ≤ med ≤ max: -2204668 ≤ 0 ≤ 69833934 IQR (CV) : 0 (26.7)	1447105 distinct values		20645538 (53.9%)	17684448 (46.1%)

1 pav. Pradinio duomenų masyvo žvalgomoji analizė

7 minėti stulpeliai, kaip galime matyti „summarytools“ paketo žvalgomosios analizės grafike (1 pav.), susideda iš datos stulpelio *TIME_PERIOD*, apimančio 33 metų laikotarpį nuo 1990 m. iki 2023 m, reikšmių stulpelio *values* ir 5 kategorines reikšmes turinčių stulpelių:

- *geo*, rodančio dviejų ženklų valstybės kodą;
- *unit*, rodančio matavimo vienetą – gigavatvalandes, teradžaulius arba tūkstančius tonų naftos ekvivalento;
- *nrg_bal*, rodančio duomenų rūšį – gamyba, vartojimas, importas, eksportas, atsargų pokytis ir kt.;
- *siec*, rodančio energijos rūšį – įvairių rūšių anglis, dujos, vėjo energija, saulės energija, hidroenergija ir kt.;
- *freq*, rodančio stebėjimų periodiškumą - šiuo atveju pateikiamos tik metinės reikšmės.

Iškart galime atkreipti dėmesį, kad svarbiausiame stulpelyje *values* ne visos reikšmės yra pateikiamos – trūkstamos reikšmės sudaro net 46.1% stebėjimų. Taip nutinka dėl įvairių priežasčių – ne visų duomenų rūšių reikšmės yra pateikiamos visų energijos rūšių lygmeniu, pvz. geoterminės energijos panaudojimas Lietuvoje vykstantiems vidaus oro skrydžiams yra nepateikiamas, nes toks reiškinys tiesiog negali egzistuoti, taip pat ne visos valstybės pateikia savo duomenis, pvz. Jungtinės Karalystės duomenys yra prieinami tik iki 2019 metų, nes nuo 2020 m. vasario mėn. ši valstybė nebėra Europos Sąjungos narė ir nebeteikia naujų duomenų Eurostatui.

Žinoma, kadangi šiuo atveju didžiausias dėmesys kreipiamas Lietuvos duomenims, būtų naudinga pašalinti likusių valstybių duomenis, o kartu sutvarkyti duomenų masę ir pagal likusius kintamuosius:

- *geo*: pasirenkame tik Lietuvos duomenis;
- *unit*: esminio skirtumo, kokiais matavimo vienetais bus atliekami visi skaičiavimai, nėra, todėl galima rinktis bet kurį iš trijų matavimo vienetų. Šiuo atveju toliau bus naudojami tūkstančiai tonų naftos ekvivalento.
- *nrg_bal*: pasirenkame tik energijos bendro vidaus vartojimo duomenis

Atrinkę tik tyrimui reikalingus duomenis gauname gerokai mažesnę duomenų rinkinį, kuriame iš daugiau nei 38 mln. eilučių lieka tik 2448 eilutės. Papildomai pašalinę nebereikalingus *geo*, *unit*, *nrg_bal* ir *freq* stulpelius ir išskleidę duomenų lentelę pagal likusias *siec* stulpelio reikšmes gauname 34 eilučių ir 77 stulpelių rinkinį, kurį galime dar kartą sumažinti palikdami tik atsinaujinančios energetikos išteklių dydžius ir papildomai bendrą visos energijos suvartojimo kiekį. Finale turime 34 eilutes ir 20 stulpelių, kurių skaičių papildomai sumažiname pašalindami vien nulines reikšmes turinčias energijos rūšis, tokias kaip *R5230B* maišytas reaktyvinis biožibalas, *R5230P* grynas reaktyvinis biožibalas, *R5290* kitas skystas biokuras, *RA410* saulės terminė energija ir *RA500* potvynių, bangų, vandenyno energija. Atskirai aptarti verta ir *RA200* geoterminės energijos suvartojimo laiko eilutę, kuri nuo 2002 m. iki 2017 m. turėjo teigiamas reikšmes. Šią energiją generavo Lietuvoje veikianti Klaipėdos geoterminė jėgainė „Geoterma“, kurios veikla 2017 metais buvo sustabdyta dėl kelių priežasčių – įmonės negebėjimo vykdyti savo finansinius įsipareigojimus ir neefektyvaus pačios energijos išgavimo, kuomet išgaunamo vandens šiluma būdavo nepakankama ir reikėdavo jį šildyti deginant dujas, o tai savo ruožtu prieštarauja ir pačiam atsinaujinančios energetikos apibrėžimui.

Pašalinus visas neaktualias energijos rūšis lieka 13 unikalių laiko eilučių, kurias galime apžvelgti detaliau:


No	Variable	Stats / Values	Freqs (% of Valid)	Graph	Valid	Missing
1	TIME_PERIOD [Date]	min : 1990-01-01 med : 2006-07-02 max : 2023-01-01 range : 33y 0m 0d	34 distinct values		34 (100.0%)	0 (0.0%)
2	TOTAL [numeric]	Mean (sd) : 8838.4 (2260.8) min ≤ med ≤ max: 7016.6 ≤ 8332.5 ≤ 17276.6 IQR (CV) : 1968.2 (0.3)	34 distinct values		34 (100.0%)	0 (0.0%)
3	RA000 [numeric]	Mean (sd) : 1001.4 (480.1) min ≤ med ≤ max: 311.6 ≤ 947.4 ≤ 1971.8 IQR (CV) : 771.9 (0.5)	34 distinct values		34 (100.0%)	0 (0.0%)
4	RA100 [numeric]	Mean (sd) : 34.7 (6) min ≤ med ≤ max: 25.5 ≤ 35.1 ≤ 51.8 IQR (CV) : 8.5 (0.2)	32 distinct values		34 (100.0%)	0 (0.0%)
5	RA300 [numeric]	Mean (sd) : 40 (56.8) min ≤ med ≤ max: 0 ≤ 5.2 ≤ 218.1 IQR (CV) : 66 (1.4)	21 distinct values		34 (100.0%)	0 (0.0%)
6	RA420 [numeric]	Mean (sd) : 4.7 (11.4) min ≤ med ≤ max: 0 ≤ 0 ≤ 59.2 IQR (CV) : 5.8 (2.4)	12 distinct values		34 (100.0%)	0 (0.0%)
7	RA600 [numeric]	Mean (sd) : 9.9 (25.7) min ≤ med ≤ max: 0 ≤ 0 ≤ 109.2 IQR (CV) : 0 (2.6)	0.00 : 28 (82.4%) 24.46! : 1 (2.9%) 25.70 : 1 (2.9%) 30.14! : 1 (2.9%) 63.39 : 1 (2.9%) 84.03! : 1 (2.9%) 109.25! : 1 (2.9%) ! rounded		34 (100.0%)	0 (0.0%)
8	R5110-5150_W6000RI [numeric]	Mean (sd) : 849.8 (336.5) min ≤ med ≤ max: 284.6 ≤ 867 ≤ 1419.3 IQR (CV) : 597.9 (0.4)	33 distinct values		34 (100.0%)	0 (0.0%)
9	R5160 [numeric]	Mean (sd) : 0.6 (1.1) min ≤ med ≤ max: -0.7 ≤ 0 ≤ 3.7 IQR (CV) : 0.7 (1.7)	-0.65! : 1 (2.9%) 0.00 : 20 (58.8%) 0.74! : 5 (14.7%) 1.47! : 2 (5.9%) 1.54! : 1 (2.9%) 2.21! : 2 (5.9%) 2.65! : 1 (2.9%) 3.53! : 1 (2.9%) 3.68! : 1 (2.9%) ! rounded		34 (100.0%)	0 (0.0%)
10	R5210B [numeric]	Mean (sd) : -1.3 (2.1) min ≤ med ≤ max: -6.5 ≤ 0 ≤ 2.3 IQR (CV) : 1.8 (-1.7)	14 distinct values		34 (100.0%)	0 (0.0%)
11	R5210P [numeric]	Mean (sd) : 7.2 (7.6) min ≤ med ≤ max: 0 ≤ 6.1 ≤ 22.2 IQR (CV) : 14 (1.1)	20 distinct values		34 (100.0%)	0 (0.0%)
12	R5220B [numeric]	Mean (sd) : 0 (5.2) min ≤ med ≤ max: -13.6 ≤ 0 ≤ 14.1 IQR (CV) : 0.9 (996.2)	13 distinct values		34 (100.0%)	0 (0.0%)
13	R5220P [numeric]	Mean (sd) : 31.7 (34.5) min ≤ med ≤ max: 0 ≤ 24.7 ≤ 102.7 IQR (CV) : 53.9 (1.1)	18 distinct values		34 (100.0%)	0 (0.0%)
14	R5300 [numeric]	Mean (sd) : 12.1 (15.6) min ≤ med ≤ max: 0 ≤ 2.2 ≤ 41.8 IQR (CV) : 22.8 (1.3)	23 distinct values		34 (100.0%)	0 (0.0%)

2 pav. Atrinkto duomenų rinkinio žvalgomoji analizė

Kaip matome iš atrinktų duomenų žvalgomosios analizės grafike (2 pav.) pateikiamų histogramų, skirtingų atsinaujinančios energetikos išteklių vartojimas yra pasiskirstęs labai įvairiai, vieni ištekliai buvo naudojami visu nagrinėjamu laikotarpiu, kiti, tokie kaip *RA600* ar *R5160*, pradėti naudoti tik pastaraisiais metais. Vis dėlto prieš tęsiant turimų duomenų aptarimą reikėtų pateikti kiekvienos laiko eilutės pavadinimo paaiškinimą, nes originalūs šių kintamųjų pavadinimai yra suteikti pagal standartizuotą tarptautinį energijos produktų klasifikavimą:


- *TOTAL* – visas suvartotas energijos kiekis;
- *RA000* – atsinaujinantys ištekliai ir biokuras (suminis visų atsinaujinančių išteklių dydis);
- *RA100* – hidroenergija;
- *RA300* – vėjo energija;
- *RA420* – saulės fotovoltinė energija;
- *RA600* – aplinkos šilumos (šilumos siurblių) energija;
- *R5110-5150_W6000RI* – pirminis kietasis biokuras;
- *R5160* – medžio anglis;
- *R5210B* – maišytas biokuras;
- *R5210P* – grynasis biokuras;
- *R5220B* – maišytas biodyzelinas;
- *R5220P* – grynasis biodyzelinas;
- *R5300* – biodujos.

Prieš pereinant prie detalesnės kiekvienos eilutės analizės dar galime apžvelgti atsinaujinančių išteklių vartojimo Lietuvoje santykinę dalį, matematiškai apskaičiuojamą *RA000* reikšmes padalinant iš *TOTAL* stulpelio reikšmių:



3 pav. Atsinaujinančių išteklių dalis bendrame energijos vartojime

Pateiktame procentinės dalies pokyčių grafike (3 pav.) galime matyti dvi kreives – mėlyną faktinių reikšmių kreivę ir nugludintą raudoną LOESS metodo kreivę, kuri leidžia išryškinti pagrindines tendencijas be išankstinių prielaidų apie laiko eilutę. Abi kreivės rodo akivaizdžią tiesinio augimo tendenciją, kurioms dar papildomai galima išskirti apie 2005 metus įvykusią struktūrinę lūžį, geriau matomą LOESS kreivėje – iki šių 2005 metų kreivė turėjo teigiamą, tačiau mažėjančio augimo tempo tendenciją, t.y. kiekvienas papildomas procentinis prieaugis buvo vis mažesnis, tačiau nuo 2005 metų įgavo daugmaž pastovų apie 2% siekiantį kasmetinį augimo tempą. Vertinant bendrai, 1990 m. siekusi mažiau nei 2%, atsinaujinančios energetikos išteklių dalis bendrame vartojime padidėjo keliolika kartų ir 2023 m. jau siekė apie 27,4%.




4 pav. Atsinaujinančios energijos vartojimas Lietuvoje

Žvelgdami į nominalų visos atsinaujinančios energetikos *RA000* vartojimo grafiką (4 pav.) galime matyti kone tiesinę liniją, kuri aiškiai pasižymi augimo tendencijomis. Vertinant trijų dešimtmečių raidą galime pastebėti, kad suvartojamas atsinaujinančios energijos kiekis išaugo nuo 320 tūkstančių arba 0,32 milijono tonų naftos ekvivalento 1990 metais iki beveik 2 milijonų tonų naftos ekvivalento 2023 metais, daugiau nei 6 kartus. Taip pat, jei pažvelgtume į pirmųjų nepriklausomybės metų duomenis, matytume, kad visas posovietinis atsinaujinančios energetikos sektorius Lietuvoje buvo sudarytas tik iš dviejų išteklių – hidroenergijos ir pirminio kietojo biokuro. Tuo tarpu dabartinis atsinaujinančios energetikos sektorius yra kur kas labiau išvystytas – pastaraisiais metais fiksuojamas net 11 skirtingų atsinaujinančios energijos rūšių vartojimas.

Atskirų energijos rūšių vartojimą galima apžvelgti apjungiant grafikus į vieną vizualizaciją, taip išvengiant perteklinio teksto apkrovimo grafikais:

Atsinaujinančios energijos vartojimas


1990–2023



Šaltinis: Eurostat

5 pav. Skirtingų atsinaujinančios energijos rūšių vartojimas Lietuvoje

Pateiktame kiekvienos energijos rūšies vartojimo grafike (5 pav.) galime matyti, kad pagal vartojamą energijos kiekį populiariausia atsinaujinančios energijos rūšis neginčytinai yra *R5110-5150_W6000RI* pirminis kietasis biokuras, o jo vartojimo kreivė kone identiškai sutampa su jau anksčiau apžvelgta suminio atsinaujinančios energijos vartojimo kreive. Lyginant su kitomis energijos rūšimis hidroenergijos vartojimas *RA100* yra daugmaž stabilus visu nagrinėjamu laikotarpiu, svyruoja 25–50 tūkst. tonų naftos ekvivalento intervale. Žvelgdami į vartojimo kreives galime atkreipti dėmesį, kad egzistuoja kreivių, rodančių neigiamą vartojimą – *R5160* medžio anglies vartojimas įgyja neigiamą reikšmę vienu laikotarpiu, o *R5210B* maišyto biokuro ir *R5220B* maišyto biodyzelino vartojimas neigiamas reikšmės įgyja nuolat. Tai nėra duomenų klaida, o tik skaičiavimo metodikos ypatybė – neigiamos reikšmės gali atsirasti dėl sukauptų atsargų arba žaliavų pervedimo tarp sektorių. Pavyzdžiui *R5210P* grynojo biokuro arba *R5220P* grynojo biodyzelino vartojime tokių neigiamų reikšmių jau nestebime. Žvelgiant į likusias energijos rūšis galime matyti, kad jos iki pat 2000 metų išlaiko nulines reikšmes, kitaip tariant yra visiškai nevartojamos, o pastaraisiais metais šių rūšių vartojimas pradeda augti, tačiau skirtingais dydžiais. Šio augimo poveikį bendrai struktūrai galime panagrinėti penkių labiausiai vartojamų energijos rūšių grafike:




6 pav. Atsinaujinančių išteklių vartojimo struktūra Lietuvoje

Žvelgdami į pateiktą struktūrinį atsinaujinančios energijos vartojimo grafiką (6 pav.) galime dar kartą įsitikinti, kad pirminis kietasis biokuras yra labiausiai naudojama atsinaujinančios energijos rūšis Lietuvoje. Tačiau nagrinėdami likusias energijos rūšis galime matyti esminius struktūrinius pokyčius – jei iki maždaug 2005 metų vienintelė kita vartojama atsinaujinančios energijos rūšis buvo hidroenergija, tai nuo šių metų jos santykinė dalis bendrame atsinaujinančios energijos vartojime vis mažėja, o alternatyvių atsinaujinančios energijos šaltinių vartojimas nuolat auga – saulės energijos išaugo sąlyginai mažiausiai, aplinkos šilumos energijos vartojimas išaugo kiek labiau, tačiau

didžiausią proveržį pasiekė vėjo energija, tapusi antra labiausiai vartojama energijos rūšimi ir pasižyminti santykinai itin dideliu augimu. Panašų lėtą saulės energijos vartojimo augimą stebėjo ir JAV duomenis tyrinėję Daimas ir kt. (2012), kartu pastebėję, kad norint didinti šių technologijų patrauklumą reikia skatinti mokslinius tyrimus, mažinančius šios energijos rūšies vartojimo priklausomybę nuo subsidijų. Pažvelgę į grafikui sudaryti suskaičiuotus santykius matytume, kad 1990 metais pirminis kietasis biokuras sudarė apie 89% visos atsinaujinančios energetikos suvartojimo, o likę 11% priskiriami hidroenergijai, tuo tarpu pastaraisiais metais pirminio kietojo biokuro dalis vis mažėja ir 2023 metais jau nebesiekia 70%, o vėjo energija tais pačiais metais jau siekia 11,65% ir viršija bet kokią hidroenergijos ar bet kurios kitos energijos rūšies santykinę dalį atsinaujinančios energijos vartojime. Tai iš esmės rodo, kad vėjo energijos vartojimas yra itin greitai augantis, jau dabar užimantis santykinai didelę viso atsinaujinančios energijos vartojimo dalį, ir dėl to gali būti labai svarbus ateities energijos poreikio prognozėms.

Galiausiai prieš pereinant prie pačio modelio sudarymo vertėtų pažvelgti į turimų laiko eilučių tarpusavio ryšius:



7 pav. Atsinaujinančios energijos rūšių vartojimo koreliacija

Pateiktame laiko eilučių koreliacijos grafike (7 pav.) dar kartą galime matyti išskirtinius *R5210B* maišyto biokuro ir *R5220B* maišyto biodyzelino ryšius su kitomis eilutėmis – jei bendrai visų eilučių koreliacija atrodo daugiau mažiau teigiama, tik ne visada stipri, tai šių ji gali būti arba visai neegzistuojanti, arba net reikšmingai neigiama – pvz. grynojo biokuro vartojimui augant dažniausiai yra stebimas maišyto biokuro vartojimo mažėjimas. Jau aptarėme, kad ši laiko eilutė gali įgyti neigiamas reikšmes dėl skaičiavimo metodikos ir neigiama koreliacijos reikšmė tai patvirtina – neigiamas maišyto biokuro vartojimas dažniausiai reiškia, kad yra išgaunamas ir vartojamas grynas biokuras. Žvelgdami į likusius tiesinius tarpusavio ryšius matome, kad dažniausiai jie yra teigiami ir statistiškai reikšmingi, išskyrus *RA100* hidroenergijos vartojimą – didžiausia reikšmė fiksuojama su pirminiu kietuoju biokuru, tačiau ji nesiekia 0,4 reikšmingumo ribos ir šis ryšys taip pat yra statistiškai nereikšmingas. Tuo tarpu stipriausią tiesinį tarpusavio ryšį turi *RA300* vėjo energijos vartojimas ir *R5300* biodujų vartojimas – Pearsono koreliacijos koeficientas siekia net 0,95 reikšmę, taigi šių eilučių tarpusavio ryšys yra kone idealiai atitinkantis. Tą patį galima pasakyti apie *RA420* saulės energijos vartojimą ir *RA600* aplinkos šilumos vartojimą arba *R5210P* grynojo biokuro ir *R5220P* grynojo biodyzelino vartojimą, kurių koreliacijos koeficiento reikšmės siekia po 0,94.

Bendrai apžvelgę turimus priklausomus kintamuosius, panagrinėję jų sandarą, raidą, tarpusavio ryšius ir santykinę svarbą bendrame atsinaujinančios energijos vartojime galime pereiti prie matematinio modelio konstravimo dalies, kuri finale leistų gauti turimų duomenų ateities reikšmių prognozes.

3. Modelio sudarymas ir prognozavimas

Apžvelgę priklausomus kintamuosius jau galime suformuluoti konkretesnius tikslus ir uždavinius, kuriuos turėtų atlikti kuriamas modelis. Jau aptarėme, kad prognozavimui gali būti taikomi įvairūs modeliai, tačiau nepaisant rūšies jie turėtų būti tarpusavyje palyginami vienodais tikslumo matais, kad būtų galima išrinkti geriausią galutinį modelį. Turėdami daugiau informacijos apie duomenis galime pridurti, kad esminis suformuoto modelio tikslas yra gauti *RA000* suminio visų atsinaujinančių energijos išteklių vartojimo ateities vertes. Šiam rezultatui pasiekti galimi du keliai – reikia arba kurti matematinį modelį pačios *RA000* laiko eilutės prognozavimui, arba gauti šį suminį rezultatą prognozuojant smulkesnes, jį sudarančias laiko eilutes. Reikia pastebėti, kad pastarasis kelias leistų išbandyti teorijos dalyje neaptartus daugiamatės analizės metodus ir pritaikyti, pavyzdžiui, vektorinės autoregresijos modelį.

3.1. Poreikio prognozavimo modelio sudarymas

Teorijos dalyje aptarėme, kad praeities tyrimuose panašaus pobūdžio duomenims sėkmingai buvo taikomi įvairių rūšių matematiniai modeliai – laiko eilučių modeliai, ekonometriniai modeliai, ARIMA šeimos modeliai, pilkieji modeliai, neuroniniai tinklai. Tuo pačiu eiliškumu galima išbandyti kiekvienos rūšies modelius turimiems Lietuvos duomenims, palyginti gaunamus tikslumo įverčius ir pagal juos išrinkti geriausiai tinkantį modelį.

3.1.1. Laiko eilutės modelis

Pradėdami nuo laiko eilutės modelio jau turime visus reikalingus duomenis – suminę visos atsinaujinančios energijos vartojimo eilutę *RA000* ir atskirų energijos rūšių vartojimą rodančias eilutes. Šį jau anksčiau aptartą laiko eilučių sąrašą sumažiname pašalindami *R5210B* maišyto biokuro vartojimą ir *R5220B* maišyto biodyzelino vartojimą. Šios eilutės nereikalingos, nes dėl taikomos skaičiavimo metodikos rodo ne realų vartojimą, o tik žaliavų perkėlimus į kitus sektorius, ir todėl gali įgyti neigiamo vartojimo kiekio reikšmes.


Likusiems duomenims R programos aplinkoje parengiama procedūra, kuri nurodytai laiko eilutei pritaiko virš 20 įvairių skirtingų modelių:

1. Vidurkio modelis;
2. Kubinio glodinimo kreivė;
3. Naivus modelis;
4. Atsitiktinis klaidžiojimas;
5. Atsitiktinis klaidžiojimas su poslinkiu;
6. Sezoniškas naivus modelis;
7. Tiesinės tendencijos regresijos modelis;
8. Tiesinės ir kvadratinės tendencijos regresijos modelis;
9. BATS;
10. TBATS;
11. Struktūrinis laiko eilučių modelis;
12. Teta modelis;
13. ETS (klaidos, tendencijos, sezoniškumo) modelis;
14. Bagged-ETS modelis;
15. Pranašo modelis;
16. Pranašo modelis su logistinio augimo parametru;

17. Hibridinis ARIMA-ETS-Teta modelis;
18. Hibridinis ARIMA-ETS-TBATS modelis;
19. Crostono modelis;
20. ETS modelis su Box-Cox transformacija;
21. XGBoost autoregresijos modelis be tendencijos;
22. XGBoost autoregresijos modelis su diferencijavimu.

Kiekvienas modelis laiko eilutei pritaikomas kartu atliekant augančio lango kryžminį patikrinimą (angl. *expanding window cross-validation*), apmokant modelį su dalimi realių praeities duomenų (75% visų stebėjimų), tikrinant modelio tikslumą prognozuojant pasirinktą skaičių stebėjimų į priekį, vėlesnėje ciklo iteracijoje pridėdant šio laiko tarpo realius stebėjimus prie mokymosi imties ir prognozuojant tą patį kiekį naujesnių stebėjimų. Atlikus prognozavimą galima suskaičiuoti visų šių gautų rezultatų tikslumo įverčių vidurkį, kuris ir sudarys galutinę kiekvieno modelio tikslumo reikšmę. Tokia procedūra leidžia turėti kiek įmanoma labiau realiose situacijose išbandytus tikslumo įverčius, leidžiančius geriau suprasti, kokį tikslumą modelis išlaikys prognozuodamas dar nežinomas ateities periodų reikšmes.

Pritaikius kiekvieną iš modelių kartu yra nubrėžiamas grafikas, rodantis realias ir modelio apskaičiuotas reikšmes, pagal jau aptartą metodiką apskaičiuojami tikslumo įverčiai, tokie kaip šaknis iš vidutinės kvadratinės paklaidos (angl. *Root mean square error, RMSE*), vidutinė absoliuti procentinė paklaida (angl. *Mean absolute percentage error, MAPE*) ir vidutinė absoliuti paklaida (angl. *Mean absolute error, MAE*). Turint šiuos įverčius jau būtų nesudėtinga tarpusavyje palyginti visus naudotus modelius, tik dar lieka neišspręstas ateities prognozavimo klausimas – įtaką tikslumo įverčiams neabejotinai turi ir prognozuojamo stebėjimų kiekio parinkimas. Iš vienos pusės, norime prognozuoti kuo daugiau ateities reikšmių, kad būtų galima suvokti ateities tendencijas ir galimus pokyčius, iš kitos pusės didelio kiekio stebėjimų prognozavimas gali lemti prastesnius tikslumo rezultatus. Norėdami atsakyti ir į šį klausimą išbandome visus modelius su prognozavimo periodu nuo vienerių metų iki ketverių, t.y. kiekvienam modeliui sukuriame keturis variantus su skirtingais prognozavimo ilgiais. Turėdami tokius išsamius rezultatus galėsime ne tik palyginti modelius tarpusavyje, bet ir matyti prognozavimo trukmės pasirinkimo įtaką kiekvieno modelio tikslumo rezultatams.



Šaltinis: autoriaus skaičiavimai

8 pav. Prognozavimo periodo įtaka tikslumo rezultatams

Žvelgdami į pateiktą prognozavimo periodo įtakos modelių tikslumui grafiką (8 pav.) visų pirma matome, kad didžioji dalis kreivių persidengia grafiko apačioje, tai rodo, kad dauguma modelių pasirodo daugmaž vienodai gerai, yra tik kelios išsiskiriančios išimtys – Crostono modelis ir paprasčiausias vidurkio modelis. Grafike taip pat galime matyti, kad esminės prognozavimo periodo parinkimo įtakos modelių tikslumui nėra – visų modelių klaidos didinant prognozavimo periodą auga, tačiau negalime išskirti griežtos ribos, kurią viršijus klaidos išaugtų neproporcingai daug. Tai reiškia, kad prognozuoti iš esmės galime visus 4 periodus į priekį, t.y. gauti reikšmes nuo 2024 metų iki 2027 metų imtinai. Priėmus tokį sprendimą galime detalčiau pažvelgti modelių tikslumą prognozuojant 4 periodus į priekį:

1 lentelė. Laiko eilučių modelių tikslumas pagal prognozavimo periodą

Periodas	Modelio pavadinimas	RMSE	MAPE	MAE
$t+1$	Tiesinės ir kvadratinės tendencijos regresijos modelis	85,91	4,62%	74,09
	Pranašo modelis	87,45	4,86%	77,48
	Hibridinis ARIMA-ETS-TBATS modelis	89,71	4,79%	79,07
	Struktūrinis laiko eilučių modelis	90,49	4,42%	74,28
	Atsitiktinis klaidžiojimas su poslinkiu	92,01	4,31%	73,39
	Bagged-ETS modelis	94,31	5,07%	81,73


Periodas	Modelio pavadinimas	RMSE	MAPE	MAE
$t+2$	Atsitiktinis klaidžiojimas su poslinkiu	90,83	4,38%	71,53
	Tiesinės ir kvadratinės tendencijos regresijos modelis	94,77	5%	79,17
	XGBoost modelis su diferencijavimu	95,31	4,47%	73,22
	Struktūrinis laiko eilučių modelis	95,52	4,71%	77,34
	Pranašo modelis	98,38	5,51%	86,68
	Hibridinis ARIMA-ETS-TBATS modelis	100,24	5,22%	84
$t+3$	Atsitiktinis klaidžiojimas su poslinkiu	101,31	4,97%	82,12
	Struktūrinis laiko eilučių modelis	101,68	5,16%	84,66
	Tiesinės ir kvadratinės tendencijos regresijos modelis	104,90	5,42%	86,46
	Pranašo modelis	106,82	5,86%	92,48
	Hibridinis ARIMA-ETS-TBATS modelis	110,24	5,82%	94,71
	Hibridinis ARIMA-ETS-Teta modelis	118,81	6,12%	100,37
$t+4$	Struktūrinis laiko eilučių modelis	103,70	5,30%	85,98
	Atsitiktinis klaidžiojimas su poslinkiu	104,04	5%	81,81
	XGBoost modelis su diferencijavimu	109,39	5,28%	85,11
	Tiesinės ir kvadratinės tendencijos regresijos modelis	111,87	5,81%	92,61
	Pranašo modelis	113,45	6,2%	97,83
	Hibridinis ARIMA-ETS-TBATS modelis	117,82	5,92%	95,74

Išrikiavus po 6 pagal RMSE įvertį geriausiai pasirodžiusius pritaikytus modelius matome, kad pradžioje geriausių rezultatų rodė tiesinės ir kvadratinės tendencijos regresijos modelis didinant prognozavimo periodą praranda savo tikslumą labiau nei kiti modeliai, o $t+3$ ir $t+4$ periodų prognozavime lyderiaujančias pozicijas užima struktūrinis laiko eilučių modelis ir atsitiktinis klaidžiojimas su poslinkiu.

2 lentelė. Vidutinis laiko eilučių modelių tikslumas

Modelio pavadinimas	RMSE	MAPE	MAE
Atsitiktinis klaidžiojimas su poslinkiu	97	4,67%	77,2
Struktūrinis laiko eilučių modelis	97,8	4,90%	80,5
Tiesinės ir kvadratinės tendencijos regresijos modelis	99,4	5,21%	83,1
Pranašo modelis	102	5,61%	88,6
Hibridinis ARIMA-ETS-TBATS modelis	105	5,44%	82,8
XGBoost modelis su diferencijavimu	106	5,06%	91,5

Išrikiavę modelius pagal jų vidutinius rezultatus matome, kad iš esmės visų jų tikslumo rezultatai yra labai panašūs, ir sunku išskirti vieną modelį, kuris būtų reikšmingai pranašesnis už visus kitus. Nepaisant to, priimant galutinį sprendimą svarbu prisiminti, kad šių modelių pagalba norime gauti 4 periodų ateities prognozę. Dėl šios priežasties vertėtų rinktis struktūrinį laiko eilučių modelį, kurio paklaidos didinant prognozavimo periodą kiekį augo mažiausiai ir kuris $t+4$ periodo prognozavimui yra tinkamiausias.



9 pav. Struktūrinio laiko eilučių modelio rezultatai

Anksčiau pateiktoje lentelėje matėme, kad šis modelis pasižymi vidutiniškai 4,90% prognozavimo paklaida, šaknis iš vidutinės kvadratinės paklaidos siekia 97,8, o vidutinės absoliučios paklaidos rodiklio reikšmė siekia 80,5. Pateiktame modelio grafike (9 pav.) galime matyti juoda spalva pažymėtus realius stebėjimus, mėlyna spalva pažymėtas modelio apskaičiuotas reikšmes ir raudonai pažymėtas ateities prognozes. Iš esmės galime matyti, kad modelis pakankamai tiksliai supranta laiko eilutės tendenciją ir prie jos prisitaiko, o ateities prognozės vienareikšmiškai rodo atsinaujinančios energijos vartojimo augimą daugmaž tiesine linija. Prognozuojamo periodo pabaigoje, 2027 metais, atsinaujinančios energijos vartojimas turėtų pasiekti apie 2,5 milijono tonų naftos ekvivalento.


3.1.2. Ekonometrinis modelis

Ankstesniame skyriuje gautus laiko eilučių modelių tikslumo rezultatus galima pabandyti pagerinti įtraukiant į modelio struktūrą egzogeninius veiksnius – teorijos dalyje jau aptarėme, kad panašaus pobūdžio tyrimuose dažnai naudojami tokie išoriniai regresoriai kaip energijos vartojimas vienam gyventojui, gyventojų skaičius, gyventojų prieaugis, energijos išteklių kaina, valstybės BVP, gyventojų pajamos, energijos subsidijos ir kiti. Iš kitos pusės reikia pastebėti, kad turimi duomenys kiek apriboja galimų modelių sudėtingumą – laiko eilutė sudaryta iš 34 stebėjimų, o įprastai laikoma, kad vienam kintamajam turėtų tekti bent 10 stebėjimų. Tokia griežto mokslinio pagrindimo neturinti praktinė taisyklė sufleruoja, kad modelį turėtų sudaryti ne daugiau 3 kintamieji, nes kitaip nepakaks duomenų modelio apmokymui ir gali nukentėti jo stabilumas. Iš kitos pusės, kuriant modelį galima

taikyti, pavyzdžiui, LASSO regularizaciją, dar žinomą kaip L1, kuri taip pat galėtų padėti atrinkti iš tikrųjų svarbius ir reikalingus regresorius.


Atskirai paminėti verta ir kintamųjų problemą kuriant pačias prognozes – į modelį įtraukus to paties laikotarpio kintamųjų reikšmes tektų atskirai prognozuoti kiekvieną regresorių, kad gautume jo ateities reikšmes, o pagal tas reikšmes finale prognozuoti priklausomą kintamąjį *RA000*. Tai reikštų savotišką dvigubą prognozavimą, kuris į visą prognozavimo procesą įneštų dar daugiau neapibrėžtumo ir galimų klaidų. Alternatyva šiam žingsniui galėtų būti kintamųjų vėlavimų įtraukimas, t.y. ateities periodų *RA000* reikšmių prognozavimas pagal *t-n* periodo nepriklausomus regresorius. Tokia alternatyva kartu būtų ir pakankamai logiška – neatrodytų keista, kad makroekonominių pokyčių įtaka nepasireiškia iš karto, o turi tam tikrą uždelstą poveikį, pasireiškiantį po vieno ar daugiau stebėjimo periodų. Dėl šios priežasties pateikdami atrinktų išorinių regresorių sąrašą kartu galime patikrinti kiekvieno jų kryžmines koreliacijas su priklausomu kintamuoju, kad geriau matytume uždelstų ryšių stiprumą:

- *BVP* – valstybės bendrasis vidaus produktas;
- *Cons_PC* – visos energijos suvartojimas, tenkantis 100 tūkst. gyventojų;
- *RCons_PC* – atsinaujinančios energijos suvartojimas, tenkantis 100 tūkst. gyventojų;
- *BVP_PC* – valstybės bendrasis vidaus produktas vienam gyventojui;
- *Pop* – gyventojų skaičius Lietuvoje;
- *VKI* – vartotojų kainų indeksas, infliacijos rodiklis. Pateikiamas 2015=100 formoje.



10 pav. Nepriklausomų kintamųjų kryžminė koreliacija su priklausomu kintamuoju

Pateiktuose grafikuose (10 pav.) matome, kad toks kryžminės koreliacijos skaičiavimas nėra korektiškas, nes beveik visos laiko eilutės pasižymi itin reikšmingomis koreliacijomis tuo pačiu periodu ir laipsniškai gėstančiomis reikšmėmis vis labiau nutolusiais periodais. Tai iškart sufleruoja, kad laiko eilutės nėra stacionarios (*RA000* atveju tą matėme jau vizualiai – laiko eilutė turėjo aiškiai išreikštą augimo tendenciją). Atlikus papildomus ADF ir KPSS stacionarumo testus galime galutinai įsitikinti šia prielaida – visi turimi kintamieji yra stipriai nestacionarūs, stacionarumui užtikrinti nepakanka net pirmųjų skirtumų, reikia nagrinėti logaritmų skirtumus. Interpretavimo prasme tai reiškia, kad nagrinėsime laiko eilučių augimo tempus, todėl sukūrus modelį ir skaičiuojant galutines prognozes reikės nepamiršti atliktų transformacijų ir tinkamai suskaičiuoti būsimas priklausomo kintamojo reikšmes. Grįžtant prie kryžminės koreliacijos - norint gauti tinkamas reikšmes visų pirma reikia užtikrinti laiko eilučių stacionarumą ir tik tuomet atlikti kryžminės koreliacijos tikrinimą:



11 pav. Stacionarių nepriklausomų kintamųjų kryžminė koreliacija su priklausomu kintamuoju

Gautame stacionarių laiko eilučių koreliacijų grafike (11 pav.) matome, kad teorinė prielaida apie uždelstą poveikį buvo dalinai teisinga – statistiškai reikšmingomis koreliacijomis t periodo atsinaujinančios energijos vartojimas pasižymi su $t-2$ periodo bendrojo vidaus produkto reikšmėmis, t periodo energijos vartojimu 100 tūkst. gyventojų, $t-2$ periodo bendrojo vidaus produkto viename gyventojui ir t periodo gyventojų skaičiumi. Kaip matome iš antrojo ir paskutinio grafiko, bendras energijos suvartojimas ir vartotojų kainų indeksas visiškai nekoreliuoja su atsinaujinančios energijos vartojimu.

Turėdami šiuos duomenis papildomai galime sukurti daugiau kintamųjų – netiesinių kintamųjų formų, pvz. pakeltų antruoju ar trečiuoju laipsniu, taip pat galime sukurti kintamųjų tarpusavio

sąveikų kintamųjų. Kadangi nusprendėme taikyti regularizaciją, išorinių kintamųjų kiekis gali būti didelis, o sudarant modelį bus atrinkti tik iš tikrųjų reikalingi kintamieji. Taip pat siekdami kiek įmanoma geriau išmatuoti modelio tikslumą laikysimės jau anksčiau išmėginto augančio lango kryžminio patikrinimo metodo, padalindami turimą nedidelę imtį į apmokymo dalį ir vėliau apskaičiuodami jos tikslumą pagal vis naujesnę testavimo dalį.

Tarpusavio koreliacijos grafikuose matėme, kad vėliausiai nepriklausomų kintamųjų efektai priklausomam kintamajam pasireiškia per 2 periodus, o tai iš esmės reikštų, kad reikia kurti modelius su neilgais išorinių kintamųjų vėlavimais ir prognozuoti jų reikšmes ateityje. Iš kitos pusės, galime palyginti tokio žingsnio naudą ir reikalingumą lygiagrečiai kurdami modelius su $t-4$ vėlavimais, kurie nereikalaus papildomo prognozavimo. Finale pritaikę regularizavimo metodus turėsime ir šių metodų palyginimą, ir žinosime apie išorinių kintamųjų prognozavimo būtinumą.

Kalbant apie regularizavimo metodus, galime išbandyti tris – tiek jau paminėtą LASSO, tiek keteros (angl. *Ridge*), tiek elastinio tinklo (angl. *Elastic net*). Tačiau šių metodų pritaikymas turi savų iššūkių – norint pritaikyti bet kurį iš trijų metodų papildomai dar reikės nustatyti parametrų λ ir α reikšmes. Parametro λ reikšmę galima nustatyti taikant vidinį kryžminį patikrinimą visiems trimis metodams, o α parametro reikšmė yra problematiška tik elastinio tinklo modeliui: jei likusių dviejų metodų α reikšmės yra atitinkamai vienetas ir nulis, tai elastiniam tinklui atliekant vidinį kryžminį tikrinimą dėl λ reikšmės reikės papildomai ieškoti ir optimalios α parametro reikšmės iš intervalo (0,1). Tik atrinkus optimalius regularizavimo metodų parametrus bus galima pritaikyti šiuos modelius turimiems duomenų rinkiniams, patikrinti jų prognozavimo pajėgumus ir gauti skaitinius tikslumo įverčius.

Pritaikę visus tris metodus gauname tokią rezultatų lentelę:

3 lentelė. Regularizavimo metodų tikslumas

Duomenų rinkinys	Regularizavimas	RMSE	MAPE	MAE
Visi	Elastinis tinklas	148,96	8,54%	138,58
	Ketera	156,22	9,09%	147,64
	LASSO	160,29	9,36%	152
$t-4$	Elastinis tinklas	150,24	8,87%	144,41
	Ketera	154,71	9,1%	148,06
	LASSO	161,9	9,53%	155,02


Išbandę tris regularizavimo metodus matome, kad techniškai geriausiai pasirodė elastinio tinklo regularizavimas naudojant visus prieinamus duomenis – šis modelis pasiekė geriausią tikslumą pagal vidutinę absoliučią procentinę paklaidą, vidutinę absoliučią paklaidą ir šaknies iš vidutinės kvadratinės paklaidos įvertį. Atliekant parametrų derinimą nustatyta, kad optimalios parametrų reikšmės $\alpha=0,76$ ir $\lambda=0,01$. Ieškant įvairių programavimo, praktinio taikymo pavyzdžių galima susidaryti įspūdį, kad toks rezultatas ir turėtų būti gaunamas – įvairioje techninėje dokumentacijoje, net ir pačiuose R paketų aprašymuose galima rasti patarimų vengti naudoti keteros ar LASSO regularizavimą, nes abu metodai yra savotiškai kraštutiniai. Su tokiu reiškiniu susiduriame ir nagrinėdami šiuos duomenis – keteros metodas nepašalina jokių į modelį įtrauktų kintamųjų, tik sumažina jų reikšmes, o per tai ir įtaką prognozėms, iki labai artimų nuliui. Tuo tarpu LASSO elgiasi priešingai ir labai griežtai šalina kintamuosius iš modelio. Žvelgiant tik į modelius su $t-4$ formos

regresoriais matome, kad skirtumas tarp LASSO ir keteros regularizavimo nebėra toks didelis, tačiau visi modeliai pasižymi didesnėmis prognozavimo paklaidomis ir neturėtų būti pasirenkami. Tai rodo, kad teisingesnis sprendimas yra įtraukti į modelį ir naujesnių stebėjimų išorinius kintamuosius, kuriuos vėliau prognozuojame naudodami automatinius ARIMA modelius. Iš kitos pusės, korelogramos nerodė jokių statistiškai reikšmingų tarpusavio ryšių didesnės eilės vėlavimuose, todėl buvo galima numanyti, kad bandant realybėje pritaikyti modelius jie nepasižymės gerais tikslumo rezultatais.

4 lentelė. Elastinio tinklo modelio rezultatai

Prognozuojamas periodas	RMSE	MAPE	MAE
$t+1$	73	4,6%	72,5
$t+2$	139	8,7%	139
$t+3$	198	11,9%	192
$t+4$	191	9,4%	158

Elastinio tinklo metodas, kuris iš esmės yra savotiškas abiejų LASSO ir keteros regularizavimo metodų mišinys, kartu ir sumažinantis modelio persimokymo galimybę, ir atrenkantis tik reikšmingiausius regresorius, turimiems duomenims pasirodė geriausiai. Dėl šios priežasties jį reikėtų rinktis galutiniam prognozavimui kaip geriausiai tinkantį modelį, tačiau pažvelgę į modelio tikslumą pagal prognozuojamo periodo nustatymą matome, kad net ir šis modelis nėra gerai tinkantis kelių ateities periodų prognozavimui. Parinkus tik vieno ateities periodo prognozavimą gautume sąlyginai neblogas paklaidas, neišsiskiriančias iš geriausių anksčiau išbandytų laiko eilučių modelių, tačiau padidinę prognozuojamų periodų kiekį bent iki dviejų iškart matome beveik dvigubai išaugančias modelio paklaidas, kurios didinant iki keturių periodų išlaiko savo aukštą lygį.



12 pav. Elastinio tinklo modelio rezultatai

Laikydami ankstesnės tvarkos, modelio rezultatų grafike (12 pav.) vėl juoda spalva pažymime realias atsinaujinančios energijos vartojimo reikšmes, mėlyna spalva pažymime modelio apskaičiuotas reikšmes ir raudona spalva pažymėtos prognozės. Lyginant su struktūrinio laiko eilučių modelio grafiku, abu modeliai vienareikšmiškai prognozuoja atsinaujinančios energijos vartojimo augimą, šiuo atveju taip pat matome, kad vartojimas turėtų augti beveik tiesine kreive kiekvienais metais ir galutinė 4 metų prognozė, nors pagal paklaidų matus yra mažiau tiksli, bet taip pat rodo, kad prognozuojamo periodo pabaigoje atsinaujinančios energijos vartojimas turėtų siekti apie 2,5 milijono tonų naftos ekvivalento.

3.1.3. ARIMA modelis

Turėdami jau dviejų rūšių modelius galime pereiti prie trečiosios – ARIMA – rūšies. Šie autoregresinių integruotų slankiųjų vidurkių modeliai būtų tarsi ankstesnių dviejų rūšių apibendrinimas – iš vienos pusės leidžiantys įtraukti į modelį įvairius paties priklausomo kintamojo atributus, iš kitos pusės leidžiantys papildyti modelį egzogeninių veiksnių matrica. Kaip matėme jau aptartuose moksliniuose tyrimuose, šis egzogeninių kintamųjų įtraukimas prognozuojant panašaus pobūdžio duomenis yra naudojamas ne visada. Iš vienos pusės tai būtų galima aiškinti išorinių veiksnių prognozavimo problematika – ankstesniame skyriuje jau aptarėme, kad norint prognozuoti pagal egzogeninius kintamuosius reikia arba naudoti tik šių kintamųjų vėlavimus, arba papildomai prognozuoti išorinių regresorių reikšmes ir remiantis jomis prognozuoti priklausomą kintamąjį, o abu

sprendimai gali sumažinti ateities prognozių tikslumą. Kita vertus, matėme, kad egzistuoja sėkmingų vien ARIMA ar SARIMA modelių taikymo pavyzdžių, o tai gali reikšti, kad išorinių kintamųjų matricos įtraukimas į modeliavimą gali būti paprasčiausiai nereikalingas – galbūt tinkamai apibrėžtas ARIMA modelis pats savaime pasiekia patenkinamus tikslumo rezultatus ir tiesiog nėra būtinybės jo apsunkinti pertekliniais duomenimis.

Šiuos samprotavimus galime išbandyti praktiškai – visų pirma sukurti paprastą ARIMA modelį, patikrinti jo tikslumo rezultatus laikantis vienodos augančio lango kryžminio tikrinimo tvarkos, tuomet naudojant jau ankstesnėje dalyje aptartus išorinius kintamuosius išplėsti modelį iki ARIMAX sandaros ir palyginus abiejų modelių tikslumą įvertinti tokio žingsnio reikalingumą. Patį išplėtimą iki ARIMAX taip pat galime atlikti dviem būdais – įtraukti į modelį tik $t-4$ periodo vėlavimus, kurie leis išvengti dvigubo prognozavimo ateities reikšmės gauti, ir įtraukti naujesnių periodų išorinius kintamuosius, kuriuos, kuriant priklausomo kintamojo prognozes, reikės taip pat suprognozuoti.

5 lentelė. ARIMA modelio tikslumas

Prognozavimo laikotarpis	RMSE	MAPE	MAE
$t+1$	57,5	3,3%	48,3
$t+2$	112	5,97%	95,1
$t+3$	110	5,62%	92,1
$t+4$	139	6,23%	107

Visų pirma išbandome patį paprasčiausią ARIMA modelį be egzogeninių kintamųjų matricos. Pritaikius automatinę modelio eilės nustatymo procedūrą gauname, kad minimizuojant pagal Akaike informacijos kriterijaus (AIC) reikšmės sudaromo modelio eilė turėtų būti (1,1,0). Gavę tokio modelio prognozavimo tikslumo rezultatus galime matyti, kad paprastas ARIMA modelis su pirmos eilės autoregresija AR(1) ir pirmais skirtumais I(1) pasirodė pakankamai neblogai – lyginant su anksčiau išbandytais modeliais visi paklaidų rezultatai yra ganėtinai geri, $t+1$ periodo prognozavimas yra tiksliausias iš visų išbandytų modelių, o didinant prognozavimo laikotarpį reikšmės išauga, tačiau ne tiek stipriai kaip elastinio modelio pagalba sudarytame regresijos modelyje.

6 lentelė. ELNET-ARIMAX(1,1,0) ($t-4$) modelio tikslumas

Prognozavimo laikotarpis	RMSE	MAPE	MAE
$t+1$	31,8	1,78%	28,6
$t+2$	131	5,78%	106
$t+3$	106	5,32%	98,3
$t+4$	146	5,55%	109

Toliau išbandome modelį su $t-4$ vėlavimais. Šio modelio konstravimas papildomai atskleidžia išorinių kintamųjų parinkimo problematiką – jau kuriant tiesinės regresijos modelius matėme, kad ne visi kintamieji yra reikšmingi ir reikalingi modeliuose, todėl galima numanyti, kad įtraukus į ARIMA modelį egzogeninių kintamųjų matricą iš visų turimų duomenų modelis gali tapti paprasčiausiai perkrautas ir ne tik nepagerinti savo prognozavimo paklaidų, bet pademonstruoti dar silpnesnius rezultatus. Šiame žingsnyje tinkamo modelio sudarymą riboja ir programinė įranga – komanda „*auto.arima()*“, nustatanti geriausią ARIMA modelio eilę, nurodytą egzogeninių kintamųjų matricą priima be papildomo tikrinimo ir kintamųjų atrinkimo. Dėl šių priežasčių reikia kurti dar vieną ciklą, kuris ne tik skaičiuotų modelio tikslumą pagal augančio lango išorinį kryžminį patikrinimą, bet ir

viduje atliktų kintamųjų atrinkimą, pvz. taikant elastingo tinklo reguliarizavimą egzogeninių kintamųjų matricai. Tokios procedūros pagalba gavę tikslumo įverčius matome, kad modelis iš tiesų pagerėja – antro ir vėlesnių laikotarpių prognozės išlieka šiek tiek žemesnės, tačiau labai panašios, tuo tarpu pirmojo ateities periodo prognozė tampa pastebimai tikslesne. Tai rodo, kad egzogeninių kintamųjų matricos įtraukimas į modelį iš tiesų turi naudos.

7 lentelė. ELNET-ARIMAX(1,1,0) modelio tikslumas


Prognozavimo laikotarpis	RMSE	MAPE	MAE
$t+1$	26,9	1,46%	23,5
$t+2$	131	5,71%	105
$t+3$	104	4,9%	91
$t+4$	98,6	3,55%	69,9

Toliau išmėginame ARIMAX modelį, kurio išorinių regresorių matricą sudaro visi galimi vėlavimai ir kuris kartu reikalauja papildomo regresorių prognozavimo ateities reikšmėms skaičiuoti. Šiam modeliui taip pat taikome elastingo tinklo reguliarizavimą reikšmingų egzogeninių kintamųjų identifikavimui. Gauti rezultatai rodo, kad toks modelis pasižymi dar geresnėmis prognozavimo savybėmis – išlaiko žemą pirmo periodo prognozavimo paklaidą ir kartu šiek tiek sumažina $t+3$ ir ypač $t+4$ periodų paklaidas.

8 lentelė. ARIMA šeimos modelių tikslumas

Modelis	RMSE	MAPE	MAE
ELNET-ARIMAX(1,1,0)	90,1	3,91%	72,4
ELNET-ARIMAX(1,1,0) ($t-4$)	104	4,61%	85,6
ARIMA(1,1,0)	105	5,28%	85,7

Turėdami visus tris modelius galime palyginti jų vidutines prognozavimo paklaidas. Šie apibendrinti rezultatai rodo, kad egzogeninių kintamųjų įtraukimas į modelį turėjo naudos, o naujesnių vėlavimų suteikiama informacija apie priklausomą kintamąjį yra didesnė už regresorių ateities reikšmių prognozavimo netikslumus. Todėl gauname, kad ARIMAX(1,1,0) modelis su elastingo tinklo reguliarizavimu išorinių regresorių atrinkimui pateikia geriausius iki šiol gautus rezultatus.



13 pav. ELNET-ARIMAX(1,1,0) modelio rezultatai

Pateiktame modelio grafike vėl galime matyti tiek juoda spalva pažymėtas realias atsinaujinančios energijos vartojimo reikšmes, tiek mėlynas modelio apskaičiuotas reikšmes, tiek raudonai pažymėtas ateities prognozes. Lyginant su anksčiau apžvelgtomis ateities prognozėmis šiuo atveju matome, kad atsinaujinančios energijos vartojimas taip pat turėtų augti, bendra tendencija išlieka ta pati, tačiau augimas nebėra toks didelis – jei ankstesni modeliai rodė, kad vartojimas 2027 metais jau priartės prie 2,5 mln. tonų naftos ekvivalento, tai šiuo atveju prognozuojamas kiekis yra mažesnis, siekiantis tik apie 2,2 mln. tonų.

3.1.4. Pilkasis modelis


Teorijos dalyje analizuojant pilkųjų modelių taikymą energetikos duomenų tyrinėjime aptarėme, kad, priklausomai nuo turimų duomenų, prognozavimui gali būti taikomi dviejų rūšių pilkieji modeliai: GM (1,1), skirtas vienos laiko eilutės nagrinėjimui, ir GM (1,N), skirtas daugiamačių duomenų masyvų tyrimams. Nagrinėdami ankstesnius mokslinius tyrimus taip pat atkreipėme dėmesį, kad esminis pilkųjų modelių privalumas yra galimybė taikyti juos itin mažoms imtims – prognozavimui pakanka turėti vos keturis praeities stebėjimus.

Šiame darbe nagrinėjamus duomenis sudaro metiniai stebėjimai nuo 1990 m. iki 2024m., iš viso 34, todėl iš vienos pusės būtų galima liberaliau elgtis su modelių mokymo ir testavimo imtimis, eksperimentuojant su mokymo dalies stebėjimų kiekiu ir tikrinant šio parametro įtaką testavimo

imties tikslumui, iš kitos pusės, kaip pastebėjo jau atliktų tyrimų autoriai, paprastas pilkasis modelis dėl savo matematinės konstrukcijos nėra labai tikslus prognozavime ir dažniausiai negeba numatyti konkrečių ateities svyravimų, o tik identifikuoja bendrai vyraujančią tendenciją ir numato jos stiprumą ateityje. Kita vertus, analizuodami patį atsinaujinančios energetikos sektorių jau aptarėme, kad ši energijos rūšis yra itin kompleksiška, priklausoma ne vien nuo matematiškai išmatuojamų ekonomikos procesų ir rodiklių, bet ir nuo geopolitinių veiksnių, nuo įvairių institucijų priimamų sprendimų ir vyraujančių politinių pažiūrų. Dėl šių priežasčių bendros ateities tendencijos identifikavimas taip pat būtų naudingas ir leistų geriau suprasti bent jau apytiksles ateities padėtį.

Vis dėlto identifikavus bendrąją tendenciją paprastesniais pilkaisiais modeliais galima bandyti išplėsti juos įvairiais papildiniais ar apjungti kartu su kitokių rūšių matematiniais modeliais – dalį tokių modifikacijų jau aptarėme analizuodami praeities tyrimus, bet šis sąrašas, žinoma, gali būti papildomas ir dar didesniu kiekiu įvairių modifikacijų.

Verta atskirai aptarti ir pilkųjų modelių pritaikymo techninę pusę – kadangi įvairių modelių ir modifikacijų yra daug, o pati pilkųjų modelių šeima yra sąlyginai nauja, jų pritaikymas reikalauja skirti daugiau laiko pačiam programavimui. Palyginimui, jei ARIMA ar kitokių laiko eilučių modelių pritaikymui jau egzistuoja R programos paketai, algoritmai, kurie automatiškai išmėgina įvairių konstrukcijų modelius ir atrinka pačius geriausius, pvz. „*auto.arima()*“ funkcija ir kitos, tai pilkųjų modelių atveju tokių automatizuotų algoritmų nėra ir modifikacijas reikia kurti rankiniu būdu. Paminėti galima du paketus: „GreyModel“, kuris leidžia greitai sukurti GM (1,1) modelį ir jo prognozes, arba „Greymodels“, kuris savyje talpina „Shiny“ programą, leidžiančią įkelti norimą laiko eilutę ir išbandyti keliolika skirtingų pilkųjų modelių modifikacijų.



14 pav. GM (1,1) modelio rezultatai

Pateiktame modelio reikšmių grafike (14 pav.) galime matyti, kad standartinis GM (1,1) modelis iš tikrųjų geba suprasti pateiktos laiko eilutės ilgo laikotarpio tendenciją ir pagal ją pateikia atitinkamas ateities prognozes. Lyginant su anksčiau išbandytais modeliais galime pastebėti, kad struktūrinis laiko eilučių modelis ir elastinio tinklo pagalba gautas regresijos modelis pateikė pakankamai panašias pilkajam modeliui ateities prognozes, ketverių metų laikotarpyje pasiekiančias arti 2,5 mln. tonų naftos ekvivalento, tuo tarpu prieš tai išbandytas ARIMAX modelis prognozavo ne tokį stiprų augimą ir turėjo vidutiniškai aukščiausius tikslumo rezultatus.

9 lentelė. GM (1,1) modelio tikslumas

Prognozavimo laikotarpis	RMSE	MAPE	MAE
t+1	71,59	3,76%	57,85
t+2	76	3,32%	53,33
t+3	99,32	4,65%	77,64
t+4	108,85	5,15%	88,75

Šio modelio prognozavimo tikslumo rezultatai, kaip ir ankstesniais atvejais, skaičiuojami augančio lango kryžminio patikrinimo metodu, pradedant nuo 24 stebėjimų (70%) apmokymo imties. Reikia atkreipti dėmesį, kad $t+2$ periodo prognozės yra vidutiniškai netgi tikslesnės už $t+1$ periodo prognozes, o prognozuodami $t+3$ ir $t+4$ laikotarpius jau galime pastebėti gana ženklų tikslumo sumažėjimą.

Turėdami šiuos pradinio modelio rezultatus ir siekdami juos pagerinti galime atlikti papildomas modelio modifikacijas. Tokios modifikacijos gali būti pakankamai įvairios, siekiančios patobulinti skirtingus modelio taikymo etapus:

- Patobulinto duomenų interpretavimo modeliai:
 - Patobulintas pilkasis modelis (angl. *Improved grey model, IGM*) (1,1)
 - Pilkasis modelis su vienu kintamuoju, vienu pirmos eilės kintamuoju ir keturiomis praeities reikšmėmis (angl. *Grey model with single variable, first-order variable and 4 background values, GM*) (1,1,4)
- Išplėstinių formų pilkieji modeliai:
 - Nehomogeniškas diskretusis pilkasis modelis (angl. *Non-homogenous discrete grey model, NDGM*) (1,1)
 - Kintančio greičio ir prisitaikančios struktūros pilkasis modelis (angl. *Variable speed and adaptive structure-based grey model, VSSGM*) (1,1)
 - Eksponentinis pilkasis modelis (angl. *Exponential grey model, EXGM*) (1,1)
- Kombinuoti modeliai:
 - Netiesinis pilkasis Bernoulli modelis (angl. *Non-linear grey Bernoulli model, NGBM*) (1,1)
- Parametriniai pilkieji modeliai:
 - Netiesinis pilkasis modelis (angl. *Non-linear grey model, NGM*) (1,1,k,c)
 - Netiesinis pilkasis modelis (angl. *Non-linear grey model, ONGM*) (1,1,k,c)

Eksperimentuojant su „Greymodels“ paketo siūlomais pilkaisiais modeliais visi šie modeliai generuoja mažesnes paklaidas, nei standartinis GM(1,1) modelis, tačiau naudojantis pakete įdiegtomis komandomis sudaromų modelių tikslumas matuojamas tik ant visos laiko eilutės, netaikant kryžminio patikrinimo. Dėl to, norint būti tikriems dėl modelio tikslumo rezultatų, praverstų

šių modelių tikslumą patikrinti dar kartą, taikant jau ankstesniuose modeliuose išbandytą augančio lango kryžminio patikrinimo metodą.

10 lentelė. GM modelių tikslumas


Modelis	RMSE	MAPE	MAE
GM (1,1)	88,94	4,22%	69,39
IGM (1,1)	89,53	4,24%	69,82
GM (1,1,4)	96,01	5,28%	83,61
NDGM (1,1)	110,2	5,98%	94,75
VSSGM (1,1)	703,88	30,63%	488,04
EXGM (1,1)	73,07	3,78%	61,4
NGBM (1,1)	90,41	4,86%	77,65
NGM (1,1,k,c)	123,92	6,59%	104,26
ONGM (1,1,k,c)	109,08	5,92%	93,85

Gavę rezultatus matome, kad didžioji dalis modelių išlaiko panašų į pradinio GM (1,1) modelio paklaidų lygį, išskyrus tik VSSGM (1,1) modelį, kuris žvelgiant bendrai per visas kryžminio patikrinimo iteracijas prognozuoja daugmaž artimas reikšmes, bet dviejų testavimo imties stebėjimų vertes prognozuoja itin mažesnes už realias. Nors vėliau reikšmės vėl priartėja prie artimų realioms, bet dėl tokių ekstremalių reikšmių modeliu nereikėtų pasitikėti. Lyginant visus modelius su GM (1,1) galime pastebėti, kad tik vienintelis eksponentinis pilkasis modelis EXGM (1,1) pasižymi mažesnėmis paklaidomis už pradinį modelį ir mažesnėmis netgi už anksčiau geriausiu laikytą ARIMAX (1,1,0) su elastinio tinklo išorinių kintamųjų reguliarizavimu.

11 lentelė. EXGM (1,1) modelio tikslumas

Prognozavimo laikotarpis	RMSE	MAPE	MAE
t+1	60,29	3,42%	52,64
t+2	68,01	3,68%	58,65
t+3	80,69	3,95%	65,51
t+4	83,29	4,05%	68,82

Detaliau nagrinėdami EXGM (1,1) modelio tikslumą galime matyti, kad jam, priešingai nei, pavyzdžiui, anksčiau aptartiems ARIMA šeimos modeliams, nėra būdingas paklaidos šuolis po pirmojo prognozuojamo periodo. Tiek šio, tiek pradinio GM (1,1) modelio atveju matome, kad kiekvienam tolimesniam prognozuojamam laikotarpiui paklaidos yra linkusios augti, tačiau daugmaž tolygiai, be didesnių šuolių. Turint tikslą prognozuoti ilgesnio laikotarpio ateitį tokį išlaikomo rezultatų stabilumo bruožą taip pat galime laikyti savotišku privalumu.



15 pav. EXGM (1,1) modelio rezultatai

Žvelgdami į modelio pateiktas reikšmes (15 pav.) galime matyti, kad modelis iš tiesų pakankamai tiksliai prisitaiko prie realių reikšmių ir tikrai perpranta bendrą laiko eilutės tendenciją, o atidžiau pažvelgę į raudona spalva pažymėtas ateities prognozes matome, kad jos, kaip ir dauguma anksčiau apžvelgtų modelių, rodo beveik tiesinį atsinaujinančios energijos vartojimo augimą ateityje, tačiau šiuo atveju ir vėl nesiekia pirmuosiuose modeliuose matytų beveik 2,5 mln. tonų energijos kiekio reikšmių, o galutinė 2027 metų prognozė siekia tik 2,388 mln. tonų naftos ekvivalento, panašiai kaip šiuo metu jau antrame pagal tikslumą ARIMAX (1,1,0) modelyje su elastinio tinklo išorinių regresorių atranka.

3.1.5. Giluminio mokymosi modelis

Pereinant prie paskutinės rūšies modelių reikia prisiminti, kad teorijos dalyje aptarėme, jog giluminio mokymosi modeliai taip pat yra itin plati šaka, apimanti didelį kiekį modelių ir jų galimų modifikacijų. Taip pat jau minėjome, kad šios šeimos modeliai dar yra vadinami „juodosios dėžės“ (angl. *black box*) modeliais, nes iš principo negalime stebėti, kokie procesai vyksta pačiame modelyje, ir galime tik kontroliuoti modeliui pateikiamus duomenis ir fiksuoti gaunamus rezultatus. Aptardami įvairius praeities tyrimus matėme, kad sėkmingai buvo taikomi įvairūs modeliai, neretai juos papildomai modifikuojant ar apjungiant su kitais modeliais. Todėl, laikantis nusistovėjusios tvarkos, šioje dalyje taip pat galime išbandyti kelis skirtingus metodus, taikant augančio lango kryžminį patikrinimą gauti jų tikslumo rezultatus, palyginti juos tarpusavyje ir identifikuoti geriausiais rezultatais pasižymintį modelį. Pagal poreikį, jei pradiniai modeliai nerodys gerų rezultatų, o taip pat

ir siekiant pranokti iki šiol geriausią rezultatą parodžiusį EXGM (1,1) modelį, pritaikytus pradinis modelius bus galima modifikuoti jau aptartais būdais.

Per daug nesigilinant į techninę pusę vertėtų paminėti, kad šios rūšies modelių konstravimui vien R programinės įrangos nepakaks, reikės „reticulate“ paketo pagalba apjungti R ir Python skaičiavimus, iš R pusės papildomai naudojant „keras3“ ir „tensorflow“ paketus.

Detaliau nagrinėjant galimus modelius galime prisiminti, kad apžvelgiant praeityje atliktus tyrimus pakankamai populiarius ir neblogais tikslumo rezultatais pasižymintys buvo konvuliuciniai neuroniniai tinklai CNN, taip pat ilgos trumpalaikės atminties modelis LSTM. Dėl to pradėti galime nuo šių modelių pritaikymo, kartu, pavyzdžiui, išbandant ir pilnų jungčių neuroninį tinklą (angl. *dense neural network*. DNN arba *fully connected neural network*, FCN).

12 lentelė. Giluminio mokymosi modelių tikslumas

Modelis	Prognozavimo laikotarpis	RMSE	MAPE	MAE
DNN	t+1	225	15,8%	208
	t+2	89,4	6,2%	89,4
	t+3	246	15,7%	236
	t+4	417	21,5%	339
	Vidurkis	244	14,8%	218
CNN	t+1	18,7	1,13%	14,5
	t+2	87,1	6,04%	87,1
	t+3	84,2	4,06%	63,6
	t+4	142	8,65%	136
	Vidurkis	83,1	4,97%	75,4
LSTM	t+1	70,5	4,36%	60,5
	t+2	84,6	5,58%	79,9
	t+3	91,4	5,47%	84,3
	t+4	87	5,08%	80,2
	Vidurkis	83,4	5,12%	76,2

Šioje vietoje verta detaliau pažvelgti į visų modelių rezultatus. Visų pirma matome, kad pagal vidutines paklaidas geriausiai pasirodo ilgos trumpalaikės atminties modelis, antroje vietoje būtų konvuliucinių neuroninių tinklų modelis ir prasčiausiai pasirodė pilnų jungčių neuroninis tinklas. Papildomai pažvelgę į kiekvieno prognozavimo periodo rezultatus galime matyti, kad DNN ir LSTM modeliai yra pakankamai stabilūs bet koku išbandytu prognozavimo laikotarpiu – reikšmės šiek tiek svyruoja, pirmo periodo prognozavimas yra šiek tiek tikslesnis už kitus, bet nežymiai. Tuo tarpu konvuliucinių neuroninių tinklų modelis, panašiai kaip anksčiau nagrinėti ARIMAX modeliai, pirmu prognozuojamu laikotarpiu yra labai tikslus, tačiau prognozuojant tolimesnes ateities reikšmes paklaidos ženkliai išauga. Tai rodo, kad nors šiuo atveju modelis nėra tinkamas, nes siekiame maksimizuoti visų keturių ateities periodų tikslumą, jis taip pat nėra ir blogas. Jei, pavyzdžiui, tikslas būtų prognozuoti tik vieno ateities laikotarpio reikšmę – modelis tam puikiai tiktų be jokių papildomų modifikacijų ir būtų geriausias iš visų trijų išbandytų.

Visgi šiuo atveju geriausių tenka pripažinti LSTM modelį, kurio vidutinis tikslumas per visus prognozuojamus laikotarpius yra didžiausias. Tačiau ir šie tikslumo rezultatai nėra ypatingai geri, ankstesnėse dalyse išbandant kitų rūšių modelius pavyko gauti pastebimai geresnius rezultatus, dėl to vertėtų paeksperimentuoti su LSTM modifikacijomis, pavyzdžiui:

- Dvigubas LSTM su šalinimu: du LSTM sluoksniai, su šalinimo procedūra tarp jų, išvengiant persimokymo;
- Dvikryptis LSTM: modeliuojamos abipusės priklausomybės;
- LSTM su rekurentiniu šalinimu ir stabilizavimu: greitesnis ir stabilesnis mokymasis;
- Daugiaeilis LSTM: vietoje pažingsninio prognozavimo gaunamos iškart 4 periodų prognozės;
- LSTM su adaptavimu: modelis geriau adaptuojasi, kuriuos išorinius kintamuosius svarbiausia naudoti.

13 lentelė. Modifikuotų LSTM modelių tikslumas


Modelis	RMSE	MAPE	MAE
Dvigubas LSTM	66	4,03%	59,3
Dvikryptis LSTM	63,1	3,85%	56,5
Rekurentinis LSTM	99,6	6,16%	89,7
Daugiaeilis LSTM	71,5	4,32%	64,5
LSTM su adaptavimu	66,1	4,34%	63,6

Iš pateiktų 5 modifikacijų rezultatų matome, kad iš esmės pagerinti pradinį LSTM modelį pavyko. Vienintelis rekurentinis LSTM modelis parodė prastesnius vidutinius rezultatus, o visi kiti modeliai buvo pranašesni už pradinį. Bendrai nagrinėjant giluminio mokymosi modelius matėme, kad egzistuoja modelių, kurie gali būti nestabilūs didinant prognozuojamų periodų kiekį, tačiau šie LSTM šeimos modeliai tokiais bruožais nepasižymėjo ir tuo dar kartą galime įsitikinti tikrindami šių modelių tikslumą. Labiausiai verta atkreipti dėmesį į dvikryptį ilgą trumpalaikės atminties modelį (angl. *Bidirectional LSTM*, *Bi-LSTM*), kuris pasirodė geriausiai iš visų modelių ir pasižymi labai panašiais prognozavimo rezultatais kaip geriausių iki šiol laikytas eksponentinis pilkasis modelis EXGM (1,1).

14 lentelė. Dvikrypčio LSTM modelio tikslumas

Prognozavimo laikotarpis	RMSE	MAPE	MAE
t+1	75,1	4,36%	60,9
t+2	79	5,36%	76,9
t+3	74,4	3,59%	56,2
t+4	35,4	2,22%	35,1

Detaliau išskaidytuose modelio rezultatuose galime matyti, kokios paklaidos vidutiniškai pasiekiamos kiekvienam prognozavimo laikotarpiui. Šie rezultatai yra ganėtinai išskirtiniai, nes modelis pasižymi ne augančiomis, bet mažėjančiomis paklaidomis – jei ankstesniais atvejais matėme, kad paklaidos arba išlieka daugmaž stabilios, arba pastebimai auga didinant prognozavimo laikotarpį, tai šiuo atveju $t+3$ periodo paklaidos sumažėja, o $t+4$ periodu yra pačios mažiausios.



16 pav. Dvikrypčio LSTM modelio rezultatai

Žvelgdami į modelio rezultatų grafiką (16 pav.) galime pastebėti, kad modelis ne tik perpranta ilgalaikę duomenų tendenciją, bet ir reaguoja į trumpalaikius svyravimus, apskaičiuotos modelio reikšmės nebėra tokios tolygiai kintančios kaip EXGM (1,1) modelio atveju. Nagrinėdami ateities prognozes ir vėl matome labai panašius rezultatus kaip ankstesniuose modeliuose, rodančius atsinaujinančios energijos vartojimo augimą ateityje. Šiuo atveju pats augimas atrodo laipsniškai mažėjantis, energijos vartojimas pasižymi vis mažesniu prieaugiu kiekvienais metais. Galutiniame prognozuojamame 2027 m. laikotarpyje atsinaujinančios energijos vartojimas turėtų priartėti prie 2,5 mln. tonų naftos ekvivalento, tačiau neviršyti šio rodiklio.

3.2. Darbo rezultatai

Apžvelgus ir išbandžius visų penkių šeimų modelius vertėtų dar kartą prisiminti taikytus metodus, esminius gautus rezultatus ir juos struktūruotai apžvelgti, priimant galutines darbo išvadas. Taip pat vertėtų detaliau panagrinėti galutinėms prognozėms pritaikytą modelį, pasiaiškinti jo konstrukciją ir ypatybes.

3.2.1. Gautos prognozės

Teorijos dalyje nagrinėdami praeityje atliktus tyrimus atsinaujinančios energetikos srityje matėme, kad duomenų tyrybai ir ateities prognozavimui gali būti taikomi įvairių formų ir sudėtingumo matematiniai modeliai. Tyrėjai sėkmingai pritaikė modelius nuo paprasčiausių laiko eilučių modelių

iki sudėtingesnių ekonometrinių ar ARIMA modelių, nedidelės apimties duomenims naudojo pastaruoju metu vis populiarėjančius pilkuosius modelius, gerus rezultatus taip pat demonstravo ir juodosios dėžės giluminio mokymosi modeliai. Kita vertus, iš praeities tyrimų sunku objektyviais kriterijais nustatyti, kokie matematiniai modeliai yra geriausi – labiausiai tinkantys ateities reikšmių prognozavimui, pasižymintys aukščiausiais tikslumo rezultatais. Tokie sunkumai iškyla dėl to, kad dažniausiai panašaus pobūdžio atsinaujinančios energetikos tyrimai nebūna tiek išsamūs modelių taikymo prasme ir, kaip matėme teorijos dalyje, autoriai ateities verčių prognozavimui įprastai taiko vienos ar dviejų rūšių modelius.

Norint turėti geresnį supratimą apie modelių tinkamumą ir jų panaudojimo galimybes šiame darbe buvo išbandyti visų penkių aptartų rūšių modeliai. Nagrinėjant kiekvienos rūšies modelius visų pirma buvo taikoma vidinė modelių atranka iš įvairių galimų alternatyvų ir standartinių modelių išplėtimų, modifikacijų – analizuojant laiko eilučių modelius išbandyta virš 20 alternatyvų, kuriant ekonometrinių tiesinės regresijos modelių eksperimentuota su įvairiais reguliarizavimo metodais reikšmingų egzogeninių kintamųjų atrinkimui, ARIMA šeimos modeliai taip pat buvo modifikuojami praplečiant juos iki ARIMAX modelių, išorinių regresorių atranką vykdant įvairiais reguliarizavimo metodais, nagrinėjant pilkųjų modelių šeimą ir vėl buvo eksperimentuojama su įvairiomis konstrukcinėmis modelių modifikacijomis, o galiausiai apžvelgiant giluminio mokymosi modelius buvo išbandytos įvairių architektūrų alternatyvos ir jų galimos modifikacijos.

Kad visus modelius būtų galima nesunkiai palyginti, didžiausią tikslumą pasiekiančio modelio ieškota visoms alternatyvoms taikant vienodus kriterijus. Visų pirma nagrinėjama laiko eilutė buvo suskaidoma į mokymo ir testavimo imtis, pradinę mokymo imtį sudarant iš 70% laiko eilutės stebėjimų. Tuomet modelis buvo kuriamas naudojant apmokymo imties duomenis ir taikant augančio lango kryžminį patikrinimą: prognozuojant po 4 ateities periodus, palyginant kiekvieno periodo prognozes su realiomis reikšmėmis, kaupiant kiekvienoje iteracijoje gautas paklaidas ir kitame žingsnyje didinant mokymosi imtį per vieną stebėjimą. Ciklo pabaigoje suskaičiuojamos galutinės kiekvieno modelio paklaidos: šaknis iš vidutinės kvadratinės paklaidos, vidutinė absoliuti procentinė paklaida ir vidutinė absoliuti paklaida. Rezultatai pateikiami apskaičiavus tiek kiekvieno prognozavimo periodo nuo $t+1$ iki $t+4$ paklaidų vidurkį, tiek ir bendrą paklaidų vidurkį per visus periodus.

Gavus paklaidų rezultatus išrinktas geriausias kiekvienos šeimos modelis ir jį pritaikius turimiems duomenims gaunamos 2024–2027 metų prognozės. Finale, išbandžius visų šeimų modelius, paaiškėjo, kad geriausiai atsinaujinančios energijos vartojimo Lietuvoje duomenims tinka eksponentinis pilkasis modelis EXGM (1,1) – tradicinio pilkojo modelio GM (1,1) modifikacija. Šio modelio pagalba prognozuojant duomenis gaunamos pačios mažiausios paklaidos pagal visus apskaičiuotus paklaidų matus. Žinoma, reikia paminėti, kad kitų šeimų modeliai nebūtinai yra ženkliai prastesni:

15 lentelė. Modelių tikslumas pagal šeimas

Šeima	Geriausias modelis	RMSE	MAPE	MAE
Pilkieji	EXGM (1,1)	73,07	3,78%	61,4
Giluminio mokymosi	Dvikryptis LSTM	63,1	3,85%	66,5
ARIMA	ARIMAX (1,1,0) + elastinis tinklas	90,1	3,91%	72,4
Laiko eilučių	Struktūrinis laiko eilučių modelis	97,8	4,9%	77,2

Šeima	Geriausias modelis	RMSE	MAPE	MAE
Ekonometriniai	Tiesinė regresija + elastingis tinklas	148,96	8,54%	138,58

Pateiktoje lentelėje galime matyti, kad pagal vidutinius tikslumo matavimus iš esmės vienodai gerai pasirodė trys modeliai – eksponentinis pilkasis modelis EXGM (1,1), giluminio mokymosi dvikryptis ilgos trumpalaikės atminties modelis, leidžiantis informacijai judėti abejomis kryptimis ir ARIMAX (1,1,0) modelis su papildoma elastingio tinklo atranka išorinių kintamųjų matricai. Tačiau pažvelgus į detalesnes modelių paklaidas pagal kiekvieną prognozavimo periodą galėjome matyti, kad modelių elgsena skiriasi – jei EXGM (1,1) pilkasis modelis išlaikė daugumą vienodą stabilumą per visus keturis laikotarpius, tai giluminio mokymosi dvikryptis ilgos trumpalaikės atminties modelis turėjo unikalią savybę rodyti vis geresnį tikslumą tolimesniems periodams, o ARIMAX (1,1,0) modelis su elastingio tinklo reguliarizavimu labai gerai tiko pirmojo periodo prognozei, tačiau visi vėlesni periodai turėjo pastebimai didesnes paklaidas. Tai, beje, galiojo ir kitiems dviem išbandytiems ARIMA šeimos modeliams – tiek paprastesniam ARIMA (1,1,0) be egzogeninių regresorių matricos, tiek vien $t-4$ išorinių kintamųjų vėlavimais paremtam ARIMAX (1,1,0) su elastingio tinklo kintamųjų atranka. Dar geresnį pirmojo laikotarpio tikslumą turėjo konvoliucinių neuroninių tinklų modelis, tačiau vėlesnės paklaidos buvo ženkliai didesnės ir todėl šį modelį pranoko LSTM architektūros modeliai.

Iš šių rezultatų galime matyti, kad modelio pasirinkimas gali priklausyti ir nuo keliamų uždavinių – šiame darbe siekta gauti būsimų 4 reikšmių prognozes, todėl geriausiu tekstu pripažinti ir mažiausias vidutines paklaidas turintį ir didžiausiu stabilumu pasižymintį EXGM (1,1) pilkąjį modelį, tačiau, jei tikslas būtų gauti tik trumpalaikę vieno periodo prognozę, pasirinkimas turėtų būti visai kitoks ir pilkieji modeliai tokiais užduočiais netiktų. Toks rezultatas dar kartą patvirtina ir ankstesnių teorijos dalyje aptartų tyrimų išvadas, kad pilkųjų modelių šeima dažniausiai nėra tinkama trumpalaikio triukšmo prognozavimui ar itin tikslų prognozių gavimui, tačiau gerai perpranta ilgalaikes duomenų tendencijas ir gerai prognozuoja jų ateities raidą. Kitas tyrėjų pastebimas privalumas – pilkieji modeliai geriausiai tinka mažoms imtims, nes modelio rezultatams apskaičiuoti pakanka vos 4 praeities stebėjimų. Nagrinėjant šią temą duomenų rinkinį sudaro metinės reikšmės nuo 1990 metų iki 2023 metų imtinai, kitaip tariant 34 stebėjimai, o tai yra kelis kartus daugiau, nei reikalauja pilkieji modeliai. Iš kitos pusės, tai tikrai nėra didelė duomenų imtis, ir, reikia paminėti, kad toks duomenų nepakankamumas taip pat galėjo lemti sąlyginai neblogus pilkųjų modelių rezultatus, lyginant su sudėtingesnėmis matematinėmis konstrukcijomis pasižyminčiais alternatyviais modeliais.

16 lentelė. EXGM (1,1) modelio ateities prognozės

Laikotarpis	Reikšmė (tūkst. t naftos ekvivalento)	Vidutinės periodo paklaidos		
		RMSE	MAPE	MAE
2024	2076,45	60,29	3,42%	52,64
2025	2175,55	68,01	3,68%	58,65
2026	2279,38	80,69	3,95%	65,51
2027	2388,16	83,29	4,05%	68,82

Finale galime pažvelgti į galutines šio darbo prognozes, vizualiai matomas 15 pav. Kaip jau anksčiau pastebėjome, labai panašius rezultatus rodė ir kiti du geriausi modeliai - ir ARIMAX (1,1,0), ir dvikryptis LSTM modelis. Pagal modelių prognozes, bendras atsinaujinančios energijos vartojimas Lietuvoje vienareikšmiškai turėtų augti, bendra ketverių metų augimo tendencija turėtų būti daugumą

tiesinės formos ir jau 2024 metų reikšmė turėtų pirmą kartą viršyti 2 mln. tonų naftos ekvivalento atsinaujinančios energijos suvartojimo, o paskutiniu prognozuojamu periodu šis vartojimas turėtų priartėti prie 2,4 mln. tonų naftos ekvivalento. Čia lyginant modelių prognozes galime pastebėti, kad prasčiau pasirodę modeliai buvo linkę perprognozuoti – jei tikslesni modeliai rodė, kad reikšmės pasieks apie 2,4 mln. tonų ribą, tai struktūrinis laiko eilučių modelio ir tiesinės regresijos su regularizavimu prognozės rodė priartėjimą jau prie 2,5 mln. tonų naftos ekvivalento ribos. Taip pat galime pastebėti, kad pagal Eurostato duomenis bendras energijos vartojimas Lietuvoje yra pakankamai stabilus, paskutinius 10 metų svyruojantis ties 7-8 mln. tonų naftos ekvivalento vertėmis. Tai rodo, kad, išliekant ilgalaikėms tendencijoms, pagal 2027 metų gaunamas prognozes Lietuvos atsinaujinančios energijos vartojimas galėtų sudaryti apie 30% visos vartojamos energijos kiekio.

Gavę tokias ateities prognozes galime prisiminti dar pačios atsinaujinančios energetikos sektoriaus apžvelgimo metu pastebėtas tendencijas, kad pastarąjį dešimtmetį itin sparčiai auga naujų atsinaujinančios energijos rūšių, tokių kaip vėjo energija, vartojimas. Matėme, kad šios energijos vartojimas jau tapo antru pagal suvartojamą kiekį po biokuro ir išstūmė iki tol virš 30 metų antroje vietoje buvusią hidroenergiją, kurios vartojimas yra daugmaž stabilus. Dėl to galime numanyti, kad šis atsinaujinančios energijos vartojimo augimas taip pat būtų didžiąja dalimi nulemtas augančio vėjo energijos vartojimo. Maža to, žvelgiant į dar tolimesnes perspektyvas galima numanyti, kad būtent vėjo energija lems atsinaujinančios energijos suvartojimo šuolį apie 2030 metus – būtent šiais metais planuojama Baltijos jūros vėjo jėgainių parko „Curonian Nord“ statybos pabaiga ir pagal planuojamus jėgainių parko pajėgumus išgaunamas energijos kiekis turėtų tenkinti apie 25% visos energijos poreikio Lietuvoje. Būtent šiuo projektu rėmėsi ir jau minėti „Ember“ energetikos analitinio centro ekspertai, teigdami, kad Lietuva turi strateginės reikšmės galimybę tapti energijos eksportuotoja savo regione. Iš kitos pusės, kaip jau aptarėme teorijos dalyje nagrinėjant teisinį atsinaujinančios energetikos reguliavimą, praeitos kadencijos Europos Komisija paskelbusi žaliąjį kursą kartu sukūrė ir subsidijavimo mechanizmą, papildomai skatinantį atsinaujinančios energetikos plėtrą. Viena vertus, toks skatinimas lemia naujas konkurencines galimybes, kaip jau aptartu Lietuvos jūrinių vėjo jėgainių parko atveju. Kita vertus jau anksčiau aptarėme, kad reikšmingai pasikeitus prioritetams, pavyzdžiui, dėl geopolitinių priežasčių, saugumo padėties, toks finansavimas gali būti peržiūrėtas ir sumažintas. Tai, priklausomai nuo pokyčių dydžio, galėtų esmingai koreguoti ateities tendencijas, nes, kaip vėlgi jau aptarėme nagrinėdami atsinaujinančiai artimos branduolinės energijos subtilumus, būtent ši energijos rūšis pasižymi žemiausiais gamybos kaštais ir, anot Tarptautinės energijos agentūros ekspertų, turėtų išlaikyti šį privalumą bent iki 2030 metų.

3.2.2. Matematinė modelio išraiška

Taip pat, turėdami atrinkę geriausią modelį, galime detaliau panagrinėti jo matematinę konstrukciją ir išsiaiškinti veikimo principą.

Turime neneigiamą n narių laiko eilutę:

$$x^{(0)} = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)) \quad (1)$$

Tada jos pirmos eilės kaupiamąsias sumas galėtume apibrėžti kaip

$$x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i), \quad k = 1, 2, \dots, n \quad (2)$$

Įprastame pilkajame modelyje GM (1,1) toliau būtų skaičiuojamas pirmos eilės kaimyninių vidurkių operatorius

$$z^{(1)}(k) = \frac{x^{(1)}(k) + x^{(1)}(k-1)}{2}, \quad k = 2, \dots, n \quad (3)$$

O modelio „balinimo“ lygtimi (angl. *whitenization equation*) laikoma

$$\frac{d}{dt}x^{(1)}(t) + ax^{(1)}(t) = b \quad (4)$$

Arba skirtumų forma

$$x^{(0)}(k) + az^{(1)}(k) = b \quad (5)$$

O modelio parametrai a ir b apskaičiuojami mažiausių kvadratų metodu $B[a, b]^T = Y$, kur

$$B = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix}, Y = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \vdots \\ x^{(0)}(n) \end{bmatrix} \quad (6)$$

Atlikus skaičiavimus $[a, b]^T = (B^T B)^{-1} B^T Y$, išsprendžiama lygtis

$$\hat{x}^{(1)}(k) = \left(x^{(0)}(1) - \frac{b}{a} \right) e^{-a(k-1)} + \frac{b}{a}, \quad k = 2, \dots, n \quad (7)$$

Ir galiausiai apskaičiuojame pradinės eilutės prognozes:

$$\hat{x}^{(0)}(k) = \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1), \quad k = 2, \dots, n \quad (8)$$

Matant pradinio GM (1,1) modelio procedūrą lengviau suprasti eksponentinio pilkojo modelio modifikacijas. Esminis skirtumas – pradinio modelio „balinimo“ lygtis papildoma įtraukiant laike kintančią eksponentinę išraišką, kuri turėtų geriau atspindėti laiko eilutės pokyčius. Ši eilutė apibrėžiama kaip

$$\frac{d}{dt}x^{(1)}(t) + ax^{(1)}(t) = b + ce^{-t} \quad (9)$$

kur c yra papildomas parametras. Reikia pastebėti, kad parinkus parametrą $c = 0$, modelis grįžta į pradinę GM (1,1) formą. Modifikacijos autoriaus Bilgilo (2020) teigimu, toks papildymas pagerina modelio tikslumą ir lankstumą. Bazinė diferencinė lygtimi yra vadinama skirtumų forma

$$x^{(0)}(k) + az^{(1)}(k) = b + c(e^{-1} - 1)e^{-k}, \quad k = 2, \dots, n \quad (10)$$

Atitinkamai skiriasi ir tolimesnis laiko atsako funkcijos skaičiavimas

$$\hat{x}^{(1)}(k) = \left(x^{(0)}(1) - \frac{b}{a} - \frac{c}{a-1} \right) e^{-a(k-1)} + \frac{b}{a} + \frac{c}{a-1} e^{-k} \quad (11)$$

Finale pagal turimą lygtį apskaičiuojama pradinės eilutės prognozė:

$$\hat{x}^{(0)}(k) = \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1), \quad k = 2, \dots, n \quad (12)$$

Taigi iš esmės modeliai yra labai panašūs, tačiau EXGM (1,1) modelis turi papildomą eksponentinį kintamąjį, leidžiantį geriau modeliuoti sudėtingesnes laiko eilutes. Gauti rezultatai parodė, kad šiame darbe nagrinėjamiems duomenims EXGM (1,1) modelis taip pat yra tinkamesnis už pradinį GM (1,1) ir eksponentinio nario pagalba geba geriau prisitaikyti prie pateiktos laiko eilutės.

Nagrinėdami prognozavimui sudarytą modelių galime pastebėti, kad gaunami tokie parametrai:

17 lentelė. EXGM (1,1) modelio parametrai

Parametras	Reikšmė
a	-0,0466
b	433,15
c	2086,29

3.3. Siūlymai ir rekomendacijos

Šiame darbe buvo siekiama atrasti kiek įmanoma tikslesnį matematinį modelių bendro atsinaujinančios energijos vartojimo Lietuvoje nagrinėjimui ir prognozavimui, tačiau kartu ignoruoti ar nenagrinėti keli galimai reikšmingi aspektai, kuriuos galėtų būti naudinga apžvelgti ateities darbuose.

Patį darbą būtų galima išplėsti iki atskirų energijos sektorių poreikio prognozavimo, įvertinant atskirų energijos rūšių raidą ir ateities tendencijas. Tokiam tikslui būtų galima taikyti šiame tyrime neišbandytus daugiamačių regresijos modelius, tokius kaip vektorinė autoregresija, pilkųjų modelių šeimos (1,N) eilės modeliai ar papildomi giluminio mokymosi modeliai. Jau matėme, kad skirtingos energijos rūšys pasižymi skirtingais bruožais ir tendencijomis, todėl tikėtina, kad atsižvelgimas į tokius individualių atsinaujinančios energijos rūšių bruožus ir ypatybes leistų pasiekti geresnius tikslumo rezultatus ir suteiktų papildomų žinių apie kiekvieno atskiros sektoriaus raidą ateityje.

Taip pat remiantis šiame darbe gautais rezultatais būtų galima atidžiau panagrinėti, kaip Lietuvai seksis įgyvendinti užsibrėžtus žaliojo kurso tikslus. Vienas iš tokių susitarimų, kaip jau aptarta anksčiau, yra iki 2030 metų sumažinti į aplinką išskiriamų teršalų kiekį bent 55%, lyginant su 1990 metais. Remiantis gautomis prognozėmis ir turint omenyje, kad ilgalaikėms tendencijoms nekintant jau 2027 metais atsinaujinančios energijos santykinis kiekis galėtų siekti apie 30%, galima papildomai įsivertinti į aplinką Lietuvoje išmetamų teršalų kiekį, jo priklausomybę nuo skirtingų rūšių energijos suvartojimo ir numatyti sutartų tikslų įgyvendinimo galimybes, identifikuoti galimas problemines vietas ir įvertinti naujų sprendimų reikalingumą. Iškilus būtinybei papildomai didinti atsinaujinančios energijos vartojimą, jau aptartų ekspertų teigimu, Lietuvai dėl savo geografinės padėties būtų naudinga plėsti vėjo jėgainių parkų statybą, ypač jūrinių jėgainių, taip kartu didinant ir energetikos sektoriaus nepriklausomybę nuo užsienio importo.

Išvados

1. Atsinaujinančios energetikos plėtra priklauso nuo politinių iniciatyvų, o geopolitiniai iššūkiai tam tikra apimtimi jau keičia prioritetus – naujoji Europos Komisijos sudėtis svarbiausiais tikslais įvardina konkurencingumo ir gynybos pramonės stiprinimą, demokratijos saugojimą.
2. Energetikos tyrimams sėkmingai gali būti taikomi įvairūs modeliai: laiko eilučių, ekonometriniai, ARIMA, pilkieji ir giluminio mokymosi modeliai, tačiau jų pritaikomumas priklauso nuo prognozuojamo laikotarpio.
3. Nagrinėtų duomenų trumpojo laikotarpio (vieno periodo) prognozavimui geriausiai tinka ARIMA šeimos modeliai arba konvoliuciniai neuroniniai tinklai CNN – nors vėlesnių laikotarpių paklaidos išauga, tačiau $t+1$ periodo prognozės pasižymi dideliu tikslumu.
4. Norint prognozuoti ilgesnį laikotarpį labiau tinka eksponentinis pilkasis modelis EXGM (1,1), dvikryptis LSTM modelis arba ARIMAX (1,1,0) su elastinio tinklo reguliarizavimu – šie modeliai pasižymi ir mažiausia vidutine paklaida per visą prognozuojamą laikotarpį, ir išlaiko paklaidų stabilumą didinant prognozuojamų laikotarpių skaičių.
5. Visų modelių prognozės rodo atsinaujinančios energijos augimą 2024–2027 metais, esant dabartinėms sąlygoms nagrinėjamo laikotarpio pabaigoje atsinaujinančios energijos vartojimas turėtų priartėti prie 2,4 mln. tonų naftos ekvivalento, arba, vertinant santykiniais dydžiais, iš užimamo ketvirtadalio visame bendros energijos suvartojime prognozuojamo laikotarpio pabaigoje turėtų sudaryti apie trečdalį visos energijos suvartojimo.

Literatūros sąrašas

1. Acheampong, M., Ertem, F. C., Kappler, B., Neubauer, P. (2016). *In pursuit of Sustainable Development Goal (SDG) number 7: Will biofuels be reliable?* Renewable and Sustainable Energy Reviews, 75 927–937
2. Ajanovic, A. (2013). *Renewable fuels – A comparative assessment from economic, energetic and ecological point-of-view up to 2050 in EU-countries.* Renewable Energy, 60 (2013) 733–738
3. Al-Hamadi, H., & Soliman, S. (2005). Long-term/mid-term electric load forecasting based on short-term correlation and annual growth. *Electric Power Systems Research*, 74(3), 353–361.
4. Alharbi, F. R., & Csala, D. (2022). A Seasonal Autoregressive Integrated Moving Average with Exogenous Factors (SARIMAX) Forecasting Model-Based Time Series Approach. *Inventions*, 7(4), 94.
5. Almeida, D. V., Kolinjivadi, V., Ferrando, T., Roy, B., Herrera, H., Gonçalves, M. V., & Van Hecken, G. (2023). The “Greening” of Empire: The European Green Deal as the EU first agenda. *Political Geography*, 105, 102925.
6. Al-Mulali, U. (2014). *The Impact of Biofuel Energy Consumption on GDP Growth, CO2 Emission, Agricultural Crop Prices, and Agricultural Production.*
7. Alpackaya, I., Fallah, M. H., Mounika, N., Sood, S., Rajvanshi, S., Lakhanpal, S., Cajla, P., Sharma, A., & Lalitha, Y. S. (2024). Renewable Energy Forecasting using Deep Learning Techniques. *E3S Web of Conferences*, 581, 01011.
8. Alsharif, M. H., Younes, M. K., & Kim, J. (2019). Time Series ARIMA model for prediction of daily and monthly average global solar radiation: The case study of Seoul, South Korea. *Symmetry*, 11(2), 240.
9. Apergis, N., Payne, J. E. (2009). *Renewable energy consumption and economic growth: Evidence from a panel of OECD countries.* Energy Policy, 38 (2010) 656–660
10. Aras, H., & Aras, N. (2004). *Forecasting residential natural gas demand.* Energy Sources, 26(5), 463–472.
11. Arroyo, J., San Roque, A. M., Mate, C., Sarabia, A. (2007). *Exponential smoothing methods for interval time series.* Proceedings of the 1st European Symposium on Time Series Prediction.
12. Arsenault, E., Bernard, J-T., Carr, C. W., Genest-Laplanche, E. (1995). A total energy demand model of Quebec. Forecasting properties. *Fuel and Energy Abstracts*, 36(5), 385.
13. Aslam, S., Herodotou, H., Mohsin, S. M., Javaid, N., Ashraf, N., & Aslam, S. (2021). A survey on deep learning methods for power load and renewable energy forecasting in smart microgrids. *Renewable and Sustainable Energy Reviews*, 144, 110992.
14. Aslan, A. (2015). *The causal relationship between biomass energy use and economic growth in the United States.* Renewable and Sustainable Energy Reviews, 57 (2016) 362–366
15. Badri, M. A., Al-Mutawa, A., Davis, D., & Davis, D. (1997). EDSSF: A decision support system (DSS) for electricity peak-load forecasting. *Energy*, 22(6), 579–589.
16. Benti, N. E., Chaka, M. D., & Semie, A. G. (2023). Forecasting Renewable Energy Generation with Machine Learning and Deep Learning: Current Advances and Future Prospects. *Sustainability*, 15(9), 7087.
17. Bessec, M., & Fouquau, J. (2008). The non-linear link between electricity consumption and temperature in Europe: A threshold panel approach. *Energy Economics*, 30(5), 2705–2721.

18. Bilgil, H. (2020). New grey forecasting model with its application and computer code. *AIMS Mathematics*, 6(2), 1497–1514.
19. Brodny, J., Tutak, M., Saki, S. A. (2020). *Forecasting the Structure of Energy Production from Renewable Energy Sources and Biofuels in Poland*. *Energies* 2020, 13, 2539.
20. Charytoniuk, W., Chen, & Van Olinda, P. (1998). Nonparametric regression based short-term load forecasting. *IEEE Transactions on Power Systems*, 13(3), 725–730.
21. Chavez, S. G., Bernat, J. X., & Coalla, H. L. (1999). *Forecasting of energy production and consumption in Asturias (northern Spain)*. *Energy*, 24(3), 183–198.
22. Cho, M., Hwang, J., & Chen, C. (2002). Customer short term load forecasting by using ARIMA transfer function model. *IEE Catalogue No. 95TH8130*, 1, 317–322.
23. Conejo, A., Plazas, M., Espinola, R., & Molina, A. (2005). Day-Ahead electricity price Forecasting using the Wavelet Transform and ARIMA models. *IEEE Transactions on Power Systems*, 20(2), 1035–1042.
24. Daim, T., Harell, G., & Hogaboam, L. (2012). Forecasting renewable energy production in the US. *Foresight*, 14(3), 225–241.
25. Ding, S., Dang, Y., Li, X., Wang, J., & Zhao, K. (2017). Forecasting Chinese CO₂ emissions from fuel combustion using a novel grey multivariable model. *Journal of Cleaner Production*, 162, 1527–1538.
26. Ding, S., Tao, Z., Li, R., & Qin, X. (2022). A novel seasonal adaptive grey model with the data-restacking technique for monthly renewable energy consumption forecasting. *Expert Systems With Applications*, 208, 118115.
27. Dones, R., Heck, T., Hirschberg, S. (2004). Greenhouse Gas Emissions from Energy Systems, Comparison and Overview.
28. Ediger, V. Ş., Akar, S., & Uğurlu, B. (2005). Forecasting production of fossil fuel sources in Turkey using a comparative regression and ARIMA model. *Energy Policy*, 34(18), 3836–3846.
29. Erdogdu, E. (2009). Natural gas demand in Turkey. *Applied Energy*, 87(1), 211–219.
30. Fumo, N., & Biswas, M. R. (2015). Regression analysis for prediction of residential energy consumption. *Renewable and Sustainable Energy Reviews*, 47, 332–343.
31. Ghalekhondabi, I., Ardjmand, E., Weckman, G. R., & Young, W. A. (2016). An overview of energy demand forecasting methods published in 2005–2015. *Energy Systems*, 8(2), 411–447.
32. Haida, T., & Muto, S. (1994). Regression based peak load forecasting using a transformation technique. *IEEE Transactions on Power Systems*, 9(4), 1788–1794.
33. Hall, D., & Scrase, J. (1998). Will biomass be the environmentally friendly fuel of the future? *Biomass and Bioenergy*, 15(4–5), 357–367.
34. Hong, S., Qvist, S., & Brook, B. W. (2017). Economic and environmental costs of replacing nuclear fission with solar and wind energy in Sweden. *Energy Policy*, 112, 56–66.
35. Inman, R. H., Pedro, H. T., & Coimbra, C. F. (2013). Solar forecasting methods for renewable energy integration. *Progress in Energy and Combustion Science*, 39(6), 535–576.
36. Intarapavich, D., Johnson, C. J., Li, B., Long, S., Pezeshki, S., Prawiraatmadja, W., Tang, F. C., & Wu, K. (1996). 3. Asia-Pacific energy supply and demand to 2010. *Energy*, 21(11), 1017–1039.
37. International Energy Agency. (2025). The Path to a New Era for Nuclear Energy. *IEA Publications*.

38. Karakan, A. (2024). Predicting energy production in renewable energy power plants using deep learning. *Energies*, 17(16), 4031.
39. Khortsriwong, N., Boonraksa, P., Boonraksa, T., Fangsuwannarak, T., Boonsrirat, A., Pinthurat, W., & Marungsri, B. (2023). Performance of deep learning techniques for forecasting PV power generation: A case study on a 1.5 MWp floating PV power plant. *Energies*, 16(5), 2119.
40. Kilinc-Ata, N. (2016). The evaluation of renewable energy policies across EU countries and US states: An econometric approach. *Energy Sustainable Development/Energy for Sustainable Development*, 31, 83–90.
41. Kumari, P., & Toshniwal, D. (2021). Deep learning models for solar irradiance forecasting: A comprehensive review. *Journal of Cleaner Production*, 318, 128566.
42. Lam, J. C., Tang, H., & Li, D. H. (2007). Seasonal variations in residential and commercial sector electricity consumption in Hong Kong. *Energy*, 33(3), 513–523.
43. Lilkov, D. (2023). Climate realism: Policy proposals for effective decarbonisation and true sustainability in the EU. *European View*, 22(2), 213–222.
44. Liu, L., & Wu, L. (2020). Forecasting the renewable energy consumption of the European countries by an adjacent non-homogeneous grey model. *Applied Mathematical Modelling*, 89, 1932–1948.
45. Liu, L., Wang, Q., Liu, M., & Li, L. (2014). An intelligence optimized rolling grey forecasting model fitting to small economic dataset. *Abstract and Applied Analysis*, 2014, 1–10.
46. Malý, J. (2024). Will the Green Deal weaken the competitiveness and cohesion of the European Union? In *Sciendo eBooks* (pp. 168–175).
47. Manigandan, P., Alam, M. S., Alharthi, M., Khan, U., Alagirisamy, K., Pachiyappan, D., & Rehman, A. (2021). Forecasting Natural Gas Production and Consumption in United States- Evidence from SARIMA and SARIMAX Models. *Energies*, 14(19), 6021.
48. Maradin, D. (2020). *Advantages and Disadvantages of Renewable Energy Sources Utilization*. *International Journal of Energy Economics and Policy*, 2021, 11(3), 176-183.
49. McCombie, C., & Jefferson, M. (2016). Renewable and nuclear electricity: Comparison of environmental impacts. *Energy Policy*, 96, 758–769.
50. Mišík, M., & Oravcová, V. (2024). Policy persistence vis-à-vis a crisis: the curious case of Slovak energy policy after the Russian invasion of Ukraine. *Energy Efficiency*, 17(4).
51. Nafil, A., Bouzi, M., Anoune, K., & Ettalabi, N. (2020). Comparative study of forecasting methods for energy demand in Morocco. *Energy Reports*, 6, 523–536.
52. Nanfack, P. F. T., Abakaka, I. M., Aziz, A., & Tsuanyo, D. (2022). Analysis of programming languages used in solving energy problems. *E3S Web of Conferences*, 354, 01006.
53. O'Neill, B. C., & Desai, M. (2003). Accuracy of past projections of US energy consumption. *Energy Policy*, 33(8), 979–993.
54. Pappas, S., Ekonomou, L., Karamousantas, D., Chatzarakis, G., Katsikas, S., & Liatsis, P. (2008). Electricity demand loads modeling using AutoRegressive Moving Average (ARMA) models.
55. Przychodzen, W., & Przychodzen, J. (2019). Determinants of renewable energy production in transition economies: A panel data approach. *Energy*, 191, 116583.
56. Razykov, T. M., Ferekides, C. S., Morel, D., Stefanakos, E., Ullal, H. S., Upadhyaya, H. M. (2011). *Solar photovoltaic electricity: Current status and future prospects*. *Solar Energy*, 85 (2011) 1580-1608.

57. Rosslowe, C., Petrovich, B. (2025). *European Electricity Review 2025*. Ember.
58. Ruhnau, O., Hennig, P., & Madlener, R. (2020). Economic implications of forecasting electricity generation from variable renewable energy sources. *Renewable Energy*, 161, 1318–1327.
59. Sampaio, P. G. V., Gonzalez, M. O. A. (2017). *Photovoltaic solar energy: Conceptual framework*. *Renewable and Sustainable Energy Reviews*, 74 (2017) 590-601.
60. Shahbaz, M., Raghutla, C., Chittedi, K. R., Jiao, Z., & Vo, X. V. (2020). The effect of renewable energy consumption on economic growth: Evidence from the renewable energy country attractive index. *Energy*, 207, 118162.
61. Suganthi, L., & Samuel, A. A. (2011). Energy models for demand forecasting—A review. *Renewable and Sustainable Energy Reviews*, 16(2), 1223–1240.
62. Tarjanne, R., Aija, K. (2008). *Comparison of Electricity Generation Costs*.
63. Teixeira, R., Cerveira, A., Pires, E. J. S., & Baptista, J. (2024). Advancing Renewable Energy Forecasting: A comprehensive review of renewable energy forecasting methods. *Energies*, 17(14), 3480.
64. Thellufsen, J. Z., Lund, H., Mathiesen, B. V., Østergaard, P. A., Sorknæs, P., Nielsen, S., Madsen, P. T., & Andresen, G. B. (2024). Cost and system effects of nuclear power in carbon-neutral energy systems. *Applied Energy*, 371, 123705.
65. Troster, V., Shahbaz, M., & Uddin, G. S. (2018). Renewable energy, oil prices, and economic activity: A Granger-causality in quantiles analysis. *Energy Economics*, 70, 440–452.
66. Tsai, S., Xue, Y., Zhang, J., Chen, Q., Liu, Y., Zhou, J., Dong, W. (2016). *Models for forecasting growth trends in renewable energy*. *Renewable and Sustainable Energy Reviews*, 77 1169–1178
67. Tunç, M., Çamdali, Ü., & Parmaksizoğlu, C. (2004). Comparison of Turkey's electrical energy consumption and production with some European countries and optimization of future electrical power supply investments in Turkey. *Energy Policy*, 34(1), 50–59.
68. Ulazia, A., & Ibarra-Berastegi, G. (2016). Study of ocean and wind energy potential with R: an innovative experience in the classroom. *2nd International Conference on Higher Education Advances, HEAd'16*.
69. Upadhyay, S., Ahmed, I., & Mihet-Popa, L. (2024). Energy management system for an industrial microgrid using Optimization Algorithms-Based Reinforcement Learning Technique. *Energies*, 17(16), 3898.
70. Wang, H., Lei, Z., Zhang, X., Zhou, B., & Peng, J. (2019). A review of deep learning for renewable energy forecasting. *Energy Conversion and Management*, 198, 111799.
71. Yuan, C., Liu, S., & Fang, Z. (2016). Comparison of China's primary energy consumption forecasting by using ARIMA (the autoregressive integrated moving average) model and GM(1,1) model. *Energy*, 100, 384–390.
72. Yucesan, M., Pekel, E., Celik, E., Gul, M., & Serin, F. (2021). Forecasting daily natural gas consumption with regression, time series and machine learning based methods. *Energy Sources Part a Recovery Utilization and Environmental Effects*, 1–16.
73. Yumurtaci, Z., & Asmaz, E. (2004). Electric energy demand of Turkey for the year 2050. *Energy Sources*, 26(12), 1157–1164.
74. Zhou, W., & Ding, S. (2020). A novel discrete grey seasonal model and its applications. *Communications in Nonlinear Science and Numerical Simulation*, 93, 105493.

75. Zhou, W., Cheng, Y., Ding, S., Chen, L., & Li, R. (2020). A grey seasonal least square support vector regression model for time series forecasting. *ISA Transactions*, 114, 82–98.