



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Lietuvos elektros energijos kainų Nord Pool biržoje prognozavimas

Baigiamasis magistro studijų projektas

Agnė Pečiulytė

Projekto autorė

Prof. Dr. Daiva Dumčiuvienė

Vadovė

Doc. Dr. Loreta Saunorienė

Vadovė

Kaunas, 2025



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Lietuvos elektros energijos kainų Nord Pool biržoje prognozavimas

Baigiamasis magistro studijų projektas

Didžiųjų verslo duomenų analitika (6213AX001)

Agnė Pečiulytė

Projekto autorė

Prof. Dr. Daiva Dumčiuvienė

Vadovė

Prof. Dr. Vytautas Snieška

Recenzentas

Doc. Dr. Loreta Saunorienė

Vadovė

Dr. Irma Jankauskienė

Recenzentė

Kaunas, 2025



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Agnė Pečiulytė

Lietuvos elektros energijos kainų Nord Pool biržoje 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.

Agnė Pečiulytė

Patvirtinta elektroniniu būdu

Pečiulytė Agnė. Lietuvos elektros energijos kainų Nord Pool biržoje prognozavimas. Magistro studijų baigiamasis projektas / vadovė prof. dr. Daiva Dumčiuvienė, vadovė doc. dr. Loreta Saunorienė; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

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

Reikšminiai žodžiai: elektros energijos kaina, išorinės verslo aplinkos veiksniai, prognozavimas.

Kaunas, 2025. 56 p.

Santrauka

Baigiamajame projekte analizuojama ir prognozuojama Lietuvos elektros energijos kaina nuo 2024-01-01 iki 2025-02-28. Ši tema yra aktuali dėl didelio visuomenės, verslo ir politikos susidomėjimo elektros kainų dinamika, būtinybės planuoti veiklą ir jos sąnaudas bei užtikrinti energetinį efektyvumą.

Nustatyta, kad Lietuvos elektros energijos kainai įtaką daro šie kintamieji: istorinės elektros energijos kainos Švedijos SE4 kainų zonoje, Lenkijoje ir Lietuvoje; dienos prieš rinkoje prognozuojamas elektros energijos suvartojimas Lietuvoje, Švedijos SE4 kainų zonoje, Latvijoje, Lenkijoje; dienos prieš rinkoje prognozuojama elektros energijos gamyba Lietuvoje, Švedijos SE1, SE2, SE3, SE4 kainų zonose, Suomijoje, Danijos DK1, DK2 kainų zonose, Latvijoje, Estijoje, Lenkijoje; prognozuojama saulės elektrinių gamyba Lietuvoje; prognozuojama vėjo elektrinių gamyba Lietuvoje; komerciniai tarpsteminiai srautai tarp Švedijos SE4 kainų zonos ir Lietuvos, tarp Latvijos ir Lietuvos, tarp Lenkijos ir Lietuvos; dujų kaina Lietuvoje.

Taip pat buvo sudaryti keturi vienmačiai ir keturi daugiamatiai prognozavimo modeliai: atsitiktinis miškas, atraminių vektorių regresija, *XGBoost*, *LightGBM*. Geriausias vienmatis prognozavimo modelis – atsitiktinis miškas, kai medžių skaičius miške lygus 300, atsitiktinai pasirenkamų vėlavimų skaičius mazgų skaidymui lygus 2, o lapuose minimalus stebėjimų skaičius lygus 5. Šio modelio vidutinė MAPE paklaida lygi 0,05 %. Geriausias daugiamatis prognozavimo modelis – *XGBoost*, kai mokymosi žingsnis, reguliuojantis kiekvieno naujo medžio įtaką galutinei prognozei, lygus 0,05, maksimalus medžio gylis lygus 6, atsitiktinai pasirenkama duomenų dalis, naudojama kiekvieno medžio apmokymui, lygi 0,8, o atsitiktinai pasirenkama kintamųjų dalis – 0,8. Visgi daugiamatis prognozavimo modelis neaplenkė vienmačio – *XGBoost* modelio vidutinė MAPE paklaida lygi 28,12 %.

Pečiulytė Agnė. Forecasting Lithuanian Electricity Prices on the Nord Pool. Master's Final Degree Project / supervisor prof. dr. Daiva Dumčiuvienė, supervisor doc. dr. Loreta Saunorienė; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology.

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

Keywords: electricity price, external business environment factors, forecasting.

Kaunas, 2025. 56.

Summary

The final project analyses and forecasts Lithuanian electricity prices for the period from January 1, 2024, to February 28, 2025. This topic is relevant due to the high level of public, business, and political interest in electricity price dynamics, as well as the need to plan activities and costs effectively and to ensure energy efficiency.

The following variables have been identified as influencing Lithuanian electricity prices: historical electricity prices in the Swedish SE4 price zone, Poland, and Lithuania; day-ahead electricity consumption forecasts for Lithuania, the Swedish SE4 price zone, Latvia, and Poland; day-ahead electricity generation forecasts for Lithuania, Swedish SE1, SE2, SE3, and SE4 price zones, Finland, Danish DK1 and DK2 price zones, Latvia, Estonia, and Poland; forecasted solar and wind power generation in Lithuania; and commercial inter-system flows between the Swedish SE4 price area and Lithuania, between Latvia and Lithuania, and between Poland and Lithuania, as well as the gas price in Lithuania.

Four univariate and four multivariate forecasting models were developed: Random Forest, Support Vector Regression, *XGBoost*, and *LightGBM*. The best-performing univariate forecasting model is the Random Forest, with parameters $n_{tree} = 300$, $m_{try} = 2$, and $nodesize = 5$, achieving an average MAPE of 0.05%. The best-performing multivariate prediction model is *XGBoost*, with parameters $eta = 0.05$, $max_depth = 6$, $subsample = 0.8$, and $colsample_bytree = 0.8$. However, the multivariate prediction model did not outperform the univariate one — the *XGBoost* model achieved an average MAPE of 28.12%.

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Įvadas.....	9
1. Literatūros apžvalga	10
1.1. Elektros energetikos sektorius	10
1.2. Elektros energijos kainoms įtaką darantys išorinės verslo aplinkos veiksniai	13
1.3. Lietuvos elektros energijos kainų analizės tyrimai	14
1.4. Prognozavimo metodai	17
2. Tyrimo modeliai ir metodai.....	22
2.1. Kintamojo tendencijų analizės ir duomenų tvarkymo metodai	22
2.2. Išorinės verslo aplinkos veiksnių identifikavimo ir tarpusavio sąveikos nustatymo metodai..	24
2.3. Prognozavimo modeliai.....	26
2.4. Prognozės tikslumo metrikos	28
2.5. Tyrimo metodai	30
3. Tyrimo rezultatai.....	32
3.1. Lietuvos elektros energijos kainos tendencijų analizė	32
3.2. Išorinės verslo aplinkos veiksnių, darančių įtaką Lietuvos elektros energijos kainai, nustatymas	35
3.3. Vienmatis ir daugiamatis elektros energijos kainos prognozavimo modeliai	44
Išvados	50
Literatūros sąrašas	51
Priedai.....	57
1 priedas. Kokybinis veiksnių tarpusavio sąveikos vertinimas	57
2 priedas. Veiksnių tarpusavio priklausomybės reikšmingumas.....	58
3 priedas. Sudaryti vienmačio atsitiktinio miško modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė.....	59
4 priedas. Sudaryti vienmatės atraminių vektorių regresijos modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė	60
5 priedas. Sudaryti vienmačiai <i>XGBoost</i> modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė	61
6 priedas. Sudaryti vienmačiai <i>LightGBM</i> modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė	62
7 priedas. Sudaryti daugiamatės atsitiktinio miško modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė.....	63
8 priedas. Sudaryti daugiamatės atraminių vektorių regresijos modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė	64
9 priedas. Sudaryti daugiamatės <i>XGBoost</i> modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė	65
10 priedas. Sudaryti daugiamatės <i>LightGBM</i> modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė.....	66

Lentelių sąrašas

1 lentelė. Literatūros šaltiniuose analizuoti elektros energijos kainai įtaką darantys išorinės verslo aplinkos veiksniai	15
2 lentelė. Lietuvos elektros energijos kainos statistinės charakteristikos (EUR/MWh).....	32
3 lentelė. Literatūros šaltiniuose nustatytas išorinės verslo aplinkos veiksnių poveikis elektros energijos kainoms	35
4 lentelė. PESTLE analizė	36
5 lentelė. Tyrime, naudojami išorinės verslo aplinkos veiksniai.....	38
6 lentelė. Grangerio priežastingumo analizės rezultatas	42
7 lentelė. Geriausi vienmačiai prognozavimo modeliai ir jų tikslumo metrikos.....	45
8 lentelė. Geriausi daugiamačiai prognozavimo modeliai.....	47

Paveikslų sąrašas

1 pav. Elektros energijos kiekio ir rinkos kainos priklausomybė [1]	11
2 pav. Elektros energijos kainos priklausomybė nuo gamintojo savikainos	11
3 pav. Lietuvos elektros energijos valandinės kainos.....	32
4 pav. Lietuvos elektros energijos valandinės kainos išskirtys	33
5 pav. Elektros energijos kainų autokoreliacijos ir dalinės autokoreliacijos grafikai	33
6 pav. MSTL dekompozicija	34
7 pav. Išorinės verslo aplinkos veiksnių kryžminio poveikio matrica	40
8 pav. Išorinės verslo aplinkos veiksnių Spearmano koreliacijos koeficientų matrica	41
9 pav. Grangerio priežastingumo analizės „gėlytės“ grafikas.....	44
10 pav. Tikroji ir vienmačių modelių prognozuota 2025-02-08–2025-02-11 elektros energijos kaina Lietuvoje.....	46
11 pav. Vienmačių prognozavimo modelių liekanų grafikas	46
12 pav. Vidutinė 24 valandų vienmatės prognozės sudarymo trukmė.....	47
13 pav. Tikroji ir daugiamatės modelių prognozuota 2025-02-08–2025-02-11 elektros energijos kaina Lietuvoje	48
14 pav. Daugiamatės prognozavimo modelių liekanų grafikas	48
15 pav. Vidutinė 24 valandų daugiamatės prognozės sudarymo trukmė	49

Ivadas

Pastaraisiais metais Lietuvos elektros energijos rinka susiduria su reikšmingais pokyčiais, kuriuos lemia tiek geopolitinė situacija, tiek sparčiai kintanti Europos Sąjungos energetikos politika, skatinanti žaliosios energetikos plėtrą. Elektros energijos kainų svyravimai tapo opia problema tiek gyventojams, tiek verslui, nes netikėti kainų šuoliai daro tiesioginę įtaką veiklos planavimui, sąnaudoms, konkurencingumui. Atsižvelgiant į tai, tampa vis svarbiau ne tik suprasti kainų kitimo priežastis, bet ir gebėti jas prognozuoti pasitelkiant duomenų analizę ir modeliavimą. Šio darbo tyrimų objektas – elektros energijos kainos Lietuvoje. Tyrimo aktualumą lemia nuolat augantis poreikis turėti patikimus įrankius, leidžiančius prognozuoti kainas ir priimti pagrįstus sprendimus. Kainų prognozavimo modeliai gali būti ypač naudingi energetikos sektoriaus įmonėms, didelės apimties vartotojams ir politikams. Šio darbo naujumas – mašininio mokymosi (atsitiktinio miško, atraminių vektorių regresijos, *XGBoost* ir *LightGBM*) vienmatis ir daugiamatis elektros energijos prognozavimo modeliai. Atsižvelgiant į iškeltą problemą, keliamas tikslas – atlikti Lietuvos elektros energijos kainų prognozavimą. Projekto uždaviniai:

1. atlikti elektros energetikos sektoriaus apžvalgą ir elektros energijos kainų Lietuvoje tendencijų analizę;
2. nustatyti išorinės verslo aplinkos veiksnius, darančius įtaką Lietuvos elektros energijos kainai;
3. sudaryti vienmatį ir daugiamatį prognozavimo modelius elektros energijos kainos kitimui paroje nustatyti;
4. įvertinti sudarytų modelių tikslumą, palyginant gautus tyrimo rezultatus.

1. Literatūros apžvalga

Elektros energija pasižymi ypatingomis savybėmis, kurių neturi joks kitas energijos šaltinis: maksimali eksergija, neribotas energinis tankis, itin maža masė. Dėl šių savybių elektros energiją pakeisti kitu energijos šaltiniu yra sunku, o kartais net neįmanoma [1].

Energetikos pramonė ir ekonomika sparčiai auga visame pasaulyje [2] ir tampa vis labiau elektrifikuota [3]. Elektra vis dažniau naudojama vietoj iškastinio kuro, norint patenkinti šilumos, judumo ir pramonės energijos poreikį. Remiantis Tarptautinės energetikos agentūros 2024 metų ataskaita [3], nuo 2010 m. elektros energijos paklausa vidutiniškai padidėjo po 2,7 % per metus, o bendra energijos paklausa – atitinkamai po 1,4 %. Šį augimą skatina spartus besivystančių ekonomikų industrializavimas, skaitmenizacija ir vis didėjantis elektrinių transporto priemonių populiarumas. Tuo pačiu metu energijos gamybos šaltinių struktūra keičiasi iš esmės – atsinaujinantys energijos ištekliai tapo vienu svarbiausiu elektros energijos gamybos komponentu [2]. 2022 metais atsinaujinantys energijos ištekliai sudarė 30 % pasaulyje pagaminamos elektros energijos, prognozuojama, kad iki 2030 metų šis rodiklis sieks beveik 50 % [4]. Tačiau paklausos augimo tempas ir su juo susijęs neapibrėžtumas taip pat kelia iššūkių užtikrinant saugų, įperkamą ir tvarų elektros energijos tiekimą [3].


1.1. Elektros energetikos sektorius

Elektros energetikos sektorius apima elektros energijos gamybą, perdavimą, skirstymą, tiekimą, vartojimą ir prekybą elektros energija [5]. Nuo XX a. pabaigos elektros energetikos sektorius, tradiciškai monopolinis ir kontroliuojamas vyriausybės, pradėjo keistis – dereguluota elektros rinka, atsirado konkurencinės rinkos taisyklės [6]. Elektros energetikos sistema sudaro [5]:

- elektrinės, kurios gamina elektrą;
- aukštos įtampos elektros perdavimo linijos, kuriomis elektros energija perduodama dideliais atstumais (Lietuvoje – perdavimo sistemos operatorius LITGRID AB);
- žemos ir vidutinės įtampos elektros skirstymo tinklas, kuriuo elektros energija persiunčiama galutiniam vartotojui (Lietuvoje – skirstomųjų tinklų operatorius ESO);
- elektros energijos vartotojai.


Prekybos elektros energija ir susijusias paslaugas siūlo *Nord Pool* – pirmaujanti Europos elektros energijos rinka [7]. *Nord Pool* teikiamomis paslaugomis naudojasi Lietuva ir dar keturiolika Europos šalių, kasdien prekiaujančių elektros energija [6] tiek dienos, tiek dienos į priekį rinkose [8]. Dienos į priekį rinkoje klientai perka ir parduoda elektros energiją uždaramame aukcione ateinančioms 24 valandoms. Pateikti pasiūlymai derinami tarpusavyje ir, atsižvelgiant į elektros energijos pasiūlą, paklausą ir perdavimo tinklo apribojimus, nustatomos ateinančios dienos elektros energijos kainos kiekvieną valandą kiekvienoje šalyje [9]. Kadangi elektros energijos rinkoje kiekvieną akimirką turi būti išlaikytas energijos pasiūlos ir paklausos balansas [10], dienos rinka veikia kartu su dienos į priekį rinka ir, atsižvelgdama į netikėtus vartojimo pokyčius ar sutrikimus, padeda užtikrinti reikiamą paklausos ir pasiūlos pusiausvyrą [11]. Dėl augančios atsinaujinančių energijos išteklių įdiegtos galios [6] ir kol kas nesant galimybei kaupti ir saugoti elektros energiją [10], didėja susidomėjimas prekyba dienos rinkoje, nes rinkos dalyviams darosi sunku išlaikyti pusiausvyrą, pasibaigus dienos į priekį sandorių laikui [11].

Elektros rinkos kaina užtikrina paklausos ir pasiūlos suderinamumą [1]. Esant didesnei pardavimo kainai, padidėja pasiūla, bet mažėja vartojimas. Elektros energijos kiekio ir rinkos kainos priklausomybės grafinis vaizdas pateikiamas 1 pav.



1 pav. Elektros energijos kiekio ir rinkos kainos priklausomybė [1]

Oy ašyje pateikta elektros energijos kaina, o Ox ašyje – kiekis. Pasiūla ir paklausa yra subalansuotos pusiausvyros A_0 taške. Norint pasiekti šią pusiausvyrą, vienintelė informacija, kuri turi būti prieinama visiems rinkos dalyviams, yra rinkos kaina. Ji leidžia kiekvienam rinkos dalyviui individualiai nuspręsti, kiek elektros energijos bus parduodama, o kiek perkama, neatsižvelgiant į kitų rinkos dalyvių elgesį. Rinkos balansavimo savybė pasireiškia, kai pasikeičia rinkos sąlygos. Tarkim, vartotojas už tam tikrą energijos kiekį pasiryžęs sumokėti daugiau. Rinkos pusiausvyros taškas pereina iš A_0 taško į A_1 tašką su didesne kaina $p_{E**} > p_{E*}$ ir didesniu kiekiu $Q^* > Q^{**}$. Tačiau pasiūla nėra tokia lanksti ir iš pradžių nereaguoja į didesnę pardavimo kainą, o tai reiškia, kad tiekimo kreivė taške A_0 kyla vertikaliai aukšty. Atitinkamai kaina pakyla iki p_{max} . Padidėjus kainai, tiekėjai didina gamybą, todėl kainos krenta nuo p_{max} iki p_{E**} , o sandorio kiekis padidėja iki Q^{**} . Esant tobulai konkurencijai (nėra rinkos galios, vartotojų ar gamintojų diskriminacijos, išorinio poveikio, o kaina skaidri), anksčiau aptarta rinkos pusiausvyrą atitinka Pareto optimumo sąlygą. Tai reiškia, kad nei vienas tiekėjas ir nei vienas vartotojas neturės geresnių sąlygų, nepabloginus sąlygų bent vienam rinkos dalyviui. Pavyzdžiui, šiek tiek padidinus pradinę pusiausvyros kainą p_{E*} , tiekėjai uždirbtų daugiau, tačiau nukentėtų vartotojai [1]. Didmeninė elektros energijos rinkos kaina priklauso nuo to, kokia yra paskutinio gamintojo, užtikrinusio elektros energijos paklausą, savikaina [12]. Ši priklausomybė iliustruota 2 pav.



2 pav. Elektros energijos kainos priklausomybė nuo gamintojo savikainos

Kai elektros energijos paklausą visapusiškai padengia pigūs energijos šaltiniai, tokie kaip vėjas, saulė ar hidroenergija, kurių kintamosios sąnaudos yra artimos nuliui, elektros energijos rinkos kaina gali būti labai žema ar net neigiama. Tačiau kai šie atsinaujinantys šaltiniai dėl sezoniškumo ar oro sąlygų negali pagaminti pakankamai energijos, paklausa tenkinama brangesniais energijos šaltiniais, pavyzdžiui, šiluminėmis elektrinėmis, naudojančiomis gamtines dujas ar kitą iškastinį kurą. Tokiu atveju rinkos kaina ženkliai padidėja dėl aukštesnių gamintojų veiklos sąnaudų. Neigiamos elektros energijos kainos susidaro dėl kelių priežasčių. Pirmiausia dėl to, kad nelanksčios elektrinės, pavyzdžiui, anglimi kūrenamos ar atominės elektrinės, patiria išlaidų, susijusių su jų stabdymu ir paleidimu [13]. Šios elektrinės naudoja vieną iš galimų *Nord Pool* biržos dienos prieš rinkos prekybos strategijų – prekybą vykdo blokinais pavedimais (angl. *block order*). Tai reiškia, kad gamintojas teikia kelių ar keliolikos valandų pasiūlymus, kuriems taikoma sąlyga „viskas arba nieko“ [14] – arba visas pasiūlymas priimamas, arba visas atmetamas. Tuo metu, kai atsinaujinantys energijos ištekliai padengia elektros energijos poreikį, o šios elektrinės dėl patvirtintų blokinių pavedimų taip pat turi veikti, susidaro neigiamos kainos [13]. Taip pat gamintojai, tokie kaip vėjų parkai, yra įsipareigoję per metus pagaminti tam tikrą energijos kiekį ir dėl to, net esant neigiamoms elektros kainoms, negali stabdyti gamybos. Nustatyta, kad nepastovi vėjo ir saulės energijos gamyba didina mažų ir neigiamų elektros energijos kainų tikimybę [15]. Gautos prognozės rodo, kad ateityje neigiamos kainos dažnės, jei elektros rinka netaps lankstesnė. Pirkėjas, neigiamos kainos atveju, laimi [16]: paneigiamas mainų principas, nes pirkėjas nemoka už prekę, bet gauna užmokestį už ją. Taigi, atsiranda piniginė paskata įvertinti ir keisti savo vartojimo įpročius.

Valstybės, siekdamos apsisaugoti nuo elektros energijos kainų elektros biržoje svyravimų, sudaro dvišalius ilgalaikius kontraktus [8]. Jų esmė – susitarimas tarp elektros energijos gamintojo ir vartotojo dėl fiksuotos elektros energijos kainos [17]. Pavyzdžiui, sutarta fiksuota 30 EUR už 1 MWh elektros energijos kainą. Jei *Nord Pool* kaina siekia 100 EUR už 1 MWh, gamintojas už kiekvieną nupirktą megavatvalandę vartotojui sumoka 70 EUR kompensaciją. Jei *Nord Pool* kaina siekia 10 EUR už 1 MWh, tada vartotojas gamintojui moka po 20 EUR už 1 MWh.

Kaip ir daugelio kitų prekių ir paslaugų atveju, elektros energijos paklausa [1] kinta per dieną ir metus [18]. Paklausa žiemą, esant rytiniams ir vakariniams pikams, paprastai yra didesnė nei vasarą, esant vidurdienio pikui. Pavasarį ir rudenį paklausa taip pat skiriasi. Elektros energijos paklausai įtaką daro ir geografinė padėtis: pietiniuose regionuose didesnis energijos poreikis patalpų vėsinimui, o šiauriniuose regionuose – šildymui [1]. Elektros energijos tiekėjai naudoja skirtingas technologijas, kad patenkintų kintančią paklausą. Naudojamų technologijų sąnaudos skirtingos, todėl paslaugų kainos skiriasi pikų ir ne pikų valandomis. Ne piko metu sistemoje yra pertekliniai gamybos pajėgumai, o piko metu sistema jaučia padidėjusį pajėgumų poreikį, dėl to atsiranda papildomos išlaidos, susijusios su pajėgumų padidinimu. Todėl vartotojai, vartojantys elektros energiją piko metu, turi prisiimti atsakomybę, kitaip tariant, sumokėti už pajėgumo didinimo ir operatyvines išlaidas [18].

Energijos kainodara yra svarbus šalies energetikos politikos įrankis, skirtas reguliuoti energijos rinką, skatinti efektyvų energijos vartojimą ir investicijas į energetikos infrastruktūrą bei atsinaujinančius energijos šaltinius. Elektros energijos kaina iš dalies priklauso nuo tarptautinių energijos rinkų veikimo ir įtakos bei nuo pačios šalies socialinės-politinės aplinkos. Lietuvoje visuomeninę elektros energijos kainą ir tarifus skelbia Valstybinė energetikos reguliavimo tarnyba (VERT).

Lietuvos elektros energijos kainos dedamosios [19]:

- elektros energijos įsigijimo kaina;
- perdavimo kaina;
- viešuosius interesus atitinkančių paslaugų (VIAP) mokestis;
- skirstymo išlaidos;
- visuomeninio tiekimo kainos ir faktinės elektros energijos įsigijimo kainos bei ankstesnio laikotarpio prognozuotos elektros energijos kainos skirtumas.

Šiame darbe pagrindinis dėmesys bus skirtas elektros energijos įsigijimo *Nord Pool* biržoje kainai.

1.2. Elektros energijos kainoms įtaką darantys išorinės verslo aplinkos veiksniai

Pasaulyje elektros energijos rinkos tampa vis labiau integruotos, o kintamųjų tarpusavio priklausomybės vis labiau komplikotos dėl atsinaujinančios energetikos plėtros ir rinkos struktūros pokyčių. Tikimasi, kad didėjantis atsinaujinančių energijos išteklių (AEI) paplitimas turės didelę įtaką elektros energijos kainoms, nes AEI būdingos beveik nulinės ribinės sąnaudos, o tradicinės, pavyzdžiui, šiluminės elektrinės, praranda savo vaidmenį kainų formavime [20].

E. Belengueris [21] tyrime nustatė, kad didžiausią įtaką 2017–2018 m. Ispanijos dienos į priekį rinkos elektros energijos kainai darantys veiksniai yra elektros energijos paklausa, vėjo ir saulės energijos gamyba. Teigiama, kad savaitės diena koreliuoja su energijos paklausa, todėl savaitės dienos, kaip atskiro įvesties veiksnio, įtraukti nėra tikslo, nes ši informacija prognozės rezultatų nepagerina. H. Acaroğlu [2] straipsnyje pateikia išsamią elektros energijos rinkos kainų ir apkrovos prognozavimo metodų apžvalgą, ypatingą dėmesį skiriant vėjo energijai. Nustatyta, kad vėjo energijos gamyba sumažina didmeninę elektros kainą, tačiau padidina nepastovumą dėl stochastinio oro sąlygų pobūdžio. Kitame straipsnyje, nagrinėjant Vakarų Danijos 2016–2017 m. duomenis, naudojami šie išorinės verslo aplinkos veiksniai [22]: temperatūra, prognozuojamas elektros energijos suvartojimas ir gamyba, prognozuojama vėjo energijos elektros energijos gamyba, naftos, gamtinių dujų kaina, vandens rezervuarų lygis. Panaudojus kintamųjų eliminavimo (angl. *Backward elimination*) metodą, nustatyta, kad temperatūra nėra naudingas kintamasis ir jį reikia pašalinti iš modelio, o elektros energijos suvartojimas ir prognozuojama vėjo energijos gamyba yra svarbiausi veiksniai. Iš ARIMA modelio pašalinus kintamąjį temperatūrą, RMSE paklaida pagerėjo 1,6 %, o MAE – 3,85 %.

Siekiant įvertinti kiekvieno naudojamo kintamojo svarbą prognozavimo procese, galima atlikti SHAP (angl. *SHapley Additive exPlanations*) analizę. Pavyzdžiui, naudojant atsitiktinių miškų regresijos metodą, Vokietijos ir Prancūzijos duomenų rinkiniams dviejų, trijų ar septynių dienų elektros energijos kainų vėlavimai beveik nenaudojami, o didžiausią įtaką daro Šveicarijos ir pačių šalių elektros energijos kainos. Taip pat akcentuojama, kad gretimų valstybių elektros energijos kainų įtraukimas į prognozavimo modelį teigiamai veikia rezultatų tikslumą [23].

H. Jiang [24] tyrimo tikslas buvo sukurti aukštos kokybės ir interpretuojamą tikimybinį elektros kainų prognozavimo modelį. Empiriniai tyrimai atlikti naudojant 2014–2016 m. *Nord Pool* elektros biržos kainas Belgijoje, 2015–2017 m. EPEX elektros biržos kainas Vokietijoje, 2016–2018 m. OMIE elektros biržos kainas Ispanijoje ir 2016–2018 m. PJM elektros biržos kainas Jungtinėse Amerikos Valstijose. Į duomenų rinkinį buvo įtraukti tokie veiksniai, kaip tinklo apkrova, energijos paklausa, vėjo ir saulės energijos gamyba, naftos kaina, rasos taško temperatūra, slėgis, saulės

spinduliuotė, temperatūra, garavimas, krituliai, CO_2 ir PM_{10} emisija, švenčių dienos. Šių veiksnių įtraukimas į modelį ne tik padidino prognozavimo efektyvumą, bet ir pagerino modelio aiškumą.

Nagrinėjant Didžiosios Britanijos dienos į priekį elektros energijos rinką, be naftos kainos, dujų kainos ir orų prognozės buvo pasiūlyta įtraukti priklausomybę tarp skirtingų EPEX SPOT ir *Nord Pool* elektros energijos prekybos biržų [25]. H. Yangas [26] naudojo Niujorko nepriklausomo sistemos operatoriaus duomenis (NYISO) ir nustatė, kad svarbiausi veiksniai, prognozuojant elektros energijos kainas, yra istorinės kainos, temperatūra, valanda ir zoninė apkrova. Daugiamačiam Ontarijo provincijos elektros kainų prognozavimo modeliui sudaryti naudojamos ankstesnės elektros energijos kainos, gamyba, apkrova, importas ir eksportas bei oro sąlygos [27].

1.3. Lietuvos elektros energijos kainų analizės tyrimai

Lietuvos elektros energijos kainų analizė ir prognozavimas nėra nauja tema. Nuo 2018 m. rasti šeši baigiamieji magistro darbai ir penki moksliniai straipsniai, nagrinėjantys šią temą.

R. Beigaitė [28] baigiamajame darbe naudojo valandinius 2016–2017 m. duomenis ir prognozę atliko kiekvienai savaitės dienai atskirai: pirmadieniais tiksliausios prognozės gaunamos naudojant regresijos modelį, nuo antradienio iki ketvirtadienio – eksponentinio glodinimo, penktadieniais – autoregresijos, šeštadieniais – paprastas, sekmadieniais – atraminių vektorių metodas. Šių prognozių MAPE paklaidų medianos svyruoja nuo 7,76 % iki 10,36 %. Vidutiniškai didžiausias prognozių tikslumas buvo pasiektas taikant atraminių vektorių regresijos modelį, į kurį buvo įtraukti istoriniai elektros kainų, vartojimo ir vėjo energijos gamybos Lietuvoje duomenys.

R. Brindza [29] baigiamajame projekte tyrė veiksnius, darančius įtaką Lietuvos elektros energijos kainai. Naudoti 2013–2018 m. vidutinės didmeninės elektros energijos kainos duomenys ir atlikta koreliacinė ir regresinė analizė. Nustatyta, kad elektros energijos kaina tiesiškai reikšmingai koreliuoja su importuojamų gamtinių dujų ir biokuro kainomis ir atsinaujinančių energijos išteklių pagaminamu elektros kiekiu.

A. Rakštytė [30] baigiamajame darbe, naudodama 2018 m. valandinius *Nord Pool* elektros biržos duomenis (Lietuvos elektros energijos kainas ir tarpsisteminius pralaidumus), nustatė, kad elektros energijos kainų prognozei tinkamiausias VAR modelis. VAR (10) modelio MAPE paklaida 24 valandų prognozei lygi 0,899 %. P. Blažys [31] baigiamajame darbe naudojo vidutinę dienos elektros energijos kainą 2016–2020 m. spalio mėn. Prognozuojant tiriamąjį laikotarpį su ARIMA (5,1,2) modeliu, apskaičiuota MAPE paklaida siekė 12,51 %. M. Jonaitis [32] baigiamajame projekte sudarė 6 skirtingus ARMA procesus, kurie implementuoti kartu su Markovo paslėptųjų grandinių modeliu. Geriausi prognozavimo rezultatai buvo gauti taikant antros eilės autoregresinį modelį AR (2) su išoriniais kintamaisiais, apimančiais elektros energijos gamybą ir vartojimą Lietuvoje, vėjo energijos gamybą, tarpsisteminius srautus bei biokuro, naftos ir gamtinių dujų kainų indeksus. G. Kvietkauskaitės [33] darbo tikslas buvo sukurti statistinį AR modelį trumpalaikėms elektros energijos kainų prognozėms Lietuvoje, įtraukiant išorinius kintamuosius. Geriausias modelis – ARIMA (3,1,2) su procentiniu filtru kainų pikams aptikti ir išoriniais kintamaisiais: kalendorinės dienos, anglies kaina, elektros energijos gamyba Švedijos hidroelektrinėse, elektros energijos gamyba Lietuvoje, gamtinių dujų kaina, temperatūra, vėjo energijos gamyba Lietuvoje. Šis modelio RSME paklaida lygi 4,82, o MEA – 3,04. M. Česnavičiaus [6] straipsnyje mokymo duomenų rinkinį sudaro laikotarpis nuo 2012 m. liepos mėn. iki 2018 m. gruodžio mėn., o testavimo duomenų rinkinį – vienerių 2019 metų laikotarpis. ARIMA modelių analizė rodo, kad AR

(1) modelis turi mažiausią prognozės paklaidą, o SARIMA (1,1,1) modelis – geriausią faktinių duomenų aproksimacijos statistiką. Naudojant abu modelius buvo sudarytas svertinis SARIMA (1,1,1) modelis. Šis modelis gali imituoti faktinę laiko eilučių dinamiką ir turi gerokai mažesnę prognozės paklaidą, palyginti su SARIMA (1,1,1) modeliu. Svertinio SARIMA (1,1,1) modelio didžiausia MAPE paklaida per visą testavimo laikotarpį lygi 11,56, o RMSE paklaida lygi 5,64.

R. Beigaitė ir T. Krilavičius [34] straipsnyje naudojo sezoninį naivųjį, eksponentinio glodinimo metodus ir neuroninį tinklą. Prognozavimas buvo atliekamas kiekvienai 2016 metų dienai. Eksponentinio glodinimo svoriams įvertinti ir neuroninio tinklo apmokymui buvo naudojami 2014–2016 m. duomenys. Tiksliausia prognozė gauta naudojant neuroninį tinklą, kurio paslėptajame sluoksnyje buvo penkiolika neuronų. Šio modelio vidutinė MAPE paklaida lygi 15,15 %, o atskirų prognozių paklaidų reikšmės svyruoja nuo 2,31 % iki 70,16 %. Kitame R. Beigaitės ir T. Krilavičiaus [35] straipsnyje trumpalaikės elektros energijos prognozės atliekamos naudojant Elmano ir Džordano pasikartojančius neuroninius tinklus. Siekiant užfiksuoti elektros energijos kainų sezoniškumą, modelio apmokymui buvo naudojami visi 2016 m. duomenys, o testavimui – 2017 m. duomenys. Didžiausias vidutinis prognozavimo tikslumas buvo pasiektas taikant Elmano neuroninį tinklą. Tuo tarpu tiksliausia pavienė prognozė, kurios MAPE paklaida siekė 2,94 %, buvo gauta naudojant Džordano neuroninį tinklą. Lyginant su vidurkio metodu, tiek Elmano, tiek Džordano neuroniniai tinklai užtikrino tikslesnes prognozes. Vis dėlto neuroninių tinklų tikslumas buvo prastesnis nei taikant sezoninį naivųjį metodą.

Elektros energijos kainų prognozavimas gali būti atliekama ir naudojant Monte Karlo modeliavimą. Kadangi elektros energijos kainų formavimas iš esmės priklauso nuo paklausos, pasiūlos ir infrastruktūros pajėgumų, staigūs šių kintamųjų pokyčiai lemia reikšmingus kainų šuolius. Dėl to kainų šuolio koeficientas gali būti apibrėžiamas kaip funkcija, priklausanti nuo prognozuojamo vartojimo, gamybos, eksporto ir importo. Įtraukus šį koeficientą į prognozavimo modelį, prognozių tikslumas reikšmingai padidėjo. Modelis užfiksavo ne tik bendrą kainų tendenciją, bet ir identifikavo daugumą reikšmingų kainų šuolių nagrinėjamu laikotarpiu – nuo 2017 m. birželio 1 d. iki lapkričio 28 d. [36].

M. Česnavičiaus ir I. Konstantinavičiūtės [37] straipsnyje įvertinta skirtingų elektros energijos gamybos šaltinių įtaka elektros rinkos kainoms. Koreliacinės analizės metodas taikomas siekiant identifikuoti elektros energijos gamybos šaltinius, kurie daro reikšmingą poveikį elektros energijos kainai, tačiau nėra statistiškai susiję su elektros energijos apkrova. Šie atrinkti šaltiniai vėliau naudojami tiesinėje regresinėje analizėje, kurioje priklausomas kintamasis yra elektros energijos rinkos kaina, o nepriklausomi – nustatyti elektros gamybos šaltiniai. Regresijos lygtis yra galutinis įrankis, leidžiantis kiekybiškai įvertinti skirtingų elektros gamybos šaltinių įtaką rinkos kainai.

1 lentelėje pateikiama 1.2 ir 1.3 poskyriuose aptartų literatūros šaltinių santrauka.

1 lentelė. Literatūros šaltiniuose analizuoti elektros energijos kainai įtaką darantys išorinės verslo aplinkos veiksniai

Literatūros šaltinio pavadinimas	Metai	Šalis	Analizuoti išorinės verslo aplinkos veiksniai
<i>Short-Term Electricity Price Forecasting through Demand and Renewable Generation Prediction</i> [21]	2025	Ispanija	Elektros energijos paklausa, vėjo ir saulės energijos gamyba, savaitės diena

Literatūros šaltinio pavadinimas	Metai	Šalis	Analizuoti išorinės verslo aplinkos veiksniai
<i>Probabilistic Electricity Price Forecasting by Integrating Interpretable Model</i> [24]	2025	Belgija, Vokietija, Ispanija, JAV	Tinklo apkrova, energijos paklausa, vėjo ir saulės energijos gamyba, naftos kaina, rasos taško temperatūra, slėgis, saulės spinduliuotė, temperatūra, garavimas, krituliai, CO_2 ir PM_{10} emisija, švenčių dienos
<i>Multivariate Probabilistic Forecasting of Electricity Prices with Trading Applications</i> [25]	2025	Didžioji Britanija	Naftos ir dujų kaina, orų prognozės, priklausomybė tarp skirtingų elektros energijos prekybos biržų (EPEX SPOT ir Nord Pool)
<i>ATTnet: An Explainable Gated Recurrent Unit Neural Network for High Frequency Electricity Price Forecasting</i> [26]	2024	JAV	Istorinės elektros energijos kainos, temperatūra, valanda ir zoninė apkrova
<i>Price Forecasting in the Ontario Electricity Market Via TriConvGRU Hybrid Model: Univariate Vs. Multivariate Frameworks</i> [27]	2024	Kanada	Istorinės elektros energijos kainos, elektros energijos gamyba, apkrova, importas, eksportas, oro sąlygos
<i>Statistical Approach to Evaluate Power Generation Sources Influence on Electricity Market Price: Lithuania Case</i> [37]	2023	Lietuva	Lietuvoje elektros energiją gaminantys aštuoni energijos šaltiniai
<i>Electricity Price Forecasting on the Day-Ahead Market using Machine Learning</i> [23]	2022	Vokietija, Prancūzija	Pačios šalies elektros energijos kainos dviejų, trijų, septynių dienų vėlavimai, gretimų valstybių (Šveicarijos) elektros energijos kaina
<i>Comprehensive Review on Electricity Market Price and Load Forecasting Based on Wind Energy</i> [2]	2021	-	Vėjo energijos gamyba
Elektros Kainų Įtakos Elektros Gamintojų Elgsenai Analizė [31]	2021	Lietuva	Vidutinė dienos elektros energijos kaina
Paslėptųjų Markovo Grandinių Taikymas Elektros Kainų Prognozei [32]	2021	Lietuva	Elektros energijos gamyba ir vartojimas Lietuvoje, vėjo energijos gamyba, tarpsteminiai srautai, biokuro, naftos, gamtinių dujų kaina
<i>Electricity Price Forecasting in Lithuania</i> [33]	2021	Lietuva	Kalendorinė diena, anglies, gamtinių dujų kaina, hidroenergija Švedijoje ir Lietuvoje, elektros energijos paklausa Lietuvoje, Švedijoje ir Suomijoje, temperatūra, vėjo energijos gamyba Lietuvoje, perdavimo tinklų neprieinamumas
Laiko Eilučių Ir Kvantilių Regresijos Modeliai Elektros Kainoms [30]	2020	Lietuva	Elektros energijos kaina Lietuvoje, tarpsteminiai pralaidumai
<i>Lithuanian Electricity Market Price Forecasting Model Based on Univariate Time Series Analysis</i> [6]	2020	Lietuva	Istorinės elektros energijos kainos Lietuvoje
<i>Electricity Price Forecasting in the Danish Day-Ahead Market using the TBATS, ANN and ARIMA Methods</i> [22]	2019	Danija	Temperatūra, prognozuojamas elektros energijos suvartojimas ir gamyba, prognozuojama vėjo energijos gamyba, naftos ir gamtinių dujų kaina, vandens rezervuarų lygis

Literatūros šaltinio pavadinimas	Metai	Šalis	Analizuoti išorinės verslo aplinkos veiksniai
Veiksnių, Darančių Įtaką Lietuvos Elektros Energijos Kainai, Tyrimas [29]	2019	Lietuva	Elektros energijos suvartojimas ir gamyba Lietuvoje, gamintojų skaičius, grynasis importas, gamtinių dujų ir biokuro kaina Lietuvoje, energijos kiekis, pagamintas iš atsinaujinančių energijos išteklių, suvartotos energijos dalis, nupirkta elektros energijos biržoje, veiklą vykdančių nepriklausomų elektros energijos tiekėjų skaičius
Elektros Energijos Kainų Prognozavimas [28]	2018	Lietuva	Elektros energijos suvartojimas, vėjo energijos gamyba Lietuvoje
<i>Electricity Price Forecasting for Nord Pool Data</i> [34]	2018	Lietuva	Istorinės elektros energijos kainos Lietuvoje
<i>Electricity Price Forecasting using Monte Carlo Simulation: The Case of Lithuania</i> [36]	2018	Lietuva	Prognozuojamas elektros energijos suvartojimas ir gamyba, eksportas, importas
<i>Electricity Price Forecasting for Nord Pool Data using Recurrent Neural Networks</i> [35]	2018	Lietuva	Istorinės elektros energijos kainos Lietuvoje

Apibendrinant galima teigti, kad elektros energijos kainų formavimuisi Lietuvoje ir kitose šalyse įtaką daro tiek paklausos ir pasiūlos santykis, tiek ir elektros energijos gamyba iš atsinaujinančių energijos išteklių, tokių kaip vėjas ir saulė. Be to, reikšmingą vaidmenį atlieka elektros energijos tarpusisteminiai srautai ir kainų dinamika aplinkinėse valstybėse, taip pat naftos ir gamtinių dujų kainų svyravimai.

1.4. Prognozavimo metodai

Prognozavimas padeda numatyti būsimas elektros energijos kainas ir planuoti bei koreguoti veiklos strategiją pagal gautą prognozę. Pavyzdžiui, elektros kainų prognozė suteikia reikiamą informaciją įrenginių techninės priežiūros planavimui ir elektros gamybos pikų planavimui, siekiant sumažinti nuostolius ir maksimaliai padidinti pelną. Taip pat elektros kainų prognozavimas būtinas investiciniams ir politiniams sprendimams priimti. Dėl didėjančio elektros energijos sistemos komplikotumo ir keliamų reikalavimų, padidėjo elektros kainos prognozavimo svarba. Svarba tokia didelė, kad elektros kainų prognozavimas tapo viena iš pagrindinių elektrotechnikos tyrimų kryptų [6].

Per pastaruosius du dešimtmečius buvo sukurta ir pasiūlyta daug metodų ir modelių, skirtų elektros kainų prognozavimui [2]. Remiantis [21] straipsniu, elektros energijos prognozavimo modelius galima suskirstyti į keturias grupes: agentais paremtas modeliavimas, struktūriniai modeliai, statistiniai modeliai ir mašininio mokymosi modeliai.

Agentais paremto modeliavimo principas – skirtingų agentų elgsenos ir tarpusavio sąveikos imitavimas. Sudėtinga konkurencingų ir decentralizuotų elektros energijos rinkų dalyvių sąveika ir tarpusavio priklausomybė yra panaši į žaidimų teorijoje nagrinėjamas sąveikas ir priklausomybes. Tačiau elektros energijos rinkos pobūdis yra pernelyg sudėtingas, kad jį būtų galima patogiai modeliuoti standartiniais žaidimų teorijos metodais [38]. Todėl buvo pristatytas naujas agentais paremto modeliavimo ir imitavimo metodas. Šio metodo gebėjimas atspindėti nepriklausomą sprendimų priėmimo elgseną ir atskirų agentų sąveiką bendroje sistemoje suteikia labai gerą įrankį elektros energijos rinkų modeliavimui ir imitavimui. 2000-ųjų pradžioje atsiradęs metodas šiandien

plačiai taikomas sprendžiant įvairius elektros energetikos sektoriaus klausimus: elektros energijos kainų pokyčiai ir prognozavimas, gamybos pakankamumą vertinimas, gamybos plėtros planavimas ir daugelis kitų [39]. Dažnai, prognozuojant elektros energijos kainas, šis metodas naudojamas kartu su kitais metodais, tokiais kaip tiesinė ir LASSO regresija [40], atraminių vektorių klasifikatorius [41], dirbtinis neuroninis tinklas [39], ilgalaikės-trumpalaikės atminties neuroninis tinklas [42]. Esami tyrimai didžiausią dėmesį skiria praeityje buvusioms ir dabartinėms energetikos sistemoms. Didėjant atsinaujinančios energijos pajėgumams, didėja mokslinių tyrimų, kuriuose būtų aiškiai integruoti reikšmingi su perėjimu prie žaliosios energijos susiję pokyčiai, poreikis. Įvairiems energetikos permainų scenarijams modeliuoti puikiai tinka agentais paremtas modeliavimas. AMIRIS (angl. *Agent-based Market Model for the Investigation of Renewable and Integrated Energy Systems*) – moderniausias tokio tipo modelis [20]. AMIRIS parametrai nustatomi taip, kad būtų galima modeliuoti įvairius galimus būsimus elektros energijos rinkos scenarijus. Vėliau šie scenarijai paverčiami išsamiais apmokymo ir testavimo duomenų rinkiniais, kurie gali būti naudojami elektros energijos kainų prognozavimui [20].

Struktūriniai modeliai remiasi teorijomis arba logika, apibrėžiančiomis, kaip skirtingi veiksniai sąveikauja tarpusavyje. Šie modeliai padeda suprasti vidines priežasties-pasekmės priklausomybes tarp kintamųjų. Elektros energetikos sektoriuje struktūriniai modeliai gali būti naudingi, siekiant parodyti pagrindinių sąveikaujančių fizinių ir ekonominių kintamųjų, lemiančių elektros energijos kainas, ryšius [21]. Kadangi šiuo metu nėra plačiai taikomų elektros energijos kaupimo ir saugojimo sprendimų [10], o elektros energijos pasiūlos ir paklausos duomenys yra plačiai prieinami elektros energijos rinkoje, lengviau nei daugumoje kitų rinkų suprasti ir analizuoti kainų bei jas lemiančių veiksnių ryšį [43]. Universalumas, lankstumas ir pritaikomumas yra pagrindiniai struktūrinių modelių privalumai. [43] straipsnyje teigiama, kad istorinės kainos gali būti ne tokios svarbios, kaip į ateitį orientuota rinkos informacija, todėl struktūriniai metodai turi didelį pranašumą prieš redukuotos formos modelius.

Taikant statistinius metodus, elektros kainos prognozuojamos naudojant ankstesnių elektros kainų ir kitų įtaką darančių kintamųjų praeities reikšmių kompoziciją. Tipiniai statistiniai metodai, remiantis [44, 45] straipsniais: naivus, autoregresijos modelis (AR), autoregresinis slenkančio vidurkio modelis (ARMA) ir jo plėtinys, įtraukiantis laiko eilutės skirtumų panaudojimą, (ARIMA), skirtingi regresijos modeliai, *Holt-Winter*, apibendrinti autoregresiniai sąlyginio heteroskedastiškumo modeliai (GARCH), TARX modeliai. Taikant naivųjį metodą, būsimos laiko eilutės vertės prognozuojamos pagal paskutinį žinomą stebėjimą. Sezoninis naivusis modelis veikia panašiai kaip ir naivusis metodas. Skirtumas tas, kad sezoninis naivusis metodas naudoja paskutinę stebėtą to paties sezono reikšmę [45]. Naivusis metodas gali būti naudojamas kaip atskaitos taškas, vertinant prognozavimo metodų tikslumą [22] – bet kuris kitas metodas turi pralenkti naivųjį. ARMA – yra vienas iš dažniausiai naudojamų metodų vienmatėms laiko eilutėms modeliuoti ir prognozuoti [45], tačiau tinkamas tik stacionarioms laiko eilutėms. Deja, dauguma laiko eilučių, kurios aprašo realaus pasaulio reiškinius, įskaitant elektros energijos kainas, yra nestacionarios. ARIMA modelis įveikia šį apribojimą, įtraukiant diferencijavimo parametą [45], ir todėl yra vienas iš plačiausiai naudojamų tiesinių modelių, skirtų laiko eilutėms prognozuoti [46]. Vakarų Danijos regiono dienos į priekį elektros energijos kainų prognozavimui naudojamas ARIMA modelis [22]. 24 valandų prognozavimo modelio apmokymo imtį sudarė 2016 m. duomenys, o testavimo – pirmosios 212 2017 m. dienos. Taip pat buvo naudotas ir kitas statistinis metodas – TBATS bei dirbtinis neuroninis tinklas. Prognozavimo efektyvumui įvertinti apskaičiuota vidutinė kvadratinė paklaida

(RMSE) ir vidutinė absoliutinė paklaida (MAE). Visų trijų modelių prognozės buvo tikslesnės nei sezoninio naiviojo metodo prognozė. Tiksliausi rezultatai buvo gauti taikant ARIMA modelį – RMSE reikšmės svyravo nuo 7,95 iki 215,22, o MAE – nuo 6,01 iki 212,11. Remiantis [22] straipsnio autoriais, naudojant procentines paklaidas, negalima gauti reikšmingų rezultatų, nes elektros energijos kainos apima teigiamas, neigiamas ir nulines vertes. A. Poggi [47] tyrime nagrinėti Vokietijos duomenys nuo 2020 m. iki 2022 m. vidurio ir naudotas SARIMA modelis. Tuo tarpu [22] tyrime teigiama, kad sezoninis ARIMA modelis nėra itin tinkamas elektros energijos kainų prognozavimui, nes gali užfiksuoti tik vieno tipo sezoniškumą, o elektros energijos kainos pasižymi dviem ir daugiau. Grįžtant prie [47] tyrimo rezultatų: kai treniravimo imtį sudaro 2020 m. duomenys, o testavimo imtį – vienos savaitės duomenys, geriausius modelių pripažintas SARIMA $(2,1,1) \cdot (2,1,0)_{24}$, kurio prognozių RMSE paklaida lygi 41,74. Kai testavimo imtį sudaro tik vienos dienos duomenys, RMSE paklaida sumažėja iki 7,9. Siekiant pagerinti prognozės tikslumą, buvo panaudota bangelių transformacija ir panaikinta sezoniškumo komponentė, o prognozėms gauti panaudotas ARIMA modelis. Atitinkamai RMSE paklaidos, testuojant savaitės duomenis sumažėjo iki 19,14, o dienos pakilo iki 16,82. AR modelio su fiktyviais (angl. *dummy*) kintamaisiais naudojimas taip pat nepagerino vienos dienos prognozės rezultatų – RMSE paklaida lygi 26,15. Padidėjusią paklaidą gali lemti tai, kad į modelį nebuvo įtraukti egzogeniniai kintamieji [47]. Statistiniai metodai paprastai yra tiesiniai prognozavimo modeliai, todėl yra mažiau efektyvūs dideliu kintamumu pasižyminčioms laiko eilutėms. Statistiniai metodai gali efektyviai atspindėti rinkos kainas lemiančius dėsningumus, tačiau nėra tinkami modeliuoti netiesines elektros energijos kainų laiko eilutes [44].

Mašininis mokymasis – tai kompiuterių mokslo šaka, siūlanti prognozavimo modelius, taikant veiksmingus mokymosi iš duomenų algoritmus. Šiems modeliams pastaraisiais dešimtmečiais skiriama daug dėmesio dėl turimų duomenų gausos ir didėjančios skaičiavimo mašinų galios [23]. Mašininio mokymosi prognozavimo metodai, priešingai nei statistiniai modeliai, aprašo duomenų savybes be išankstinės informacijos apie jų pasiskirstymą. Kadangi šie metodai nėra tiesiogiai priklausomi nuo parametrų, kuriais modeliuojama reiškinio elgsena, šiuos metodus paprasčiau pritaikyti ir jie pasižymi patikimais rezultatais net tada, kai taikomi sudėtingoms netiesinėms laiko eilutėms. Mašininio mokymosi modeliai apima įvairius metodus, pavyzdžiui, dirbtiniai neuroniniai tinklai (ANN), artimiausių kaimynų metodas, evoliucija pagrįsti skaičiavimai, atraminių vektorių klasifikatorius (SVM), atsitiktiniai miškai ir daugelis kitų [48]. ANN yra bene plačiausiai naudojamas prognozavimo metodas ir dažnai taikomas trumpalaikėms elektros energijos kainų prognozėms [21]. Q. Dango [49] straipsnyje naudotas ANN su vienu paslėptu sluoksniu ir dvidešimt neuronų jame. Tyrimas atliktas remiantis Čikagos elektros energijos kainų duomenimis, apimančiais 730 dienų laikotarpį nuo 2017 m. sausio 1 d. Dėl skirtingų elektros energijos kainų svyravimų įvairiais metų laikais, straipsnio autoriai pasiūlė kiekvieno sezono duomenis apdoroti ir modelius apmokyti atskirai. 7 atsitiktinių dienų prognozės MAPE paklaida svyruoja nuo 1 % iki 14,86 %, o vidutinė MAPE paklaida – apie 13 %. L. Tschoros [23] straipsnyje naudota atraminių vektorių regresija (SVR), atsitiktinių miškų regresija (RFR), gilieji neuroniniai tinklai (DNN) ir konvoliucinis neuroninis tinklas (CNN). Nustatyta, kad Prancūzijos ir Belgijos 2016–2021 m. duomenų rinkiniams tinkamiausias SVR modelis: vidutinė absoliutinė paklaida (MAE) atitinkamai lygi 6,61 ir 9,51, o simetrinė vidutinė absoliutinė procentinė paklaida (SMAPE) lygi 14,23 ir 19,17. Vokietijos to pačio laikotarpio duomenims – DNN modelis: MAE paklaida lygi 18,79, o SMAPE – 7,66. Atsitiktinių miškų regresijos modelis parodė prasčiausius rezultatus visose nagrinėtose šalyse. Klasikiniai mašininio mokymosi metodai (atsitiktiniai miškai, atraminių vektorių klasifikatorius ir

panašiai) ir giliojo mokymosi metodai lyginami [50] straipsnyje. Naudojami duomenys – Airijos elektros energijos kainos nuo 2018-09-30 iki 2019-12-12. Empiriniai rezultatai atskleidė, kad paprastesni modeliai veikia stebėtinai gerai, nepaisant elektros energijos kainų nepastovumo. Tiesinės regresijos ir K-artimiausių kaimynų (KNN) algoritmai pateikė tiksliausias prognozes tarp visų straipsnyje realizuotų mašininio mokymosi metodų. Vidutinė MAE paklaida atitinkamai lygi 11,21 ir 11,52. Nedaug atsiliko atsitiktinio miško ir LASSO regresijos rezultatai – MAE paklaida lygi 11,54 ir 11,62. Papildomai įrodyta, kad naudojant KNN modelį galima gauti tikslias prognozes per palyginti trumpą, 4,09 s, apmokymo laiką. Atsitiktiniai miškai, priešingai, nors prognozė tiksli, tačiau apmokymas užtruko 112,4 s – ilgiausiai iš visų straipsnyje naudotų mašininio mokymosi metodų. Yra ne vienas straipsnis, kuriame daroma išvada, kad mašininio mokymosi metodai pranoksta statistinius metodus [2, 47, 51, 52]. Tačiau [53] straipsnio autoriai teigia, kad pažangiuose tyrimuose statistiniai ir mašininio mokymosi modeliai nėra sąžiningai palyginami, t. y. pažangūs mašininio mokymosi modeliai dažnai lyginami su paprastais statistiniais modeliais, be kruopščios požymių inžinerijos, požymių atrankos ar kryžminio validavimo. Naujosios Zelandijos elektros energijos kainų prognozavimo rezultatai rodo, kad GARCH ir stochastinio kintamumo modeliai ypač gerai veikia, kai jie derinami su požymių atrankos metodais ir papildomais faktoriais. Daugumoje nagrinėjamų scenarijų šie modeliai, sujungti su LASSO požymių atranka, pranoko mašininio mokymosi modelius [53]. Taip pat vienas iš mašininio mokymosi metodų trūkumų yra tas, kad jie laikomi juodosiomis dėžėmis, todėl sunku paaiškinti ryšį tarp įvesties ir išvesties kintamųjų.

Vis dažniau skirtingų tipų modeliai naudojami kartu – sukuriama hibridiniai modeliai. Tokiu būdu laiko eilutę galima išskaidyti į mažo ir didelio kintamumo komponentus, kur kiekvienas metodas, išnaudodamas savo stipriąsias savybes, gali apdoroti atskiras dalis [46]. Pavyzdžiui, [54] tyrime buvo pristatytas naujas hibridinis modelis, jungiantis bangų transformaciją ir LSTM neuroninį tinklą su Adamo optimizavimu, skirtas elektros energijos kainoms prognozuoti. Atlikus bangų transformaciją, laiko eilutės tampa stabilesnės, todėl neuroninis tinklas gali tiksliau atspindėti elektros energijos kainų dinamiką. Modelis išbandytas Naujojo Pietų Velso ir Prancūzijos elektros energijos rinkose, siekiant patvirtinti hibridinio modelio pranašumą. O [27] tyrime, konvoliucinis neuroninis tinklas (CNN) naudotas kartu su GRU (angl. *Gated Recurrent Unit*). Šis hibridinis metodas sukurtas siekiant pasinaudoti CNN stiprybėmis erdvinio modelių atpažinimui ir GRU – laikinųjų priklausomybių fiksavimui, taip sudarant išsamesnį kainų tendencijų vaizdą. Siekiant įvertinti sudarytą modelį, buvo atlikti trys skirtingų 2022 m. savaitių tyrimai. Rezultatai rodo, kad siūlomas modelis pirmajame eksperimente vidutiniškai 63,3 %, antrajame – 41,8 %, o trečiajame – 28,2 % sumažina prognozavimo paklaidą. Beje, šio hibridinio modelio vieno, dviejų ir trijų žingsnių į priekį prognozės tikslumas pranoko ne tik statistinių modelių, bet ir tradicinių mašininio mokymosi metodų tikslumą. H. Jiangas [24] straipsnyje pasiūlė naują *LNBeatsX* modelį, kuriame buvo sujungti *NBeatsX* ir *LassoNet* modeliai. Atlikti empiriniai tyrimai parodė, kad *LNBeatsX* modelis pasižymi aukštesniu prognozavimo tikslumu, stabilumu ir aiškia interpretacija, palyginti su tradiciniais metodais. Be to, *L-NBeatsX* modelis ne tik pateikia tikimybinę prognozę, bet ir įvertina išorinių veiksnių daromą įtaką. E. Belenguerio [21] tyrimo tikslas buvo sukurti hibridinį prognozavimo modelį, skirtą Ispanijos dienos į priekį rinkos kainų prognozavimui. Naudoti 2017–2018 m. duomenys. Elektros paklausos prognozavimui buvo taikytas panašių dienų modelis (angl. *Similar day method*). Šiuo metodu gautos savaitės į priekį elektros energijos paklausos prognozės RMAE paklaida labai maža – 1,98 %. Vėjo energijos prognozė sudaryta naudojant dirbtinį neuroninį tinklą su *ReLU* aktyvavimo funkcija. Pastarasis modelis savo tikslumu lenkia Ispanijos

perdavimo sistemos operatoriaus naudojamą prognozavimo priemonę SIPREOLICO. 48 valandų prognozės RMAE paklaida atitinkamai lygi 14 % ir 20 %. Saulės energijos gamybos prognozavimui naudotas konvoliucinis neuroninis tinklas. Elektros energijos kainų prognozės sudarymui naudotas dirbtinis neuroninis tinklas su *ReLu* aktyvavimo funkcija ir prieš tai aptartų kintamųjų prognozių rezultatai. Atlikus dviejų dienų elektros kainų prognozę su straipsnyje pasiūlytu modeliu gautos prognozės bendrasis tikslumas siekė 69,9 %, o metinis ekonominis naudos padidėjimas 9970 EUR už 1 MW. Papildomai buvo atliktas tyrimas, siekiant nustatyti optimalų apmokymo imties dydį dviejų dienų prognozei. Nustatyta, kad tiksliausia prognozė gaunama, kai apmokymo imties dydis yra 30 dienų.

Kiekybiniai laiko eilučių prognozavimo metodai taip pat dar gali būti skirstomi į vienmačius ir daugiamačius [45] metodus. Vienmačiai metodai – tai metodai, kuriais modeliuojami būsimi laiko eilutės stebėjimai pagal jos ankstesnius stebėjimus. O daugiamaciai metodai išplečia vienmačius metodus, atsižvelgdami į papildomas laiko eilutes, kurios naudojamos kaip aiškinamieji kintamieji. Papildomų veiksnių įtraukimas į prognozavimo modelį gali reikšmingai pagerinti prognozės tikslumą [55]. L. Tschoros [23] tyrime prognozės tampa gerokai tikslesnės (prognozių tikslumo vertinimo metrikų įverčiai padidėja 15 %), kai į prognozavimo modelį įtraukiami papildomi kintamieji. H. Acaroğlu [2] nustatė, kad kuo daugiau išorinių veiksnių yra naudojama, tuo prognozės tampa tikslesnės. Tačiau didėjantis į modelį įtrauktų veiksnių skaičius didina prognozavimo modelio sudėtingumą.

Taigi, elektros energijos kainų prognozavimas yra viena iš aktualiausių temų energetikos srityje, plačiai nagrinėjama tarptautiniuose moksliniuose tyrimuose. Nors pastaraisiais metais Lietuvoje pastebimas didesnis susidomėjimas šia tyrimų kryptimi, mokslinių darbų vis dar palyginti nedaug. Be to, daugumoje jų taikomi tradiciniai statistiniai prognozavimo metodai, kurie ne visada sugeba identifikuoti ir įvertinti kompleksiškus elektros energijos rinkos pokyčius bei jų priežastinius ryšius. Todėl naudinga išbandyti Lietuvos elektros energijos kainų modeliavimui dar nenaudotus prognozavimo modelius. Siekiant pagrįstai ir efektyviai prognozuoti elektros kainos kitimą Lietuvoje, pirmiausia būtina išanalizuoti elektros energetikos sektoriaus dinamiką ir kainų tendencijas – tai leidžia suprasti ilgalaikius ir trumpalaikius pokyčius bei rinkos specifiką. Išorinės verslo aplinkos veiksnių, darančių įtaką elektros energijos kainai, identifikavimas gali padėti pagerinti prognozavimo modelio tikslumą. Nustačius šiuos veiksnius galima pereiti prie modeliavimo, taikant tiek vienmačius, tiek daugiamačius prognozavimo metodus. Galiausiai, kad atliktas tyrimas turėtų praktinę vertę, būtina įvertinti prognozavimo modelių tikslumą ir palyginti gautus rezultatus, tokiu būdu nustatant patikimiausią prognozavimo modelį. Tokia uždavinių seka sudaro nuoseklią tyrimo struktūrą, leidžiančią pasiekti pagrindinį tikslą – sukurti Lietuvos elektros energijos kainų prognozavimo modelį. Tyrimo rezultatais galėtų naudotis elektros energijos gamybos ir tiekimo įmonės, verslo subjektai bei politikai, siekiantys priimti duomenimis grįstus sprendimus energetikos srityje.

2. Tyrimo modeliai ir metodai

Siekiant atlikti elektros energijos kainų prognozavimą, šiame tyrime sudaromi ir lyginami vienmatis ir daugiamatis modeliai. Vienmatis modelis remiasi tik prognozuojamos laiko eilutės praeities duomenimis ir analizuoja jos dinamiką laike, neatsižvelgiant į kitus išorinius kintamuosius:

$$\hat{y}_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-n}); \quad (1)$$

čia $\hat{y}_{t+1}$ – prognozuojama reikšmė laiko momentu $t + 1$; $y_t, \dots, y_{t-n}$ – prognozuojamos laiko eilutės praeities stebėjimai; n – vėlavimų (angl. *lag*) skaičius.

Pasikliaujant vien tik vienmačiu elektros energijos kainų prognozavimo modeliu, gali nepavykti trumpalaikėje perspektyvoje įvertinti tinklo ypatybių ir gauti tikslios prognozės [2]. Todėl į daugiamatį modelį įtraukiami nepriklausomi kintamieji, kurie gali turėti įtakos prognozuojamai laiko eilutei:

$$\hat{y}_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-n}, x_{1,t}, x_{1,t-1}, \dots, x_{1,t-m}, \dots, x_{k,t}, x_{k,t-1}, \dots, x_{k,t-m}); \quad (2)$$

čia $\hat{y}_{t+1}$ – prognozuojama reikšmė laiko momentu $t + 1$; $y_t, \dots, y_{t-n}$ – prognozuojamos laiko eilutės praeities stebėjimai; n – vėlavimų (angl. *lag*) skaičius; $x_{i,t-j}$ – i -tojo išorinio kintamojo praeities stebėjimas su j -uoju vėlavimu; k – išorinių kintamųjų skaičius, m – išorinių kintamųjų vėlavimų skaičius.

Prieš sudarant prognozavimo modelius reikia atlikti elektros energijos kainų tendencijų analizę, identifikuoti įtaką elektros energijos kainoms darančius išorinius veiksnius, sutvarkyti ir paruošti tyrime naudojamus duomenis.

2.1. Kintamojo tendencijų analizės ir duomenų tvarkymo metodai

Prognozavimo algoritmų taikymas reikalauja, kad analizuojama laiko eilutė būtų reguliari. Interpoliacija yra vienas iš dažniausiai taikomų sprendimo būdų, leidžiantis atstatyti trūkstamas reikšmes. Yra įvairių interpoliavimo metodų: tiesinis, kvadratinis, splaino, artimiausio kaimyno ir t.t. Tiesinis interpoliavimas – pagrindinis ir paprasčiausias interpoliavimo būdas, kai naujos reikšmės gaunamos sujungiant dvi gretimas žinomas reikšmes tiesia linija [56]. Tačiau tokiu atveju kiekviename intervale taikoma pastovi tendencija tarp gretimų atkarpų susidaro netikslumai ir bendra interpoliuotos kreivės forma neatspindi realaus proceso kitimo dėsningumo. Kubinio splaino interpoliacija – tai pažangesnis metodas, leidžiantis sklandžiai atkurti duomenų reikšmes tarp žinomų taškų, išvengiant kampų perėjimų, būdingų tiesinei interpoliacijai. Šiuo atveju tarp kiekvienų dviejų gretimų taškų pritaikoma trečiojo laipsnio (kubinė) funkcija [56]. Kubinio splaino interpoliacija užtikrina funkcijos, jos pirmosios ir antrosios išvestinių tolydumą.

Laiko eilučių duomenyse dažnai pasitaiko staigių nukrypimų, kurie gali padaryti neigiamą įtaką modeliuojamų reiškinių dinamikai. Tokie nukrypimai, vadinami išskirtimais, dažniausiai yra nesisteminiai, todėl jų neįmanoma tinkamai atspindėti taikant standartinius laiko eilučių modelius. Išskirčių identifikavimas yra itin svarbus procesas, nes išskirtys daro tiesioginę įtaką modelio parinkimui, parametrų įvertinimo tikslumui ir atitinkamai prognozavimo rezultatams. Šis procesas prasideda nuo sezoniškumo ir trendo komponentių pašalinimo iš laiko eilutės. Likusioje liekanų komponentėje stebėjimas y_t laikomas išskirtimi, jei [57]:

$$Q_1 - 3 \times IQR > y_t > Q_3 + 3 \times IQR; \quad (3)$$

čia y_t – stebėjimas laiko momentu t ; Q_1 – 25-asis liekanų verčių procentilis; Q_3 – 75-asis liekanų verčių procentilis; IQR – tarpkvartilinis plotis (25-to ir 75-to procentilių skirtumas).

Tokiu būdu nustatytos išskirtys pakeičiamos tiesiškai interpoliuotomis reikšmėmis, naudojant kaimyninius stebėjimus, ir procesas kartojamas.

Kitas reikalavimas prognozuojamai laiko eilutei – stacionarumas. Stacionari laiko eilutė neturi trendo, jos dispersija laikui bėgant yra pastovi, o autokoreliacija – nuosekli. ADF (angl. *Augmented Dickey-Fuller*) testas yra plačiai naudojamas metodas, skirtas laiko eilučių stacionarumui įvertinti [58]. ADF testas tikrina šias nulinę ir alternatyvią hipotezes:

H_0 : Laiko eilutė yra nestacionari;

H_A : Laiko eilutė yra stacionari.

Nulinę hipotezę galima atmesti ir daryti išvadą, kad laiko eilutė yra stacionari, kai testo p reikšmė yra mažesnė už tam tikrą reikšmingumo lygmenį (pvz., 0,05). Jeigu nulinė hipotezė nėra atmetama, galima taikyti diferencijavimą – apskaičiuoti gretimų stebėjimų skirtumus ir testą pakartoti. Diferencijavimas dažnai leidžia transformuoti nestacionarią laiko eilutę į stacionarią. Jei po pirmojo diferencijavimo vis dar nepavyksta pasiekti stacionarumo, galima taikyti antrojo ar net trečiojo laipsnio diferencijavimą.

Autokoreliacija yra viena iš svarbiausių laiko eilutės charakteristikų, vertinanti tiesinį ryšį tarp laiko eilutės reikšmių ir jų vėlavimų [22]. *Ljung-Box* testas skirtas tikrinti, ar laiko eilutėje yra autokoreliacija. *Ljung-Box* testo hipotezės formuluojamos taip:

H_0 : Liekanos pasiskirsčiusios nepriklausomai;

H_A : Liekanos nėra nepriklausomai pasiskirsčiusios; joms būdinga koreliacija.

Nulinė hipotezė atmetama, jei testo p reikšmė mažesnė už tam tikrą reikšmingumo lygmenį. Kai atliekamas laiko eilutės autokoreliacijos tikrinimas prieš modeliavimą, siekiama atmesti nulinę hipotezę, t. y. norima įrodyti, kad laiko eilutė pasižymi autokoreliacija. Tokiu atveju galima teigti, kad praeities reikšmės daro įtaką būsimiems stebėjimams, todėl prognozavimas tampa prasmingas. Vertinant prognozavimo modelio tinkamumą, autokoreliacija analizuojama modelio liekanose. Šiuo atveju siekiama, kad nulinės hipotezės atmesti nepavyktų – tai reikštų, jog liekanos yra atsitiktinės, nepriklausomos, o sudarytas modelis yra tinkamas.

Dalinė autokoreliacija leidžia įvertinti konkretaus vėlavimo k įtaką laiko eilutės reikšmei, eliminuojant tarpinių vėlavimų nuo 1 iki $k - 1$ įtaką. Reikšmingi vėlavimai dalinės autokoreliacijos grafike gali atskleisti pasikartojančias struktūras, galimai rodančias sezoniškumo komponentę laiko eilučių duomenyse.

Laiko eilutės dekompozicija yra svarbus procesas, leidžiantis identifikuoti pagrindinius laiko eilutės struktūrinius komponentus – trendą, sezoniškumą ir liekanas – bei geriau suprasti dėsningumus, o kartu ir pagerinti prognozės tikslumą [59]. Išskiriami du pagrindiniai dekompozicijos modeliai:

adityvus ir multiplikatyvus. Adityvus modelis taikomas, kai sezoniškumo komponentės svyravimai laikui bėgant išlieka pastovūs. Tokiu atveju bendra laiko eilutė aprašoma kaip komponentių suma:

$$X_t = \hat{S}_t + \hat{T}_t + \hat{R}_t; \quad (4)$$

čia X_t – stebėjimas laiko momentu t ; $\hat{S}_t$ – sezoniškumo komponentė; $\hat{T}_t$ – trendo komponentė; $\hat{R}_t$ – liekanų komponentė.

Tuo tarpu multiplikatyvi dekompozicija taikoma tais atvejais, kai sezoniškumo svyravimų amplitudė didėja. Tokiu atveju komponentės tarpusavyje sudauginamos. Didėjant duomenų dažniui (pvz., stebėjimai kas valandą ar minutę), realiuose duomenų rinkiniuose vis dažniau pasitaiko laiko eilutės, pasižyminčios daugiau nei vienu sezoniškumu. Atsižvelgiant į tai, [59] siūlo naudoti MSTL (angl. *Multiple Seasonal-Trend decomposition using Loess*) metodą – tai STL (angl. *Seasonal-Trend decomposition using Loess*) metodo plėtinys, leidžiantis išskaidyti laiko eilutę į kelias sezoniškumo komponentes ir trendą. MSTL pateikia adityvų dekompozicijos modelį, kuriame įtraukiamos kelios sezoniškumo komponentės:

$$X_t = \hat{S}_t^1 + \hat{S}_t^2 + \dots + \hat{S}_t^n + \hat{T}_t + \hat{R}_t; \quad (5)$$

čia n – sezoninių komponentių skaičius.

MSTL yra itin greitas, skaičiavimo požiūriu efektyvus algoritmas, kuris gali būti pritaikomas vis didesniems laiko eilučių duomenų kiekiams.

2.2. Išorinės verslo aplinkos veiksnių identifikavimo ir tarpusavio sąveikos nustatymo metodai

Siekiant ištirti sudėtingą ir nuolat kintančią sistemą, tokią kaip elektros energetikos sektorius, taikoma integruota metodologija, apimanti mokslinės literatūros apžvalgą, PESTLE analizę bei ekspertines šios srities žinias.

Pirmiausia atliekama literatūros analizė, siekiant identifikuoti, kokius išorinės verslo aplinkos veiksnius naudojo kiti autoriai prognozuodami elektros energijos kainas. Apžvelgti straipsniai ir juose nagrinėti veiksniai sisteminami lentelėje. Atlikta analizė suteikia pradinį supratimą apie išorinius veiksnius, darančius įtaką elektros energijos kainų formavimuisi.

PESTLE analizė (angl. *Political, Economic, Social, Technological, Legal and Environmental analysis*) – tai rinkodaros ir strateginio planavimo priemonė, naudojama pramonės šakų, įmonių ir sektorių, įskaitant energetikos sektorių, sisteminei aplinkos veiksnių analizei [60]. Šis metodas padeda įvertinti įvairių makroaplinkos veiksnių poveikį sektoriui, suskirstant juos į šešias pagrindines kategorijas: politiniai (P), ekonominiai (E), socialiniai (S), technologiniai (T), teisiniai (L) ir aplinkosauginiai (E) veiksniai. Politiniai veiksniai apima visus valdžios sprendimus, kurie gali turėti įtaką verslo aplinkai. Ekonominiai veiksniai – tai su šalies ir regiono ekonomika susiję aspektai, tokie kaip BVP, infliacija, nedarbo lygis. Socialiniai veiksniai apima demografinius, kultūrinius ir visuomenės elgsenos aspektus. Jie formuoja žmonių elgesį ir poreikius. Technologiniai veiksniai susiję su inovacijomis, technologine pažanga, naujų technologijų diegimo tempu ir jų prieinamumu. Teisiniai veiksniai apima įstatymus, veiklos reguliaciją, standartus ir kitus norminius aktus nacionaliniu ir tarptautiniu lygiu. Aplinkosauginiai veiksniai susiję su klimato

sąlygomis, geografinėmis ypatybėmis, aplinkosaugos reikalavimais, CO_2 emisijų ribojimu bei atsinaujinančių išteklių prieinamumu.

Ekspertinės energetikos sektoriaus žinios išorinių kintamųjų pasirinkimo uždavinyje taip pat yra labai svarbios. Tai per ilgametę veiklą sukauptos žinios ir įžvalgos, kurios nėra tiesiogiai gaunamos iš standartinių duomenų šaltinių ar kiekybinių metodų. Daugelis veiksnių, turinčių įtakos elektros kainoms, nėra išmatuojami ar prognozuojami (pvz., politiniai sprendimai, infrastruktūros sutrikimai). Ekspertinis kokybinis vertinimas tampa neatsiejama elektros kainų prognozavimo proceso dalimi. Ekspertas gali numatyti potencialius scenarijus ir įvertinti jų tikimybes, remdamasis sukaupta patirtimi ir intuicija.

Nustačius galimus išorinius kintamuosius, būtina įvertinti jų įtaką elektros energijos kainų dinamikai. Tam taikomas Grangerio priežastinio ryšio testas (angl. *Granger causality test*) – statistinis metodas, leidžiantis nustatyti, ar vieno kintamojo praeities reikšmės padeda geriau prognozuoti kito kintamojo reikšmes [61]. Testas atliekamas lyginant du regresijos modelius: vieną, apimančią tik priklausomojo kintamojo Y vėlavimus, ir kitą – papildomai įtraukiant nepriklausomojo kintamojo X vėlavimus. Kad analizė būtų pagrįsta, abi laiko eilutės turi būti stacionarios. Pirmasis redukuotas modelis:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \dots + \beta_p Y_{t-p} + \varepsilon_t; \quad (6)$$

čia Y_t – priklausomojo kintamojo Y reikšmė laiko momentu t ; $\beta_0, \dots, \beta_p$ – regresijos koeficientai; Y_{t-1}, Y_{t-p} – priklausomojo kintamojo Y vėlavimai; ε_t – atsitiktinė paklaida.

Antrasis pilnas modelis:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \dots + \beta_p Y_{t-p} + \alpha_1 X_{t-1} + \dots + \alpha_p X_{t-p} + \varepsilon_t; \quad (7)$$

čia Y_t – priklausomojo kintamojo Y reikšmė laiko momentu t ; $\beta_0, \dots, \beta_p, \alpha_1, \dots, \alpha_p$ – regresijos koeficientai; Y_{t-1}, Y_{t-p} – priklausomojo kintamojo Y vėlavimai; X_{t-1}, X_{t-p} – nepriklausomojo kintamojo X vėlavimai; ε_t – atsitiktinė paklaida.

Norint nustatyti, ar papildomi X_t vėlavimai statistiškai reikšmingai pagerina modelio tikslumą, atliekamas F-testas. F-statistika apskaičiuojama pagal formulę:

$$F = \frac{\frac{RSS_r - RSS_f}{k}}{\frac{RSS_f}{n - 2p - 1}}; \quad (8)$$

čia RSS_r – redukuoto modelio paklaidų kvadratų suma; RSS_f – pilno modelio paklaidų kvadratų suma; k – laisvės laipsnių skaičius; n – stebėjimų skaičius.

Tikrinamos šios hipotezės:

$$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_p = 0 \text{ (} X \text{ nedaro įtakos } Y \text{ kitimui);}$$

$$H_A: \exists \alpha_j \neq 0, j \in [1; p].$$

Nulinė hipotezė atmetama (testo p reikšmė yra mažesnė už tam tikrą reikšmingumo lygmenį), kai išorinis kintamasis X priežastingai veikia prognozuojamą laiko eilutę Y ($X \rightarrow Y$), tai yra išorinio kintamojo X praeities reikšmės pagerina laiko eilutės Y prognozavimo tikslumą, lyginant su prognoze, paremta tik Y praeities reikšmėmis.

Nustatytas Grangerio priežastinis ryšys ne visada reiškia tikrąjį priežastinį poveikį tarp kintamųjų [61]. Tokie rezultatai gali būti klaidinantys, ypač jei egzistuoja trečiasis nepastebėtas kintamasis arba abu tiriami kintamieji pasižymi panašia ilgalaikę dinamiką laike. Dėl šių priežasčių Grangerio testo rezultatai turėtų būti vertinami remiantis eksperimentinėmis žiniomis.

2.3. Prognozavimo modeliai

Šiame darbe bus sudaryti keturi mašininio mokymosi modeliai: atsitiktiniai miškai, atraminių vektorių regresija, *XGBoost* ir *LightGBM* algoritmai. Pirminiam šių modelių veikimo įvertinimui naudojamas sezoninis naivusis modelis.

Sezoninis naivusis – vienas paprasčiausių laiko eilučių prognozavimo metodų, paremtas prielaida, kad būsimos reikšmės kartosis pagal tą patį sezoniškumą, kuris stebėtas ankstesniu laikotarpiu [45]. Šio metodo esmė – kiekvienai prognozuojamai reikšmei priskirti analogiško sezono ankstesnę reikšmę:

$$\hat{y}_{t+1} = \hat{y}_{t+1-m}; \quad (9)$$

čia $\hat{y}_{t+1}$ – prognozuojama reikšmė laiko momentu $t + 1$; m – sezoniškumo periodas.

Sezoninis naivusis prognozavimo metodas taikomas kaip bazinis prognozavimo modelis, leidžiantis objektyviai įvertinti kitų, sudėtingesnių prognozavimo metodų rezultatus.

Atsitiktinis miškas – tai kelių sprendimų medžių, kurie yra apmokyti naudojant skirtingus duomenų poaibius, derinys [23]. L. Breimanas [62] pirmasis pristatė šį modelį, kuris pasižymi aukštu prognozavimo tikslumu, maža dispersija, lengvu pritaikymu ir optimizavimu [63]. Atsitiktinio miško algoritmas iš apmokymo aibės Ψ kiekvienam iš K medžių, $k = 1, \dots, K$, sudaro N dydžio imtį Ψ_k . Kiekvienoje imtyje Ψ_k medis T auginamas rekursyviai skaidant imties erdvę kiekviename mazge, kol pasiekiamas nustatytas stabdymo kriterijus (mažiausias lapų skaičius, maksimalus medžio gylis arba kiti apribojimai). Kiekviename mazge iš visų galimų kintamųjų n atsitiktinai parenkama dalis – p . Geriausias medžio T padalijimas nustatomas remiantis vidutine kvadratine paklaida (MSE). Atsitiktinis miškas tinka tiek regresijos, tiek klasifikavimo uždaviniams spręsti. Sprendžiant prognozavimo uždavinį, naudojamas regresijos medžių pagrindu veikiantis atsitiktinis miškas, kuriame derinamas maišymas (angl. *bagging*) su atsitiktinių poaibių metodu, o galutinis rezultatas – atskirų sprendimų medžių rezultatų vidurkis:

$$\widehat{f}_K(x) = \frac{1}{K} \sum_{k=1}^K T(x, \theta_k); \quad (10)$$

čia x – įvesties modelis; θ_k – k -tasis medis.

Atsitiktinio miško modelis atsparus persimokymo problemai, geba apdoroti didelės apimties duomenis, pasižymi dideliu mokymosi efektyvumu ir turi mažą hiperparametrų skaičių [64].

Atraminių vektorių regresija (SVR) – tai prižiūrimas mašininio mokymosi metodas, pagrįsta optimizavimo uždaviniu. Esminė idėja – surasti funkciją, kuri kuo tiksliau prognozuoja laiko eilutės reikšmes, leidžiant tam tikrą paklaidos ribą, tačiau kartu užtikrinant modelio paprastumą [65].

Darant prielaidą, kad $D = \{x_i, y_i\}_{i=1}^n$ yra apmokymo duomenų rinkinys, kur $x_i \in \mathbb{R}^p$ ir $y_i \in \mathbb{R}$, SVR metodas bando surasti tokią funkciją $f(x)$, kad prognozuojamos reikšmės būtų nutolusios ne daugiau nei per ξ nuo stebėjimų y_i , o stebėjimai y_i tilptų į juostą, kurios plotis 2ε :

$$f(x) = w^T x + b; \quad (11)$$

čia w – svorių vektorius; b – laisvasis narys.

Norint surasti optimalią regresijos funkciją, SVR sprendžia šią optimizavimo problemą:

$$\min_{w, b, \xi, \xi^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*); \quad (12)$$

$$\begin{cases} y_i - (w^T x_i + b) \geq \varepsilon + \xi_i, i = 1, \dots, n; \\ (w^T x_i + b) - y_i \geq \varepsilon + \xi_i^*, i = 1, \dots, n; \\ \xi_i \xi_i^* \geq 0, i = 1, \dots, n; \end{cases}$$

čia w – svorių vektorius; b – laisvasis narys; C – parametras, kuris kontroliuoja modelio tinkamumo ir sudėtingumo mažinimo santykį; ξ_i, ξ_i^* – baudos kintamieji;

Jei duomenys nėra tiesiškai atskiriami, SVR taiko branduolio triuką, kuris duomenis perkelia į aukštesnės dimensijos erdvę, kur juos galima atskirti ar aproksimuoti tiesine funkcija. Dažniausiai naudojami branduolių tipai: tiesinis, sigmoidinis, polinominis, radialinis. Remiantis [65], Gauso radialinis branduolys tam tikruose tyrimuose pasižymi geresniu veikimu. Gauso radialinė bazinė branduolio funkcija (RBF):

$$K(x_i, y_i) = \exp\left(-\frac{\|x_i - y_i\|^2}{2\sigma^2}\right); \quad (13)$$

čia σ – branduolio juostos plotis (didesnis už 0).

Naudojant RBF branduolio triuką, funkcija išreiškiama taip:

$$f(x) = \sum_{i=1}^n (\alpha_i + \alpha_i^*) K(x_i, y_i) + b; \quad (14)$$

čia α_i, α_i^* – koeficientai, gaunami optimizavimo metu.

Branduolio triukas leidžia SVR metodą taikyti sudėtingoms duomenų struktūroms ir modeliuoti netiesinius duomenų sąryšius [23].

XGBoost (angl. *eXtreme Gradient Boosting*) – vienas iš ansamblinio mokymosi algoritmų. Jis grindžiamas sprendimų medžių sistema ir naudoja gradiento didinimo (angl. *gradient boosting*) metodą. *XGBoost* algoritmas veikia iteratyviai: vieno medžio liekanos nuosekliai įvedamos į kitą medį, o kiekvienas paskesnis medis minimizuoja savo pirmtako liekanas [47, 66]. Be to, kiekvienas

sprendimų medis sudaromas ir apmokomas ne su visu duomenų rinkiniu, o su duomenų poaibiu. Šis atrankos procesas padeda įvesti įvairovę tarp medžių ir sumažina persimokymo tikimybę [66]. *XGBoost* algoritmas kiekvienoje iteracijoje optimizuoja medžio struktūrą ir lapų išvesties reikšmes taip, kad būtų minimizuota bendra tikslo funkcija:

$$L = \sum_{i=1}^n \text{los}(g_i, \hat{g}_i) + \sum_{k=1}^K \Psi(h_k); \quad (15)$$

čia $\text{los}(g_i, \hat{g}_i)$ – nuostolio funkcija, vertinanti prognozavimo paklaidą; $\Psi(h_k)$ – reguliavimo narys, ribojantis modelio kompleksumą.

(15) lygtyje esančią nuostolių funkciją galima apskaičiuoti taip:

$$\text{los}(g, \hat{g}) = \frac{-1}{N} \sum_{i=1}^N (g_i \log(\hat{g}_i) + (1 - g_i) \log(1 - \hat{g}_i)); \quad (16)$$

čia g_i – stebėjimas laiko momentu t ; $\hat{g}_i$ – modeliuojama vertė laiko momentu t .

XGBoost algoritmas yra vienas pažangiausių ir plačiai taikomų mašininio mokymosi metodų. Jis išsiskiria dideliu prognozavimo tikslumu, gebėjimu apdoroti didelius ir sudėtingus duomenų rinkinius [66]. *XGBoost* dažnai veikia ženkliai greičiau [51] nei tradiciniai metodai, tokie kaip atsitiktiniai miškai.

LightGBM (angl. *Light Gradient Boosting Machine*) – taip pat priskiriamas ansamblių metodų grupei ir veikia panašiai kaip *XGBoost*, tačiau pasižymi keliais esminiais skirtumais. Pirmiausia *LightGBM* metodas sprendimų medžio auginimui taiko gylį ribojančią lapų strategiją (angl. *leaf-wise*) [67]. Tai reiškia, kad kiekviename žingsnyje plečiamas tik tas mazgas, kuris tuo metu duoda didžiausią nuostolio sumažėjimą. Kiti gradiento didinimo metodai medį augina kiekviename žingsnyje, išplėsdami visus mazgus (angl. *level-wise*). Taip pat, taikant *LightGBM* algoritmą, vietoj to, kad kiekvienam duomenų taškui būtų skaičiuojamos tikslios reikšmės, duomenys sugrupuojami į intervalus (angl. *histogram algorithm*). Be to, *LightGBM* algoritme naudojami du nauji metodai [67]: GOSS (angl. *Gradient-Based One-Side Sampling*) ir EFB (angl. *Exclusive Feature Bundling*). GOSS metodas užtikrina, kad būtų naudojama ta dalis duomenų, kuri turi didžiausias gradientines reikšmes, o likusi dalis imama atsitiktinai. EFB metodas kintamuosius, kurie yra vienas kitą paneigiantys arba nesusiję (angl. *mutually exclusive*) sujungia į vieną. Tokiu būdu be reikšmingos informacijos praradimo yra sumažinamas kintamųjų skaičius. GOSS ir EFB metodai leidžia *LightGBM* algoritmui veikti greičiau, išlaikant aukštą tikslumo lygį [67].

2.4. Prognozės tikslumo metrikos

Prognozės tikslumo metrikos yra būtinos siekiant objektyviai įvertinti prognozavimo modelio tikslumą bei palyginti skirtingų modelių ar metodų prognozavimo kokybę. Jos leidžia priimti pagrįstus sprendimus dėl modelio tobulinimo, taip pat padeda pasirinkti tinkamiausią prognozavimo metodą konkrečiai analizuojamai problemai. Dažniausiai taikomos tikslumo vertinimo metrikos yra vidutinė absoliutinė procentinė paklaida (MAPE), vidutinė procentinė paklaida (MPE) ir šaknis iš vidutinės kvadratinės paklaidos (RMSE).

Vidutinė absoliutinė procentinė paklaida (MAPE) matuoja prognozės paklaidų vidutinę absoliučią vertę, išreikštą procentais nuo tikrosios reikšmės:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_t - F_t}{A_t} \right| \cdot 100 \% ; \quad (17)$$

čia A_t – faktinė stebėjimo reikšmė laiko momentu t ; F_t – prognozuota stebėjimo reikšmė laiko momentu t ; n – prognozuojamų stebėjimų skaičius.

MAPE parodo, kiek vidutiniškai procentais prognozė nukrypsta nuo faktinių laiko eilutės reikšmių. Pavyzdžiui, jei MAPE reikšmė yra 8 %, tai reiškia, kad prognozė vidutiniškai 8 % skiriasi nuo tikrųjų reikšmių. Jei MAPE reikšmė yra mažesnė nei 10 %, prognozė vertinama kaip itin tiksli [52]. Tačiau ši metrika nėra tinkama, kai faktinės reikšmės yra artimos nuliui [35], nes tokiais atvejais net nedidelis absoliutus prognozės nuokrypis gali lemti labai didelę procentinę paklaidą, o tai iškreipia bendrą vertinimą.

Vidutinė procentinė paklaida (MPE) matuoja vidutinį prognozės nuokrypį, išreikštą procentais, nuo faktinių reikšmių:

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{A_t - F_t}{A_t} \cdot 100 \% ; \quad (18)$$

čia A_t – faktinė stebėjimo reikšmė laiko momentu t ; F_t – prognozuota stebėjimo reikšmė laiko momentu t ; n – prognozuojamų stebėjimų skaičius.

Skirtingai nei MAPE, MPE nevertina paklaidos absoliučiai, todėl ji išlaiko nuokrypio kryptį (teigiamą arba neigiamą), leidžiančią įvertinti, ar prognozės sistemingai pervertina ar nuvertina stebėjimus. Teigiamą MPE reikšmę rodo, kad modelis pervertina faktines laiko eilutės reikšmes, o neigiamą, kad nuvertina. MPE metrika naudinga šališkumo (angl. *bias*) įvertinimui. Kaip ir MAPE, ši metrika gali būti nepatikima, kai faktinės reikšmės artėja prie nulio.

Šaknis iš vidutinės kvadratinės paklaidos (RMSE) parodo vidutinį paklaidos dydį:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (A_t - F_t)^2} ; \quad (19)$$

čia A_t – faktinė stebėjimo reikšmė laiko momentu t ; F_t – prognozuota stebėjimo reikšmė laiko momentu t ; n – prognozuojamų stebėjimų skaičius.

Mažesnė RMSE reikšmė indikuoja didesnę prognozavimo modelio tikslumą. Ši metrika yra jautri didelėms paklaidoms, nes prognozavimo netikslumai, t. y. klaidos keliamos kvadratu.

2.5. Tyrimo metodai

Kadangi *Nord Pool* platformoje duomenys nebėra laisvai pasiekiami, šiame tyrime reikalingi elektros energijos rinkos duomenys buvo imami iš *ENTSO-E Transparency Platform*¹ platformos, kurioje centralizuotai renkami ir skelbiami visos Europos rinkai skirti elektros energijos gamybos, transportavimo ir vartojimo duomenys. Tyrime analizuojamos valandinės Lietuvos elektros energijos kainos nuo 2024 m. sausio 1 d. iki 2025 m. vasario 28 d. Pirmų 13 mėnesių duomenys naudojami prognozavimo modelių apmokymui, o paskutinio mėnesio (2025 m. vasario mėn.) duomenys naudojami modelių testavimui.

Vienmatės elektros energijos kainos laiko eilutės 24 valandų prognozei generuoti sudaromi penki prognozavimo modeliai (sezoninis naivusis, atsitiktinis miškas, atraminių vektorių regresija, *XGBoost* ir *LightGBM*). Gautos prognozės ir jų tikslumo metrikos kiekvienu atveju įrašomos į atskirus *excel* failus. Taip pat pateikiama kiekvieno prognozavimo modelio skaičiavimo trukmė, kuri leidžia įvertinti ne tik modelio tikslumą, bet ir jo efektyvumą – tai ypač svarbu taikant modelius praktiniuose sprendimuose, kai reikalingas greitas prognozių generavimas. Toliau sudaroma literatūros analizės santrauka, atliekama PESTLE analizė ir, remiantis gautais rezultatais, ekspertinėmis žiniomis ir reikiamų duomenų prieinamumu, nustatomi išorinės verslo aplinkos veiksniai. Daugiamatis 24 valandų elektros energijos kainos prognozavimo modelis sudaromas naudojant tuos pačius keturis prognozavimo metodus kaip ir vienmačio modelio atveju, išskyrus sezoninį naivųjį, kuris šiuo atveju nesudaromas. Gautos prognozės ir jų tikslumo metrikos įrašomos į *excel* failus. Tokiu būdu galima palyginti ne tik skirtingų prognozavimo modelių veikimą, bet ir nustatyti, ar papildomų kintamųjų įtraukimas pagerina prognozavimo tikslumą.

Visi aukščiau aptarti tyrimo modeliai ir metodai realizuojami R programavimo aplinkoje, panaudojant ten esančias standartines funkcijas ir paketus, skirtus laiko eilučių analizei bei prognozavimui. R programavimo aplinka pasirinkta dėl turimų techninių žinių ir plataus įvairių analizės ir prognozavimo metodų pasirinkimo.

R aplinkoje *randomForest* funkcija iš *randomForest* paketo įgyvendina L. Breimano atsitiktinio miško algoritmą klasifikavimo ir regresijos uždaviniams spręsti. Yra trys pagrindiniai atsitiktinio miško hiperparametrai:

1. *ntree* – medžių skaičius nurodo, kiek sprendimų medžių bus suformuota miške. Didesnis sprendimų medžių skaičius gali pagerinti prognozės stabilumą, bet padidina skaičiavimo laiką. Tyrime analizuojamos šios *ntree* vertės: 200, 300, 350;
2. *mtry* – atsitiktinai pasirenkamų kintamųjų skaičius kiekvienam mazgo skaidymui. Šis parametras nulemia modelio įvairiapusiškumą. Mažesnės *mtry* reikšmės padidina medžių įvairovę, o didesnės leidžia geriau išnaudoti duomenų informaciją kiekviename medyje. Vienmatėje prognozėje analizuojamos šios *mtry* vertės: 1, 2, 3, o daugiamatėje – 5, 7, 9;
3. *nodesize* – minimalus stebėjimų skaičius lapuose. Regresijos atveju tai reiškia, kiek mažiausiai stebėjimų turi būti galutiniame mazge, kad būtų sustabdytas skaidymas. Mažesnės *nodesize* reikšmės leidžia sukurti sudėtingesnius (giliau išskaidytus) medžius, o didesnės – sukuria paprastesnį modelį, kuris gali būti ne toks jautrus triukšmui. Tyrime analizuojamos šios *nodesize* vertės: 5, 10.

¹ ENTSO-E Transparency Platform platformos nuoroda: [Transparency Platform](#)

Atraminų vektorių regresija R aplinkoje atliekama naudojant *svm* funkciją iš *e1071* paketo. Modelio veikimas ir prognozavimo tikslumas priklauso nuo kelių svarbių hiperparametrų:

1. *epsilon* – apibrėžia nejautrią nuostolių funkciją. Tai yra zoną aplink tikrąsias reikšmes, kurioje paklaidos nėra baudžiamos. Šis parametras leidžia SVR modeliui toleruoti nedidelius netikslumus prognozėse. Tyrime analizuojamos šios *epsilon* reikšmės: 0,01, 0,05 ir 0,1;
2. *cost* (arba *C*) – baudos koeficientas. Didesnės *cost* reikšmės leidžia sumažinti paklaidą treniravimo duomenyse, bet gali padidinti persimokymo riziką. Tyrime analizuojamos šios *cost* reikšmės: 1, 10;
3. *kernel* – branduolio funkcija, kuri nusako, kaip duomenys transformuojami į aukštesnės dimensijos erdvę. Naudojamas branduolys lemia modelio gebėjimą modeliuoti sudėtingus netiesinius ryšius. Tyrime naudojami radialinis ir polinominis branduoliai.

R aplinkoje *XGBoost* algoritmas realizuotas naudojant *xgb.train* funkciją iš *xgboost* paketo. Ši funkcija leidžia detalai kontroliuoti modelio treniravimo procesą. Tyrime modelio konfigūravimui naudoti šie hiperparametrai:

1. *eta* – mokymosi žingsnis, kuris reguliuoja kiekvieno naujo medžio įtaką galutinei prognozei. Mažesnės *eta* reikšmė sumažina persimokymo riziką, bet lėtina modelio apmokymą. Tyrime analizuojamos šios *eta* reikšmės: 0,01, 0,05 ir 0,1;
2. *max_depth* – apibrėžia maksimalų medžio gylį, t. y. kiek kartų medžio šakos gali būti padalintos. Didesnės reikšmės leidžia modeliuoti sudėtingesnius duomenų ryšius, tačiau padidina persimokymo tikimybę. Tyrime analizuojamos šios *max_depth* reikšmės: 4, 6;
3. *subsample* – tai atsitiktinai pasirenkama dalis duomenų, naudojama kiekvieno medžio apmokymui. Tyrime analizuojamos šios *subsample* reikšmės: 0,8 ir 0,9;
4. *colsample_bytree* – nurodo, kokia dalis kintamųjų bus atsitiktinai pasirenkama kiekvieno medžio sudarymui. Šis parametras padeda sumažinti koreliaciją tarp medžių. Tyrime analizuojamos šios *colsample_bytree* reikšmės: 0,8 ir 0,9.

R aplinkoje *LightGBM* algoritmas įgyvendinamas naudojant *lgb.train* funkciją iš *lightgbm* paketo. Tyrime modelio treniravimui buvo naudojami šie hiperparametrai:

1. *learning_rate* – mokymosi žingsnis. Mažesnės reikšmės užtikrina stabilesnį, bet lėtesnį mokymąsi, ir padeda išvengti persimokymo. Tyrime analizuojamos šios *learning_rate* reikšmės: 0,01, 0,05, 0,1;
2. *num_leaves* – tai maksimalus lapų skaičius medyje. Šis parametras tiesiogiai susijęs su modelio galia: kuo daugiau lapų, tuo sudėtingesnis modelis. Tyrime analizuojamos šios *num_leaves* reikšmės: 7 ir 13;
3. *feature_fraction* – nurodo, kokia dalis kintamųjų bus atsitiktinai pasirenkama kiekvieno medžio sudarymui. Tai padeda sumažinti koreliaciją tarp medžių. Tyrime analizuojamos šios *feature_fraction* reikšmės: 0,7 ir 0,8;
4. *bagging_fraction* – atsitiktinai pasirenkama dalis duomenų, naudojama kiekvieno medžio apmokymui. Tyrime analizuojamos šios *bagging_fraction* reikšmės: 0,7 ir 0,8.


Visi skaičiavimai atlikti su Intel(R) Core(TM) Ultra 5 125U 1.30 GHz procesoriumi, 32 GB RAM ir 64 bitų Windows operacine sistema.

3. Tyrimo rezultatai

Šiame skyriuje pateikiami pagrindiniai tyrimo rezultatai.

3.1. Lietuvos elektros energijos kainos tendencijų analizė

Tyrimas pradedamas nuo Lietuvos elektros energijos kainos tendencijų analizės. 3 pav. pateikta Lietuvos elektros energijos valandinė kaina nuo 2024 m. sausio 1 d. iki 2025 m. vasario 28 d.



3 pav. Lietuvos elektros energijos valandinės kainos

Remiantis pateiktu grafiku, galima teigti, kad elektros energijos kaina Lietuvoje pasižymi dideliu kintamumu. Daugelį kainų svyravimų galima paaiškinti, žinant regiono elektros energijos rinkos situaciją. Lietuva reikšmingą dalį elektros energijos importuoja iš Švedijos per *NordBalt* jungtį. Ši jungtis yra strategiškai svarbi Lietuvos integracijai į Šiaurės Europos elektros energijos rinką ir užtikrina galimybę importuoti pigesnę elektros energiją iš Skandinavijos regiono. Todėl, kai 2024 metų pradžioje visame Šiaurės Europos regione ilgą laiką laikėsi itin žema neigiama temperatūra ir dėl to padidėjo elektros energijos paklausa, o atsinaujinančių šaltinių gamyba sumažėjo, Lietuvoje buvo fiksuotas didžiulis kainų šuolis. Tuo metu Skandinavijos regione beveik nepūtė vėjas, o dėl ilgą laiką buvusios neigiamos temperatūros sustojo ir hidroenergijos gamyba, kuri paprastai kompensuoja vėjo energijos trūkumą. Todėl nebelikus galimybių importuoti pigią elektros energiją iš Skandinavijos elektros energijos poreikį Lietuvoje teko užtikrinti brangesnėmis šiluminėmis elektrinėmis. 3 pav. matomas ir didesnis elektros kainos nepastovumas bei dažnesnės aukštos kainos birželio–spalio mėnesiais. Šiuo laikotarpiu vyko *NordBalt* kabelio remonto darbai ir Lietuva neteko dalies pastovios ir ekonomiškai palankios pasiūlos. Be to, analizuojamu laikotarpiu 186 valandas buvo fiksuotos neigiamos elektros energijos kainos. 2 lentelėje pateiktos pagrindinės Lietuvos elektros energijos kainos statistinės charakteristikos.


2 lentelė. Lietuvos elektros energijos kainos statistinės charakteristikos (EUR/MWh)

Minimali reikšmė	Q1	Mediana (Q2)	Vidurkis	Q3	Maksimali reikšmė
-19,96	47,62	85,08	91,78	120	1428,91

Vidutinė elektros energijos kaina Lietuvoje nuo 2024-01-01 iki 2025-02-28 lygi 91,78 EUR/MWh. Šiuo laikotarpiu elektros energijos kaina svyravo nuo -19,96 EUR/MWh iki 1428,91 EUR/MWh.


25 % kainų buvo mažesnės nei 47,62 EUR/MWh, 50 % – mažesnės nei 85,08 EUR/MWh, o 75 % – mažesnės nei 120 EUR/MWh.

Iš 3 pav. pateikto grafiko sunku spręsti, ar Lietuvos elektros energijos valandinės kainos laiko eilutė yra reguliari, todėl naudojama R programavimo aplinkos *summary* funkcija. Gauti rezultatai patvirtina, kad laiko eilutė – reguliari, t. y. trūkstančių reikšmių šioje laiko eilutėje nėra ir interpoliacija nebus atliekama. 3 pav. pateiktame grafike taip pat matomi staigūs kainų šuoliai – tai išskirtys, kurias reikia pašalinti. Išskirtys, rastos su R programavimo aplinkos *tsoutliers* funkcija, pažymėtos mėlyna spalva 4 pav. pateiktame grafike.




4 pav. Lietuvos elektros energijos valandinės kainos išskirtys

Pašalinus išskirtis, tikrinamas laiko eilutės stacionarumas. ADF testo p reikšmė mažesnė už 0,05, todėl nulinė hipotezė atmetama. Daroma išvada, kad elektros energijos kainos laiko eilutė – stacionari. Toliau tikrinama laiko eilutės autokoreliacija. *Ljung-Box* testo p reikšmė mažesnė už 0,05 – nulinė hipotezė atmetama. Daroma išvada, kad elektros energijos kainos laiko eilutė koreliuota, t. y. praeityje užfiksuoti stebėjimai daro įtaką dabartiniams. 5 pav. pateikti autokoreliacijos (ACF) ir dalinės autokoreliacijos (PACF) grafikai.



5 pav. Elektros energijos kainų autokoreliacijos ir dalinės autokoreliacijos grafikai

ACF grafikas padeda įvertinti autokoreliacijos reikšmingumą. Remiantis grafiku, daroma išvada, kad autokoreliacija yra reikšminga imtinai iki 40 vėlavimo, o reikšmingiausia su pirmuoju vėlavimu. Pakilimas ties dvidešimt ketvirtu vėlavimu gali reikšti dienos sezoniškumą. PACF grafike taip pat matoma reikšminga autokoreliacija su pirmuoju vėlavimu. Nors ACF grafike užfiksuotas galimas dienos sezoniškumas, bet, remiantis literatūra ir ekspertinėmis žiniomis, daroma prielaida, kad elektros energijos kaina pasižymi daugiau nei vieno tipo sezoniškumu. Buvo išbandyti įvairūs laiko eilutės MSTL dekompozicijos su skirtingais sezoniškumais variantai. Remiantis komponentių svarba laiko eilutės duomenims, buvo išrinkta geriausia laiko eilutės MSTL dekompozicija, kurios rezultatas matomas 6 pav.



6 pav. MSTL dekompozicija

Atlikus MSTL dekompoziciją, paaiškėjo, kad liekanų komponentė pati svarbiausia – tai nėra netikėta, nes analizuojama labai nepastovi ir kintanti laiko eilutė. Liekanų komponentės svarba identifikuoja elektros energijos kainos prognozavimo sudėtingumą. Tikrinant liekanų autokoreliaciją, nulinė hipotezė atmetama, nes *Ljung-Box* testo *p* reikšmė mažesnė už 0,05. Iš to

seka, kad liekanos priklausomos laike, t. y. liekanų komponentė nėra tiesiog baltas triukšmas, o pasirinktas MSTL dekompozicijos modelis nepilnai paaiškina laiko eilutės dinamiką. Toliau komponentės svarbos mažėjimo kryptimi likusios komponentės išsidėsto taip: dienos sezoniškumas, savaitės sezoniškumas, trendas.

3.2. Išorinės verslo aplinkos veiksnių, darančių įtaką Lietuvos elektros energijos kainai, nustatymas

Prognozuojant Lietuvos elektros energijos kainą, kalbėti tik apie Lietuvą ir joje vykstančius procesus būtų neteisinga, nes elektros energijos rinka yra stipriai integruota į platesnį regioninį ir tarptautinį energetikos sektorių. Siekiant išsiaiškinti įtaką darančius veiksnius, pirmiausiai buvo atlikta literatūros apžvalga, kuri aprašyta ir pateikta 1.2 ir 1.3 poskyriuose. 3 lentelėje pateikiama šios apžvalgos santrauka – dažniausiai naudoti išorinės verslo aplinkos veiksniai ir jų poveikis elektros energijos kainoms.

3 lentelė. Literatūros šaltiniuose nustatytas išorinės verslo aplinkos veiksnių poveikis elektros energijos kainoms

Veiksny	Poveikis
Vėjo energijos gamyba	Sumažina elektros energijos kainą [28, 29, 33], bet padidina jos nepastovumą [2, 21, 22]. Didina neigiamos elektros energijos kainos tikimybę [15, 29] ir lemia kainų šuolius [22].
Elektros energijos paklausa	Mažesnė paklausa lemia elektros energijos kainos mažėjimą [21, 22]. Didžiausios elektros energijos paklausos laikotarpiais elektros energijos kainos paprastai kyla ir atvirkščiai [24, 28, 33].
Bendra elektros energijos gamyba šalyje	Kai gamyba yra mažesnė nei 1000 MWh, stebimos labai žemos elektros energijos kainos [22]. Elektros energijos gamyba prisideda prie elektros energijos kainų svyravimų [24, 27].
Tarpsisteminiai srautai	Suvienodina elektros energijos kainas skirtingose šalyse [22]. Staigūs, netikėti srautų pokyčiai, lemia padidėjusias elektros energijos kainas [36].
Naftos kaina	Nepastebėtas elektros energijos kainų lygio didėjimas, didėjant naftos kainoms [22]. Naftos kainų svyravimai tiesiogiai veikia gamybos sąnaudas, taigi, ir elektros energijos kainas [24].
Dujų kaina	Konkretus poveikis neužfiksuotas [22]. [29] nustatyta, kad dujų kainai didėjant, elektros energijos kaina taip pat didėja. Šis poveikis juntamas iki tol, kol importuojamų dujų kaina pasiekia 27,71 EUR už 1 MWh. Daroma prielaida, kad ateityje dujų kainos poveikis elektros energijos kainai mažės.
Temperatūra	Didėjanti temperatūra, neturi pastebimo poveikio elektros energijos kainoms, bet, kai temperatūra nukrenta žemiau 0 laipsnių, pastebimi kainų šuoliai [22]. Nustatyta, kad poveikio elektros energijai nedaro [21].
Saulės energijos gamyba	Padidina elektros energijos kainos nepastovumą [27].

Kadangi keliuose straipsniuose nustatyta, jog temperatūra elektros energijos kainoms įtakos nedaro, o pašalinus šį kintamąjį gaunama tikslesnė prognozė, tolimesniame tyrime šis kintamasis nebus naudojamas. Be to, Lietuvoje nėra elektros energiją gaminančių elektrinių, kurios kaip žaliavą naudotų naftą, todėl naftos kaina šiame tyrime taip pat nėra analizuojama.

Atlikus literatūros apžvalgos apibendrinimą, toliau tiriama elektros energetikos sektoriaus makroaplinka ir atliekama PESTLE analizė. Šios analizės rezultatas pateiktas 4 lentelėje.

4 lentelė. PESTLE analizė

-	Politis	Ekonominis	Socialinis	Technologinis	Teisinis	Aplinkosaugos
Veiksny	Valstybės energetikos politika Geopolitinė situacija	Infliacija Investicijos Pajamų lygis Dvišaliai kontraktai	Visuomenės požiūris Vartojimo įpročiai	Inovacijos Skaitmenizacija Aukštos kvalifikacijos darbuotojai	Energetikos sektoriaus reguliavimas Tarptautiniai susitarimai	Gamtos ištekliai Anglies dioksido kreditai
Pasekmė	Parama atsinaujintiems šaltiniams Ribojimai Žaliavų importas, eksportas, kaina	Sąnaudos Paklausos pokytis	Palaikymas Paspriešinimas Paklausos pokytis	Atsinaujinanti energetika Saugojimo sprendimai Išmanusis elektros tinklas	Energetinis saugumas ir patikimumas Veiklos reguliavimas Biurokratija	Atsinaujinanti energetika CO ₂ emisijos mažėjimas
Poveikis	Teigiamas ir neigiamas	Teigiamas ir neigiamas	Teigiamas ir neigiamas	Teigiamas ir neigiamas	Teigiamas ir neigiamas	Teigiamas ir neigiamas
Svarba	Labai didelė	Didelė	Vidutinė	Didelė	Labai didelė	Didelė

Politiniai veiksniai daro reikšmingą įtaką šalies energetikos politikai ir jos raidai. Valstybės sprendimai šioje srityje dažnai lemia, kokie energijos šaltiniai bus plėtojami, kokios technologijos bus remiamos, bei kaip bus reguliuojamas elektros energijos gamybos, tiekimo ir vartojimo procesas. Nacionalinės energetikos politikos pagrindu valstybė gali taikyti įvairias priemones – subsidijas atsinaujintiems energijos šaltiniams bei skatinti privačių įmonių dalyvavimą tvartos energetikos projektuose. Kitas svarbus politinis veiksnys yra geopolitinė situacija. Tarptautiniai santykiai, politiniai konfliktai ar priklausomybė nuo išteklių turinčių valstybių tiesiogiai veikia žaliavų – tokių kaip gamtinės dujos, nafta ar anglis – importą, eksportą bei jų kainą. Pavyzdžiui, gamtinės dujas eksportuojančioms šalims pritaikyti muitai gali lemti tiekimo sutrikimus ar žaliavų kainos svyravimus. Dėl to valstybės dažnai siekia diversifikuoti energijos tiekimo šaltinius arba investuoja į vietinius energijos resursus, kad sumažintų priklausomybę nuo išorės.

Ekonominiai veiksniai taip pat daro svarbų poveikį. Pavyzdžiui, infliacija lemia bendrą kainų lygio kitimą, o tai atsispindi ir energetikos sektoriuje. Didėjant infliacijai, brangsta žaliavos, darbo jėga bei investiciniai projektai. Tai didina energijos gamybos sąnaudas ir galutinę kainą vartotojams. Infliacija gali mažinti energetinių produktų paklausą, ypač jei gyventojų pajamų lygis nesikeičia arba mažėja. Investicijos yra kitas svarbus ekonominis veiksnys. Tiek viešojo, tiek privataus sektoriaus kapitalo srautai į energetiką lemia inovacijas, infrastruktūros plėtrą ir naujų technologijų diegimą. Didelės investicijos į atsinaujinančius energijos šaltinius gali paskatinti ilgalaikį sąnaudų mažėjimą, didesnę energetinį efektyvumą ir sumažinti priklausomybę nuo importuojamų žaliavų. Tokios investicijos turi ilgalaikį teigiamą poveikį. Aukštesnis gyventojų pajamų lygis lemia didesnę elektros energijos suvartojimą tiek buityje, tiek transporto, paslaugų sektoriuose. Dvišaliai kontraktai – tai tiesioginiai susitarimai tarp valstybių dėl elektros energijos tiekimo. Jie leidžia užtikrinti stabilesnes energijos kainas ir tiekimo saugumą. Tokie kontraktai dažnai sudaromi ilgam laikotarpiui ir padeda sumažinti svyruojančių pasaulinių rinkų daromą poveikį. Tačiau šie susitarimai taip pat gali būti nepalankūs, jei rinkos sąlygos pasikeičia.

Socialiniai veiksniai tampa vis reikšmingesni energetikos sektoriuje. Vienas pagrindinių socialinių veiksnių yra visuomenės požiūris į energetiką, ypač į atsinaujinančius šaltinius, branduolinę energiją, iškastinio kuro naudojimą ar aplinkosaugos klausimus. Vis daugiau žmonių ima reikšti susirūpinimą dėl klimato kaitos ir taršos, todėl stiprėja žaliųjų energijos šaltinių populiarumas. Kita vertus, kai kuriais atvejais visuomenė gali prieštarauti tam tikriems energetikos projektams – pavyzdžiui, vėjo jėgainių statybai šalia gyvenviečių, nerimaujant dėl galimos žalos sveikatai, kraštovaizdžiui ar nekilnojamojo turto vertei. Kitas svarbus socialinis aspektas – vartojimo įpročiai. Išaugęs komforto poreikis, lemia padidėjusią energijos paklausą ir rytinį bei vakarinį kainų pikus.

Technologiniai veiksniai turi ypač didelę svarbą energetikos sektoriuje. Vienas reikšmingiausių technologinių veiksnių yra inovacijos. Naujos technologijos leidžia sparčiau plėtoti atsinaujinančią energetiką. Tobulėjant technologijoms, mažėja atsinaujinančių energijos šaltinių sąnaudos, didėja efektyvumas, o tuo pačiu – ir konkurencingumas lyginant su tradiciniais, iškastinio kuro pagrindu veikiančiais energijos šaltiniais. Inovacijos taip pat leidžia kurti pažangius elektros energijos saugojimo sprendimus, kurie yra būtini, užtikrinant elektros energijos tiekimo stabilumą. Skaitmenizacija – dar vienas esminis veiksnys. Ji apima visą infrastruktūros skaitmeninimą, duomenų surinkimą ir analizę, automatizavimą bei dirbtinio intelekto taikymą energetikos sektoriuje. Skaitmenizacija sudarė sąlygas kurti išmaniuosius elektros tinklus (angl. *smart grids*), kuriuose elektros energija ir būsenos informacija juda visomis kryptimis. Didelę reikšmę turi ir aukštos kvalifikacijos darbuotojai. Technologijų diegimas reikalauja ne tik pažangios įrangos, bet ir specialistų, gebančių ją valdyti, tobulinti bei užtikrinti jos saugų ir efektyvų veikimą. Tačiau kartu technologijos gali turėti ir neigiamą poveikį, pavyzdžiui, didinti atskirtį tarp skirtingų regionų ar socialinių grupių.

Teisiniai veiksniai energetikos sektoriuje yra ypač reikšmingi. Teisės aktai ir tarptautiniai susitarimai lemia, kaip veikia visa energetikos sistema – nuo gamybos iki tiekimo, nuo investicijų iki vartotojų teisių. Vienas pagrindinių teisinių veiksnių – energetikos sektoriaus reguliavimas. Jis apima įstatymus, nutarimus, licencijavimo tvarkas, tarifų nustatymą, veiklos priežiūrą bei konkurencijos užtikrinimą. Reguliavimas turi užtikrinti, kad energetikos sistema būtų patikima, efektyvi, teisingai veikianti ir atitinkanti visuomenės interesus. Tinkamai parengta reguliavimo sistema užtikrina energetinį saugumą – tai yra nenutrūkstamą tiekimą, stabilią infrastruktūrą ir greitą reagavimą. Kitas svarbus veiksnys – tarptautiniai susitarimai, tokie kaip Paryžiaus susitarimas dėl klimato kaitos, skatina šalis mažinti šiltnamio efektą sukeliančių dujų emisiją ir pereiti prie tvaresnių energijos šaltinių. Šie susitarimai daro spaudimą nacionalinėms vyriausybėms priimti atitinkamus sprendimus ir prisidėti prie bendrų tikslų. Tačiau teisinis reguliavimas gali turėti ir neigiamų pasekmių. Viena iš jų – biurokratija. Per daug sudėtingos, neaiškos ar dažnai besikeičiančios taisyklės gali stabdyti projektų įgyvendinimą, atbaidyti investuotojus ar lemti neefektyvų viešųjų lėšų panaudojimą.

Aplinkosaugos veiksnių svarba ypač didėja. Vienas esminių aspektų – gamtos išteklių naudojimas. Energetika tiesiogiai priklauso nuo gamtinių resursų – naftos, dujų, anglies, vandens, vėjo, saulės. Šiuo metu atsisakoma tradicinių, taršių, iškastinį kurą naudojančių elektros energijos šaltinių ir pereinama prie švarių, atsinaujinančių alternatyvų, siekiant išsaugoti ekosistemas ir sumažinti ilgalaikę žalą gamtai. Kitas reikšmingas veiksnys – anglies dioksido (CO_2) kreditų sistema, taikoma daugelyje pasaulio šalių, ypač Europos Sąjungoje. Pagal ją įmonėms nustatoma CO_2 emisijos riba. Viršijus šią ribą, reikia nusipirkti atitinkamą skaičių CO_2 kreditų, o nepanaudotus kreditus galima parduoti kitoms įmonėms. Tai sukuria finansinę paskatą mažinti CO_2 išmetimą. Vis dėlto ir

aplinkosaugos veiksniai gali turėti neigiamą poveikį – ypač trumpuoju laikotarpiu. Griežti ribojimai ir reikalavimai gali sulėtinti projektų įgyvendinimą, padidinti sąnaudas, sukelti aplinkosaugos ir ekonominių interesų konfliktus.

Taigi, visų šešių kategorijų veiksniai daro didesnę ar mažesnę tiek teigiamą, tiek neigiamą įtaką elektros energetikos sektoriui. Tiesa, daugelis PESTLE analizėje aptartų veiksnių arba nėra išmatuojami arba jų duomenys kinta dideliais laiko tarpais (metais, pusmečiais, mėnesiais) ir dėl to daugiamaciame prognozavimo modelyje nebus naudojami. 5 lentelėje pateikti veiksniai, kuriuos, remiantis literatūros apžvalga, PESTLE analize ir ekspertinėmis žiniomis, nuspręsta naudoti tyrime. Taip pat lentelėje pateikiami veiksnių matavimo vienetai, pavadinimų trumpiniai, naudojami tyrime ir atlikti duomenų tvarkymo ir paruošimo analizei veiksmai.

5 lentelė. Tyrime, naudojami išorinės verslo aplinkos veiksniai


Veiksny, matavimo vnt.	Trumpinys	Atlikti veiksmai
Istorinės elektros energijos kainos Švedijos SE4 kainų zonoje, EUR/MWh	<i>PriceSE4</i>	Išskirčių šalinimas
Istorinės elektros energijos kainos Lenkijoje, MW	<i>PricePL</i>	Išskirčių šalinimas
Dienos prieš rinkoje prognozuojamas elektros energijos suvartojimas Lietuvoje, MW	<i>Load</i>	Nuo 2024-11-17 duomenys transformuoti į valandinius – apskaičiuotas vidutinis 15 min. intervalų suvartojimas Trūkstamų reikšmių interpoliavimas Išskirčių šalinimas
Dienos prieš rinkoje prognozuojamas elektros energijos suvartojimas Švedijos SE4 kainų zonoje, MW	<i>LoadSE4</i>	Išskirčių šalinimas Pirmo laipsnio diferencijavimas ir sukurtas kintamasis <i>d_LoadSE4</i>
Dienos prieš rinkoje prognozuojamas elektros energijos suvartojimas Latvijoje, MW	<i>LoadLV</i>	Išskirčių šalinimas Pirmo laipsnio diferencijavimas ir sukurtas kintamasis <i>d_LoadLV</i>
Dienos prieš rinkoje prognozuojamas elektros energijos suvartojimas Lenkijoje, MW	<i>LoadPL</i>	Nuo 2024-06-13 duomenys transformuoti į valandinius – apskaičiuotas vidutinis 15 min. intervalų suvartojimas Išskirčių šalinimas
Dienos prieš rinkoje prognozuojama elektros energijos gamyba Lietuvoje, MW	<i>Gen</i>	Nuo 2024-10-08 duomenys transformuoti į valandinius – apskaičiuota vidutinė 15 min. intervalų gamyba Trūkstamų reikšmių interpoliavimas
Dienos prieš rinkoje prognozuojama elektros energijos gamyba Švedijos SE1 kainų zonoje, MW	<i>GenSE1</i>	-
Dienos prieš rinkoje prognozuojama elektros energijos gamyba Švedijos SE2 kainų zonoje, MW	<i>GenSE2</i>	-
Dienos prieš rinkoje prognozuojama elektros energijos gamyba Švedijos SE3 kainų zonoje, MW	<i>GenSE3</i>	-
Dienos prieš rinkoje prognozuojama elektros energijos gamyba Švedijos SE4 kainų zonoje, MW	<i>GenSE4</i>	-

Veiksny, matavimo vnt.	Trumpinys	Atlikti veiksmai
Dienos prieš rinkoje prognozuojama elektros energijos gamyba Suomijoje, MW	<i>GenFI</i>	Nuo 2024-01-01 duomenys transformuoti į valandinius – apskaičiuota vidutinė 15 min. intervalų gamyba
Dienos prieš rinkoje prognozuojama elektros energijos gamyba Danijos DK1 kainų zonoje, MW	<i>GenDK1</i>	-
Dienos prieš rinkoje prognozuojama elektros energijos gamyba Danijos DK2 kainų zonoje, MW	<i>GenDK2</i>	-
Dienos prieš rinkoje prognozuojama elektros energijos gamyba Latvijoje, MW	<i>GenLV</i>	Nuo 2024-12-16 duomenys transformuoti į valandinius – apskaičiuota vidutinė 15 min. intervalų gamyba Pirmo laipsnio diferencijavimas ir sukurtas kintamasis <i>d_GenLV</i>
Dienos prieš rinkoje prognozuojama elektros energijos gamyba Estijoje, MW	<i>GenEE</i>	Išskirčių šalinimas Trūkstumų reikšmių interpoliavimas
Dienos prieš rinkoje prognozuojama elektros energijos gamyba Lenkija, MW	<i>GenPL</i>	Nuo 2024-06-13 duomenys transformuoti į valandinius – apskaičiuota vidutinė 15 min. intervalų gamyba
Prognozuojama saulės elektrinių gamyba Lietuvoje, MW	<i>SolarLT</i>	Nuo 2024-10-08 duomenys transformuoti į valandinius – apskaičiuota vidutinė 15 min. intervalų gamyba Trūkstumų reikšmių interpoliavimas
Prognozuojama vėjo elektrinių gamyba Lietuvoje, MW	<i>WindLT</i>	Nuo 2024-10-08 duomenys transformuoti į valandinius – apskaičiuota vidutinė 15 min. intervalų gamyba Trūkstumų reikšmių interpoliavimas
Komeraciniai tarpvietiniai srautai tarp Švedijos SE4 kainų zonos ir Lietuvos, MW	<i>SE4_LT</i>	-
Komeraciniai tarpvietiniai srautai tarp Latvijos ir Lietuvos, MW	<i>LV_LT</i>	-
Komeraciniai tarpvietiniai srautai tarp Lenkijos ir Lietuvos, MW	<i>PL_LT</i>	-
Dujų kaina Lietuvoje ² , EUR/MWh	<i>GasPrice</i>	Nuo 2024-10-08 duomenys transformuoti į valandinius – kiekvienos paros kaina parkartota dvidešimt keturis kartus ir sugludinta splainų metodu

Nustačius išorinės verslo aplinkos veiksnus ir sutvarkius turimus jų duomenis, reikia įvertinti veiksnių tarpusavio ryšius. Pirmiausia, remiantis ekspertinėmis žiniomis, atliekamas kokybinis veiksnių tarpusavio sąveikos vertinimas (žr. 1 priedą). Kiekvieno veiksnio daromas poveikis kitam veiksmui vertinamas balais nuo 0 iki 3, kur 0 reiškia labai silpną arba neegzistuojantį poveikį, o 3 – stiprų, reikšmingą poveikį. Gautos matricos eilučių reikšmių suma atspindi veiksnio aktyvumą – tai yra jo daromą poveikį kitiems veiksnams, o stulpelių reikšmių suma nusako pasyvumą – tai yra, kiek stipriai nagrinėjamas veiksnys yra veikiamas kitų veiksnių. Aktyvumo suma ir pasyvumo suma leidžia veiksnus suskirstyti į 4 grupes: aktyvūs, kritiniai, reaguojantys ir pasyvūs veiksniai.

² Dujų kaina gauta iš licencijuotos gamtinių dujų Baltijos šalyse ir Suomijoje biržos operatorės *GET Baltic* internetinio puslapio – [Prekybos informacija - GET Baltic](#)


Remiantis pirmame priede pateiktais veiksnų tarpusavio sąveikos vertinimo rezultatais, sudaryta kryžminio poveikio matrica, kuri pateikta 7 pav.



7 pav. Išorinės verslo aplinkos veiksnų kryžminio poveikio matrica

Prognozuojama saulės ir vėjo elektrinių gamyba Lietuvoje (*WindLT*, *SolarLT*) ir dienos prieš rinkoje prognozuojamas elektros energijos suvartojimas Švedijos SE4 kainų zonoje (*LoadSE4*) yra aktyvūs veiksniai (aukštas aktyvumas ir žemas pasyvumas), kurie kitiems veiksniams daro žymiai didesnę įtaką, nei kiti veiksniai jiems. Dienos prieš rinkoje prognozuojamas elektros energijos suvartojimas ir gamyba Lietuvoje (*Load*, *Gen*), dienos prieš rinkoje prognozuojama elektros energijos gamyba Latvijoje ir Švedijos SE1, SE2, SE4 kainų zonose (*GenLV*, *GenSE1*, *GenSE2*, *GenSE4*) ir komerciniai tarpsisteminiai srautai tarp Švedijos SE4 kainų zonos ir Lietuvos (*SE4_LT*) – nustatyti kaip kritiniai veiksniai (aukštas aktyvumas ir pasyvumas), tai yra labai įtakingi, taip pat ir labai priklausomi veiksniai. Istorinės elektros energijos kainos Švedijos SE4 kainų zonoje (*PriceSE4*), dienos prieš rinkoje prognozuojama elektros energijos gamyba Švedijos SE3 kainų zonoje (*GenSE3*), komerciniai tarpsisteminiai srautai tarp Latvijos ir Lietuvos ir tarp Lenkijos ir Lietuvos (*PL_LT*, *LV_LT*) yra reaguojantys veiksniai (žemas aktyvumas ir aukštas pasyvumas) – tai veiksniai, kurie yra stipriau veikiami kitų veiksnų nei patys daro poveikį. Reaguojantys veiksniai dažnai priklauso nuo aktyviųjų. Likę veiksniai: dienos prieš rinkoje prognozuojamas elektros energijos suvartojimas Lenkijoje ir Latvijoje (*LoadPL*, *LoadLV*), istorinės elektros energijos kainos Lenkijoje (*PricePL*), dienos prieš rinkoje prognozuojama elektros energijos gamyba Suomijoje, Danijos DK1 ir DK2 kainų zonose, Estijoje ir Lenkijoje (*GenFI*, *GenDK1*, *GenDK2*, *GenEE*, *GenPL*) ir dujų kaina Lietuvoje (*GasPrice*) – buferiniai – pasižymi silpnu poveikiu kitiems veiksniams ir taip pat yra mažai priklausomi nuo kitų įtakos. Tačiau daugelis buferinių veiksnų yra arti aktyviųjų arba reaguojančių veiksnų ribos, todėl bus reikalinga tolimesnė išorinės verslo aplinkos veiksnų analizė. Elektros energijos kaina Lietuvoje buvo priskirta prie kritinių veiksnų.

Vykdam tyrimą, toliau atliekama koreliacinė analizė. Išorinės verslo aplinkos veiksnių koreliacinė analizė naudojama nustatyti kintamųjų tarpusavio priklausomybę – multikolinearumą. Išorinės verslo aplinkos veiksnių Spearmano koreliacijos rezultatas pateikiamas 8 pav.



8 pav. Išorinės verslo aplinkos veiksnių Spearmano koreliacijos koeficientų matrica

Stipriausios veiksnių tarpusavio koreliacijos, kai Spearmano koreliacijos koeficientas modulių lygus 0,7 ir daugiau, yra tarp skirtingose šalyse pagaminamos elektros energijos kiekio, taip pat ir tarp skirtingose šalyse suvartojamos elektros energijos kiekio. Šios stiprios koreliacijos yra tikėtinos ir pagrįstos bendrais ekonominiais, klimato, politikos ir rinkos veiksniais. Stiprūs ryšiai tarp kintamųjų atspindi šiuolaikinės energetikos ir Šiaurės Europos regiono rinkos sąveikos principus. Elektros energijos gamybos apimtys atskleidžia ekonomikos svyravimus, kurie regiono mastu dažnai yra panašūs. Taip pat Šiaurės Europos rinkoje elektros energijos poreikis pramonės ar paslaugų sektoriuose yra panašus dėl vyraujančio sezoniškumo ir oro sąlygų. Dėl šių priežasčių skirtingose šalyse stebimi panašūs elektros energijos gamybos ir suvartojimo modeliai. Be to, šalis jungia inžinerinės infrastruktūros, tokios kaip elektros energijos perdavimo linijos ar dvišaliai kontraktai. Šie fiziniai ir teisiniai išsipareigojimai kuria šalių tarpusavio priklausomybės ryšius, lemiančius sinchronizuotą elektros tinklų valdymą. Daugelis 8 pav. matomų korelacių yra statistiškai reikšmingos, nes testo p reikšmė mažesnė už 0,05 (žr. 2 priedą). Šios koreliacijos taip pat gali būti interpretuojamos kaip įrodymas, kad energetikos sektorius ir elektros energijos kaina

šalyje vis labiau priklauso nuo globalių ekonominių, klimato, politikos ir rinkos procesų, o ne nuo lokalių nacionalinės reikšmės veiksnių.

Grangerio priežastingumo analizė atliekama, siekiant nustatyti, kurie iš 5 lentelėje pateiktų veiksnių daro įtaką elektros energijos kainai Lietuvoje. Grangerio priežastingumo analizės rezultatai pateikiami 6 lentelėje.

6 lentelė. Grangerio priežastingumo analizės rezultatas

Veiksnių pora	Vėlavimas	F-testo p reikšmė
$Price \leftrightarrow PriceSE4$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow PricePL$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow Load$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow LoadPL$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow Gen$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow GenSE1$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow GenSE2$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow GenSE4$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow GenFI$	23	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow GenDK1$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow GenEE$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow GenPL$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow SolarLT$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow d_LoadSE4$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow d_LoadLV$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow d_GenLV$	24	$2,2 \cdot 10^{-16}$
$Price \leftrightarrow GenSE3$	24	$8,21 \cdot 10^{-15}$
$Price \leftrightarrow GenDK2$	24	$5,382 \cdot 10^{-12}$
$Price \leftrightarrow PL_LT$	23	$1,25 \cdot 10^{-11}$
$Price \leftrightarrow WindLT$	24	$9,806 \cdot 10^{-8}$
$Price \leftrightarrow LV_LT$	23	$6,55 \cdot 10^{-6}$
$Price \leftarrow GasPrice$	23	0,0015
$Price \leftrightarrow SE4_LT$	23	0,013

Atlikus Grangerio priežastingumo analizę, nustatyta, kad Lietuvos elektros energijos kaina *Price* yra reikšmingai susijusi su daugybe kitų energetinių ir ekonominių veiksnių. Dauguma ryšių yra dvipusiai, t. y. tiek kintamasis daro įtaką elektros energijos kainai, tiek ir elektros energijos kaina daro įtaką kintamajam. Lietuvos elektros energijos kainos ryšiai su Švedijos SE4 zonos ir Lenkijos elektros energijos kainomis ($Price \leftrightarrow PriceSE4$ ir $Price \leftrightarrow PricePL$) gali būti pagrįsti tiesioginėmis fizinėmis jungtimis tarp šalių ir bendrų išorinių veiksnių veikimu Baltijos jūros regione ir ne tik. Pavyzdžiui, dalyvavimas toje pačioje *Nord Pool* biržoje, kurioje naudojamas vieningas kainų formavimo algoritmas *Euphemia*. Taip pat Europos žaliasis kursas nustato visoms Europos Sąjungos šalims tą patį dekarbonizacijos tikslą. Siekiant šio tikslo, atsisakoma elektros energijos gamybos iš iškastinio kuro, o dėl to didėja kainų koreliaciją regione. Taip pat vienoda CO_2 kreditų

kaina visame regione automatiškai sinchronizuoja elektros kainų pokyčius. Tiesa Lenkijoje, kur kaip energetinė žaliava dominuoja akmens anglis, CO_2 kreditų kainos įtaka stipresnė nei aukštą atsinaujinančių šaltinių procentą turinčioje Švedijoje.


Priežastinis ryšys $Price \leftrightarrow Load$ rodo, kad prognozuojama elektros energijos paklausa Lietuvoje turi tiesioginį poveikį Lietuvos elektros energijos kainai – augant vartojimui, didėja spaudimas tiekimo sistemai, o tai lemia kainos kilimą. Taip pat aukštesnės elektros energijos kainos gali skatinti vartotojų elgsenos pokyčius tokius kaip vartojimo mažinimas ar efektyvesnis energijos naudojimas. Prognozuojama elektros energijos paklausa kaimyninėse šalyse taip pat daro įtaką Lietuvos elektros energijos kainai ($Price \leftrightarrow Load_{PL}$, $Price \leftrightarrow d_Load_{SE4}$, $Price \leftrightarrow d_Load_{LV}$) ir atvirkščiai. Didėjant paklausai kaimyninėse šalyse, daugiau pagaminamos elektros energijos skiriama vidaus poreikiams, o tai riboja eksporto galimybes į Lietuvą ir gali sukelti kainų augimą.

Prognozuojamas bendras elektros gamybos lygis Lietuvoje ir kitose šalyse (Švedijoje, Suomijoje, Danijoje, Estijoje, Latvijoje, Lenkijoje) daro įtaką elektros energijos kainai Lietuvoje. Pavyzdžiui, Švedijoje dominuoja hidroelektrinių ir branduolinė energija, Danijoje – vėjo elektrinių gamyba, Latvijoje pavasariais suintensyvėja hidroenergijos gamyba, o žiemą dominuoja šiluminių elektrinių gamyba. Estijoje išgaunami skalūnai užtikrina didžiąją dalį šalyje pagaminamos elektros energijos, o Lenkijoje – akmens anglis. Taigi, didėjant elektros energijos gamybai (ypač kai pasiūla viršija paklausą), kainos rinkoje linkusios mažėti. Taip pat kylančios kainos skatina gamybos įmones gaminti elektros energiją ir gauti didesnes pajamas, bet padidėjusi gamyba ir sumažėjusi paklausa lemia mažėjančias kainas. Aukštų kainų laikotarpiais operatoriai stengiasi maksimizuoti įrenginių prieinamumą ir atidėti planinę priežiūrą. Atskirai nagrinėta prognozuojama saulės ir vėjo energijos gamyba Lietuvoje. Šie atsinaujinantys šaltiniai dėl savo nepastovios gamybos veikia elektros energijos pasiūlos pusę, pavyzdžiui, saulėtą ir vėjuotą dieną elektros pasiūla gali smarkiai išaugti, mažindama rinkos kainą ar net formuodama neigiamas elektros energijos kainas.

Komercinių tarpsisteminių srautų ir elektros energijos kainos Lietuvoje ($Price \leftrightarrow PL_LT$, $Price \leftrightarrow LV_LT$, $Price \leftrightarrow SE4_LT$) priežastiniai ryšiai yra ypač svarbūs. Tarpsisteminiai srautai yra didžiausias apribojimas, kuris formuoja elektros energijos kainas. Elektros energijos srautų kryptis tarp šalių paprastai priklauso nuo kainų skirtumo – energija teka iš pigesnės kainų zonos į brangesnę. Lietuvos–Lenkijos elektros tinklų jungtis *LitPol Link* (500 MW galios) dar 2016 m. atvėrė Lietuvai galimybę veikti su kitų Vakarų Europos valstybių energetikos sistemomis ir leidžia plėtoti bendrą Europos elektros energijos rinką. 2024 metais pasirašyta bendradarbiavimo sutartis dėl dar vienos Lietuvos ir Lenkijos jungties vystymo – *Harmony Link* sausumos elektros perdavimo jungties. *Harmony Link* jungtis integruos Lietuvos elektros sistemą į kontinentinės Europos tinklus, sudarydama sąlygas veikti vieningu sinchroniniu režimu. Kita Lietuvai labai svarbi jungtis – jūrinis *NordBalt* kabelis (700 MW galios) su Švedija. Ši jungtis buvo būtina sąlyga norint kurti bendrą Baltijos valstybių ir Skandinavijos regiono elektros energijos rinką. Nuo 2016 metų veikianti *NordBalt* elektros jungtis suteikia Lietuvai galimybę importuoti elektros energiją iš Šiaurės Europos šalių, kurios pasižymi gausiais hidroenergetikos ištekliais ir pigesne elektros energijos kaina. Taip pat Lietuva, Latvija ir Vokietija planuoja teikti paraišką dėl 2 GW galios hibridinės jūrinės jungties tarp Baltijos šalių ir Vokietijos. Ši jungtis prisidėtų prie konkurencingų kainų Baltijos regione kūrimo, nes investuotojai į atsinaujinančią energetiką būtų užtikrinti dėl elektros energijos eksporto į Vokietiją galimybes.

Grangerio priežastingumo analizė parodė, kad dujų kaina Lietuvoje turi vienpusį priežastinį poveikį elektros kainai Lietuvoje ($Price \leftarrow GasPrice$), o atvirkštinis ryšys nėra reikšmingas. Šis rezultatas yra ekonomiškai pagrįstas ir atitinka energetikos rinkų veikimo logiką. Dujos yra vienas pagrindinių kuro šaltinių šiluminėse elektrinėse, todėl jų kainų pokyčiai tiesiogiai veikia elektros gamybos sąnaudas. Kylant gamtinių dujų kainai, padidėja elektros energijos gamybos savikaina. Šis priežastinis ryšys aktualus visoje Europoje, išgyvenančioje energetikos sektoriaus struktūrinius pokyčius. Reaguojant į geopolitinę situaciją ir žaliavų tiekimo saugumo klausimus, Europos Sąjunga išsikėlė strateginį tikslą iki 2027 metų visiškai atsisakyti gamtinių dujų importo iš Rusijos. Ši ambicija skatina valstybes nares spartinti energetinę transformaciją, didinant atsinaujinančių energijos šaltinių dalį ir diversifikuojant kuro tiekimo grandines. Dėl to visos regiono šalys susiduria su panašiais iššūkiais – aukštesnėmis importuojamų energijos išteklių kainomis, padidėjusiu rinkų nepastovumu bei būtinybe greitai prisitaikyti prie rinkos pokyčių.

9 pav. pateiktas Grangerio priežastingumo analizės rezultatų apibendrinimas, „gėlytės“ grafikas.



9 pav. Grangerio priežastingumo analizės „gėlytės“ grafikas

„Gėlytės“ grafikas leidžia vizualiai įvertinti svarbiausių veiksnių priežastinius ryšius su elektros energijos kaina. Remiantis literatūros šaltinių apžvalgos, makroaplinkos PESTLE analizės, kryžminio poveikio matricos, išorinių veiksnių koreliacijos analizės ir Grangerio priežastingumo analizės rezultatais, nuspręsta daugiamačio elektros energijos kainos prognozavimo modelio sudarymui naudoti visus dvidešimt tris 5 lentelėje pateiktus išorinės verslo aplinkos veiksnius.

3.3. Vienmatis ir daugiamatis elektros energijos kainos prognozavimo modeliai

Atlikus elektros energijos kainos tendencijų analizę, duomenų tvarkymą ir nustčius išorinės verslo aplinkos veiksnius, galima sudaryti vienmatį elektros energijos kainos prognozavimo modelį. Autokoreliacijos grafike (žr. 5 pav.) matyti, kad pirmieji trys vėlavimai yra reikšmingiausi, todėl jie naudojami vienmačio modelio sudarymui. Pirmiausiai sudaromas sezoninis naivusis 24 valandų prognozavimo modelis ir įvertinamas jo tikslumas prognozuojant 2025 m. vasario mėnesio kainas. Toliau sudaromas atsitiktinio miško modelis ir išbandomos visos 2.5 poskyryje nurodytų parametru


reikšmių įmanomos kombinacijos. Kiekvienam modeliui apskaičiuojamos tikslumo vertinimo metrikų (MAPE, MPE ir RMSE) minimalios, maksimalios, vidutinės reikšmės ir standartiniai nuokrypiai (žr. 3 priedą). Ši informacija leidžia įvertinti modelių prognozavimo kokybę ne tik vidutiniškai, bet ir atsižvelgiant į rezultatų sklaidą. Toliau analogiškai sudaromas atraminių vektorių regresijos modelis, *XGBoost*, *LightGBM* modeliai ir išbandomos jų parametrų reikšmių, kurios nurodytos 2.5 poskyryje, kombinacijos. Visų tirtų modelių prognozių tikslumo vertinimo metrikos pateikiamos atitinkamai 4, 5 ir 6 prieduose. 7 lentelėje pateikta kiekvieno modelio optimali parametrų kombinacija ir vidutinė absoliutinė procentinė paklaida, vidutinė procentinė paklaida ir šaknis iš vidutinės kvadratinės paklaidos.

7 lentelė. Geriausi vienmačiai prognozavimo modeliai ir jų tikslumo metrikos

Geriausia modelio parametrų kombinacija	Tikslumo metrika	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis
Sezoninis naivusis	MAPE, %	20,3	69,4	612	114
	MPE, %	–609	–23,6	86,2	130
	RMSE, EUR/MWh	29,6	71,9	178	31,7
Atsitiktinis miškas (<i>ntree</i> = 300, <i>mtry</i> = 2, <i>nodesize</i> = 5)	MAPE, %	0,01	0,05	0,52	0,1
	MPE, %	–0,03	0,03	0,51	0,1
	RMSE, EUR/MWh	0,01	0,42	5,95	1,17
Atraminių vektorių regresija (<i>epsilon</i> = 0,1, <i>cost</i> = 1, <i>kernel</i> = <i>radial</i>)	MAPE, %	1,73	4,31	15,90	2,56
	MPE, %	–5,18	–1,78	0,9	1,72
	RMSE, EUR/MWh	3,96	5,35	15,59	2,12
<i>XGBoost</i> (<i>eta</i> = 0,1, <i>max_depth</i> = 6, <i>subsample</i> = 0,9, <i>colsample_bytree</i> = 0,9)	MAPE, %	0,07	0,15	0,53	0,1
	MPE, %	–0,37	0,01	0,41	0,11
	RMSE, EUR/MWh	0,11	0,47	4,7	0,87
<i>LightGBM</i> (<i>learning_rate</i> = 0,05, <i>num_leaves</i> = 7, <i>feature_fraction</i> = 0,8, <i>bagging_fraction</i> = 0,8)	MAPE, %	0,22	0,54	1,25	0,29
	MPE, %	–0,14	0,15	0,96	0,24
	RMSE, EUR/MWh	0,32	1,93	10,67	2,56


Visi mašininio mokymosi modeliai aplenkė sezoninį naivųjį. Geriausias vienmatis prognozavimo modelis – atsitiktinis miškas, kai medžių skaičius miške lygus 300, atsitiktinai pasirenkamų vėlavimų skaičius mazgų skaidymui lygus 2, o lapuose minimalus stebėjimų skaičius lygus 5. Labai maža vidutinė absoliutinė procentinė paklaida (0,05 %) rodo, kad prognozės tikslumas yra labai aukštas. Net blogiausiu atveju paklaida neviršija 0,52 %. Mažas vidutinės absoliutinės procentinės paklaidos standartinis nuokrypis rodo, kad tikslumas gan stabilus visą prognozavimo laikotarpį. Vidutinė procentinė paklaida padeda vertinti ne tik paklaidos dydį, bet ir jos kryptį – šiuo atveju prognozės yra gana subalansuotos: elektros energijos kainos nėra nei pervertinamos, nei nuvertinamos. Šaknies iš vidutinės kvadratinės paklaidos maksimali reikšmė indikuoja galimus pavienius prognozės pikus. Tačiau net blogiausiu atveju gauta prognozė nuo tikrosios elektros energijos kainos vidutiniškai skiriasi tik 5,95 EUR už 1 MWh. Nedaug nuo geriausio atsitiktinio miško atsiliko *XGBoost* modelis.

Kelių dienų tikrosios ir geriausių vienmačių modelių prognozuotos elektros energijos kainos pateikiamos 10 pav.



10 pav. Tikroji ir vienmačių modelių prognozuota 2025-02-08–2025-02-11 elektros energijos kaina Lietuvoje

2025-02-08–2025-02-11 periodas pasirinktas dėl to, nes vasario 8 d. Lietuva atsijungė nuo BRELL žiedo, dirbo izoliuotu režimu, o vasario 9 d. įvyko sinchronizacija su kontinentine Europa. Beveik visas valandas, išskyrus dvi ar tris, atsitiktinio miško, *XGBoost* ir *LightGBM* modelių prognozių skirtumas nuo tikrųjų elektros kainų buvo nežymus. 11 pav. pateikiamas kiekvieno geriausio vienmačio modelio liekanų grafikas.



11 pav. Vienmačių prognozavimo modelių liekanų grafikas

Prognozuojamu laikotarpiu atramių vektorių modelis buvo linkęs pervertinti elektros energijos kainą. Taip pat vasario 11 dieną buvo dvi valandos (6:00 ir 18:00), kurių kainų nepavyko nei

vienam geriausiam modeliui pakankamai tiksliai išprognuoti. Be pastarųjų dviejų valandų buvo dar keturios, kurių kainas sekėsi sunkiau prognozuoti geriausiam vienmačiam modeliui – atsitiktiniam miškui. 12 pav. pateikiamos geriausių vienmačių atsitiktinio miško, atraminių vektorių regresijos, *XGBoost* ir *LightGBM* modelių vidutinės vienos dienos prognozės sudarymo trukmės.



12 pav. Vidutinė 24 valandų vienmatės prognozės sudarymo trukmė

Nors atsitiktinio miško modelio apmokymas užtruko gerokai ilgiau nei kitų analizuotų metodų, 24 valandų trukmės prognozė buvo sugeneruota per mažiau nei 20 sekundžių. Toks skaičiavimo laikas yra pakankamai trumpas ir praktiškai priimtinas operatyviai prognozei generuoti.


Daugiamačio 24 valandų prognozavimo modelio sudarymo atveju viskas analogiškai kartojama kaip ir vienmačio modelio atveju tik skirtumas tas, kad dabar nebesudaromas sezoninis naivusis metodas ir be istorinių Lietuvos elektros energijos kainų naudojami papildomi kintamieji, aptarti 3.2 poskyryje. 7, 8, 9 ir 10 prieduose atitinkamai pateiktos visos išbandytos atsitiktinio miško, atraminių vektorių regresijos, *XGBoost* ir *LightGBM* daugiamačių modelių parametrų reikšmių kombinacijos ir gautos tikslumo metrikos. 8 lentelėje išrinktos ir pateiktos kiekvieno daugiamačio modelio optimalios parametrų kombinacijos, užtikrinusios didžiausią prognozavimo tikslumą.

8 lentelė. Geriausi daugiamačiai prognozavimo modeliai

Geriausia modelio parametrų kombinacija	Tikslumo metrika	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis
Atsitiktinis miškas (<i>ntree</i> = 200, <i>mtry</i> = 7, <i>nodesize</i> = 5)	MAPE, %	6,21	30,56	273,71	48,51
	MPE, %	–266,98	–3,63	29,92	52,76
	RMSE, EUR/MWh	13,66	41,12	91,78	21,15
Atraminių vektorių regresija (<i>epsilon</i> = 0,1, <i>cost</i> = 10, <i>kernel</i> = <i>radial</i>)	MAPE, %	7,09	31,31	272,36	47,83
	MPE, %	–262,08	–4,47	25,64	51,78
	RMSE, EUR/MWh	14,89	40,44	77,27	16,78
<i>XGBoost</i> (<i>eta</i> = 0,05, <i>max_depth</i> = 6, <i>subsample</i> = 0,8, <i>colsample_bytree</i> = 0,8)	MAPE, %	7,27	28,12	210,31	36,68
	MPE, %	–187,61	0,22	24,72	38,4
	RMSE, EUR/MWh	13,95	41,04	75,56	19,87
<i>LightGBM</i> (<i>learning_rate</i> = 0,1, <i>num_leaves</i> = 13, <i>feature_fraction</i> = 0,7, <i>bagging_fraction</i> = 0,8)	MAPE, %	7,14	32,67	270,31	48,26
	MPE, %	–259,48	–5,15	22,88	51,83
	RMSE, EUR/MWh	14,14	41,25	73,45	18,48


Ir šiuo atveju visi modeliai aplenkė vienmatį sezoninį naivųjį modelį. Geriausias daugiamačis prognozavimo modelis – *XGBoost*, kai mokymosi žingsnis, reguliuojantis kiekvieno naujo medžio įtaką galutinei prognozei, lygus 0,05, maksimalus medžio gylis lygus 6, atsitiktinai pasirenkama duomenų dalis, naudojama kiekvieno medžio apmokymui, lygi 0,8, o atsitiktinai pasirenkama

kintamųjų dalis – 0,8. Deja, daugiamačių modelių atveju paklaidos yra žymiai didesnės, lyginant su vienmačiais modeliais. Nei vienam daugiamačiam modeliui nepavyko aplenkti geriausio vienmačio atsitiktinio miško. 13 pav. pateikiamos to pačio 2025-02-08–2025-02-11 periodo tikrosios ir geriausių daugiamačių modelių suprognuozuotos elektros energijos kainos.




13 pav. Tikroji ir daugiamačių modelių prognozuota 2025-02-08–2025-02-11 elektros energijos kaina Lietuvoje

Šiuo atveju gautų prognozių kreivės yra labiau nutolusios nuo tikrosios kainų dinamikos – gautų prognozių reikšmės pasižymi didesniu išsibarstymu ir nuokrypiu nuo faktinių kainų. Nors visi taikyti daugiamačiai modeliai gebėjo atkurti bendrą kainų tendenciją, nė vienam iš jų nepavyko tiksliai prognozuoti didelių kainų svyravimų. 14 pav. pateiktas daugiamačių prognozavimo modelių liekanų grafikas.



14 pav. Daugiamačių prognozavimo modelių liekanų grafikas

Visi daugiamačiai modeliai buvo linkę prognozuoti mažesnę elektros energijos kainą nei buvo iš tikrųjų. Tam tikromis valandomis skirtumas tarp tikrosios ir prognozuotos elektros energijos kainos buvo lygus apie 200 EUR už 1 MWh – tai labai prastas rezultatas. 15 pav. pateikiama vidutinė geriausių daugiamačių modelių prognozės sudarymo trukmė.



15 pav. Vidutinė 24 valandų daugiamatės prognozės sudarymo trukmė

Daugiamačio modelio atveju atraminių vektorių regresija ir atsitiktinis miškas užtruko žymiai ilgiau nei atitinkamas vienmatis modelis. Pailgėjusią trukmę lemia didelis skaičius į modelį įtrauktų išorinių kintamųjų. Visgi ir dabar trukmė nėra per ilga ir vis dar išlieka priimtina 24 valandų prognozei generuoti. Geriausias daugiamatis prognozavimo modelis – *XGBoost* – užtruko taip pat trumpai kaip ir vienmačio modelio atveju – iki 1 s. Tyrimo metu buvo patvirtinta literatūros šaltiniuose rasta išvada, kad *XGBoost* ir *LightGBM* metodai veikia greičiau nei tradiciniai mašininio mokymosi metodai, tokie kaip atsitiktiniai miškai.

Grįžtant prie tyrimo metu gauto geriausio prognozavimo modelio – vienmačio atsitiktinio miško, reikia patikrinti šio modelio liekanų prielaidas. Pirmiausiai nustatyta, kad vienmačio atsitiktinio miško liekanos statistiškai reikšmingai skiriasi nuo normaliojo skirstinio, nes *Shapiro-Wilk* testo p reikšmė mažesnė už 0.05. Šio fakto nereikėtų labai sureikšminti, nes realaus pasaulio duomenys labai retai būna pasiskirstę pagal normalųjį skirstinį. Toliau tikrinama modelio liekanų autokoreliacija: *Ljung-Box* testo p reikšmė lygi 0,9945. Iš to seka, kad modelio liekanos nėra autokoreliuotos – tai viena esminių laiko eilučių prognozavimo kokybės sąlygų. Kadangi liekanos pasiskirsčiusios nepriklausomai, galima teigti, kad vienmatis atsitiktinis miškas yra tinkamas, patikimas ir efektyvus elektros energijos kainos Lietuvoje prognozavimo modelis.

Išvados

1. Elektros energetikos sektorius yra vienas svarbiausių nacionalinės ekonomikos elementų, kuris veikia šalies ekonominį augimą, energetinį saugumą. Pastaraisiais dešimtmečiais elektros energetikos sektorius patiria reikšmingų pokyčių – dereguluota rinka, konkurencija, populiarėjantys atsinaujinantys energijos šaltiniai. Lietuvoje elektros energijos kaina pasižymi dideliu nepastovumu. Užfiksuotos ir neigiamos elektros energijos kainos. Vidutinė elektros energijos kaina Lietuvoje nuo 2024-01-01 iki 2025-02-28 lygi 91,78 EUR už 1 MWh. Šiuo laikotarpiu kaina svyravo nuo –19,96 EUR už 1 MWh iki 1428,91 EUR už 1 MWh.
2. Lietuvos elektros energijos kainai įtaką daro šie kintamieji: istorinės elektros energijos kainos Švedijos SE4 kainų zonoje, Lenkijoje ir Lietuvoje; dienos prieš rinkoje prognozuojamas elektros energijos suvartojimas Lietuvoje, Švedijos SE4 kainų zonoje, Latvijoje, Lenkijoje; dienos prieš rinkoje prognozuojama elektros energijos gamyba Lietuvoje, Švedijos SE1, SE2, SE3, SE4 kainų zonose, Suomijoje, Danijos DK1, DK2 kainų zonose, Latvijoje, Estijoje, Lenkijoje; prognozuojama saulės elektrinių gamyba Lietuvoje; prognozuojama vėjo elektrinių gamyba Lietuvoje; komerciniai tarp sisteminiai srautai tarp Švedijos SE4 kainų zonos ir Lietuvos, tarp Latvijos ir Lietuvos, tarp Lenkijos ir Lietuvos; dujų kaina Lietuvoje.
3. Elektros energijos kainos kitimui paroje nustatyti buvo sudarytas bazinis vienmatis sezoninis naivusis prognozavimo modelis. Taip pat sudaryti vienmatis bei daugiamatis atraminių vektorių regresijos modeliai; Lietuvos elektros energijos kainos prognozavimui iki šiol nenaudoti vienmatis ir daugiamatis atsitiktinių miškų, *XGBoost* ir *LightGBM* modeliai. Tyrime buvo naudojamos šios atsitiktinio miško parametrų reikšmės: medžių skaičius – 200, 300 ir 350; mazgo skaidymui atsitiktinai pasirenkamų kintamųjų skaičius – 1, 2, 3 (vienmačiu atveju) ir 5, 7, 9 (daugiamačiu atveju); minimalus stebėjimų skaičius lapuose – 5 ir 10. Atraminių vektorių regresijos modeliams buvo pritaikyti radialinis ir polinominis branduoliai. Analizuoti trys jautrumo zonos parametrai – 0,01, 0,05 ir 0,1 – bei du baudos koeficiento dydžiai – 1 ir 10. *XGBoost* algoritmui buvo taikomos šios hiperparametrų reikšmės: mokymosi žingsnis – 0,01, 0,05 ir 0,1; maksimalus medžių gylis – 4 ir 6; medžio apmokymui naudojama duomenų dalis – 0,8 ir 0,9; medžio sudarymui pasirenkama kintamųjų dalis – 0,8 ir 0,9. *LightGBM* algoritmui buvo pasirinktos šios reikšmės: mokymosi žingsnis – 0,01, 0,05 ir 0,1; maksimalus lapų skaičius – 7 ir 13; medžio sudarymui pasirenkama kintamųjų dalis – 0,8 ir 0,9; medžio apmokymui naudojama duomenų dalis – 0,8 ir 0,9.
4. Geriausias vienmatis prognozavimo modelis – atsitiktinis miškas, kai medžių skaičius miške lygus 300, atsitiktinai pasirenkamų vėlavimų skaičius mazgų skaidymui lygus 2, o lapuose minimalus stebėjimų skaičius lygus 5. Šio modelio vidutinė absoliutinė procentinė paklaida lygi 0,05 %. Geriausias daugiamatis prognozavimo modelis – *XGBoost*, kai mokymosi žingsnis, reguliuojantis kiekvieno naujo medžio įtaką galutinei prognozei, lygus 0,05, maksimalus medžio gylis lygus 6, atsitiktinai pasirenkama duomenų dalis, naudojama kiekvieno medžio apmokymui, lygi 0,8, o atsitiktinai pasirenkama kintamųjų dalis – 0,8. Geriausias daugiamatis prognozavimo modelis neaplenkė vienmačio modelio. *XGBoost* modelio vidutinė absoliutinė procentinė paklaida lygi 28,12 %.

Ateityje gautą geriausio vienmačio atsitiktinio miško modelį, reikėtų pritaikyti 15 minučių elektros energijos prekybai *Nord Pool* biržoje, kuri Lietuvos rinkai prasidės nuo 2025 m. birželio mėn. Taip pat reikėtų dar daugiau dėmesio skirti išorinės verslo aplinkos veiksnių analizei, papildomai įtraukiant energijos kaupimo akumuliatorius (baterijas).

Literatūros sąrašas

1. ZWEIFEL, Peter; PRAKTIKNJO, Aaron ir ERDMANN, Georg. *Energy Economics - Theory and Applications*. 2017. Prieiga per: https://www.researchgate.net/publication/315526769_Energy_Economics_-_Theory_and_Applications. [žiūrėta 2024-05-12].
2. Acaroğlu Hakan; García Márquez ir Fausto Pedro. Comprehensive Review on Electricity Market Price and Load Forecasting Based on Wind Energy. *Energies*, vol. 14 (2021), nr. 22, pp. 7473. Prieiga per: <https://www.mdpi.com/1996-1073/14/22/7473>. [žiūrėta 2025-04-09].
3. IEA. *World Energy Outlook 2024*. [2024-10-16]. Prieiga per: <https://www.iea.org/reports/world-energy-outlook-2024>. [žiūrėta 2025-04-09].
4. IEA. *World Energy Outlook 2023*. [2023-10-24]. Prieiga per: <https://www.iea.org/reports/world-energy-outlook-2023>. [žiūrėta 2025-04-09].
5. *Sektoriaus Veikla*. [2023-11-28]. Prieiga per: <https://enmin.lrv.lt/lt/veiklos-sritys-3/elektra/sektorius-veikla-3/>. [žiūrėta 2024-05-14].
6. ČESNAVIČIUS, Mindaugas. Lithuanian electricity market price forecasting model based on univariate time series analysis. *Energetika (Vilnius, Lithuania)*, vol. 66 (2020), nr. 1. Prieiga per: <https://www.lituanistika.lt/content/101181> [žiūrėta 2025-04-09].
7. *About Us*. Prieiga per: <https://www.nordpoolgroup.com/en/About-us/>. [žiūrėta 2024-05-14].
8. *Elektros Energijos Rinka*. [2023-11-28]. Prieiga per: <https://enmin.lrv.lt/lt/veiklos-sritys-3/elektra/elektros-energijos-rinka/>. [žiūrėta 2024-05-14].
9. *Day-Ahead Market*. Prieiga per: <https://www.nordpoolgroup.com/en/the-power-market/Day-ahead-market/>. [žiūrėta 2024-05-14].
10. BOROWSKI, Piotr F. Zonal and Nodal Models of Energy Market in European Union. *Energies (Basel)*, vol. 13 (2020), nr. 16, pp. 4182. Prieiga per: <https://search.proquest.com/docview/2434631410>. [žiūrėta 2025-04-09].
11. *Intraday Market*. Prieiga per: <https://www.nordpoolgroup.com/en/the-power-market/Intraday-market/>. [žiūrėta 2024-05-14].
12. GERMESHAUSEN, Robert ir WÖLFING, Nikolas. How marginal is lignite? Two simple approaches to determine price-setting technologies in power markets. *Energy Policy*, vol. 142 (2020), pp. 111482. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S0301421520302305>. [žiūrėta 2025-05-17].
13. VAN LEEUWEN, Charlotte ir MULDER, Machiel. Power-to-gas in electricity markets dominated by renewables. *Applied Energy*, vol. 232 (2018), pp. 258–272. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S0306261918315319>. [žiūrėta 2025-05-18].
14. Nord Pool. *Block Order*. Prieiga per: <https://www.nordpoolgroup.com/en/trading/day-ahead-trading/order-types/block-bid>. [žiūrėta 2025-05-16].

15. BIBER, Albert; FELDER, Mine; WIELAND, Christoph ir SPLIETHOFF, Hartmut. Negative price spiral caused by renewables? Electricity price prediction on the German market for 2030. *The Electricity Journal*, vol. 35 (2022), nr. 8, pp. 107188. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S1040619022001142>. [žiūrėta 2025-05-18].
16. AUST, Benjamin ir HORSCH, Andreas. Negative market prices on power exchanges: Evidence and policy implications from Germany. *The Electricity Journal*, vol. 33 (2020), nr. 3, pp. 106716. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S1040619020300087>. [žiūrėta 2025-05-18].
17. POMBO-ROMERO, Julio; RÚAS-BARROSA, Oliver ir VÁZQUEZ, Carlos. Assessing the value and risk of renewable PPAs. *Energy Economics*, vol. 139 (2024), pp. 107861. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S0140988324005693>. [žiūrėta 2025-05-17].
18. BHATTACHARYYA, Subhes C. *Energy economics*. 2nd ed. London: Springer, 2019. Prieiga per: <https://link.springer.com/book/10.1007/978-1-4471-7468-4>. [žiūrėta 2024-05-14].
19. . Elektros kainų tarifai (2023). Prieiga per: <https://enmin.lrv.lt/lt/veiklos-sritys-3/elektra/elektros-kainu-tarifai/>. [žiūrėta 2024-05-14].
20. NITSCH, Felix; SCHIMECZEK, Christoph ir BERTSCH, Valentin. Applying machine learning to electricity price forecasting in simulated energy market scenarios. *Energy Reports*, vol. 12 (2024), pp. 5268–5279. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S2352484724007327>. [žiūrėta 2025-04-28].
21. BELENGUER, E.; SEGARRA-TAMARIT, J.; PÉREZ, E. ir VIDAL-ALBALATE, R. Short-term electricity price forecasting through demand and renewable generation prediction. *Mathematics and Computers in Simulation*, vol. 229 (2025), pp. 350–361. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S0378475424003938>. [žiūrėta 2025-04-09].
22. Orhan Altuğ Karabiber ir George Xydis. Electricity Price Forecasting in the Danish Day-Ahead Market Using the TBATS, ANN and ARIMA Methods (2019). Prieiga per: https://www.researchgate.net/publication/331677145_Electricity_Price_Forecasting_in_the_Danish_Day-Ahead_Market_Using_the_TBATS_ANN_and_ARIMA_Methods. [žiūrėta 2025-04-27].
23. TSCHORA, Léonard; PIERRE, Erwan; PLANTEVIT, Marc ir ROBARDET, Céline. Electricity price forecasting on the day-ahead market using machine learning. *Applied Energy*, vol. 313 (2022), pp. 118752. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S0306261922002057>. [žiūrėta 2025-04-28].
24. He Jiang, Yawei Dong, Yao Dong, Jianzhou Wang. Probabilistic electricity price forecasting by integrating interpretable model (2025). Prieiga per: <https://www.sciencedirect.com/science/article/abs/pii/S0040162524006449>. [žiūrėta 2025-04-09].
25. Ilyas Agakishiev, Wolfgang Karl Härdle, Milos Kopa, Karel Kozmik, Alla Petukhina. Multivariate probabilistic forecasting of electricity prices with trading applications (2025). Prieiga per: <https://www.sciencedirect.com/science/article/pii/S0140988324007163>. [žiūrėta 2025-04-09].
26. HAOLIN YANG, Kristen R. Schell. ATTnet: An explainable gated recurrent unit neural network for high frequency electricity price forecasting (2024). Prieiga per: <https://www.sciencedirect.com/science/article/pii/S0142061524001960>. [žiūrėta 2025-04-09].

27. BEHDAD EHSANI, Pierre-Olivier Pineau, Laurent Charlin. Price forecasting in the Ontario electricity market via TriConvGRU hybrid model: Univariate vs. multivariate frameworks (2024). Prieiga per: <https://www.sciencedirect.com/science/article/abs/pii/S0306261924000321>. [žiūrėta 2025-04-09].
28. BEIGAITĖ, Rita. Elektros energijos kainų prognozavimas (2018). Prieiga per: <https://hdl.handle.net/20.500.12259/36430>. [žiūrėta 2025-04-29].
29. BRINDZA, Rimantas. *Veiksnių, darančių įtaką Lietuvos elektros energijos kainai, tyrimas* /, 2019. Prieiga per: <https://epubl.ktu.edu/object/elaba:36885019/>. [žiūrėta 2025-04-29].
30. RAKŠTYTĖ, Aušra. *Laiko eilučių ir kvantilių regresijos modeliai elektros kainoms*, 2020. Prieiga per: <https://epublications.vu.lt/object/elaba:81591480/>. [žiūrėta 2025-04-29].
31. BLAŽYS, Paulius. *Elektros kainų įtakos elektros gamintojų elgsenai analizė* /, 2021. Prieiga per: <https://epublications.vu.lt/object/elaba:193199960/index.html>. [žiūrėta 2025-04-29].
32. JONAITIS, Martynas. *Paslėptųjų Markovo grandinių taikymas elektros kainų prognozei*, 2021. Prieiga per: <https://epubl.ktu.edu/object/elaba:96883801/>. [žiūrėta 2025-04-29].
33. KVIETKAUSKAITE, Greta. *Electricity price forecasting in lithuania* /, 2021. Prieiga per: <https://epublications.vu.lt/object/elaba:81590503/>. [žiūrėta 2025-04-29].
34. BEIGAITE, Rita; KRILAVIČIUS, Tomas ir MAN, Ka L. Electricity Price Forecasting for Nord Pool Data. 2018-01. Prieiga per: <https://ieeexplore.ieee.org/document/8472762>. [žiūrėta 2025-04-29].
35. BEIGAITĖ, Rita ir KRILAVIČIUS, Tomas. Electricity price forecasting for Nord Pool data using recurrent neural networks. *CEUR Workshop proceedings [electronic resource]: IVUS 2018, International conference on information technologies, Kaunas, Lithuania, 27 April, 2018. Aachen : CEUR-WS, 2018, Vol. 2145* (2018). Prieiga per: <http://ceur-ws.org/Vol-2145/p12.pdf>. [žiūrėta 2025-04-29].
36. TAT, Andrejus Ngugen. Electricity Price Forecasting Using Monte Carlo Simulation: The Case of Lithuania. *Ekonomika*, vol. 97 (2018), nr. 1, pp. 76–86. Prieiga per: <https://www.journals.vu.lt/ekonomika/article/view/11696>. [žiūrėta 2025-04-29].
37. ČESNAVIČIUS, Mindaugas ir KONSTANTINAVIČIŪTĖ, Inga. Statistical approach to evaluate power generation sources influence on electricity market price: Lithuania case *In: Transformations in business & economics*, pp. 316–331 Anonymous , 2023. Prieiga per: <https://www.lituanistika.lt/content/111360>. [žiūrėta 2025-04-29].
38. Vladimir S. ir Koritarov. Real-world market representation with agents (2004). Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/1310872>. [žiūrėta 2025-04-09].
39. Christoph Fraunholza, Emil Krafta, Dogan Kelesa, Wolf Fichtnera. Advanced price forecasting in agent-base delectricity market simulation (2021). Prieiga per: <https://www.sciencedirect.com/science/article/abs/pii/S0306261921002142>. [žiūrėta 2025-04-09].
40. Carla Gonçalves; Miguel Ribeiro; João Viana; Renato Fernandes; José Villar ir kt. Explanatory and Causal Analysis of the MIBEL Electricity Market Spot Price (2019). Prieiga per: <https://ieeexplore-ieee-org.ezproxy.ktu.edu/document/8810763>. [žiūrėta 2025-04-09].

41. Tiago Pinto, Tiago M. Sousa, Isabel Praça, Zita Vale, Hugo Morais. Support Vector Machines for decision support in electricity markets' strategic bidding (2016). Prieiga per: <https://www.sciencedirect.com/science/article/abs/pii/S0925231215010553>. [žiūrėta 2025-04-09].
42. FELIX NITSCH, ir Christoph Schimeczek. Electricity price forecasts in agent-based energy system simulations (2020). Prieiga per: https://www.researchgate.net/publication/346648311_Electricity_price_forecasts_in_agent-based_energy_system_simulations. [žiūrėta 2025-04-09].
43. CARMONA, René ir COULON, Michael. A Survey of Commodity Markets and Structural Models for Electricity PricesIn: *Quantitative Energy Finance: Modeling, Pricing, and Hedging in Energy and Commodity Markets*, pp. 41–83Fred Espen Benth; Valery A. Kholodnyi ir Peter Laurence (eds.). New York, NY: Springer, 2014. Prieiga per: https://doi.org/10.1007/978-1-4614-7248-3_2. [žiūrėta 2025-04-10].
44. Jesus Lago, Fjo De Ridder, Peter Vrancx, Bart De Schutter. Forecasting day-ahead electricity prices in Europe: The importance of considering market integration (2018). Prieiga per: <https://www.sciencedirect.com/science/article/pii/S0306261917316999>. [žiūrėta 2025-04-09].
45. VITOR CERQUEIRA, Luis Torgo, Carlos Soares. Machine Learning vs Statistical Methods for Time Series Forecasting: Size Matters (2019). Prieiga per: <https://arxiv.org/abs/1909.13316>. [žiūrėta 2025-04-09].
46. Fabian Corrêa Cardoso, Rafael Alceste Berri, Eduardo Nunes Borges, BRUNO LOPES DALMAZO, ir Giancarlo Lucca, Viviane Leite Dias de Mattos. Echo state network and classical statistical techniques for time series forecasting: A review (2024). Prieiga per: <https://www.sciencedirect.com/science/article/abs/pii/S0950705124002740>. [žiūrėta 2025-04-09].
47. Aurora Poggi, Luca Di Persio, Matthias Ehrhardt. Electricity Price Forecasting via Statistical and Deep Learning Approaches: The German Case (2023). Prieiga per: <https://www.mdpi.com/2673-9909/3/2/18>. [žiūrėta 2025-04-09].
48. Antonio Rafael Sabino Parmezan, Vinicius M.A. Souza, Gustavo E.A.P.A. Batista. Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model (2019). Prieiga per: <https://www.sciencedirect.com/science/article/abs/pii/S0020025519300945>. [žiūrėta 2025-04-09].
49. Qiyun Dang; Di Wu ir Benoit Boulet. EV Charging Management with ANN-Based Electricity Price Forecasting (2020). Prieiga per: <https://ieeexplore.ieee.org/document/9161659>. [žiūrėta 2025-04-09].
50. O'LEARY, Christian; LYNCH, Conor; BAIN, Rose; SMITH, Gary ir GRIMES, Diarmuid. A Comparison of Deep Learning Vs Traditional Machine Learning for Electricity Price Forecasting. , pp. 6–12.2021-03. Prieiga per: <https://ieeexplore.ieee.org/document/9476947>. [žiūrėta 2025-04-28].
51. Bhupesh Kumar Mishra, Vjosa Preniqi, Dhavalkumar Thakker & Erich Feigl. Machine learning and deep learning prediction models for time-series: a comparative analytical study for the use case of the UK short-term electricity price prediction (2024). Prieiga per: <https://link.springer.com/article/10.1007/s43926-024-00075-4>. [žiūrėta 2025-04-09].

52. ELIANA VIVAS, Héctor Allende-Cid, Rodrigo Salas. A Systematic Review of Statistical and Machine Learning Methods for Electrical Power Forecasting with Reported MAPE Score (2020). Prieiga per: <https://www.mdpi.com/1099-4300/22/12/1412>. [žiūrėta 2025-04-09].
53. GAURAV KAPOOR, Nuttanan Wichitaksorn. Electricity price forecasting in New Zealand: A comparative analysis of statistical and machine learning models with feature selection (2023). Prieiga per: <https://www.sciencedirect.com/science/article/pii/S0306261923008103>. [žiūrėta 2025-04-09].
54. ZIHAN CHANG, Yang Zhang, Wenbo Chen. Electricity price prediction based on hybrid model of adam optimized LSTM neural network and wavelet transform (2019). Prieiga per: <https://www.sciencedirect.com/science/article/abs/pii/S0360544219314768>. [žiūrėta 2025-05-06].
55. ANDREA CERASA, Alessandro Zani. Enhancing electricity price forecasting accuracy: A novel filtering strategy for improved out-of-sample predictions (2025). Prieiga per: <https://www.sciencedirect.com/science/article/pii/S030626192500087X>. [žiūrėta 2025-05-06].
56. ZAGHIYAN, Mohammad Reza; ESLAMIAN, Saeid; GOHARI, Alireza ir EBRAHIMI, Mohammad Saleh. Temporal correction of irregular observed intervals of groundwater level series using interpolation techniques. *Theoretical and Applied Climatology*, vol. 145 (2021), nr. 3, pp. 1027–1037. Prieiga per: <https://doi.org/10.1007/s00704-021-03666-1>. [žiūrėta 2025-05-06].
57. FILHO, Dalson Figueiredo; SILVA, Lucas; PIRES, Antônio ir MALAQUIAS, Caio. Living with outliers: How to detect extreme observations in data analysis. *BIB - Revista Brasileira de Informação Bibliográfica em Ciências Sociais* (2023), nr. 99. Prieiga per: <https://bibanpocs.emnuvens.com.br/revista/article/view/619>. [žiūrėta 2025-05-06].
58. WANG, Jin; JI, Tianyao ir LI, Mengshi. A Combined Short-Term Forecast Model of Wind Power Based on Empirical Mode Decomposition and Augmented Dickey-Fuller Test. *Journal of Physics: Conference Series*, vol. 2022 (2021), nr. 1, pp. 012017. Prieiga per: <https://dx.doi.org/10.1088/1742-6596/2022/1/012017>. [žiūrėta 2025-05-06].
59. BANDARA, Kasun; HYNDMAN, Rob J. ir BERGMEIR, Christoph. *MSTL: A Seasonal-Trend Decomposition Algorithm for Time Series with Multiple Seasonal Patterns*. Prieiga per: <http://arxiv.org/abs/2107.13462>. [žiūrėta 2025-05-07].
60. AMEGA, Kokou; MOUMOUNI, Yacouba; LARÉ, Yendoubé; BHANDARI, Ramchandra; TAKOUDA, Pidenam ir kt. Power system transformation in emerging countries: A SWOT/PESTLE analysis approach towards resiliency and reliability. *Heliyon*, vol. 10 (2024), nr. 12. Prieiga per: [https://www.cell.com/heliyon/abstract/S2405-8440\(24\)09049-2](https://www.cell.com/heliyon/abstract/S2405-8440(24)09049-2). [žiūrėta 2025-05-07].
61. SHOJAIE, Ali ir FOX, Emily B. *Granger Causality: A Review and Recent Advances*. Prieiga per: <http://arxiv.org/abs/2105.02675>. [žiūrėta 2025-05-07].
62. BREIMAN, Leo. Random Forests. *Machine Learning*, vol. 45 (2001), nr. 1, pp. 5–32. Prieiga per: <https://doi.org/10.1023/A:1010933404324>. [žiūrėta 2025-05-06].
63. DUDEK, Grzegorz. A Comprehensive Study of Random Forest for Short-Term Load Forecasting. *Energies*, vol. 15 (2022), nr. 20, pp. 7547. Prieiga per: <https://www.mdpi.com/1996-1073/15/20/7547>. [žiūrėta 2025-05-06].

64. DENG, Song; DONG, Xia; TAO, Li; WANG, Junjie; HE, Yi ir kt. Multi-type load forecasting model based on random forest and density clustering with the influence of noise and load patterns. *Energy*, vol. 307 (2024), pp. 132635. Prieiga per:
<https://www.sciencedirect.com/science/article/pii/S0360544224024095>. [žiūrėta 2025-05-04].
65. MALDONADO, Sebastián; GONZÁLEZ, Agustín ir CRONE, Sven. Automatic time series analysis for electric load forecasting via support vector regression. *Applied Soft Computing*, vol. 83 (2019), pp. 105616. Prieiga per:
<https://www.sciencedirect.com/science/article/pii/S1568494619303965>. [žiūrėta 2025-05-07].
66. DEHVARI, Masoud; FARZANEH, Saeed ir FOROOTAN, Ehsan. Forecasting rainfall events based on zenith wet delay time series utilizing eXtreme gradient boosting (XGBoost). *Advances in Space Research*, vol. 75 (2025), nr. 3, pp. 2584–2598. Prieiga per:
<https://www.sciencedirect.com/science/article/pii/S027311772401130X>. [žiūrėta 2025-05-07].
67. NIU, B. ir HUANG, Z. Multi-step probabilistic forecasting for sunspot numbers based on LightGBM. *Advances in Space Research* (2025). Prieiga per:
<https://www.sciencedirect.com/science/article/pii/S0273117725002595>. [žiūrėta 2025-05-07].

Priedai

1 priedas. Kokybinis veiksmų tarpusavio sąveikos vertinimas

-	Price	PriceSE4	PricePL	Load	LoadSE4	LoadLV	LoadPL	Gen	GenSE1	GenSE2	GenSE3	GenSE4	GenFI	GenDK1	GenDK2	GenLV	GenEE	GenPL	SolarLT	WindLT	SE4_LT	LV_LT	PL_LT	GasPrice
Price		2	2	2	1	1	1	2	1	1	1	1	1	1	1	1	1	1	0	0	2	2	2	0
PriceSE4	2		2	1	1	1	2	2	1	1	1	1	1	1	1	1	1	1	0	0	3	2	2	0
PricePL	2	2		1	1	1	1	2	1	1	1	1	1	1	1	1	1	1	0	0	2	2	3	0
Load	3	1	1		1	1	1	3	1	1	1	1	1	1	1	1	1	1	0	0	3	3	3	0
LoadSE4	2	3	1	1		1	1	2	3	3	3	3	1	2	2	1	1	1	0	0	2	1	1	0
LoadLV	2	1	1	1	1		1	2	1	1	1	1	1	1	1	3	1	1	0	0	1	2	1	0
LoadPL	2	1	3	1	1	1		2	1	1	1	1	1	1	1	1	1	3	0	0	1	1	2	0
Gen	3	1	1	3	1	1	1		1	1	1	1	1	1	1	1	1	1	0	0	3	3	3	0
GenSE1	1	2	1	1	2	1	1	2		2	2	1	2	1	1	1	1	1	0	0	2	1	1	0
GenSE2	1	2	1	1	2	1	1	2	2		2	2	1	1	1	1	1	1	0	0	2	1	1	0
GenSE3	1	2	1	1	2	1	1	2	2	2		2	1	1	1	1	1	1	0	0	2	1	1	0
GenSE4	3	3	1	2	3	1	1	3	2	2	2		1	1	1	1	1	1	0	0	3	2	2	0
GenFI	1	1	1	1	1	1	1	2	2	1	1	1		1	1	1	1	1	0	0	1	1	1	0
GenDK1	1	1	1	1	1	1	1	2	1	1	1	1	1		1	1	1	1	0	0	1	1	1	0
GenDK2	1	1	1	1	1	1	1	2	1	1	1	1	1	1		1	1	1	0	0	1	1	1	0
GenLV	3	1	1	2	1	3	1	3	1	1	1	1	1	1	1		3	1	0	0	2	3	2	0
GenEE	3	1	1	2	1	2	1	2	1	1	1	1	3	1	1	3		1	0	0	1	2	1	0
GenPL	3	1	3	2	1	1	3	3	1	1	1	1	1	1	1	1	1		0	0	3	3	3	0
SolarLT	3	2	2	2	2	2	2	3	1	1	1	2	1	1	1	2	1	2		0	3	3	3	0
WindLT	3	2	2	2	2	2	2	3	1	1	1	2	1	1	1	2	1	2	0		3	3	3	0
SE4_LT	3	2	0	1	1	0	0	3	1	1	1	3	1	1	1	2	1	1	0	0		3	3	0
LV_LT	3	1	0	1	1	1	0	3	1	1	1	2	1	1	1	3	1	1	0	0	3		3	0
PL_LT	3	1	2	1	0	0	1	3	1	1	1	2	1	1	1	2	1	3	0	0	3	3		0
GasPrice	2	0	0	1	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	2	2	2	0

2 priedas. Veiksnių tarpusavio priklausomybės reikšmingumas

-	PriceSE4	PricePL	Load	LoadPL	Gen	GenSE4	GenSE3	GenSE2	GenSE1	GenFI	GenDK1	GenDK2	GenEE	GenPL	SolarLT	WindLT	PL_LT	LV_LT	SE4_LT	GasPrice	d_LoadSE4	d_LoadLV	d_GenLV
PriceSE4	1	0	0	0	0	0	0	0	0	0	0	0,8004	0	0	0	0	0,019	0	0	0	0	0,5657	0,6504
	PricePL	1	0	0	0,5023	0	0	0	0	0	0	0	0,0001	0	0	0	0	0	0	0	0	0,0758	0,4492
		Load	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
			LoadPL	1	0	0	0	0	0	0	0	0	0	0	0	0	0,0003	0	0	0,0001	0,0152	0,0036	0,466
				Gen	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0,1205	0	0,0006	0,0023	0
					GenSE4	1	0	0	0	0	0	0	0	0	0,057	0	0	0	0	0	0,0028	0,0128	0,1501
						GenSE3	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0,0041	0,0003	0,0052
							GenSE2	1	0	0	0	0	0	0	0	0	0	0	0	0	0,3636	0	0,0055
								GenSE1	1	0	0	0	0	0	0	0	0	0	0	0	0,2069	0,0472	0,0091
									GenFI	1	0	0	0	0	0	0	0	0	0	0	0,1906	0,0067	0,0146
										GenDK1	1	0	0	0	0	0	0	0	0	0,0009	0,2245	0,4617	0,118
											GenDK2	1	0	0	0,1758	0	0,0025	0,9128	0	0	0,0034	0,0006	0,1802
												GenEE	1	0	0	0	0	0	0	0	0,0724	0	0
													GenPL	1	0	0	0,0009	0	0,02	0	0	0,0409	0,0025
														SolarLT	1	0	0	0	0	0	0	0	0
															WindLT	1	0	0	0	0	0	0	0
																PL_LT	1	0	0	0	0	0	0
																	LV_LT	1	0	0	0	0	0,2671
																		SE4_LT	1	0	0	0	0,1217
																			GasPrice	1	0,3003	0,5277	0,9384
																				d_LoadSE4	1	0	0
																					d_LoadLV	1	0
																						d_GenLV	1

3 priedas. Sudaryti vienmačio atsitiktinio miško modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė

Modelis	ntree	mtry	nodesize	MAPE, %				MPE, %				RMSE, EUR/MWh				Trukmė, s			
				Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis
Atsitiktinis miškas	200	1	5	0,0092	0,0532	0,5130	0,0958	-0,0296	0,0289	0,5033	0,0993	0,0144	0,4220	5,9072	1,1618	9,6084	10,4928	12,2041	0,5476
			10	0,0178	0,0682	0,6106	0,1162	-0,0589	0,0318	0,5980	0,1203	0,0186	0,5661	6,9673	1,4301	5,7419	6,2281	6,7509	0,2853
		2	5	0,0086	0,0524	0,5265	0,0982	-0,0306	0,0286	0,5160	0,1012	0,0135	0,4241	6,0476	1,1841	11,2875	12,1808	13,8215	0,4766
			10	0,0153	0,0675	0,6134	0,1156	-0,0467	0,0329	0,6028	0,1204	0,0163	0,5680	7,0187	1,4373	6,6885	7,2715	7,7503	0,2957
		3	5	0,0097	0,0520	0,5334	0,0993	-0,0262	0,0284	0,5233	0,1022	0,0140	0,4235	6,1288	1,1999	12,1602	13,1317	15,1927	0,5523
			10	0,0179	0,0686	0,6196	0,1181	-0,0507	0,0327	0,6061	0,1213	0,0168	0,5671	7,0793	1,4475	7,5745	8,3510	9,2173	0,3918
	300	1	5	0,0081	0,0523	0,5316	0,0991	-0,0327	0,0282	0,5219	0,1022	0,0139	0,4254	6,1176	1,2003	15,5543	16,1493	17,0300	0,3471
			10	0,0182	0,0696	0,6229	0,1187	-0,0544	0,0333	0,6073	0,1223	0,0172	0,5811	7,1103	1,4638	9,8055	10,1274	10,7293	0,2137
		2	5	0,0083	0,0526	0,5183	0,0970	-0,0327	0,0290	0,5089	0,1002	0,0134	0,4240	5,9545	1,1733	18,6444	19,4999	20,8008	0,5313
			10	0,0164	0,0691	0,6166	0,1175	-0,0559	0,0325	0,6035	0,1213	0,0173	0,5735	7,0552	1,4487	11,8527	12,2595	12,7063	0,2276
		3	5	0,0082	0,0531	0,5325	0,0996	-0,0301	0,0286	0,5227	0,1025	0,0136	0,4331	6,1236	1,2027	21,6383	22,5439	23,5854	0,5512
			10	0,0184	0,0686	0,6214	0,1182	-0,0553	0,0325	0,6063	0,1217	0,0167	0,5699	7,1189	1,4547	13,7282	14,0532	14,7033	0,2502
	350	1	5	0,0080	0,0518	0,5190	0,0967	-0,0371	0,0276	0,5096	0,1002	0,0141	0,4222	5,9651	1,1737	20,1449	20,9294	21,7950	0,4671
			10	0,0181	0,0691	0,6250	0,1180	-0,0580	0,0325	0,6111	0,1224	0,0177	0,5713	7,1588	1,4571	12,4770	13,1717	14,0851	0,3721
		2	5	0,0094	0,0530	0,5264	0,0985	-0,0303	0,0288	0,5169	0,1016	0,0145	0,4326	6,0615	1,1928	24,8256	25,5000	26,8498	0,5014
			10	0,0165	0,0696	0,6259	0,1188	-0,0554	0,0332	0,6137	0,1229	0,0165	0,5731	7,1683	1,4613	15,0385	15,7460	16,3685	0,3895
		3	5	0,0093	0,0521	0,5273	0,0982	-0,0327	0,0285	0,5178	0,1015	0,0144	0,4234	6,0681	1,1914	28,4825	29,8514	31,2076	0,6158
			10	0,0168	0,0685	0,6119	0,1171	-0,0500	0,0335	0,5989	0,1206	0,0181	0,5723	7,0053	1,4450	17,9536	18,8181	20,1484	0,5107

4 priedas. Sudaryti vienmatės atraminių vektorių regresijos modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė

Modelis	epsilon	cost	kernel	MAPE, %				MPE, %				RMSE, EUR/MWh				Trukmė, s			
				Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis
Atraminių vektorių regresija	0,01	1	polynomial	24,3566	40,8521	196,7274	32,5862	-188,4362	-2,7474	29,6455	41,1162	24,3716	90,7786	301,8803	78,1568	6,4531	7,9054	9,7371	1,0201
			radial	0,1507	0,4478	3,1762	0,5785	-0,1523	0,2255	2,8001	0,5447	0,2544	1,1016	11,2895	2,2363	0,6666	0,9015	1,2820	0,1623
		10	polynomial	24,3574	40,8491	196,5137	32,5503	-188,2233	-2,7568	29,6321	41,0808	24,3631	90,8353	302,2665	78,2165	35,9465	38,8554	41,7826	1,4727
			radial	0,0965	0,3170	1,4678	0,2658	-0,2389	0,0474	0,9106	0,2123	0,1560	0,5084	4,6402	0,8211	0,5085	0,6682	0,8701	0,0865
	0,05	1	polynomial	24,4145	40,8531	196,5021	32,5685	-188,2311	-2,9387	29,5159	41,0339	24,3732	91,3333	302,3706	78,5705	6,4777	7,8915	10,0934	0,9356
			radial	0,9959	2,4220	15,2341	2,5920	-2,4167	-0,5352	7,9279	1,8506	2,0634	2,9994	14,5811	2,3608	0,2014	0,3681	0,6754	0,1128
		10	polynomial	24,4256	40,8535	196,4868	32,5661	-188,2158	-2,9418	29,5158	41,0315	24,3726	91,3482	302,6418	78,6001	36,8834	43,8514	50,3277	4,0308
			radial	1,0121	2,1941	13,9037	2,3551	-2,6547	-0,5121	7,1793	1,7094	1,8095	2,4540	7,2304	0,9739	0,3797	0,4825	0,5690	0,0438
	0,10	1	polynomial	24,8777	41,0451	194,0806	32,0326	-185,5141	-2,5691	30,0749	40,5933	24,1152	92,4488	303,6427	78,5286	5,7577	7,6186	8,9257	0,8706
			radial	1,7322	4,3095	15,9032	2,5635	-5,1832	-1,7835	0,9006	1,7178	3,9629	5,3490	15,5851	2,1237	0,1308	0,2068	0,4047	0,0517
		10	polynomial	24,8780	41,0457	194,1021	32,0384	-185,5355	-2,5693	30,0699	40,5997	24,1161	92,4372	303,4820	78,5369	40,5763	46,0371	58,5210	4,1980
			radial	1,6839	4,9400	33,7403	5,7929	-5,1896	-1,1086	18,0766	4,1030	3,9458	5,0711	10,8005	1,2133	0,2344	0,3517	0,4733	0,0656

5 priedas. Sudaryti vienmačiai *XGBoost* modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė

Modelis	eta	max_depth	subsample	colsample_bytrees	MAPE, %				MPE, %				RMSE, EUR/MWh				Trukmė, s			
					Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis
XGBoost	0,01	4	0,80	0,80	36,2216	36,6372	37,4201	0,2620	36,2216	36,6372	37,4201	0,2620	25,0161	58,3439	87,9962	14,3894	0,3984	0,5126	0,7227	0,0857
				0,90	36,0483	36,6288	37,4430	0,2782	36,0483	36,6288	37,4430	0,2782	24,9682	58,3394	88,0002	14,3838	0,4189	0,5024	0,6610	0,0675
			0,90	0,80	36,0483	36,6113	37,3885	0,2659	36,0483	36,6113	37,3885	0,2659	25,0124	58,2904	87,7342	14,3446	0,3707	0,5016	0,6736	0,0701
				0,90	36,1413	36,6178	37,4083	0,2594	36,1413	36,6178	37,4083	0,2594	24,9977	58,2946	87,8210	14,3548	0,3747	0,4360	0,5272	0,0507
		6	0,80	0,80	36,3751	36,6469	37,4150	0,2551	36,3751	36,6469	37,4150	0,2551	25,0270	58,3511	88,0129	14,4082	0,5196	0,6583	0,8491	0,0834
				0,90	36,2668	36,6359	37,4073	0,2647	36,2668	36,6359	37,4073	0,2647	25,0458	58,3437	87,9795	14,3976	0,5198	0,6627	0,7915	0,0642
			0,90	0,80	36,2254	36,6150	37,3689	0,2544	36,2254	36,6150	37,3689	0,2544	25,0433	58,2949	87,7863	14,3647	0,5087	0,6154	0,9776	0,1301
				0,90	36,1904	36,6129	37,3657	0,2575	36,1904	36,6129	37,3657	0,2575	25,0360	58,2951	87,9154	14,3716	0,5015	0,5811	0,9037	0,1039
	0,05	4	0,80	0,80	0,5165	0,6332	1,2503	0,1387	0,4799	0,6296	1,2503	0,1403	0,4276	1,4178	8,2023	1,5139	0,3756	0,4163	0,5289	0,0437
				0,90	0,5461	0,6602	1,2463	0,1333	0,5461	0,6600	1,2463	0,1334	0,4016	1,4649	8,2458	1,5194	0,3757	0,4461	0,6190	0,0639
			0,90	0,80	0,5092	0,6517	1,2723	0,1461	0,2836	0,6296	1,2723	0,1534	0,4186	1,4002	8,0221	1,4655	0,3744	0,4612	0,6277	0,0536
				0,90	0,5224	0,6575	1,2399	0,1694	-0,0621	0,6115	1,2399	0,1860	0,4322	1,4148	8,0134	1,4584	0,3731	0,5149	0,6996	0,0640
		6	0,80	0,80	0,5550	0,6440	1,2463	0,1357	0,4403	0,6350	1,2463	0,1406	0,4352	1,4389	8,2766	1,5207	0,5054	0,6128	0,7926	0,0846
				0,90	0,5011	0,6365	1,2153	0,1303	0,4768	0,6311	1,2153	0,1337	0,4046	1,4216	8,2594	1,5220	0,5043	0,6611	1,0531	0,1185
			0,90	0,80	0,5363	0,6311	1,2067	0,1297	0,4880	0,6279	1,2067	0,1321	0,3795	1,3996	8,0661	1,4716	0,5141	0,6441	0,7691	0,0652
				0,90	0,5613	0,6443	1,2577	0,1347	0,5020	0,6405	1,2577	0,1372	0,3974	1,4183	8,0362	1,4684	0,4948	0,6055	0,7297	0,0625
	0,10	4	0,80	0,80	0,0873	0,2087	0,4973	0,0939	-0,2027	0,0335	0,4446	0,1159	0,1981	0,5465	4,7106	0,8595	0,3700	0,4552	0,6219	0,0670
				0,90	0,0727	0,2303	1,2068	0,2055	-0,8871	0,0089	0,4217	0,1957	0,1720	0,5531	4,8353	0,8833	0,3335	0,4123	0,5860	0,0587
			0,90	0,80	0,0870	0,2080	0,5037	0,0991	-0,1631	0,0136	0,4450	0,1043	0,1882	0,5277	4,6410	0,8493	0,2774	0,4209	0,5972	0,0819
				0,90	0,1055	0,2376	1,1288	0,1921	-0,9047	0,0015	0,3988	0,1979	0,1691	0,5619	4,6922	0,8509	0,3205	0,4273	0,5584	0,0711
		6	0,80	0,80	0,0784	0,1574	0,5966	0,1150	-0,4762	0,0201	0,4389	0,1294	0,0866	0,4606	4,8684	0,9078	0,4148	0,5863	0,7472	0,0789
				0,90	0,0790	0,1606	0,6422	0,1198	-0,5108	0,0114	0,3950	0,1302	0,1259	0,4738	4,8655	0,9043	0,4388	0,5947	0,7771	0,0829
			0,90	0,80	0,0724	0,1563	0,5060	0,1044	-0,3364	0,0176	0,4158	0,1106	0,0926	0,4646	4,6395	0,8631	0,4591	0,6410	0,8325	0,0919
				0,90	0,0654	0,1533	0,5295	0,1040	-0,3653	0,0067	0,4117	0,1136	0,1075	0,4693	4,7003	0,8741	0,3922	0,5444	0,7336	0,0727

6 priedas. Sudaryti vienmačiai *LightGBM* modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė

Modelis	learning_rate	num_leaves	feature_fraction	bagging_fraction	MAPE, %				MPE, %				RMSE, EUR/MWh				Trukmė, s			
					Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis
LightGBM	0,01	7	0,70	0,70	11,2741	22,1541	174,5894	30,1277	-172,0499	4,6940	23,6129	35,6428	13,2314	32,6178	64,8340	13,7267	0,2179	0,2497	0,3085	0,0204
				0,80	11,2580	22,1673	174,4557	30,0966	-171,9463	4,6934	23,6364	35,6240	13,2490	32,6112	64,9549	13,7267	0,2209	0,2592	0,3098	0,0183
			0,80	0,70	11,2741	22,1541	174,5894	30,1277	-172,0499	4,6940	23,6129	35,6428	13,2314	32,6178	64,8340	13,7267	0,2161	0,2535	0,3611	0,0337
				0,80	11,2580	22,1673	174,4557	30,0966	-171,9463	4,6934	23,6364	35,6240	13,2490	32,6112	64,9549	13,7267	0,2322	0,2577	0,3715	0,0289
		13	0,70	0,70	11,1781	21,2107	160,8508	27,6152	-158,3866	4,8538	21,4911	33,0119	13,3217	31,1898	57,2454	12,2670	0,3709	0,3988	0,4564	0,0196
				0,80	11,1879	21,2116	160,7541	27,5943	-158,3101	4,8542	21,5122	33,0005	13,3595	31,1949	57,2678	12,2879	0,3622	0,3863	0,4491	0,0198
			0,80	0,70	11,1781	21,2107	160,8508	27,6152	-158,3866	4,8538	21,4911	33,0119	13,3217	31,1898	57,2454	12,2670	0,3690	0,3835	0,4662	0,0179
				0,80	11,1879	21,2116	160,7541	27,5943	-158,3101	4,8542	21,5122	33,0005	13,3595	31,1949	57,2678	12,2879	0,3752	0,3974	0,5135	0,0272
		0,05	7	0,70	0,2535	0,6815	3,2261	0,5799	-2,8929	0,1863	1,3874	0,6898	0,3633	2,1673	11,5619	2,8332	0,2257	0,2506	0,2879	0,0161
				0,80	0,2214	0,6900	3,4656	0,6239	-3,0902	0,1744	1,3954	0,7208	0,3394	2,1820	11,5859	2,8321	0,2277	0,2598	0,3229	0,0231
			0,80	0,70	0,2535	0,6815	3,2261	0,5799	-2,8929	0,1863	1,3874	0,6898	0,3633	2,1673	11,5619	2,8332	0,2297	0,2496	0,2945	0,0162
				0,80	0,2214	0,6900	3,4656	0,6239	-3,0902	0,1744	1,3954	0,7208	0,3394	2,1820	11,5859	2,8321	0,2335	0,2702	0,4244	0,0467
			13	0,70	0,2544	0,6065	2,4619	0,4736	-2,2419	0,1718	1,3185	0,5641	0,3560	2,0786	11,1822	2,7343	0,3618	0,4215	0,4916	0,0339
				0,80	0,2482	0,6057	2,4845	0,4737	-2,3169	0,1648	1,2868	0,5757	0,3549	2,0763	11,2000	2,7408	0,3678	0,4129	0,4585	0,0196
				0,70	0,2544	0,6065	2,4619	0,4736	-2,2419	0,1718	1,3185	0,5641	0,3560	2,0786	11,1822	2,7343	0,3581	0,3897	0,4420	0,0180
				0,80	0,2482	0,6057	2,4845	0,4737	-2,3169	0,1648	1,2868	0,5757	0,3549	2,0763	11,2000	2,7408	0,3810	0,4357	0,5529	0,0476
	0,10	7	0,70	0,70	0,3200	0,6552	1,3229	0,2818	-0,2498	0,1448	1,0317	0,2784	0,5011	2,0616	10,7568	2,5376	0,1305	0,1944	0,4022	0,0558
				0,80	0,2895	0,6271	1,2900	0,2804	-0,1442	0,1298	0,9969	0,2684	0,3853	2,0340	10,6833	2,5296	0,1386	0,1946	0,2384	0,0349
			0,80	0,70	0,3200	0,6552	1,3229	0,2818	-0,2498	0,1448	1,0317	0,2784	0,5011	2,0616	10,7568	2,5376	0,1389	0,1926	0,2409	0,0378
				0,80	0,2895	0,6271	1,2900	0,2804	-0,1442	0,1298	0,9969	0,2684	0,3853	2,0340	10,6833	2,5296	0,1336	0,2054	0,3052	0,0455
		13	0,70	0,70	0,2214	0,5370	1,2451	0,2854	-0,1417	0,1545	0,9627	0,2414	0,3190	1,9345	10,6688	2,5576	0,1996	0,2839	0,4116	0,0589
				0,80	0,2085	0,5440	1,2646	0,2869	-0,1111	0,1568	1,0378	0,2569	0,2492	1,9369	10,7853	2,5697	0,2044	0,3154	0,5050	0,0753
			0,80	0,70	0,2214	0,5370	1,2451	0,2854	-0,1417	0,1545	0,9627	0,2414	0,3190	1,9345	10,6688	2,5576	0,2476	0,3427	0,4683	0,0662
				0,80	0,2085	0,5440	1,2646	0,2869	-0,1111	0,1568	1,0378	0,2569	0,2492	1,9369	10,7853	2,5697	0,2374	0,3455	0,4651	0,0758

7 priedas. Sudaryti daugiamačiai atsitiktinio miško modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė

				MAPE, %				MPE, %				RMSE, EUR/MWh				Trukmė, s				
Modelis	ntree	mtry	nodesize	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	
Atsitiktinis miškas	200	5	5	6,8210	30,2177	269,2291	47,6391	-262,4644	-2,0645	30,7580	52,0066	15,4403	41,3051	92,2474	20,8504	33,9632	38,1937	44,9284	2,7296	
			10	6,5924	30,8650	282,4730	50,0535	-275,5642	-2,9092	30,5385	54,4665	13,0125	41,3307	91,7596	20,8305	23,3773	24,5377	28,5522	1,2082	
		7	5	6,2078	30,5634	273,7147	48,5086	-266,9804	-3,6268	29,9151	52,7604	13,6616	41,1181	91,7833	21,1516	37,7961	41,1698	46,2012	1,8780	
			10	7,0086	30,6882	282,8614	50,1880	-275,3220	-3,4883	29,6890	54,3220	14,1467	41,3599	91,9776	20,8987	25,0020	26,6815	31,0227	1,3625	
		9	5	7,8888	30,2817	273,1989	48,3913	-265,7208	-3,7022	29,0231	52,5192	14,4815	41,1182	90,6257	20,9592	39,5905	42,2929	49,6700	2,6990	
			10	7,2490	30,4035	275,5000	48,8088	-267,7716	-4,1128	28,6708	52,8599	14,3662	41,1551	89,5758	20,6567	28,6539	30,1939	33,8091	1,3185	
		300	5	5	7,3855	30,4234	267,6592	47,3575	-260,6147	-2,0905	32,0545	51,7769	14,8684	41,5998	94,8386	21,0806	49,3879	51,2424	53,0300	0,9308
				10	7,4571	30,9942	279,5589	49,4720	-272,5081	-2,7485	29,8351	53,9225	15,9062	41,7023	91,3249	20,7299	34,9987	36,3117	41,0486	1,0858
			7	5	6,8534	30,6779	278,4188	49,3605	-270,6170	-3,3968	29,3577	53,4519	13,5725	41,2211	89,8795	20,8134	58,1179	60,0943	61,9092	0,9970
				10	7,7377	30,6218	276,8420	49,0584	-269,3317	-3,6116	30,7414	53,1984	14,8255	41,1591	92,8670	21,0445	41,6974	44,1698	46,9098	1,3768
			9	5	7,7238	30,5910	277,5150	49,1713	-270,2644	-4,0213	29,7094	53,3621	14,5481	41,2699	90,5010	20,8078	64,7048	73,0437	79,0278	3,9724
				10	8,1766	30,5580	277,9174	49,2215	-269,9790	-4,2103	28,9461	53,2411	14,2975	41,1499	90,9247	20,8759	42,4504	47,1189	53,6064	2,5994
	350	5	5	6,2360	30,5129	271,1233	47,9924	-264,0879	-2,7242	29,6220	52,2923	13,5787	41,1137	91,0503	20,7030	56,8451	63,0995	87,5061	5,1850	
			10	6,7109	30,9000	283,1408	50,2162	-276,0112	-2,7688	30,9530	54,5926	14,4858	41,4525	93,4581	21,2170	43,8603	61,2068	87,1445	14,9349	
		7	5	6,2495	30,1329	271,6106	48,0998	-264,0052	-3,3864	28,7234	52,1271	13,6688	40,9278	89,5570	20,7188	72,8136	107,0908	154,4368	34,5853	
			10	7,6003	30,4475	270,7935	47,9015	-263,4314	-3,1773	29,5384	52,1169	14,3839	41,2915	91,8169	20,8539	45,2999	53,3567	105,1829	14,1419	
		9	5	7,1433	30,3934	276,9710	49,1046	-269,5211	-4,1582	28,2081	53,0995	13,6390	40,8693	87,8090	20,7012	71,6177	346,7013	5,043,5258	934,7229	
			10	7,2218	30,4487	271,8611	48,1383	-264,2328	-4,1279	28,1280	52,1521	13,9476	41,0026	87,8324	20,7187	75,0074	153,9135	945,4315	218,9400	

8 priedas. Sudaryti daugiamatės atraminių vektorių regresijos modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė

Modelis	epsilon	cost	kernel	MAPE, %				MPE, %				RMSE, EUR/MWh				Trukmė, s			
				Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis
Atraminių vektorių regresija	0,01	1	polynomial	11,8662	36,9100	312,1747	54,7471	-307,4629	-7,2355	34,8479	61,8310	14,7542	47,3056	91,6370	20,8442	24,5105	28,6489	33,6370	2,1723
			radial	10,0427	31,3553	276,8406	48,7871	-268,4137	-0,5001	27,7342	53,7339	16,9361	42,4599	85,2303	19,7844	28,7884	31,3281	35,1593	1,4183
		10	polynomial	12,3381	36,8831	220,2093	37,4940	-191,1785	-5,3377	35,4989	42,4612	20,9651	50,0186	90,2776	20,1793	128,0407	143,7524	173,6841	11,0331
			radial	7,3447	30,7804	251,9919	43,9696	-238,6047	-3,4735	26,0555	47,6113	15,1145	41,0312	83,9206	17,2338	219,4988	690,5470	1.228,3138	341,9521
	0,05	1	polynomial	11,5316	36,7959	304,2213	53,2798	-299,2455	-7,3896	34,3831	60,3769	14,8722	47,5341	90,6663	21,2084	8,2031	17,4543	28,1824	8,0834
			radial	10,8643	31,0360	267,3168	47,0045	-258,4574	-0,2238	27,1316	51,8742	16,8193	42,3168	85,1792	19,8282	20,7246	22,7706	26,9263	1,4953
		10	polynomial	11,1293	36,7286	223,2437	38,0753	-200,2358	-5,5866	33,7919	43,9914	20,7997	49,8583	88,8934	20,3892	108,6440	125,0050	135,9057	7,0629
			radial	7,3822	30,6705	256,7345	44,8946	-244,8122	-3,7041	25,1910	48,6503	15,2231	40,6030	79,3685	16,8991	158,7167	431,1343	4.356,3651	803,0631
	0,10	1	polynomial	11,8971	37,2048	319,3449	56,1919	-313,9337	-8,1841	33,6556	63,1143	14,7454	47,3437	93,3830	21,4911	6,7164	7,1600	7,9176	0,2549
			radial	10,1628	30,7124	260,7928	45,8125	-251,7847	-0,5870	27,4068	50,4328	17,0971	42,0172	84,4092	19,8317	13,6753	17,4508	20,9951	1,6716
		10	polynomial	12,0025	36,6884	223,6311	38,0412	-200,5934	-4,7505	36,8707	44,3729	20,8779	49,9705	87,9818	19,9200	98,5811	120,2401	319,4126	44,2406
			radial	7,0920	31,3103	272,3627	47,8324	-262,0767	-4,4739	25,6429	51,7790	14,8881	40,4423	77,2734	16,7791	88,4385	98,9992	111,3238	5,0368

9 priedas. Sudaryti daugiamaciai *XGBoost* modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė

Modelis	eta	max_depth	subsample	colsample_bytrees	MAPE, %				MPE, %				RMSE, EUR/MWh				Trukmė, s			
					Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis
XGBoost	0,01	4	0,80	0,80	31,4846	49,4623	195,8676	29,6039	-152,0692	34,3979	58,5894	37,5238	25,5428	80,4320	151,8356	29,2301	0,5613	0,5942	0,7049	0,0313
				0,90	30,4134	49,0964	195,9981	29,6922	-155,6496	33,7238	58,0921	38,1425	24,6527	79,7446	150,4207	29,2079	0,5612	0,6007	0,8034	0,0570
			0,90	0,80	32,6581	49,4368	196,8280	29,7790	-153,6325	34,3746	59,0226	37,8070	25,2917	80,3820	152,2364	29,3795	0,5101	0,5389	0,6430	0,0253
				0,90	31,0822	49,1616	195,8113	29,6432	-155,4407	33,7893	58,2227	38,1269	24,5707	79,8417	150,5311	29,2750	0,5203	0,5607	0,6154	0,0226
		6	0,80	0,80	31,1597	48,4826	178,1309	26,2897	-126,9418	35,5489	56,1744	32,7599	27,0297	79,4552	146,8723	27,8101	0,8212	0,8536	1,0106	0,0359
				0,90	30,6075	47,7608	177,1488	26,2773	-126,5023	34,6829	56,5712	32,6081	26,8447	78,7822	148,2197	28,1043	0,8394	0,8718	1,0005	0,0431
			0,90	0,80	31,6988	48,1758	179,9431	26,7346	-131,6193	34,9330	56,1386	33,5856	26,3744	79,0031	146,4190	28,0371	0,8328	0,8608	0,9579	0,0238
				0,90	31,1945	48,1253	184,9501	27,6861	-135,3538	34,3031	55,9297	34,2175	26,5143	78,8118	147,2300	28,0960	0,8634	0,8773	0,9716	0,0201
	0,05	4	0,80	0,80	7,1902	30,0366	229,5410	40,0781	-207,8463	0,1220	26,6883	42,3816	15,3637	42,1579	83,6489	20,5765	0,2196	0,4861	0,5797	0,0839
				0,90	6,2669	30,5078	248,2743	43,5240	-229,2154	-0,9343	26,9724	46,1441	12,9189	42,1527	82,3504	20,5687	0,2235	0,4958	0,5949	0,0903
			0,90	0,80	7,6082	30,1900	220,9186	38,3155	-196,5718	0,4564	26,7910	40,3768	14,8579	42,8394	83,3530	20,3185	0,2013	0,4948	0,5999	0,0862
				0,90	6,4975	30,0382	221,6053	38,5443	-196,8768	0,1045	26,9695	40,3878	13,9039	42,5216	83,7913	20,5214	0,3138	0,6203	1,0839	0,1819
		6	0,80	0,80	7,2737	28,1232	210,3113	36,6843	-187,6051	0,2171	24,7162	38,3994	13,9542	41,0404	75,5630	19,8723	0,4115	0,8575	1,0207	0,1326
				0,90	7,6368	29,1381	234,0334	41,0595	-211,9048	-1,6830	27,0696	42,9439	15,4931	40,8967	78,8979	19,5439	0,4252	0,8996	1,0507	0,1258
			0,90	0,80	6,7825	28,6334	217,2403	38,0228	-194,5079	-0,1960	28,3858	39,9780	13,6723	41,2032	87,2917	20,5886	0,4301	0,8559	1,0401	0,1066
				0,90	8,1312	28,7511	218,0162	38,1441	-194,7172	-1,2601	25,9876	39,6071	15,3868	41,0211	78,9782	19,9153	0,4442	0,9357	1,3890	0,2111
	0,10	4	0,80	0,80	6,0876	29,4153	224,2714	39,2178	-207,0351	-1,9440	29,4448	42,3128	16,3035	41,1107	87,4566	20,1433	0,1536	0,4352	0,7375	0,1617
				0,90	7,7300	29,7822	229,4600	40,1423	-211,1016	-2,4087	25,4342	42,6538	15,0201	40,6491	79,3143	19,0587	0,1681	0,4867	0,7989	0,1761
			0,90	0,80	6,6205	29,9181	240,8758	42,3047	-221,2065	-1,3055	26,3820	44,7639	13,8704	41,1203	77,8218	19,5713	0,1985	0,5123	0,9220	0,1830
				0,90	9,5899	29,6867	238,8198	41,8153	-219,5935	-2,0845	24,9311	44,4395	16,9294	40,7010	78,7471	18,8324	0,1959	0,5108	0,7736	0,1642
		6	0,80	0,80	7,1636	29,1807	239,2793	42,2027	-219,4898	-2,7191	34,4276	44,4554	14,8767	39,8311	77,3178	19,3786	0,3466	0,8660	1,3226	0,2513
				0,90	8,0766	28,8784	242,0003	42,6828	-219,5928	-3,3828	23,9664	43,8921	14,5171	39,1008	73,9075	17,9981	0,3975	0,9299	1,3934	0,2707
			0,90	0,80	7,8708	28,0717	210,9701	36,9635	-187,8279	-1,6393	28,6199	38,2782	13,2792	39,8275	90,2462	20,4172	0,3227	0,9414	1,5691	0,3148
				0,90	8,3515	27,5306	201,1814	35,1295	-180,1756	-1,4571	25,2991	36,8175	15,5092	39,1827	74,1199	18,7094	0,3580	0,8697	1,2746	0,2553

10 priedas. Sudaryti daugiamačiai *LightGBM* modeliai, jų tikslumo vertinimo metrikos ir prognozės sudarymo trukmė

Modelis	learning_rate	num_leaves	feature_fraction	bagging_fraction	MAPE, %				MPE, %				RMSE, EUR/MWh				Trukmė, s			
					Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis	Minimali reikšmė	Vidurkis	Maksimali reikšmė	Standartinis nuokrypis
LightGBM	0,01	7	0,70	0,70	18,9745	43,0876	367,4053	64,7833	-363,2742	1,6293	44,8286	73,7882	23,5540	58,2004	125,6662	27,1213	0,0872	0,3482	0,4991	0,0690
				0,80	19,0691	43,1345	367,9323	64,8761	-363,8502	1,5465	44,9470	73,9156	23,6969	58,1626	125,6221	27,1186	0,0759	0,3259	0,4073	0,0571
			0,80	0,70	18,6705	43,3255	377,5336	66,7213	-373,7207	0,6268	44,3923	75,6255	23,3150	57,8188	124,8414	26,9711	0,0813	0,3331	0,3949	0,0575
				0,80	18,9743	43,2393	372,9475	65,8365	-369,1820	0,8505	44,9159	74,8005	23,4312	57,8236	125,6633	27,0911	0,0902	0,3334	0,4251	0,0615
		13	0,70	0,70	15,7987	41,6100	349,4252	61,6435	-344,5831	2,1906	44,4514	70,1386	24,4711	57,1408	125,1061	26,8506	0,1273	0,4728	0,5541	0,0750
				0,80	15,3882	41,9827	361,3850	63,8905	-356,7747	1,6539	44,1126	72,3706	24,4102	57,0566	124,3485	26,9753	0,1237	0,5492	0,7116	0,1049
			0,80	0,70	15,5254	42,3759	378,6781	67,0119	-374,8747	0,6770	44,1058	75,4547	24,9075	56,8134	124,4430	26,7849	0,1909	0,5486	0,7293	0,0994
				0,80	15,4416	41,8022	363,0665	64,1098	-358,7106	1,3057	44,0566	72,4907	24,6968	56,7033	124,1930	26,9048	0,1707	0,5621	0,6979	0,0919
	0,05	7	0,70	0,70	9,3408	34,2863	273,1160	48,7721	-262,4182	-4,7391	29,3500	52,9878	19,4907	44,0756	97,9819	21,9540	0,0953	0,3041	0,4232	0,0745
				0,80	10,0421	35,7801	318,5867	56,9938	-312,6137	-6,4825	26,6295	61,9197	19,0987	43,9561	90,8415	21,2164	0,0880	0,2938	0,3992	0,0806
			0,80	0,70	10,2477	35,8611	321,1940	57,5521	-315,6855	-6,8614	27,3327	62,5412	18,6858	44,0781	95,2556	21,6344	0,0900	0,2926	0,4453	0,0856
				0,80	8,6913	38,1187	385,3402	69,4468	-381,8567	-8,8637	27,0839	74,7910	18,3298	44,2189	94,3013	21,6313	0,1019	0,2822	0,3969	0,0732
		13	0,70	0,70	7,9627	33,5894	284,3028	50,7895	-276,1862	-4,3828	26,2331	55,1846	16,5288	42,7412	82,6208	20,3743	0,1338	0,4492	0,6017	0,1123
				0,80	9,6959	34,0604	290,5976	51,9355	-283,5576	-5,0545	26,1746	56,5649	17,4678	43,0947	83,5609	20,2395	0,1233	0,4461	0,6494	0,1009
			0,80	0,70	8,3217	34,9240	322,5216	57,6934	-316,8263	-6,3526	23,9575	62,4208	17,0627	42,6817	78,7318	19,3782	0,1345	0,4254	0,5498	0,1039
				0,80	8,1035	32,7632	269,0062	47,9504	-260,0797	-4,3458	24,9135	52,0289	17,1812	42,4014	82,3648	20,1764	0,1374	0,4463	0,6284	0,1190
	0,10	7	0,70	0,70	7,8555	33,9288	273,3206	48,7831	-264,8412	-6,1817	25,8787	52,9478	18,4439	42,5430	81,5653	18,9478	0,0530	0,1806	0,4390	0,0739
				0,80	8,4221	34,5731	291,3270	52,1141	-283,3456	-6,1644	25,2453	56,4537	19,2048	42,6657	78,2039	19,2442	0,0592	0,1689	0,2819	0,0565
			0,80	0,70	8,5225	33,4126	268,8546	48,1074	-258,5117	-6,4435	26,2080	51,7402	19,2125	42,1148	81,1378	18,8725	0,0707	0,1556	0,2514	0,0455
				0,80	8,3092	34,7728	299,8912	53,7016	-291,2939	-7,0187	25,2720	57,7860	15,6428	42,9632	81,3721	19,5017	0,0553	0,1710	0,2560	0,0483
		13	0,70	0,70	7,8150	31,7422	263,4568	46,9021	-254,1504	-4,2740	23,2389	50,6184	16,2059	41,0228	73,2254	18,5514	0,0799	0,2822	0,4536	0,0928
				0,80	7,1363	32,6748	270,3076	48,2614	-259,4797	-5,1480	22,8771	51,8269	14,1418	41,2490	73,4483	18,4768	0,1030	0,2977	0,5778	0,1080
			0,80	0,70	8,0438	33,7763	321,1512	57,6574	-314,0039	-7,6120	22,8057	61,6306	16,4198	40,8122	77,2332	18,4719	0,1566	0,4007	0,7957	0,1623
				0,80	8,9672	33,0854	297,8793	53,4428	-291,5042	-7,1070	21,0493	57,4498	18,1907	40,7365	75,2772	17,9513	0,1340	0,4003	1,7068	0,2785