



Kauno technologijos universitetas
Matematikos ir gamtos mokslų fakultetas

Degalų kainų dinamikos modeliavimas ir prognozavimas

Baigiamasis magistro studijų projektas

David Petrov
Projekto autorius

prof. dr. Alina Stundžienė

Vadovė

prof. dr. Evaldas Vaičiukynas

Vadovas

Kaunas, 2026



Kauno technologijos universitetas
Matematikos ir gamtos mokslų fakultetas

Degalų kainų dinamikos modeliavimas ir prognozavimas

Baigiamasis magistro studijų projektas
Didžiųjų verslo duomenų analitika (6213AX001)

David Petrov

Projekto autorius

prof. dr. Alina Stundžienė
Vadovė

prof. dr. Evaldas Vaičiukynas
Vadovas

prof. dr. Vytautas Snieška
Recenzentas

doc. dr. Mantas Landauskas
Recenzentas

Kaunas, 2026



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

David Petrov

Degalų kainų dinamikos modeliavimas ir prognozavimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autorius 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.

David Petrov

Patvirtinta elektroniniu būdu

David Petrov. Degalų kainų dinamikos modeliavimas ir prognozavimas. Magistro studijų baigiamasis projektas / vadovė prof. dr. Alina Stundžienė, vadovas prof. dr. Evaldas Vaičiukynas; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

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

Reikšminiai žodžiai: degalų kainos, benzinas, dyzelinas, Brent nafta, Prophet modelis, išoriniai šokai, COVID-19, Ukrainos karas.

Kaunas, 2026. 77 p.

Santrauka

Degalų kainų dinamika turi reikšmingą poveikį transporto, logistikos, gamybos sektorių veiklos rezultatams. Kadangi mažmeninių benzino ir dyzelino kainų svyravimai tiesiogiai veikia namų ūkių vartojimo išlaidas ir verslo subjektų veiklos kaštus, šių degalų rūšių kainų pokyčių analizė ir prognozavimas yra aktualus, formuojant šalies ekonomikos politiką ir padeda rinkos dalyviams priimti pagrįstus verslo sprendimus. Darbo objektas – mažmeninių benzino ir dyzelino kainų dinamika Lietuvoje. Darbo tikslas – įvertinti pagrindinius mažmeninių degalų kainas lemiančius veiksnius, nustatyti išorinių šokų poveikį bei atrinkti tiksliausius benzino ir dyzelino kainų prognozavimo modelius.

Pirmojoje darbo dalyje yra atliekama mokslinės literatūros analizė, kurios metu nagrinėjama degalų samprata, naftos produktų klasifikacija, pagrindiniai degalų kainų pokyčius lemiantys veiksniai bei aptariami panašiuose moksliniuose tyrimuose taikomi ekonometriniai prognozavimo metodai. Literatūros analizė parodė, kad degalų kainų dinamika pasižymi kompleksiskumu, o ją stipriausiai veikia pasaulinės žaliavinės naftos kainos, vidaus ekonominiai rodikliai ir netikėti išoriniai šokai.

Antrojoje darbo dalyje aprašyti tyrime naudoti duomenys, jų paruošimo analizei procesas bei taikyta modeliavimo metodologija. Tyrimo tikslo įgyvendinimui naudojami mėnesiniai Lietuvos mažmeninių benzino ir dyzelino kainų, makroekonominių rodiklių bei išorinius šokus atspindinčių pseudo kintamųjų duomenys. Duomenų modeliavimui yra taikomi vienmačių ir daugiamačių duomenų modeliai, o ryšys tarp priklausomų ir nepriklausomų kintamųjų nustatomas naudojant Granger priežastingumo testą. Modelių tikslumas vertinamas remiantis RMSE ir MAPE paklaidų rodikliais.

Tyrimo rezultatai parodė, kad tiksliausias mažmeninių benzino ir dyzelino kainų prognozes pateikia Prophet metodologija paremti modeliai. Benzino kainų dinamikai didžiausią statistiškai reikšmingą poveikį turėjo Brent naftos kainų ir Lietuvos nedarbo lygio rodiklių pokyčiai, o dyzelino kainų raida priklausė nuo Brent naftos kainos ir harmonizuoto vartotojų kainų indekso skystojo kuro rinkoje nepriklausomų kintamųjų. Tyrimo metu taip pat buvo nustatyta, kad COVID-19 pandemijos sukeltas šokas pasižymėjo statistiškai reikšmingu poveikiu mažmeninių dyzelino kainų dinamikai, tuo tarpu Ukrainos karo poveikis dyzelino kainoms, kaip ir benzino kainų atveju, išliko statistiškai nereikšmingu. 2026 metų prognozavimo rezultatai atskleidė, kad metų pradžioje Prophet modeliai gana tiksliai prognozavo abiejų degalų rūšių kainų raidą, tačiau pavasarį, sustiprėjus geopolitiniams neramumams Artimuosiuose Rytuose, prognozių tikslumas reikšmingai sumažėjo. Šie tyrimo rezultatai indikuoja, jog nors Prophet modeliai geba efektyviai įvertinti ilgalaikes degalų rinkos tendencijas įprastomis rinkos sąlygomis, jų prognozavimo efektyvumas smarkiai sumažėja tais

laikotarpiais, kai degalų rinkoje pasireiškia staigūs struktūriniai lūžiai, kuriuos dažniausiai sukelia išoriniai geopolitiniai ar ekonominiai šokai.

David Petrov. Modeling and Forecasting of Fuel Price Dynamics. Master's Final Degree Project / supervisor prof. dr. Alina Stundžienė, supervisor prof. dr. Evaldas Vaičiukynas; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology.

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

Keywords: fuel prices, gasoline, diesel fuel, Brent crude oil, Prophet forecasting model, external shocks, COVID-19, Ukraine war.

Kaunas, 2026. 77.

Summary

Fuel price dynamics have a strong impact on the performance of the transport, logistics, and manufacturing sectors. Since changes in retail gasoline and diesel prices directly affect household spending and business operating costs, analyzing and forecasting these price movements is important for shaping economic policy and helping market participants make informed decisions. The object of this study is the dynamics of retail gasoline and diesel prices in Lithuania. The main aim is to assess the key factors influencing retail fuel prices, evaluate the impact of external shocks, and identify the most accurate forecasting models for gasoline and diesel prices.

The first part of the study reviews scientific literature on the concept of fuel, the classification of petroleum products, the main factors affecting fuel price changes, and the econometric forecasting methods used in similar studies. The literature review showed that fuel price dynamics are complex and are mainly influenced by global crude oil prices, domestic economic indicators, and unexpected external shocks.

The second part describes the data used in the research, the data preparation process, and the applied modeling methods. Monthly data on retail gasoline and diesel prices in Lithuania, macroeconomic indicators, and dummy variables representing external shocks were used to achieve the research objective. Both univariate and multivariate models were applied, while relationships between dependent and independent variables were identified using the Granger causality test. Model accuracy was evaluated using RMSE and MAPE error measures.

The results showed that Prophet-based models provided the most accurate forecasts for both retail gasoline and diesel prices. Gasoline price dynamics were mainly affected by changes in Brent crude oil prices and Lithuania's unemployment rate, while diesel price movements were influenced by Brent crude oil prices and the Harmonised Index of Consumer Prices in the liquid fuel market. The study also found that the COVID-19 pandemic had a statistically significant effect on retail diesel price dynamics, while the impact of the Russia–Ukraine war on diesel prices, as in the gasoline market, was not statistically significant. Forecasts for 2026 showed that Prophet models predicted both fuel price trends relatively accurately at the beginning of the year, but forecasting accuracy decreased significantly in the spring due to rising geopolitical tensions in the Middle East. These results suggest that while Prophet models can effectively capture long-term fuel market trends under normal conditions, their forecasting accuracy becomes much weaker during periods of sudden structural change caused by major geopolitical or economic shocks.

Turinys

Lentelių sąrašas	9
Paveikslų sąrašas	10
Santrumpų ir terminų sąrašas	11
Įvadas.....	12
1. Degalų rinkos bei jų kainą lemiančių veiksnių analizė	14
1.1. Degalų samprata ir rūšys	14
1.2. Degalų rinkos apžvalga	16
1.3. Benzino ir dyzelino kainą lemiantys veiksniai	21
1.4. Degalų kainų dinamikos tyrimuose naudojami metodai	27
1.5. Literatūros apžvalgos apibendrinimas	28
2. Tyrimo metodai	30
2.1. Degalų kainų dinamikos ekonometrinio tyrimo procesas	30
2.2. Duomenų rinkinio analizė	31
2.3. Laiko eilučių stacionarumo samprata ir testavimas.....	33
2.4. Vienmačių laiko eilučių modelių teorinis pagrindas	36
2.5. Daugiamačių laiko eilučių modelių teorinis pagrindas	42
2.5.1. Granger priežastingumo analizė laiko eilučių tyrimuose	43
2.5.2. ARIMAX modelių teorinis pagrindas	44
2.5.3. Prophet modelių teorinis pagrindas	45
2.5.4. ARDL modelių teorinis pagrindas.....	47
2.6. Prognozavimo klaidų įverčių teorinis pagrindas	48
3. Tyrimo rezultatai.....	50
3.1. Priklausomų kintamųjų apžvalga	50
3.2. Nepriklausomų kintamųjų apžvalga	52
3.3. Benzino kainų modeliavimas ir prognozavimas.....	55
3.3.1. Vienmačių benzino kainų modelių vertinimas	56
3.3.2. Benzino kainų ir išorinių veiksnių Granger priežastingumo ryšio vertinimas	56
3.3.3. Daugiamačių benzino kainų modelių vertinimas	57
3.3.4. Benzino kainų dinamikos prognozavimas.....	61
3.4. Dyzelino kainų modeliavimas ir prognozavimas	63
3.4.1. Vienmačių dyzelino kainų modelių vertinimas.....	63
3.4.2. Dyzelino kainų ir išorinių veiksnių Granger priežastingumo ryšio vertinimas.....	64
3.4.3. Mažmeninių dyzelino kainų modelių vertinimas	65
3.4.4. Dyzelino kainų dinamikos prognozavimas ir išorinių šokų poveikio vertinimas	69
Išvados	72
Rekomendacijos	74
Literatūros sąrašas	75
Priedai.....	78
1 priedas. Nepriklausomų kintamųjų dinamikos grafikai.....	78
2 priedas. Vienmačių modelių rezultatai	81
3 priedas. Granger priežastingumo analizės rezultatai	82
4 priedas. VAR modelių išsklotinės.....	84
5 priedas. ARDL benzino kainų modelių išsklotinės.....	88
6 priedas. ARDL dyzelino kainų modelių išsklotinės.....	94

7	priedas. ARIMAX modelių rezultatai	101
8	priedas. Prophet modelių rezultatai	102
9	priedas. Tiksliausio benzino kainos modelio (Prophet) išklotinė.....	103
10	priedas. Tiksliausio dyzelino kainos modelio (Prophet) išklotinė.....	104
11	priedas. Prognozuojamos 2026 metų mažmeninių kainų reikšmės ir jų grafikai.....	105

Lentelių sąrašas

1 lentelė. Pagrindinės degalų rūšys ir jų paskirtis (Sudaryta pagal [1]).....	15
2 lentelė. Moksliniuose šaltiniuose nustatyti benzino ir dyzelino kainų pokyčius lemiantys veiksniai	24
3 lentelė. Tyrimo priklausomi kintamieji.....	31
4 lentelė. Tyrimo nepriklausomi kintamieji	32
5 lentelė. Mažmeninių benzino ir dyzelino kainų kintamųjų aprašomoji statistika.....	50
6 lentelė. Mažmeninių benzino ir dyzelino kainų kintamųjų stacionarumo įvertinimas	52
7 lentelė. Nepriklausomų kintamųjų aprašomoji statistika	52
8 lentelė. Nepriklausomų kintamųjų stacionarumo įvertinimas.....	54
9 lentelė. Vienmačių benzino kainų modelių paklaidų rezultatai	56
10 lentelė. Benzino kainų Granger priežastingumo ryšio vertinimas	57
11 lentelė. Benzino kainų VAR modelių rezultatai	58
12 lentelė. Benzino kainų ARIMAX modelių rezultatai.....	58
13 lentelė. Benzino kainų Prophet modelių rezultatai	59
14 lentelė. Benzino kainų ARDL modelių ex-post rezultatai	60
15 lentelė. Tiksliausio benzino kainų ARDL modelio ex-ante rezultatai	60
16 lentelė. Benzino kainų modelių rezultatų palyginimas	61
17 lentelė. Mažmeninių benzino prognozuojamų bei realių kainų reikšmių palyginimas (Sudaryta pagal [8]).....	62
18 lentelė. Vienmačių dyzelino kainų modelių rezultatai	64
19 lentelė. Dyzelino kainų Granger priežastingumo ryšio vertinimas.....	64
20 lentelė. Dyzelino kainų VAR modelių rezultatai	66
21 lentelė. Dyzelino kainų ARIMAX modelių rezultatai	66
22 lentelė. Dyzelino kainų Prophet modelių rezultatai	67
23 lentelė. Dyzelino kainų ARDL ex-post modelių rezultatai	68
24 lentelė. Tiksliausio dyzelino kainų ARDL modelio ex-ante rezultatai	69
25 lentelė. Dyzelino kainų modelių rezultatai.....	69
26 lentelė. Mažmeninių dyzelino prognozuojamų bei realių kainų reikšmių palyginimas (Sudaryta pagal [8]).....	71

Paveikslų sąrašas

1 pav. Žaliavinės naftos perdirbimo procesas ir pagrindinių naftos produktų susidarymo temperatūros (Sudaryta pagal [4]).....	15
2 pav. 2019-2024 m. laikotarpio skirtingų degalų rūšių paklausos dinamika (Sudaryta pagal [5]) .	16
3 pav. 2019-2024 m. laikotarpio skirtingų degalų rūšių vartojimas Lietuvoje, kilotonomis (Sudaryta pagal [8]).....	17
4 pav. 2013-2025 m. laikotarpio mažmeninių benzino ir dyzelino kainų dinamika Lietuvoje (Sudaryta pagal [8]).....	18
5 pav. Naftos ir jos produktų vartojimo skirtinguose sektoriuose augimo tempas 2021-2024 m. laikotarpiu (Sudaryta pagal [5]).....	19
6 pav. 2006-2025 m. laikotarpio WTI kainų dinamika (Sudaryta pagal [11]).....	20
7 pav. Žaliavinės naftos ir benzino/dyzelino kainas lemiančių veiksnių schema (Sudaryta autoriaus)	27
8 pav. Degalų kainų dinamikos ekonometrinio tyrimo schema (Sudaryta autoriaus)	30
9 pav. Mažmeninių benzino ir dyzelino kainų mėnesių pogrupių grafikai.....	50
10 pav. Mažmeninių benzino ir dyzelino kainų laiko eilučių dekompozicija.....	51

Santrumpų ir terminų sąrašas

Santrumpos:

ADF – Dickey–Fuller testas;

ARDL – autoregresinis su paskirstytais vėlavimais modelis;

ARIMA – integruotas autoregresinis slankiojo vidurkio modelis;

Doc.; (angl. *Assoc. Prof.*) – docentas;

Dr. – daktaras;

EI; (angl. *Energy Institute*) – Energetikos institutas;

ETS – eksponentinio glodinimo modelis;

IEA; (angl. *International Energy Agency*) – Tarptautinė energetikos agentūra;

KPSS – Kwiatkowski–Phillips–Schmidt–Shin testas;

Lekt.; (angl. *Lect.*) – lektorius;

MAPE; (angl. *Mean Absolute Percentage Error*) – vidutinė absoliutinė procentinė paklaida;

OPEC; (angl. *Organization of the Petroleum Exporting Countries*) – Naftą eksportuojančių šalių organizacija;

Prof. – profesorius;

RMSE; (angl. *Root Mean Square Error*) – vidutinė kvadratinė paklaida;

VAR – vektorinės autoregresijos modelis;

WTI; (angl. *West Texas Intermediate*) – Šiaurės Amerikos naftos rinkos etalono kaina;

Terminai:

Egzogeninis – išorinis; ekonomikoje tai kintamasis, kurio reikšmės nustatomos už modelio ribų ir jis nėra paaiškinamas pačios sistemos vidiniais ryšiais.

Ex-ante – kai analizė ar vertinimas, atliekami prieš įvykstant procesui, remiantis prognozėmis ar prielaidomis.

Ex-post – kai analizė ar vertinimas atliekami remiantis faktiniais duomenimis, jau įvykus procesui.

Frakcinė distiliacija – mišinio (dažniausiai naftos) atskyrimo procesas, pagrįstas skirtingų komponentų virimo temperatūrų skirtumais, kai medžiagos atskiriamos kolonoje į atskiras frakcijas.

Hidrovalymas – naftos perdirbimo procesas, kuriame iš naftos frakcijų pašalinami sieros, azoto ir deguonies junginiai.

Įvadas

XXI amžiuje pasaulio ekonomika žengė į moderniąją epochą, kuri pasižymėjo sparčiu technologijų tobulėjimu ir jų pritaikymu kasdieniauose verslo procesuose. Didėjant technologijų pritaikomumui, eksponentiškai augo ir energijos išteklių vartojimas, todėl per pirmuosius du šio amžiaus dešimtmečius išryškėjo energijos sektoriaus pokyčių poveikis kitų sektorių veiklos rezultatams. Dauguma verslų gana greitai suprato, jog efektyvus energijos srautų valdymas ir sudarytos patikimos šių išteklių tiekimo grandinės, padeda sumažinti veiklos riziką, apsisaugant nuo staigių ir netikėtų kainų šuolių, tačiau aukštas nuspėjamumo lygis kuro rinkoje, ženkliai apsunkina tvarių veiklos modelių kūrimo procesus.

Nepaisant technologinio protrūkio, kurį lydėjo spartėjanti skaitmenizacija ir augantys globalizacijos procesai, pasaulio ekonomika išgyveno kelis sąstingio laikotarpius, kurie tam tikrais atvejais peraugo į ekonominius nuosmukius ar net krizes. Dauguma finansų pasaulio ekspertų išskiria 2008-ųjų krizę, kaip ekonomikos pažeidžiamumo pavyzdį, tačiau 2019 metais prasidėjusi COVID-19 pandemija ir nuo 2022 metų besitęsiantis karas Ukrainoje atskleidė globalių verslo modelių trūkumus, kurie yra pagrįsti logistinėmis grandinėmis. Skirtingai nei nekilnojamojo turto rinkos burbulo sukelta krizė 2008 metais, karas ir pandemija tapo pagrindiniais išorinės aplinkos faktoriais, kurie turėjo stiprų poveikį energijos sektoriuje. Logistinių grandinių neapibrėžtumas ir politiniais motyvais priimami sprendimai lėmė energijos išteklių kainų svyravimus, kurie atsispindėjo įvairiuose šalių ūkių sektoriuose. Vertinant energijos išteklių poveikį kitų sektorių rezultatams ypatingas dėmesys yra skiriamas degalų kainoms, kurios tiesiogiai veikia transporto, gamybos, logistikos ir net paslaugų sektorius. Globalių tiekimo grandinių priklausomybė nuo geopolitinių konfliktų ir gamtinių išteklių ribotumo veiksniai lemia tai, jog degalų kainų sudedamųjų dalių dinamika yra sunkiai prognozuojama, o jų staigūs pokyčiai kelia aukštą neapibrėžtumo riziką tiek galutiniams vartotojams, tiek verslams bei šalių ekonomikai.

Temos aktualumas. Atsižvelgiant į aukštą energijos išteklių kainų neapibrėžtumą, siekiant nustatyti finansiškai tvarias veiklos strategijas, kurios padėtų suvaldyti dinamiškoje verslo aplinkoje kylančias rizikas, būtina kurti patikimus degalų kainų prognozavimo modelius, kurie ne tik laiku numatytų galimus kainų pokyčius, bet ir užtikrintų priimtų ekonominių sprendimų pagrįstumą. Tiksli degalų kainų prognozė leistų verslams tinkamai įvertinti veiklos kaštus, planuojant ateinančių laikotarpių biudžetus ir užtikrintų veiklos tęstinumą net ir didelių ekonominių sukrėtimų atveju.

Dauguma šiuolaikinių prognozavimo modelių remiasi ne tik klasikinais statistiniais metodais, bet ir dirbtinio intelekto generuojamais algoritmais, gebančiais apdoroti ypač didelių duomenų kiekio rinkinius ir sėkmingai identifikuoti duomenyse vyraujančius dėsningumus. Verta pastebėti, kad šių dienų aktualijos vis dažniau pasižymi energijos išteklių krizėmis, kurias lemia ne tik žmogaus valdomi veiksniai (politiniai nesutarimai ir karai), bet ir gamtiniai faktoriai, tokie kaip išteklių ribotumas bei klimato kaita. Efektyvūs, statistiniais metodais pagrįsti, degalų kainų prognozavimo modeliai įvertintų tiek žmogiškuosius, tiek gamtinius energijos sektoriaus faktorius, o tai leistų iš anksto numatyti galimus kainų šuolius ir priimti strateginius sprendimus, kurie tinkamai suvaldytų kylančias rizikas makroekonominio ir mikroekonominio kontekstu.

Degalų kainos pasižymi esminiu poveikiu verslo sektorių bei bendros šalies ekonomikos veiklai, todėl tikslių energijos išteklių kainų prognozavimo modeliai tampa pagrindiniu įrankiu, padedančiu suvaldyti šios produkcijos kainų svyravimų riziką. Atsižvelgiant į tai, kad energijos išteklių kainų

dinamika svariai prisideda prie infliacijos augimo ir tiesiogiai veikia verslų veiklos kaštų pokyčius, išsamus prognozavimo modelių tyrimas padės identifikuoti tinkamus degalų kainų modeliavimo įrankius, kurie padės priimti tinkamai pagrįstus strateginius sprendimus ne tik nacionaliniu, bet ir tarptautiniu lygmeniu.

Darbo problema – degalų kainų prognozavimas yra sudėtingas dėl didelio kainų nepastovumo, kurį lemia įvairūs ekonominiai ir geopolitiniai veiksniai. Degalų kainos pasižymi ryškiais struktūriniais lūžiais, sezoniškumu ir jautrumu ekonominių ciklų pokyčiams, todėl skirtingomis ekonominėmis sąlygomis kainų elgsena gali reikšmingai kisti. Dėl šių priežasčių, darbe keliamas klausimas – pagrindiniai degalų – benzino ir dyzelino – kainą lemiantys veiksniai ir koks modelis leidžia geriausiai prognozuoti degalų kainas, įvertinant išorės šokų poveikį.

Darbo tikslas – sukurti mažmeninių benzino ir dyzelino kainų prognozavimo modelį bei įvertinti šokų poveikį jų dinamikai.

Darbo uždaviniai:

1. išanalizuoti mokslinę literatūrą, nagrinėjančią degalų sampratą bei benzino ir dyzelino kainų formavimosi mechanizmus;
2. identifikuoti pagrindinius išorinius veiksnius bei šokus, lemiančius benzino ir dyzelino kainų dinamiką;
3. aprašyti ir teoriškai pagrįsti tyrime taikomus laiko eilučių analizės metodus ir prognozavimo modelius;
4. įvertinti Granger priežastingumo ryšius tarp mažmeninių benzino bei dyzelino kainų ir mokslinėje literatūroje identifikuotų, degalų kainų dinamiką lemiančių, veiksnių;
5. sudaryti mažmeninių benzino ir dyzelino kainų prognozavimo modelius, įvertinant išorinių veiksnių bei šokų poveikį.

Tyrimo metodai: palyginamoji mokslinės literatūros analizė, statistinė antrinių duomenų analizė, priežastingumo vertinimas, laiko eilučių analizė, vienmačių ir daugiamatčių duomenų modeliavimas, prognozavimo modelių tikslumo vertinimas ir palyginimas, rezultatų apibendrinimas bei išvadų formulavimas.

1. Degalų rinkos bei jų kainą lemiančių veiksnių analizė

Degalų kainų prognozavimo modeliai apima daugelį tarpusavyje susijusių veiksnių. Siekiant identifikuoti faktorius, lemiančius degalų kainų svyravimą rinkoje, šiame skyriuje yra atliekama mokslinės literatūros analizė. Analizės metu yra aptariama degalų sąvoka, išskiriamos pagrindinės degalų rūšys bei identifikuojami veiksniai, kurie turi įtakos benzino ir dyzelino kainų susiformavimui, taip pat, apžvelgiamos bendros šių produktų rinkų tendencijos.

1.1. Degalų samprata ir rūšys

Remiantis Tarptautinės energetikos agentūros (angl. *International Energy Agency, IEA*) [1] pateikiama informacija, degalai yra vienas svarbiausių energijos išteklių, užtikrinančių transporto, pramonės, žemės ūkio ir energetikos sektorių veiklą. IEA [1] teigimu, degalų sąvoka apima energiją išskiriančias medžiagas, kurios degimo ar kitų cheminių procesų metu naudojamos mechaniniam darbui, šilumos gamybai ar energijos tiekimui. Kadangi degalų vartojimas yra glaudžiai susijęs su ekonominiu aktyvumu, logistikos procesais ir technologine pažanga, jų rinka išlieka itin jautri makroekonominiams bei geopolitiniams pokyčiams.

Pasauliniu mastu degalų reikšmė atsiskleidžia platesniame pirminės energijos balanso kontekste. Remiantis Energetikos instituto (angl. *Energy Institute, EI*) [2] duomenimis, pasaulio energijos balanse reikšmingą dalį sudaro įvairūs pirminės energijos šaltiniai, tarp kurių svarbiausi yra:

- nafta ir jos produktai;
- anglis;
- gamtinės dujos;
- branduolinė energija;
- atsinaujinantys energijos šaltiniai.

Nors pasaulio energetikos struktūra yra diversifikuota, pastarųjų dešimtmečių dinamika rodo, kad būtent nafta ir jos produktai išlieka vienais svarbiausių bei ekonomiškai jautriausių energijos išteklių. Naftos produktai pasižymi aukštu vartojimo lygiu, reikšmingu poveikiu pasaulio ekonomikai ir išskirtiniu kainų nepastovumu, kurį lemia platus pasiūlos, paklausos, geopolitinių bei makroekonominių veiksnių spektras. Dėl šios priežasties naftos produktų rinkos analizė ir jų kainų prognozavimas išlieka viena svarbiausių energetikos ekonomikos tyrimų kryptių.

Naftos produktai, tai žalios naftos perdirbimo proceso metu išgauti itin degūs skysti arba dujiniai angliavandenilių mišiniai, kurie per milijonus metų susiformavo iš organinių medžiagų liekanų. Naftos produktai yra plačiai naudojami transporto, pramonės, energetikos bei chemijos sektoriuose. IEA [1] pateikiamas naftos produktų sąvokos apibrėžimas išskiria ne tik fizinę produktų kilmę, bet ir jų ekonominę reikšmę. Kiekviena naftos produktų rūšis atlieka unikalias funkcijas pasaulinėje ekonomikos erdvėje, todėl jos pasižymi skirtingomis kainų bei paklausos savybėmis.

Hamiltonas [3] pažymi, kad nors visi naftos produktai kyla iš bendro žaliavinės naftos perdirbimo proceso, degalų kategorijai priskiriami produktai sudaro atskirą heterogeninę grupę, todėl jų kainų elgsena negali būti vertinama kaip vienaalytė sistema. Skirtingos cheminės savybės, technologiniai perdirbimo ypatumai ir galutinio vartojimo paskirtys lemia tai, kad benzino, dyzelino ar kitų degalų rūšių kainų dinamika gali skirtis priklausomai nuo sezoniškumo, reguliacinės aplinkos, ekonominio

aktyvumo ar geopolitinių sukrėtimų. Dėl šių priežasčių, analizuojant degalų rinką per naftos produktų prizmę, būtina atskirai įvertinti skirtingas degalų rūšis ir jų specifines rinkos charakteristikas.

Atsižvelgdama į šiuos skirtumus, IEA [1] degalus klasifikuoja pagal jų paskirtį ir vartojimo sritis, o metiniuose leidiniuose išskiria didžiausią pasaulinės energetikos vartojimo dalį sudarančias degalų grupes. 1 lentelėje yra pateikiamos pagrindinės degalų rūšys, kurios pasižymi didžiausiu vartojimo lygiu pasaulyje.

1 lentelė. Pagrindinės degalų rūšys ir jų paskirtis (Sudaryta pagal [1])

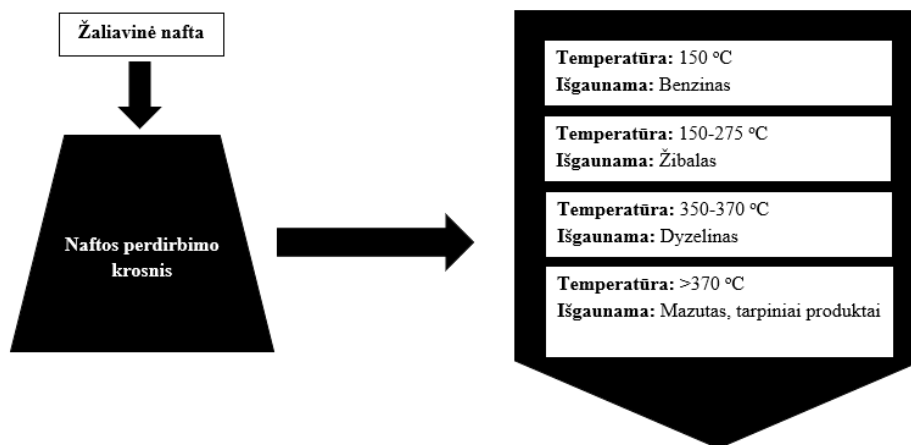
Degalų rūšis	Pagrindinė naudojimo sritis
Benzinas	Lengvųjų automobilių degalai
Dyzelinas	Krovininių ir lengvųjų automobilių degalai
Aviacinis kuras	Oro transporto priemonių degalai
Mazutas	Energetikos sektorius, vandens transporto priemonių degalai
Suskystintos naftos dujos (LPG)	Energetikos sektorius

Pasak Kaiserio ir kt. [4], kiekviena degalų rūšis pasižymi unikalia struktūra, kurią lemia galutinės frakcijų proporcijos žaliavinės naftos perdirbimo procese. Šios proporcijos tiesiogiai priklauso nuo naudojamos žaliavinės naftos savybių bei taikomų technologinių sprendimų. Kaiseris ir kt. [4] savo tyrime akcentuoja, kad žaliavinės naftos kokybę apibrėžia dvi pagrindinės charakteristikos:

- tankis;
- sieros kiekis.

Šie du parametrai lemia ne tik galutinio produkto sudėtį, bet ir perdirbimo kaštus bei technologinių procesų sudėtingumą. Mažesnio tankio ir sieringumo nafta leidžia išgauti didesnės pridėtinės vertės produktus, tuo tarpu didesnio sieros kiekio nafta, reikalauja sudėtingesnių perdirbimo technologijų, įskaitant papildomą hidrovalymo procesą, kuris didina gamybos sąnaudas ir mažina rafinavimo efektyvumą.

Siekiant iliustruoti degalų kilmę ir jų susidarymą žaliavinės naftos perdirbimo procese, 1 paveiksle yra pateikiama naftos frakcinės distiliacijos proceso schema.



1 pav. Žaliavinės naftos perdirbimo procesas ir pagrindinių naftos produktų susidarymo temperatūros (Sudaryta pagal [4])

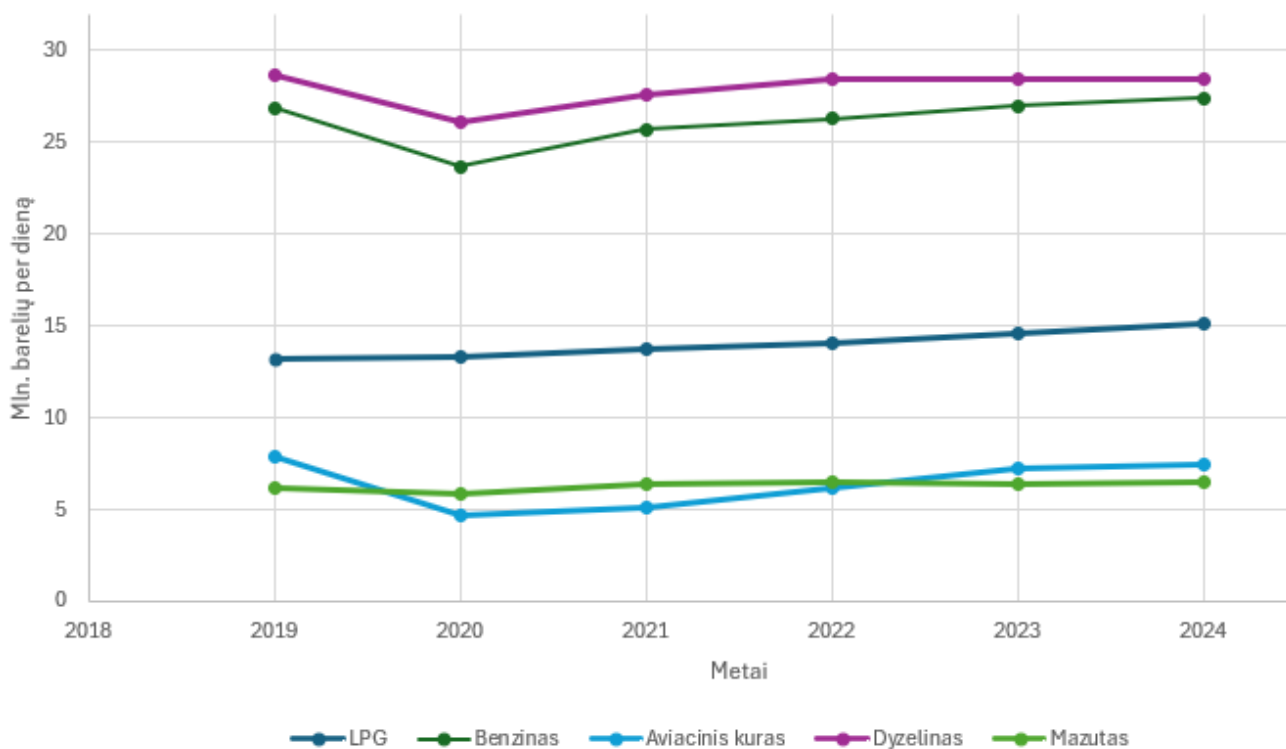
Frakcinės distiliacijos proceso schema atskiria žaliavinę naftą į skirtingas dalis (frakcijas) pagal jų virimo temperatūrą, o kiekviena frakcija tampa pagrindu konkrečiai naftos produktų grupei. Lengviausios frakcijos naudojamos benzinui ir LPG gaminti, vidutinės padeda išgauti dyzeliną ir žibalą, kuris naudojamas aviacinio kuro produktų gamyboje, o sunkiosios frakcijos sudaro mazuto ir visų kitų likusių naftos produktų pagrindą. Technologinių pajėgumų skirtumai tarp naftos perdirbimo gamyklų lemia nevienodą produktų išgavimo struktūrą skirtinguose regionuose, todėl net ir naudojant panašios sudėties žaliavinę naftą, skirtingose šalyse ar regionuose galutinių naftos produktų išgavimo greitis ir kokybė gali skirtis dėl rafinavimo efektyvumo [4].

Taigi, galima teigti, jog degalų samprata apibūdina daugialypę ir struktūriškai sudėtingą energijos išteklių grupę. Atskiri degalų tipai pasižymi nevienodomis savybėmis, lemiančiomis jų paklausos dinamiką, kainų elgseną ir jautrumą makroekonominiams bei geopolitiniams veiksniams. Išsamus degalų sampratos, jų klasifikacijos ir vartojimo struktūros supratimas sudaro teorinį pagrindą šios produkcijos rinkos analizei, kuri tiksliai identifikuos degalų rinkos pokyčius lemiančius veiksnius.

1.2. Degalų rinkos apžvalga

IEA [1] nurodo, kad degalų rūšys skiriasi ne tik savo cheminėmis savybėmis, bet ir ekonomine reikšme, nes kiekviena rūšis atlieka specifinę funkciją pasaulinėje energetikos sistemoje. Siekiant įvertinti degalų rinkos raidą, pirmiausia būtina identifikuoti konkrečias degalų rūšis, kurių kainos bus modeliuojamos tyrimo metu.


Vienas iš degalų rinkos elementų yra paklausos struktūra. Remiantis 2 paveiksle pateikiama skirtingų degalų rūšių pasaulinės paklausos dinamika 2019-2024 metų laikotarpiu, galima teigti, kad dyzelino ir benzino produktų vartojimas pasauliniu mastu išliko didžiausiu lyginant su likusiais degalų produktais.



2 pav. 2019-2024 m. laikotarpio skirtingų degalų rūšių paklausos dinamika (Sudaryta pagal [5])


Atsižvelgus į Europos Komisijos [6] pateikiamus duomenis, galima teigti, kad dyzelino bei benzino vartojimo dalis Europos Sąjungos šalyse yra gerokai didesnė nei kitų degalų rūšių ir siekia maždaug 64 % visos degalų paklausos. Tokia didelė benzino ir dyzelino paklausa Europos šalyse yra siejama su intensyviu krovinių transporto naudojimu logistiniuose procesuose ir istoriniu dyzelinių transporto priemonių paplitimu. Pasak Kilianus ir Zhou [7], dėl intensyvaus dyzelino kuro vartojimo komercijoje, jo kainos tampa dar labiau priklausomos nuo pramonės gamybos ciklų, tarptautinės prekybos srautų ir ekonomikos augimo tempo, skirtingai nei benzino kainos, kurios dažniau reaguoja į namų ūkių pajamų ir vartotojų elgsenos pokyčius.

Vertinant situaciją Lietuvos degalų rinkoje, pastebimos panašios tendencijos kaip ir kitose Europos Sąjungos šalyse. Įvertinus 3 paveiksle pateikiamą degalų vartojimo Lietuvos rinkoje statistiką, galima teigti, jog populiariausia degalų rūšis yra dyzelinas, kuris pasižymi ypač dideliu vartojimo lygiu pramonės ir transporto sektoriuose. Antroje vietoje pagal vartojimo apimtį yra benzinas, kurio paklausa daugiausia siejama su lengvųjų automobilių naudojimu namų ūkiuose. Nors benzino vartojimas yra mažesnis nei dyzelino, jis išlieka reikšminga Lietuvos degalų rinkos dalimi, ypač urbanizuotose teritorijose, kur intensyvus lengvųjų automobilių eismas lemia nuolatinę paklausą.



3 pav. 2019-2024 m. laikotarpio skirtingų degalų rūšių vartojimas Lietuvoje, kilotonomis (Sudaryta pagal [8])

Atsižvelgiant į tai, jog tiek Europos Sąjungos, tiek Lietuvos rinkose didžiausia paklausa pasižymi dyzelinas bei benzinas, būtent šių dviejų degalų rūšių kainų tendencijos padės įvertinti degalų rinkos dinamiką. Mažmeninių benzino ir dyzelino kainų grafikai yra pateikiami 4 paveiksle.




4 pav. 2013-2025 m. laikotarpio mažmeninių benzino ir dyzelino kainų dinamika Lietuvoje (Sudaryta pagal [8])

Benzino ir dyzelino kainų dinamikos grafikai atskleidžia, reikšmingus ilgalaikius bei trumpalaikius degalų kainų svyravimus Lietuvos rinkoje. 2013-2014 metų laikotarpiu tiek benzino, tiek dyzelino kainų pokyčiai pasižymėjo siauromis svyravimų amplitudėmis, tačiau nuo 2014 m. spalio mėnesio abiejų degalų rūšių kainose buvo fiksuojamas staigus kritimas. Ši mažėjimo tendencija tęsėsi iki 2015 metų pradžios, kai benzino ir dyzelino kainos pasiekė lokalius minimumus, po kurių vėlgi sekė staigus, tačiau trumpalaikis kainų šuolis iki 2025 metų gegužės. 2016 metų pradžioje, kainų nepastovumas benzino bei dyzelino rinkose stabilizavosi ir įgavo nuosaikią ilgalaikę augimo tendenciją. Šis kainų augimo etapas buvo lydintas trumpalaikių svyravimų ir tęsėsi iki 2018 metų spalio, kai buvo užfiksuotas dar vienas struktūrinis duomenų lūžis. 2019 metų pradžioje tiek benzino, tiek dyzelino kainos vėl pradėjo mažėti ir sausio mėnesį pasiekė lokalų minimumą, po kurio rinkoje vėl susiformavo santykinio stabilumo laikotarpis. Ryškiausias benzino ir dyzelino kainų dinamikos struktūrinis lūžis įvyko 2020 metų kovo mėnesį, kai degalų kainos pradėjo smarkiai mažėti ir gegužės mėnesį pasiekė žemiausią analizuojamo laikotarpio tašką. Šie degalų kainų dinamikos pokyčiai Lietuvos rinkoje buvo siejami su COVID-19 pandemijos pradžia bei įvestais griežtais ekonominės veiklos ribojimais, kurie lėmė neigiamą paklausos šoką transporto ir logistikos sektoriuose. Po COVID-19 sukulto šoko, benzino ir dyzelino kainos stabilizavosi 2021 metų pradžioje, kai kainų dinamika vėl įgavo spartaus augimo tendenciją, kurią lėmė rinkų atsigavimas dėl sušvelnintų ekonominės veiklos apribojimų. 2022 metų vasarį prasidėjęs karas Ukrainoje paskatino dar didesnę benzino ir dyzelino kainų augimo tempą pirmojoje metų pusėje. Spartus ekonomikos atsigavimas po pandemijos, padidėjusi energijos išteklių paklausa bei geopolitinės įtampos augimas lėmė tai, jog 2022 metų birželį buvo pasiektos maksimalios benzino ir dyzelino kainų lygio reikšmės nagrinėjamo laikotarpio metu. Nors abiejų degalų rūšių kainų pokyčių kryptys sutapo, dyzelino kainų svyravimai buvo ryškesni ir dažnesni. Nuo 2022 metų antrosios pusės benzino ir dyzelino kainos pradėjo mažėti ir galutinai stabilizavosi tik 2023 metų pirmoje pusėje. Benzino kainos stabilizavosi sausio mėnesį, o dyzelinų kainų mažėjimas tęsėsi iki birželio mėnesio. Šis skirtumas tarp benzino ir dyzelino kainų dinamikos po karo Ukrainoje pradžios atspindi iki 2025 metų pabaigos vyravusias tendencijas degalų rinkoje, remiantis kuriomis, tiek benzino, tiek dyzelino kainos išliko aukštesniame lygyje nei prieš karą ir pasižymėjo didesnėmis svyravimų amplitudėmis. Apibendrinant galima teigti, kad benzino ir dyzelino kainų dinamika 2013-2025 m. laikotarpiu atskleidžia reikšmingus struktūrinius duomenų nestabilumus, svyravimus bei didelį jautrumą globaliems ekonominiams ir geopolitiniais šokams.

Apie tai, kad benzino ir dyzelino kainoms yra būdingas aukštas nepastovumo lygis, kuris priklauso nuo žaliavinės naftos kainų ir yra tiesiogiai susijęs su makroekonominiais bei geopolitiniais procesais užsimena Fattouhas ir Mahadeva [9], kurie teigia, kad benzino ir dyzelino kainos yra unikalios tuo, jog jos apima ne tik fizinių produktų mainus, bet ir finansinius bei institucinės politikos mechanizmus, todėl šių produktų rinka dažnai analizuojama kaip globali sistema, kurioje regioniniai įvykiai gali turėti plataus masto pasekmių.

Vertinant tai, kad benzinas ir dyzelinas sudaro didžiausią naftos produktų paklausos dalį Europos Sąjungos ir Lietuvos rinkose, natūralu, jog šių degalų rūšių kainos yra glaudžiai susijusios su bendru žaliavinės naftos ir jos produktų vartojimu pasaulinėje rinkoje. 5 paveiksle yra pateikiama naftos ir iš jos pagamintų produktų vartojimo augimo tempo dinamika dominuojančiuose energijos vartojimo sektoriuose, milijonais barelių per dieną.



5 pav. Naftos ir jos produktų vartojimo skirtinguose sektoriuose augimo tempas 2021-2024 m. laikotarpiu (Sudaryta pagal [5])

Analizuojant naftos ir jos produktų vartojimo augimo tempo dinamiką pagal sektorius, išryškėja aiškios struktūrinės tendencijos, atspindinčios platesnius ekonomikos ciklus. 2021 ir 2022 metais didžiausią vartojimo augimo tempo dalį sudarė kelių transporto sektorius, tačiau nuo 2023 metų jo augimo tempas pastebimai sulėtėjo. Šį pokytį galima sieti su efektyvesnių transporto priemonių diegimu, didėjančiu elektromobilių skaičiumi bei platesniu alternatyvių energijos šaltinių naudojimu.

Aviacijos ir pramonės sektoriuose naftos vartojimo augimo tempas per visą analizuojamą laikotarpį išliko santykinai stabilus, nors 2022 metais pramonės sektoriuje buvo fiksuotas neigiamas augimo lygis. Tuo tarpu kitų sektorių vartojimo augimo tempas nuosekliai mažėjo visus ketverius metus, o tai rodo palaipsniui mažėjančią jų priklausomybę nuo benzino, dyzelino ir kitų naftos produktų bei spartėjančią energetinę diversifikaciją.

Įvertinus įvairius degalų rinkos aspektus, galima konstatuoti, jog didžiausia paklausa tiek Lietuvos, tiek Europos Sąjungos mastu pasižymi būtent benzino ir dyzelino degalų rūšys. Analizės metu, taip pat, buvo įvertinta benzino ir dyzelino kainų dinamika, pasižymėjusi akivaizdžiais struktūriniais lūžiais, kuriuos lėmė išoriniai šokai. Dėl šios priežasties, degalų kainų svyravimai negali būti pilnai

paaškinami vien vidiniais rinkos veiksniais, todėl tikslinga plačiau aptarti išorinių šokų sampratą ir jų vaidmenį degalų kainų susiformavimo procesuose.

Mokslinėje literatūroje šokai suprantami kaip staigūs, netikėti ir fundamentaliai rinkos pusiausvyrą keičiantys įvykiai. Degalų rinkoje šokai formuojasi dėl pasiūlos sutrikimų, paklausos pokyčių, geopolitinių konfliktų, finansų rinkų įtampos ar makroekonominių pakitimų. Šokų netikėtumo faktorius ir stiprus poveikis kainų dinamikai lemia tai, jog šokų poveikio benzino ir dyzelino kainoms analizė yra viena svarbiausių energetikos sektoriaus tyrimų kryptių.

Analizuojant benzino ir dyzelino kainų šokus, pirmiausia būtina įvertinti, kaip šokai pasireiškia žaliavinės naftos rinkoje, nes būtent joje formuojasi pirminiai impulsai, kurie vėliau pasireiškia galutinėse degalų kainose. Vienas patikimiausių rodiklių, atspindinčių šokus žaliavinės naftos rinkoje, yra kainų dinamika. Nagrinėdami žaliavinės naftos kainų tendencijas Zhangas ir kt. [10], savo tyrime pasitelkė Šiaurės Amerikos naftos rinkos etalono West Texas Intermediate (WTI) kainą, kuris 6 paveiksle pateikia žaliavinės naftos barelio vertę JAV doleriais (USD).



6 pav. 2006-2025 m. laikotarpio WTI kainų dinamika (Sudaryta pagal [11])

WTI kainų dinamikos grafike pastebimas akivaizdus žaliavinės naftos kainos šuolis iki 133,96 dolerių už barelį ribos 2008 metais liepos mėnesį, kurį lėmė jau anksčiau minėta finansų krizė, ir jį lydintis staigus kainos mažėjimas 2009 metais. Per 2008 metų krizę naftos produktų vartojimas ženkliai susitraukė, tuo tarpu pasiūla praktiškai nekito. Dėl šių priežasčių, 2009 metų vasario mėnesį, žaliavinės naftos šaltinių rezervai buvo perpildyti, kas lėmė staigų kainos sumažėjimą iki 39,08 dolerių už barelį ribos. Galiausiai, žaliavinės naftos kaina rinkoje stabilizavosi 2009 metų birželio mėnesį ties 69,67 dolerių už barelį riba. Šie kainų pokyčiai atspindi pasiūlos ir paklausos pusiausvyros dinamiką bei jos poveikį benzino ir dyzelino kainoms, kurį savo moksliniuose tyrimuose minėjo Alhaedas ir Husseinai [12] bei Hosseini ir kt. [13]. Mokslininkų išvados taip pat atsispindi ir 2020 metų balandžio mėnesio WTI kainoje (pastebimas ženklus sumažėjimas iki 16,98 dolerių už barelį ribos), kai dėl pandemijos apribojimų dauguma verslų sustabdė savo veiklą, todėl, panašiai kaip ir 2008 metais, ženkliai sumažėjo naftos produktų vartojimas. Po 2020 metais užklupto COVID-19 pandemijos šoko, žaliavinės naftos rinka sąlyginai stabilizavosi 2021 m. balandžio mėnesį, kai WTI

kaina grįžo į nuosaikaus augimo intervalą ties 61,42 dolerių už barelį riba. Šis stabilumo laikotarpis tęsėsi iki 2022 m. vasario 24 d., kai prasidėjo Rusijos karas prieš Ukrainą ir žaliavinės naftos rinkoje susiformavo naujas geopolitinis šokas.

Sulaukus oficialaus Rusijos karinių veiksmų pradžios paskelbimo, žaliavinės naftos kainos rinkoje įgijo spartaus augimo tempą [10]. Pagal WTI kainas, nuo karo Ukrainoje pradžios, naftos kaina sparčiai augo iki 2022 metų birželio mėnesio pradžios, kai barelio kaina stabilizavosi pasiekus aukščiausią tašką nuo 2008 metų ir sustojus ties 114,7 dolerių už barelį riba. Pasak Zhango ir kt. [10] ši kainos augimą sukėlė energijos sandorių sankcijos, kurios lėmė tiekimo grandinių žlugimą ir neužtikrintumą dėl ateities sandorių. Be pritaikytų sankcijų, didžiojo septyneto šalys taip pat įvedė Rusijos eksportuojamos žaliavinės naftos kainos lubas, kurios neigiamai paveikė tarptautinės prekybos srautą.

Įvertinus mokslinėje literatūroje taikomus šokų identifikavimo metodus ir WTI kainų dinamiką, galima išskirti tris reikšmingus išorinių veiksnių šokus, atspindinčius žaliavinės naftos kainose. Pirmasis – 2008 m. finansų krizė, kurios poveikis WTI kainoms tęsėsi nuo 2008 m. liepos iki 2009 m. birželio ir pasižymėjo itin dideliu kintamumu dėl staiga susitraukusios paklausos. Antrasis – COVID-19 pandemijos šokas, prasidėjęs 2020 m. balandį ir trukęs iki 2021 m. balandžio, kai dėl pasaulinių veiklos apribojimų ir paklausos nuosmukio naftos kainos patyrė reikšmingų svyravimų. Trečiasis – 2022 m. Rusijos karo prieš Ukrainą sukeltas šokas, kurio poveikis WTI kainoms buvo ryškiausias nuo 2022 m. vasario iki 2022 m. birželio, kai rinką paveikė sankcijos, tiekimo grandinių sutrikimai ir geopolitinis neužtikrintumas. Nors šie laikotarpiai žymi aiškius ekonominių ir geopolitinių sukrėtimų etapus, bendras WTI kainų elgesys patvirtina literatūroje aprašytą dėsningumą, jog po staigių kainų šuolių ar kritimų rinka ilguoju laikotarpiu grįžta į naują pusiausvyrą, kuri formuojasi pagal paklausos ir pasiūlos santykį.

1.3. Benzino ir dyzelino kainą lemiantys veiksniai

Akivaizdu, jog žaliavinė nafta yra vienas svarbiausių išteklių pasauliniu mastu, tačiau pačios naftos naudojimas yra ribotas, nes šį produktą būtina apdirbti prieš pateikiant jį galutiniam vartotojui. Pasak EI [2], maždaug 80-90% perdirbamos naftos yra naudojama degalų gamyboje, o tokį aukštą žaliavinės naftos vartojimo lygį kuro pramonėje sąlygoja jos lengvas pritaikomumas gaminant skirtingų rūšių degalus. EI [2] patvirtina aukštą naftos pritaikomumo lygį energijos sektoriuje konstatuodami, kad pasitelkus neapdirbtos naftos atsargas galima sukurti šias degalų rūšis:

- Benzina (lengvųjų automobilių kuras),
- Dyzeliną (sunkiosios technikos ir transporto priemonių kuras) ir
- Mazutą (jūrinio transporto kuras).

Kadangi žaliavinė nafta yra naudojama skirtingų degalų rūšių gamyboje ir neturi tinkamų alternatyvų, natūralu, jog veiksniai, lemiantys naftos kainų pokyčius tiesiogiai veikia ir benzino bei dyzelino kainų dinamiką. Šią išvadą konstatuoja Hosseini ir kt. [13], pripažindami, jog žaliavinės naftos kaina sudaro pagrindinę benzino, dyzelino ir visų kitų naftos produktų kainų struktūros dalį, o jos svyravimai tiesiogiai persiduoda naftos produktų kainoms galutinio vartojimo rinkose.

Žaliavinės naftos rinka išsiskiria tuo, jog jos kainų dinamiką neįmanoma paaiškinti remiantis vien tik klasikiniu pasiūlos ir paklausos modeliu, nes jų susiformavimą lemia platus veiksnių spektras, apimantis ne tik ekonominius rodiklius, bet ir geopolitinio stabilumo, tarptautinių politinių

sprendimų, technologinės pažangos energijos gavybos srityje bei vis griežtėjančios klimato kaitos ir aplinkosaugos politikos faktorių rinkinį. Tokie veiksniai įvairovė lemia didelį kainų nepastovumą ir apsunkina jų ilgalaikį prognozavimą [12].

Atsižvelgiant į šiuos aspektus, galima teigti, jog žaliavinės naftos kainą lemiantys veiksniai turi tiesioginį poveikį benzino ir dyzelino kainoms, todėl būtina juos įvertinti, atliekant galutinių benzino ir dyzelino kainų dinamikos analizę.

Kilianas ir Zhou [7] teigia, kad žaliavinės naftos kainų dinamiką lemia pasaulinės ekonomikos augimo tempai bei pramonės ir transporto sektorių veiklos intensyvumas, kurie priskiriami ekonominių veiksnių grupei. Tyrėjai nurodo, jog spartus ekonomikos augimas sukelia reikšmingus žaliavinės naftos paklausos šuolius ir lemia ilgalaikes kainų kilimo tendencijas, o ekonomikos lėtėjimo ar recesijos laikotarpiais, naftos kainos pasižymi mažėjimo tendencijomis dėl susitraukusio vartojimo ir stiprėjančio rinkos spaudimo. Šio ryšio identifikavimas yra itin svarbus prognozavimo kontekste, nes ekonominiai ciklai pasižymi nevienoda trukme bei skirtingu poveikio intensyvumu, todėl jų įtaka kainų formavimuisi nėra simetriška.

Prie ekonominių veiksnių grupės taip pat galima priskirti ir finansų rinkų stabilumą. Pasak Antonakakis ir kt. [14], didėjantis finansinis neapibrėžtumas didina kainų nepastovumą tais atvejais, kai žaliavinė nafta prekybos sandoriuose yra pateikiama ne kaip fizinis energijos išteklius, o kaip finansinė investicija. Tokiu būdu, finansinių krizių metu didėjant finansinių instrumentų kainų svyravimams, žaliavinės naftos kainos irgi patiria pokyčius, kurie dažniausiai neatspindi pasiūlos ar paklausos variacijų. Dėl šių priežasčių, žaliavinės naftos kainų tendencijų įvertinimui siūloma taikyti kompleksinę požiūrį, integruojant tiek ekonomikos, tiek finansų rinkų dinamikos veiksniai [14].

Rinkos dalyvių lūkesčių ir jų elgsenos veiksniai mokslinėje literatūroje yra vertinami kaip vieni iš sudėtingiausių ekonominių faktorių veikiančių žaliavinės naftos kainų dinamiką. Alquistas ir kt. [15] bei Ready [16] teigia, kad rinkos dalyvių lūkesčiai, gaunamos informacijos interpretavimas bei psichologiniai jos vertinimo mechanizmai gali lemti trumpalaikius kainų svyravimus, kurie nėra tiesiogiai susiję su pasiūlos ar paklausos pokyčiais. Tokie svyravimai dažnai kyla dėl rinkos dalyvių reakcijos į naujienas, prognozes, kažkokius politinius signalus arba tiesiog gandas, todėl žaliavinės naftos kainų pokyčiai tokiais atvejais yra labiau susiję su informacijos suvokimu nei su realiais ekonomiais procesais. Šis ekonominis veiksnys dažnai pasireiškia trumpalaikiuose kainos pokyčiuose ir yra sunkiai modeliuojamas, nes skirtingas lūkesčių formavimasis gali sukelti staigius ir neprognozuojamus kainų šuolius.

Nagrinėjant naftos rinkos pokyčius Liu ir kt. [17] atkreipia dėmesį į tai, jog nuo 2008 metų krizės, naftos kainų pokyčius vis mažiau lemia paklausos bei pasiūlos pusiausvyra, nes šiai rinkai vis didesni poveikį turi spekuliacijos finansų rinkose. Liu ir kt. [17] teigia, kad spartėjantys globalizacijos procesai pašalina ekonomines ribas ne tik tarp pasaulio regionų, bet ir tam tikrų sektorių. Nuolat didėjantis žmonių priklausomumas nuo energijos išteklių lėmė tai, jog naftos produkcija tiesioginiu ar netiesioginiu būdu yra plačiai naudojama praktiškai visuose verslo sektoriuose. Platus naftos produkcijos naudojimas lemia ypatingai didelį naftos kainų pokyčių poveikį šalių pasaulinės ekonomikos stabilumui, todėl Liu ir kt. [17] teigia, jog naftos produktų rinka savo poveikiu globalios ekonomikos stabilumui, panašėja į finansų rinkas, kuriose vykstančios nuolatinės spekuliacijos, gali sukelti pasaulinio lygio krizes. Šis rinkų supanašėjimas nėra atsitiktinis, nes tiek finansinių, tiek energijos produktų kainų šuolius dažnai lemia politiniai nesutarimai arba nenumatytos katastrofos,

tačiau toks rinkų supanašėjimas neišvengiamai didina jų tarpusavio poveikį vienas kitam. Pasak Liu ir kt. [17] rinkoje įsivyravus neužtikrintumui dėl finansų rinkų stabilumo ateityje, finansinių instrumentų spekuliacijos, gali lemti naftos produkcijos tiekimo srautų sumažėjimą, kuris tokiu atveju sukeltų spekuliacinį burbulą naftos rinkoje.

Alhaedas ir Husseinai [12] bei Zhangas ir kt. [10] išskiria geopolitinius pokyčius kaip vieną reikšmingiausių veiksnių, lemiančių trumpalaikius žaliavinės naftos kainų pokyčius. Geopolitiniai neramumai dažnai pasižymi ypatingai dideliu neapibrėžtumu, o tai ženkliai riboja jų prognozavimo galimybes, todėl politinis nestabilumas pagrindiniuose naftos gavybos regionuose (Artimieji Rytai, Šiaurės Afrika, Rytų Europa) tiesiogiai veikia rinkos dalyvių lūkesčius – naftos gavyba užsiimančios bendrovės yra linkusios gauti papildomą kompensaciją už patiriamą riziką, vykdant savo veiklą politiškai nestabilioje aplinkoje. Tokiais atvejais, žaliavinės naftos kaina, kurią sumoka pirkėjai, ženkliai išauga dėl papildomos „rizikos premijos“ nors naftos pasiūla tuo metu išlieka nepakitusi, todėl galima teigti, kad rinkos neapibrėžtumo augimas ir investuotojų siekis apsidrausti nuo potencialių rizikų žaliavinės naftos rinkoje gali sukelti nenumatytus kainų pokyčius.

Šias išvalgas taip pat patvirtina Caldara ir Iacoviello [18] bei jų mokslinio tyrimo rezultatai, kurie nurodo, jog geopolitinės rizikos indeksų augimas turi statistiškai reikšmingą poveikį naftos kainų kintamumo augimui, o kainų reakcijos dažnai pasireiškia dar iki realių politinių sprendimų ar karinių veiksmų. Hamiltonas [3] taip pat akcentuoja, jog geopolitiniai įvykiai turi poveikį ne tik naftos pasiūlai, bet ir finansų rinkų mechanizmams, per kuriuos formuojasi rinkos dalyvių lūkesčiai dėl būsimų kainų, todėl žaliavinės naftos rinka yra ypatingai jautri įvairioms politinėms naujienoms ar spekuliacijoms.

Tiek Alhaedas ir Husseinai [12], tiek Hosseini ir kt. [13] akcentuoja, jog žaliavinės naftos kaina ir jos pokyčiai yra tiesiogiai susiję su geopolitine aplinka, tačiau savo tyrimuose šie mokslininkai nenagrinėja karinių veiksmų skirtinguose pasaulio regionuose poveikio naftos kainos atžvilgiu. Zhangas ir kt. [10] šį faktorių išanalizuoja detaliau, patvirtindami, jog žaliavinės naftos kainos pasižymi dideliu jautrumu geopolitiniams ir ekonominiams svyravimų įvykiams. Kaip pavyzdį, Zhangas ir kt. [10] pateikia Rusijos invazijos į Ukrainą poveikį žaliavinės naftos kainoms 2022 metais. Prieš karo pradžią, Rusija sudarė maždaug 12 procentų viso pasaulio naftos gavybos ir pagal šį rodiklį nusileido tik Jungtinėms Amerikos Valstijoms. Įvedus ekonomines sankcijas Rusijai, jos dalis naftos gavyboje sumažėjo iki 11 procentų, o naftos produktų rinkoje įsivyravo nenumatyti kainų svyravimai, kuriuos lėmė ekonominis šokas, todėl galima teigti, kad karinis konfliktas Ukrainoje fundamentaliai pakeitė žaliavinės naftos kainų dinamikos tendencijas ir suteikė šiai rinkai dar didesnę nepastovumą.

Zhangas ir kt. [10] teigia, kad karas Ukrainoje, be trumpalaikio poveikio žaliavinėms naftos kainoms, pasižymės ir ilgalaikėmis pasekmėmis, kurios pakeis pagrindines rinkos veikimo sąlygas. Naujų ekonominių sankcijų įvedimas prieš Rusiją ir jų sugriežtinimas, privers Europos šalis keisti savo energijos sektorių vykdomą politiką, diversifikuojant žaliavinės naftos importą ir didinant atsinaujinančios energijos šaltinių naudojimą, kurie yra vertinami kaip tvaresni žaliavinės naftos pakaitalai.

Gamtinių išteklių veiksniai, tokie kaip naftos rezervų dydis ir gavybos pajėgumų ribotumas, formuoja ilgalaikes žaliavinės naftos kainų tendencijas ir lemia struktūrinę rinkos jautrumą pasiūlos pokyčiams. IEA [1] duomenys rodo, kad naftos gavybos pajėgumų ribotumas padidina rinkos jautrumą bet kokiems pasiūlos sutrikimams, todėl įvairūs geopolitiniai, technologiniai ar infrastruktūriniai

trikdžiai gali sukelti neproporcingai didelius žaliavinės naftos kainų svyravimus. Rinka neturi pakankamo rezervinio pasiūlos mechanizmo, kuris galėtų greitai ir efektyviai kompensuoti netikėtus pasiūlos šokus, todėl galima teigti, kad žaliavinės naftos išteklių rezervų lygis bei gavybos pajėgumų dinamika yra vieni iš pagrindinių veiksnių, lemiančių ilgalaikį žaliavinės naftos kainų stabilumą.

Verta pastebėti, kad nepaisant tiesioginio žaliavinės naftos kainų poveikio, negalima teigti, jog analizuojant benzino ir dyzelino kainų pokyčius, užtenka įvertinti tik žaliavinės naftos kainą lemiančius veiksnius, nes degalų, kaip galutinės vartojimo prekės kainą lemia ir papildomi gamybos bei logistiniai procesai, kurių poveikį būtina atskirai įvertinti, atliekant kainų modeliavimo tyrimus. 2 lentelėje yra pateikiama mokslinės literatūros šaltiniuose išskiriamų, benzino ir dyzelino kainas lemiančių, veiksnių apžvalga.

2 lentelė. Moksliniuose šaltiniuose nustatyti benzino ir dyzelino kainų pokyčius lemiantys veiksniai

Veiksnių grupė	Veiksnys	Autorius
Ekonominiai	Žaliavinės naftos produkcijos vartojimas	Gyagri ir kt. [19]
	Naftos apdirbimo kaštai	Gyagri ir kt. [19]
	Valstybės degalų rezervų dydis	Gyagri ir kt. [19]
	Naftos šaltinių rezervų lygis	IEA [1]
	Žaliavinės naftos kainų pokyčiai	Gyagri ir kt. [19], Kilianas ir Zhou [7]
	Ekonominio aktyvumo ciklai	Baumeisteris ir Kilianas [20], Kilianas ir Zhou [7]
	Finansų rinkų stabilumas	Liu ir kt. [17], Antonakakis ir kt. [14]
	Rinkos dalyvių lūkesčiai	Alquistas ir kt. [15]; Ready [16]
	Kainų dinamikos poveikio asimetrija	Borensteinas ir kt. [21]
	Degalų rinkos konkurencijos lygis	Kilianas ir Zhou [7], Borensteinas ir kt. [21]
	Rinkos informacijos asimetrija	Borensteinas ir kt. [21]
Politiniai	Akcizų ir subsidijų taikymas	Gyagri ir kt. [19], Marinas ir Zanfei [22]
	Šalies mokesčių struktūra	Gyagri ir kt. [19], Marinas ir Zanfei [22]
	Geopolitinis vietinio regiono stabilumas	Alhaedas ir Husseinai [12], Zhangas ir kt. [10], Caldara ir Iacoviello [18], Hamiltonas [3], Hosseini ir kt. [13]
	Degalų kainų reguliavimas	Marinas ir Zanfei [22]
Technologiniai	Naftos apdirbimo pajėgumai	Ederingtonas ir kt. [23]
Logistiniai	Logistinių grandinių išsivystymo lygis	Gyagri ir kt. [19], Ederingtonas ir kt. [23]
	Degalų tiekimo infrastruktūros patikimumas	Ederingtonas ir kt. [23]
Aplinkosauginiai	Atsinaujinančių energijos šaltinių paklausa	Ederingtonas ir kt. [23]

Benzino ir dyzelino kuro kainų susiformavimas, mokslinėje literatūroje yra vertinamas kaip procesas, kurį lemia skirtingų sričių veiksnių visuma. Pasak Gyagri ir kt. [19], panašiai kaip ir žaliavinės naftos kainos, benzino bei dyzelio produkcijos vertinimą rinkoje lemia platus spektras ekonominių, politinių

bei rinkos rodiklių, tačiau pagrindine kuro produkcijos kainos sudedamąja dalimi išlieka būtent žaliavinės naftos kaina. Gyagri ir kt. [19] savo tyrime taip pat patvirtina, jog žaliavinės naftos paklausos bei pasiūlos dinamika, geopolitiniai konfliktai ir OPEC šalių priimami sprendimai dėl naftos gavybos kiekio turi stiprų poveikį kuro kainoms, tačiau be šių veiksnių, mokslinėje literatūroje taip pat galima išskirti papildomus faktorius, kurie išskirtinai veikia tik benzino bei dyzelino kuro kainų dinamiką ir neturi jokio poveikio žaliavinės naftos vertinimui rinkoje. Vienas iš pagrindinių tokių veiksnių yra naftos perdirbimo kaštai. Šių išlaidų dydis dažnai priklauso nuo perdirbimo proceso kompleksiskumo, kurį lemia išgautos žaliavinės naftos kokybė ir klampumas. Didesnio klampumo nafta reikalauja intensyvesnių ir laikui imlesnių apdirbimo procesų, todėl natūralu, jog prastesnės kokybės žaliavinės naftos naudojimas dažnai lems išaugusius gamybos kaštus, o tai atsispindės ir galutinėje kuro kainoje.

Gyagri ir kt. [19] taip pat akcentuoja, jog dauguma šalių turi atskiras saugyklas, kuriose yra sandėliuojamos žaliavinės naftos kuro produktų atsargos, kurios gali būti naudojamos kirtiniais atvejais, kai kuro tiekimo grandinės nutrūksta arba rinkos vartojimas ženkliai viršija pasiūlą. Tokiu būdu, valstybės panaudodamos savo rezervus, sugeba suvaldyti staigų benzino bei dyzelino kainų augimą ir sugrąžina jas į rinkos normos ribas.

Kilianas ir Zhou [7], kaip ir Gyagri ir kt. [19] savo tyrime akcentuoja, kad nors žaliavinės naftos kainų pokyčiai neturi tiesiogiai proporcingo poveikio galutinėms benzino ir dyzelino kuro kainoms, tačiau šis faktorius išlieka pagrindine jų susiformavimo pagrindu. Kilianas ir Zhou [7] teigia, kad kainų pokyčio mechanizmas veikia asimetriškai, todėl žaliavinės naftos kainų šokai benzino ir dyzelino kainose pasireiškia su tam tikrais vėlinimais, kurių trukmė priklauso nuo rinkos struktūros, konkurencijos lygio, paklausos elastingumo ir naftos perdirbimo pajėgumų.

Rinkos struktūros veiksniai dar labiau sustiprina šią asimetriją. Kilianas ir Zhou [7] atskleidžia, kad žaliavinės naftos kainų dinamikos poveikis degalų kainoms gali skirtis intensyvumu priklausomai nuo šoko krypties, pavyzdžiui, augant naftos kainoms, benzino ir dyzelino kainos dažnai reaguoja gerokai greičiau, nei tais atvejais, kai žaliavinės naftos kaina rinkoje mažėja. Toks dėsningumas degalų rinkoje pasireiškia dėl rinkos dalyvių siekiamybės kompensuoti ankstesniuose perioduose patirtus nuostolius arba išlaikyti aukštas savo verslų pelno maržas. Dėl šių priežasčių, žaliavinės naftos kainų pokyčių poveikis galutinėms benzino ir dyzelino kainoms pasižymi ne tik vėlavimu, bet ir nepastovumu, kurį lemia rinkos netobulumai. Dėl šių priežasčių, benzino ir dyzelino kainų dinamika dažnai neatspindi momentinių pasaulinės žaliavinės naftos rinkos svyravimų.

Borensteinas ir kt. [21] savo tyrime empiriškai įrodė, jog degalų kainos iš tiesų žymiai greičiau reaguoja į žaliavinės naftos kainų kilimą nei į jų mažėjimą. Šį dėsningumą tyrėjai paaiškino aukšta rinkos koncentracija, kuri įprastai pasižymi ribota konkurencija bei vyraujančia informacijos asimetrija tarp rinkos tiekėjų ir vartotojų. Kartu šie veiksniai leidžia rinkos dalyviams išlaikyti aukštesnes kainas net ir sumažėjus žaliavinės naftos taip sukeliant asimetrišką žaliavinės naftos kainų dinamikos poveikį galutinėms benzino ir dyzelino kainoms.

Be ekonominių aspektų, kuro kainų dinamiką reikšmingai veikia ir sezoniškumo veiksniai, kurie skirtingiems naftos produktams pasireiškia nevienodai. Baumeisteris ir Kilianas [20] pažymi, kad benzino paklausa šiltuoju metų laikotarpiu išauga dėl intensyvesnio transporto naudojimo, didesnių kelionių srautų ir turizmo aktyvumo, todėl benzino kainos pasižymi ryškesniu sezoniškumu. Tuo tarpu dyzelino paklausa yra kur kas stabilesnė, nes ji labiau susijusi su pramonės, logistikos ir žemės

ūkio veiklomis, kurių intensyvumas priklauso nuo ekonominių ciklų, o ne nuo metų laikų. Dėl šių skirtumų benzino ir dyzelino kainų reakcija į rinkos pokyčius gali būti nevienoda, o sezoniškumo poveikis asimetriškas.

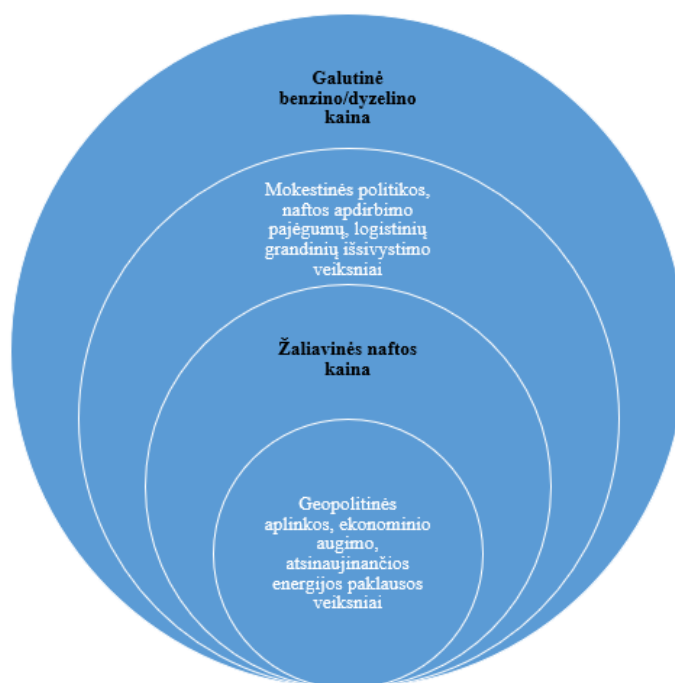
Gyagri ir kt. [19], savo tyrime papildomai išskiria valstybių vedamos politikos, mokesčių įstatymų ir aplinkosauginių reguliavimų priemones kaip papildomus veiksnius, lemiančius galutiniams vartotojams nustatytų kuro kainų lygio pokyčius. Agresyvėjanti aplinkosauginių reikalavimų politika lemia tai, jog vis labiau yra skatinamas tvaresnio kuro vartojimas taip pat yra keliami kuro kokybės kriterijai, kurie reikalauja sunkesnių apdirbimo procesų, o tai lemia benzino ir dyzelino kuro gamybos kaštų augimą. Be šių subtilumų, galutinės benzino ir dyzelino kuro kainos stipriai priklauso ir nuo mokesstinės šalies praktikos. Kaip pavyzdį, Gyagri ir kt. [19] pateikia kuro akcizų pokyčių įtaką šios produkcijos kainoms, akivaizdu, jog pakėlus taikomus akcizus, šis netiesioginis mokestis bus apmokamas galutinio vartotojo, todėl tokiu atveju galutinės benzino ir dyzelino kainos neišvengiamai augs. Derėtų atsižvelgti ir į valstybių taikomas subsidijas, kurios dažniausiai kritiniais atvejais padeda kuro tiekėjams išlaikyti savo kainas rinkos normos ribose dėka suteikiamų valstybinių kompensacijų ir papildomų išmokų.

Šiuos pastebėjimus papildė Marinas ir Zanfei [22], kurie pabrėžia, jog skirtingose šalyse taikomos mokesčių struktūros lemia reikšmingus galutinių degalų kainų skirtumus net ir esant identiškoms žaliavinės naftos kainoms pasaulinėje rinkoje. Autoriai pažymi, kad akcizų lygis, PVM tarifai, aplinkosauginiai mokesčiai ir įvairios fiskalinės lengvatos sukuria unikalią kiekvienos šalies kainodaros architektūrą, todėl degalų kainų palyginimas tarp valstybių reikalauja ne tik žaliavinės naftos kainų analizės, bet ir išsamaus fiskalinės politikos vertinimo. Dėl šių priežasčių, mokesčių politika laikoma vienu iš struktūrinių veiksnių, galinčių lemti ilgalaikius benzino ir dyzelino kainų skirtumus, nepriklausomai nuo globalių energetikos rinkos tendencijų.

Technologinių veiksnių grupėje ypatingas dėmesys skiriamas naftos apdirbimo pajėgumams, kurie lemia tiek pasiūlos lankstumą, tiek galutinio vartojimo degalų kainų dinamiką. Ederingtonas ir kt. [23] pabrėžia, kad naftos perdirbimo procesų įtaka benzino ir dyzelino kainoms pasireiškia ne vien per technologinį kompleksumą, kaip akcentuoja Gyagri ir kt. [19], bet ir per pačių perdirbimo gamyklų pajėgumų apribojimus. Šie apribojimai tampa kritiniu kainų formavimosi veiksniumi tais atvejais, kai naftos perdirbimo gamyklos susiduria su nenumatytais veiklos trikdžiais, techniniais gedimais ar priverstinėmis profilaktinėmis patikromis, kurios automatiškai sumažina jų gamybinius pajėgumus. Tokie sutrikimai gali sukelti staigius ir sunkiai prognozuojamus kainų šuolius, ypač regionuose, kuriuose žaliavinės naftos perdirbimo infrastruktūra yra ribota, o pasiūlos alternatyvos – menkos.

Kitas svarbus veiksnys, darantis tiesioginę įtaką benzino ir dyzelino kainų pokyčiams, yra transportavimo bei distribuciniai kaštai. Kaip ir daugumos kitų galutinio vartojimo prekių atveju, logistinės išlaidos sudaro reikšmingą galutinės kainos dalį. Degalų atveju šios išlaidos priklauso nuo pasirinktų transportavimo būdų: vamzdynų, specializuoto jūrinio transporto, geležinkelių ar kelių transporto. Ederingtonas ir kt. [23] pažymi, kad regiono infrastruktūros išsivystymo lygis, sandėliavimo pajėgumai ir logistinių tinklų efektyvumas bei patikimumas tiesiogiai lemia galutinę degalų kainodarą. Dėl šios priežasties, regioniniai infrastruktūros skirtumai gali sukelti lokalius kainų šuolius, ypač tose teritorijose, kuriose nėra pakankamų naftos perdirbimo pajėgumų arba kur transportavimo alternatyvos yra ribotos. Tokiu būdu logistiniai veiksniai formuoja struktūrinį kainų jautrumą tiekimo grandinės sutrikimams ir lemia reikšmingus regioninius degalų kainų skirtumus.

Kaip ir žaliavinės naftos atžvilgiu, benzino bei dyzelino kainas lemia taip pat ir regiono ekonominio augimo perspektyvos. Pasak Ederingtonas ir kt. [23], augančių ekonomikų šalyse, didėja bendras vartojimo lygis, o tai natūraliai lemia ir kuro vartojimo augimą, tačiau verta pastebėti, jog per pastarąjį dešimtmetį įsivyravusios tendencijos lemia tai, jog ekonomiškai stipresnių šalių vartotojai yra linkę rinktis tvaresnius transporto sprendimus, kurie remiasi atsinaujinančių energijos šaltinių naudojimu, todėl ypatingai ekonomiškai stiprių šalių rinkose pastebėtinai dyzelino ir benzino kuro paklausos mažėjimas, o tai lemia ir kuro kainos susitraukimą. Nepaisant šio fakto Ederingtonas ir kt. [23] atkreipia dėmesį, jog benzino ir dyzelino kuras vis dar išlieka pirmojo būtinumo preke ir išsaugo aukštą paklausos lygį pasaulinėje rinkoje vien dėl tos priežasties, jog šiuo metu naudojami atsinaujinančios energijos šaltinių kuro sprendimai negali patenkinti visų vartotojų lūkesčių (avariniai generatoriai, oro bei jūrinio transporto priemonės yra varomos išskirtinai žaliavinės naftos kuro produktais) ir tam tikrais atvejais savo efektyvumu nusileidžia dyzeliniam ar benzininiam kurui. Taigi, atsižvelgiant į benzino ir dyzelino kainą lemiančių veiksnių mokslinės literatūros analizės rezultatus ir jais paremtą, 7 paveiksle pavaizduotą, schemą, galima teigti, jog degalų kainos yra stipriai susietos su žaliavinės naftos kainų pokyčiais.



7 pav. Žaliavinės naftos ir benzino/dyzelino kainas lemiančių veiksnių schema (Sudaryta autoriaus)

Vertinant tiek benzino, tiek dyzelino kainų kintamuosius bei jų dinamiką, galima nagrinėti vienodus faktorių rinkinius, kurie susideda iš ekonominio augimo, politinio stabilumo, naftos gavybos bei atsinaujinančios energijos šaltinių naudojimo rodiklių. Vis dėl to, siekiant detaliai įvertinti minėtų kintamųjų tendencijas, būtina atsižvelgti ir į papildomus faktorius, kurie susidaro išskirtinai benzino arba dyzelino kuro gamybos, tiekimo ar vartojimo etapuose, taip pat, svarbu įvertinti egzistuojančius mokestinius aspektus, kurie yra taikomi konkrečiam degalų tipui ir ženkliai prisideda prie galutinio vartojimo kainos.

1.4. Degalų kainų dinamikos tyrimuose naudojami metodai

Įvertinus įvairius mokslinės literatūros šaltinius, yra pastebima, jog degalų, ypač benzino ir dyzelino, kainų analizė dažnai yra grindžiama ekonometrinių bei statistinių modelių kūrimu. Siekdami įvertinti

tiek trumpalaikius svyravimus, tiek ilgalaikes struktūrinės degalų kainų tendencijas, tyrėjai apjungia klasikinės bei moderniosios laiko eilučių analizės teorijos siūlomus modelius.

Vienas iš labiausiai paplitusių degalų kainų modeliavimo metodų yra integruoti autoregresiniai slankiojo vidurkio (ARIMA) modeliai. Pasak Boxo ir kt.[24] bei Brockwello ir Davis [25] šie modeliai naudojami siekiant įvertinti trumpalaikius kainų pokyčius, tačiau jų taikymas ilgalaikių rinkos struktūros pokyčių modeliavime yra ribotas. Siekiant kompensuoti ARIMA apribojimus ilguosiuose laikotarpiuose, tyrėjai taiko vektorinės autoregresijos (VAR) modelius arba jų struktūrinę modifikaciją (SVAR). Baumeisteris ir Kilianas [20] savo tyrime pasitelkia SVAR modelius, siekdami analizuoti tarpusavio ryšius tarp benzino ir dyzelino kainų bei makroekonominių rodiklių, papildomai įvertinant pasiūlos ir paklausos šokus ilgalaikėje perspektyvoje.

Kai kurie tyrėjai analizuodami degalų kainas, daugiau dėmesio skiria ne jų dinamikai, o jų pokyčius lemiantiems veiksniams. Pavyzdžiui, Baffesas ir kt. [26] bei Fattouhas ir Mahadeva [9] įvairių makroekonominių rodiklių šokų poveikio degalų kainoms vertinimui taiko VAR bei SVAR modelius, kurie identifikuoja pasiūlos, paklausos, geopolitinių ar finansinių rinkų rodiklių struktūrinius lūžius ir įvertina jų poveikį galutinėms degalų kainoms.

Hyndmanas ir Athanasopoulosas [27] teigia, kad degalų kainos dažnai pasižymi sezoniškumu bei ilgalaikiu trendu, todėl jų prognozavimui tinkamiausia naudoti eksponentinio glodinimo (ETS) modelius. Bernardi ir kt. [28], pritaria šiai nuomonei, tačiau benzino ir dyzelino kainų analizėje siūlo taikyti išplėstas ETS modelių variacijas, kurios leidžia tiksliau modeliuoti nestacionarumu pasižyminčias laiko eilutes. ETS modelių taikymą kuro kainų prognozavime akcentuoja ir Makridakis ir kt. [29], kurie tyrimo metu nustatė, jog kombinuotos modeliavimo technikos, integruojančios ARIMA bei jos plėtinių SARIMA ir ARIMAX, taip pat ETS ir mašininio mokymosi metodus, dažnai pasižymi didesniu tikslumu nei pavieniai modeliai.

Atsižvelgus į skirtinguose moksliniuose šaltiniuose taikomas degalų kainų analizė metodologijas, galima teigti, kad dauguma tyrėjų yra linkę taikyti įvairiapusių ekonometrinių ir statistinių metodų derinius, kurie įvertina degalų kainų dinamiką ir identifikuoja juos lemiančius veiksnus. Laiko eilučių analizės modeliai, struktūriniai makroekonominiai metodai, kintamumo analizė bei eksponentinio glodinimo technikos kartu sudaro visapusišką metodologijų sistemą, kuri užtikrina išsamų benzino ir dyzelino kainų elgsenos vertinimą.

1.5. Literatūros apžvalgos apibendrinimas

Atlikta mokslinės literatūros bei statistinių šaltinių analizė atskleidė, jog degalų kainų formavimasis ir jų dinamika yra daugialypis reiškinys, kurį lemia tarpusavyje glaudžiai sąveikaujantys ekonominiai, politiniai, geopolitiniai, technologiniai bei rinkos struktūros veiksniai. Degalų rinka pasižymi dideliu nepastovumu bei struktūriniais lūžiais, o tai apsunkina kainų elgsenos modeliavimą ir prognozavimą. Papildomo nepastovumo degalų kainoms suteikia moksliniuose tyrimuose nagrinėjamas asimetrinis žaliavinės naftos kainų poveikis galutinėms benzino ir dyzelino kainoms, taip pat, yra išskiriama pasiūlos ir paklausos disbalanso bei geopolitinių įvykių svarba trumpalaikiams degalų kainų šokams.

Mokslinės literatūros analizė taip pat atskleidė, jog benzino ir dyzelino kuro rūšys pasižymi nevienoda paklausos struktūra ir jautrumu ekonominiams ciklams, todėl jų kainų dinamika negali būti vertinama kaip vienalytė sistema. Atsižvelgiant į tai, kad benzinai ir dyzelinas sudaro didžiąsias

kuro paklausos dalį Europos Sąjungos ir Lietuvos rinkose, jų kainų dinamikos modeliavimas tinkamai atspindi bendrą kuro kainų raidos tendenciją.

Benzino kainos dažniau reaguoja į vartotojų elgsenos pokyčius, sezoniškumą ir namų ūkių pajamų dinamiką, tuo tarpu dyzelino kainos, yra glaudžiau susijusios su pramonės aktyvumu, logistikos srtais bei tarptautinės prekybos apimtimis. Galutinį degalų kainų lygį rinkoje taip pat reikšmingai veikia naftos perdirbimo kaštai, gamybinių pajėgumų apribojimai, transportavimo ir sandėliavimo infrastruktūros išsivystymo lygis bei valstybės taikoma fiskalinė ir mokesstinė politikos.

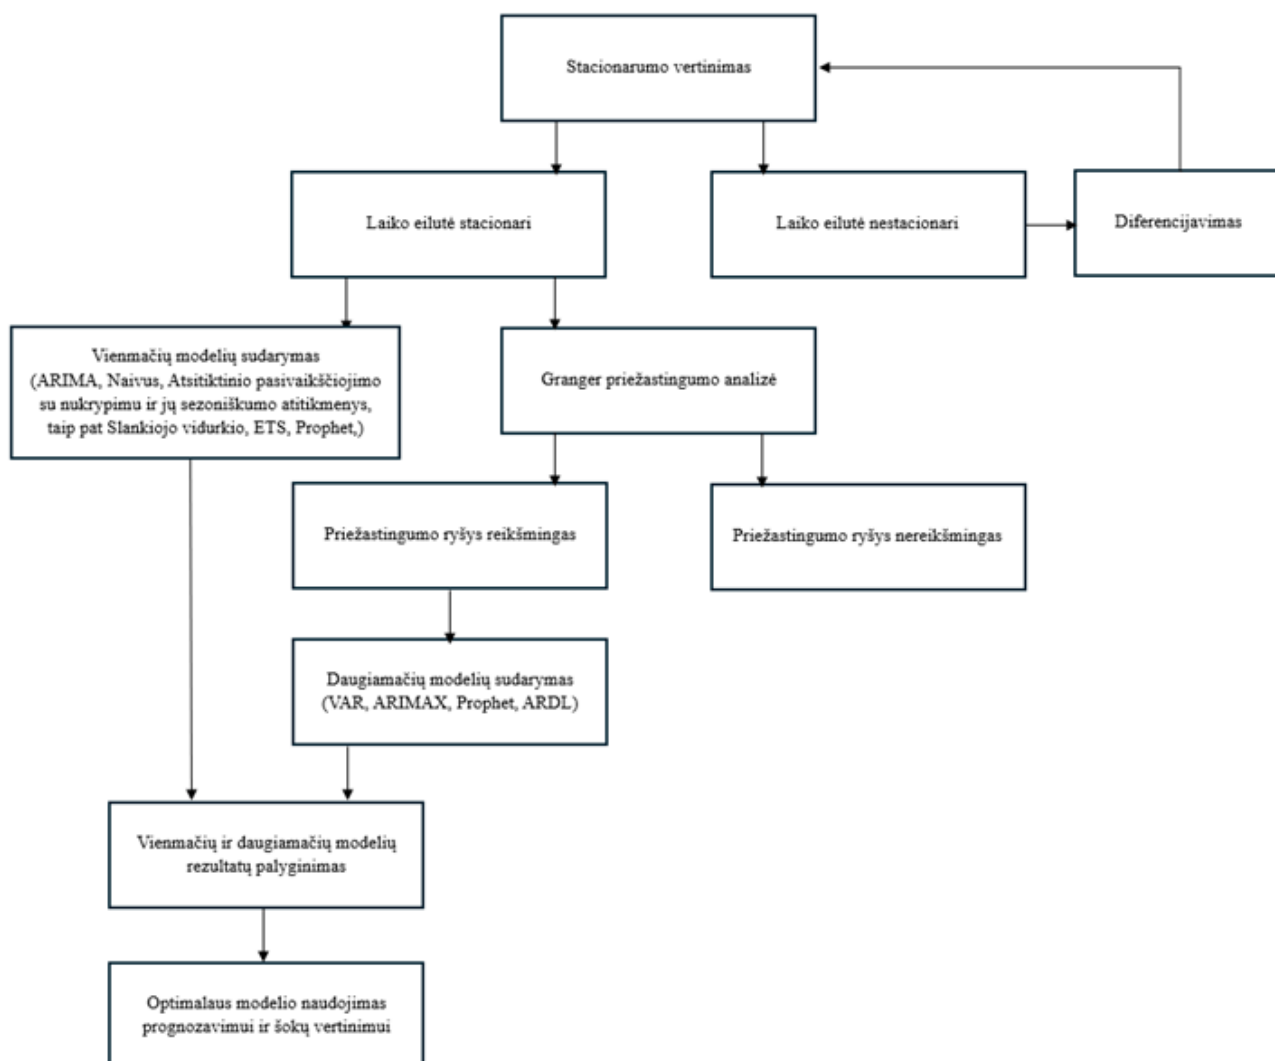
Nors degalų kainų dinamiką lemiančius veiksniai yra ganėtinai lengva identifikuoti, jų prognozavimo rezultatų patikimumas išlieka ribotas, ypač tais atvejais, kai rinkoje vyrauja didelis ekonominis neapibrėžtumas arba netikėti geopolitiniai sukrėtimai. Aukštas kainų nepastovumas, struktūriniai analizuojamos laiko eilutės pokyčiai ir duomenyse vyraujantis sezoniškumas, lemia tai, jog degalų kainų prognozavimui būtina pasitelkti pažangesnius statistinius metodus, kurie geba prisitaikyti prie nuolat nenuspėjamai kintančių rinkos sąlygų. Nors dauguma mokslinių tyrimų išskiria įvairius laiko eilučių analizės metodus, šiuo metu dar nėra pasiektas konkretus susitarimas dėl tinkamiausios degalų kainų modeliavimo technikos, kuri užtikrintų patikimus mažmeninių benzino ir dyzelino kainų prognozavimo rezultatus esant skirtingoms ekonominėms sąlygoms.

2. Tyrimo metodai

Kadangi degalų kainų pokyčiai yra fiksuojami laiko dimensijoje, todėl šių duomenų analizė ir prognozavimas dažniausiai yra grindžiami laiko eilučių teoriniu pagrindu. Šiame skyriuje detaliau apžvelgiama laiko eilučių samprata, sudedamosios komponentės bei aprašomi laiko eilučių analizėje taikomi tyrimo metodai ir prognozavimo modelių pagrindai.

2.1. Degalų kainų dinamikos ekonometrinio tyrimo procesas

Mokslinių tyrimų analizė identifikavo benzino ir dyzelino kainas lemiančių faktorių grupes, tačiau siekiant įvertinti jų poveikį degalų kainų dinamikai, būtina įvertinti priežastingumo ryšį tarp analizuojamų kintamųjų bei sudaryti daugiamačius modelius, kurių tikslumas taip pat yra palyginamas su vienmačiais modeliais. Vienmačių, ARIMAX ir Prophet modelių sudarymas bei Granger priežastingumo ryšio analizė yra atliekami naudojant integruotą R programavimo kalbos aplinką „R studio“, o daugiamačių VAR ir ARDL modelių sudarymui pasitelktas ekonometrinės analizės ir statistinių skaičiavimų programinės įrangos paketas „Gretl“. 8 paveiksle yra pateikiama degalų kainų dinamikos ekonometrinio tyrimo proceso schema.



8 pav. Degalų kainų dinamikos ekonometrinio tyrimo schema (Sudaryta autoriaus)

Pagal numatytą ekonometrinio tyrimo eigą, pirmiausiai yra įvertinamas visų tyrime naudojamų kintamųjų stacionarumas, pasitelkiant ADF ir KPSS testus su reikšmingumo lygiu $\alpha = 0,05$. Tais atvejais, kai yra nustatoma, kad laiko eilutė neatitinka stacionarumo sąlygos, yra atliekamas jos diferencijavimas.

Kai visos tyrime nagrinėjamos laiko eilutės tenkina stacionarumo sąlygą, toliau yra sudaromi vienmačiai modeliai, kuriuose įvertinamas benzino ir dyzelino kainų istorinių duomenų efektyvumas prognozuojant šių degalų rūšių dinamiką.

Sekantis tyrimo žingsnis – įvertinti išorinių veiksnių poveikį degalų kainų dinamikai. Siekiant atrinkti tik tuos kintamuosius, kurie gali turėti reikšmingos įtakos benzino ir dyzelino kainų pokyčiams, yra atliekama Granger priežastingumo ryšio analizė. Statistiškai reikšmingas priežastingumo ryšys yra nustatomas tarp tų kintamųjų, kurių F statistikos tikimybė yra mažesnė už 0,1 kritinę reikšmę. Identifikavus nepriklausomus kintamuosius, kurie turi statistiškai reikšmingą priežastingumo ryšį su benzino ir dyzelino kainų kintamaisiais, toliau yra sudaromi daugiamačiai modeliai.

Sukūrus daugiamačius modelius, pirmiausiai yra nustatomas jų parametrų reikšmingumas, vertinant t kriterijaus statistikos rodiklio tikimybę, kurios kritinė reikšmė siekia 0,05. Tie parametrai, kurių tikimybė viršija nustatytą kritinę ribą, yra pašalinami iš modelio lygties. Gavus galutines daugiamačių modelių išraiškas, jų rezultatai yra lyginami su vienmačiais, pasitelkiant RMSE ir MAPE paklaidų rodiklius. Modelis, kuris prognozuojant benzino ir dyzelino kainas pasižymi mažiausiomis paklaidomis, pasirenkamas galutiniam tyrimo etapui. Tais atvejais, kai pagal RMSE ir MAPE kriterijus geriausias modelis nesutampa, prioritetą teikiama tam modeliui, kuris pasižymi mažesne RMSE paklaidų reikšme.

Atrinkus optimalius benzino ir dyzelino kainų prognozavimo modelius, užrašomos jų lygtys, įvertinamas šokų poveikis degalų kainų dinamikai ir atliekamas atitinkamos degalų rūšies kainų prognozavimas 2026 metams.

2.2. Duomenų rinkinio analizė

Atsižvelgiant į tai, jog degalų sąvoka yra labai plati, analizuojant šios produkcijos rinką, buvo nustatyta, jog didžiausią paklausą generuoja benzino ir dyzelino degalų rūšys. Dėl šios priežasties, 3 lentelėje mažmeninių benzino ir dyzelino kainų statistiniai duomenys yra pateikiami kaip priklausomi kintamieji, kurie atspindės degalų kainų dinamiką tyrimo metu.

3 lentelė. Tyrimo priklausomi kintamieji

Kintamojo pavadinimas	Kintamojo matavimo vienetai	Kintamojo trumpinys
Mažmeninė benzino kaina	Eurai už 1000 litrų	Petrol_Price
Mažmeninė dyzelino kaina	Eurai už 1000 litrų	Diesel_Price

Atlikta mokslinės literatūros analizė padėjo nustatyti benzino ir dyzelino kainas lemiančius veiksniai, remiantis kuriais, buvo atrinkti atitinkami nepriklausomi kintamieji. Be įprastų statistinių rodiklių, nepriklausomų kintamųjų grupei taip pat buvo priskirti ir du pseudo kintamieji, kurie leidžia įvertinti šokų poveikį benzino ir dyzelino kainoms. Visas nepriklausomų kintamųjų sąrašas ir juos atitinkantys veiksniai yra pateikiami 4 lentelėje.

4 lentelė. Tyrimo nepriklausomi kintamieji

Veiksnių grupė	Veiksny	Kintamojo pavadinimas	Kintamojo matavimo vienetai	Kintamojo trumpinys
Politiniai	Šalies mokesčių struktūra	Mokesčių dalis benzino kainoje	Procentai	Petrol_Tax_Prctg
		Mokesčių dalis dyzelino kainoje	Procentai	Diesel_Tax_Prctg
	Akcizų ir subsidijų taikymas	Benzinui taikomas akcizas	Eurai už 1000 litrų	Petrol_Excises
		Dyzelinui taikomas akcizas	Eurai už 1000 litrų	Diesel_Excises
Ekonominiai	Žaliavinės naftos kainų pokyčiai	Brent naftos kaina	JAV doleriai už barelį	Brent_Oil
	Valstybės kuro rezervų dydis	Lietuvos benzino ištekliai	Tūkst. tonų	LT_Petr
		Lietuvos dyzelino ištekliai	Tūkst. tonų	LT_D
		Lietuvos naftos ištekliai	Tūkst. tonų	LT_Oil
		Lietuvos naftos atsargos	Dienos	Emergency_Oil
	Degalų rinkos konkurencijos lygis	Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje	-	HICP
	Ekonominio aktyvumo ciklai	Importas	Tūkst. tonų	Import
		Pramonės sektoriaus produkcijos apimčių indeksas	-	Prod_Manufact
		Lietuvos nedarbo lygis	Procentai	Unemployment
	Žaliavinės naftos produkcijos vartojimas	Kelių transporto priemonių skaičius	Vienetai	Transp_Nbr
Aplinkosauginiai	Atsinaujinančių energijos šaltinių paklausa	Gamtinių dujų vartojimas Lietuvoje	Teradžiauliai	Gass_LT
		Elektros energijos pasiūla Lietuvos rinkoje	Gigavatvalandės	El_LT
-	Išorinis šokas	COVID-19 pandemijos šokas	-	D1_Covid
		Ukrainos karo šokas	-	D2_UKR

Kadangi energetikos sektoriuje yra dažnai atliekami kainų priežastingumo tyrimai, šios srities nepriklausomų kintamųjų spektras yra platus, todėl svarbu tinkamai argumentuoti pasirinktus išorinius faktorius, kurių poveikis bus analizuojamas tolimesnėje analizėje. Mokslinės literatūros analizės metu buvo nustatyta, kad benzino ir dyzelino kainas veikiantys faktoriai iš dalies skiriasi, todėl buvo suformuoti du atskiri nepriklausomų kintamųjų rinkiniai, kurie bus taikomi daugiamačių

modelių vertinime. Benzino kainos modeliavimui buvo atrinkti šie nepriklausomi kintamieji: mokesčių dalis benzino kainoje, benzinui taikomas akcizas, Brent naftos kaina, Lietuvos benzino išteklių, Lietuvos naftos išteklių, Lietuvos naftos atsargos dienomis, harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje, Lietuvos nedarbo lygis, kelių transporto priemonių skaičius, gamtinių dujų vartojimas Lietuvoje, elektros energijos pasiūla Lietuvos rinkoje, COVID-19 pandemijos šokas ir Ukrainos karo šokas. Tuo tarpu dyzelino kainos modeliavimui bus naudojami šie nepriklausomi kintamieji: mokesčių dalis dyzelino kainoje, dyzelinui taikomas akcizas, Brent naftos kaina, Lietuvos dyzelino išteklių, Lietuvos naftos išteklių, Lietuvos naftos atsargos dienomis, harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje, importas, pramonės sektoriaus produkcijos apimčių indeksas, Lietuvos nedarbo lygis, kelių transporto priemonių skaičius, gamtinių dujų vartojimas Lietuvoje, elektros energijos pasiūla Lietuvos rinkoje, COVID-19 pandemijos šokas ir Ukrainos karo šokas.

Tyrime naudojami kintamieji buvo surinkti iš Europos komisijos ir Valstybės duomenų agentūros duomenų bazių. Benzino bei dyzelino mažmeninių kainų duomenys yra teikiami kiekvieną savaitę, tačiau įvertinus tai, jog dauguma egzogeninių veiksnių, kurių poveikis bus nagrinėjamas degalų kainų atžvilgiu, yra mėnesiniai, buvo priimtas sprendimas paversti priklausomų kintamųjų duomenis irgi į mėnesinius, apskaičiuojant kiekvieno mėnesio vidutinę kainos reikšmę. Siekiant įvertinti COVID-19 pandemijos ir Ukrainos karo šokų poveikį, buvo sukurti atitinkami pseudo kintamieji, kurie šoko poveikio laikotarpiu įgyja reikšmę 1, o laikotarpiais, kai šokas nėra aktyvus, kintamasis įgyja reikšmę 0. Šokų poveikio laikotarpiai buvo nustatyti remiantis mokslinės literatūros analizės rezultatais ir WTI kainų dinamika:

- COVID-19 pandemijos šoko laikotarpis: nuo 2020 m. balandžio iki 2021 m. balandžio;
- Ukrainos karo šoko laikotarpis: nuo 2022 m. vasario iki 2022 m. birželio.

Lietuvos benzino, dyzelino ir naftos išteklių rodiklių duomenys buvo pradėti rinkti tik nuo 2013 metų, o kelių transporto priemonių skaičiaus stebiniai fiksuojami nuo 2012 metų. Siekiant išvengti netikslaus nepriklausomų kintamųjų poveikio įvertinimo dėl praleistų reikšmių, visų tyrimo kintamųjų duomenų laikotarpis buvo nustatytas nuo 2013 metų sausio mėnesio iki 2025 metų gruodžio mėnesio, todėl kintamųjų duomenų imtys sudarytos iš 156 stebinių.

2.3. Laiko eilučių stacionarumo samprata ir testavimas

Nors aprašomosios statistikos matai suteikia informaciją apie pagrindines laiko eilutės savybes, tačiau siekiant ją modeliuoti, pirmiausia yra būtina įvertinti jos stacionarumo prielaidą.

Laiko eilutė yra vertinama stacionaria, kai jos statistinės savybės nekinta laike. Mokslinėje literatūroje vertinant stacionarumą, yra išskiriami du laiko eilučių tipai:

- griežtai stacionarios (angl. *strictly stationary*);
- silpnai stacionarios (angl. *weakly stationary*).

Brockwellas ir Davis [25] savo tyrime nurodo, jog griežtai stacionarios laiko eilutės išsiskiria tuo, jog jų bet kurios stebėjimų sekos jungtinis pasiskirstymas išlieka nepakitęs, nepriklausomai nuo laiko momento, kuriame ji yra stebima. Kadangi griežto stacionarumo sąlygą patikrinti empiriškai yra sudėtinga, praktiniuose ekonominiuose tyrimuose dažniausiai yra taikoma silpnosios stacionarumo sąlyga. Pasak Tsay [30] silpnai stacionari laiko eilutė pasižymi trimis pagrindinėmis savybėmis:

1. atsitiktinio kintamojo y_t reikšmė yra pastovi ir nekinta laike. Apskaičiavimas atliekamas pagal (2.3.1) formulę:

$$E(y_t) = \mu, \forall t; \quad (2.3.1)$$

čia μ – pastovi vidutinė reikšmė.

2. dispersija turi baigtinę reikšmę ir yra pastovi. Apskaičiavimas atliekamas pagal (2.3.2) formulę:

$$Var(y_t) = \sigma^2, \forall t; \quad (2.3.2)$$

čia σ^2 – pastovi dispersija.

3. autokovariacija priklauso tik nuo vėlinimų, o ne nuo konkretaus laiko momento. Apskaičiavimas atliekamas pagal (2.3.3) formulę:

$$Cov(y_t, y_{t-k}) = \gamma_k, \forall t; \quad (2.3.3)$$

čia γ_k – autokovariacija su vėlavimu k .

Hyndmanas ir Athanasopoulos [27] atkreipia dėmesį, jog dauguma klasikinių laiko eilučių modelių remiasi prielaida, kad analizuojama laiko eilutė yra stacionari arba gali būti paversta stacionaria pritaikius atitinkamas transformacijas. Dėl šios priežasties, prieš pereinant prie modelių sudarymo ir jų parametrų identifikavimo bei vertinimo, pirmiausia būtina nustatyti, ar laiko eilutė atitinka stacionarumo sąlygą.

Nestacionarumas laiko eilutėse nustatomas tais atvejais, kai duomenys pasižymi trendu, kintančia dispersija arba kitais struktūriniais pokyčiais, dėl kurių pagrindinės statistinės savybės kinta laike. Vienas dažniausių nestacionarumo šaltinių yra vienetinė šaknis (angl. *unit root*), rodanti, kad procesas turi ilgalaikę priklausomybę ir nėra linkęs grįžti į pastovų vidutinį lygį [31]. Laiko eilutė, kuri turi vienetinę šaknį, gali būti aprašyta pasitelkiant pirmos eilės autoregresinį modelį, pagal (2.3.4) formulę:

$$y_t = \phi y_{t-1} + \varepsilon_t; \quad (2.3.4)$$

čia ϕ – autoregresinis koeficientas;
 y_{t-1} – laiko eilutės reikšmė ankstesniu momentu;
 ε_t – atsitiktinė paklaida.

Jeigu $|\phi| < 1$, autoregresinis procesas yra stacionarus, o jo vidurkis ir dispersija nekinta laike, tačiau jeigu $\phi = 1$, procesas tampa nestacionariu [31].

Nustačius, jog nagrinėjama laiko eilutė yra nestacionari, jos transformavimui yra taikomas diferencijavimas, kuris pašalina trendo komponentę ir stabilizuoja vidurkį. Apskaičiavimas atliekamas pagal (2.3.5) formulę:

$$\Delta y_t = y_t - y_{t-1}; \quad (2.3.5)$$

čia y_t – laiko eilutės reikšmė laiko momentu t ;
 y_{t-1} – laiko eilutės reikšmė ankstesniu momentu.

Jei diferencijuota laiko eilutė tampa stacionaria, ji yra vadinama integruotu pirmos eilės procesu ir žymima I(1). Kai laiko eilutė tampa stacionaria po d diferencijavimų, ji yra žymima I(d) [30].

Laiko eilutės stacionarumas įvertinamas pasitelkiant įvairius statistinius testus. Vienas dažniausiai taikomų statistinių testų stacionarumo identifikavimui yra išplėstinis Dickey – Fuller (ADF) testas. Testo skaičiavimai atliekami pagal (2.3.6) formulę:

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \sum_{i=1}^p \delta_i \Delta y_{t-i} + \varepsilon_t; \quad (2.3.6)$$

čia Δy_t – pirmos eilės skirtumas;
 α – konstanta;
 β – trendo koeficientas;
 t – laiko momentas;
 γ – koeficientas, nusakantis ryšį tarp dabartinės ir ankstesnio laikotarpio reikšmių;
 p – autoregresijos eilė;
 δ_i – i -ojo uždelsto skirtumo koeficientas;
 Δy_{t-i} – kintamojo skirtumas ankstesniu laikotarpiu;
 ε_t – atsitiktinė paklaida.

Koeficientas γ naudojamas vienetinės šaknies tikrinimui. Kai $\gamma = 0$, tai signalizuoja, jog nagrinėjama laiko eilutė turi vienetinę šaknį ir yra nestacionari [32]. ADF testo atveju yra iškeliamos nulinė ir alternatyvioji hipotezės, kurios įvertina ar laiko eilutė turi vienetinę šaknį:

- H_0 : laiko eilutė turi vienetinę šaknį ir nėra stacionari.
- H_1 : laiko eilutė neturi vienetinės šaknies ir yra stacionari.

Siekiant padidinti stacionarumo vertinimo patikimumą, be ADF testo dažnai yra taikomas KPSS testas, kurio metu yra formuojamos šios hipotezės:

- H_0 : laiko eilutė yra stacionari.
- H_1 : laiko eilutė nėra stacionari.

Hyndmanas ir Athanasopoulos [27] savo tyrime nurodo, kad ADF bei KPSS testų kombinavimas laikomas gerąja laiko eilučių analizės praktika, nes tokiu būdu yra sumažinama klaidingų išvadų apie stacionarumo sąlygos tenkinimą tikimybė, ypatingai tai atvejais, kai yra analizuojami ekonominiai arba finansiniai rodikliai.

Stacionarumo sąlyga ir jos vertinimo metodai yra neatsiejama laiko eilučių analizės dalis, leidžianti įvertinti, ar nagrinėjami duomenys pasižymi pastoviomis statistinėmis savybėmis. Ši informacija yra būtina tam, jog tyrėjas galėtų pagrįstai taikyti sudėtingesnius modelius ir interpretuoti jų rezultatus

nepažeidžiant teorinių prielaidų. Tinkamai identifikuotas stacionarumas užtikrina nuoseklias išvadas ir padidina prognozavimo rezultatų patikimumą.

2.4. Vienmačių laiko eilučių modelių teorinis pagrindas

Vienmačių laiko eilučių prognozavimo modelių grupei priskiriami tiek klasikiniai statistiniai metodai, tiek sudėtingesnės struktūros laiko eilučių modeliai.

Vieni dažniausiai taikomų vienmačių laiko eilučių prognozavimo metodų yra ARMA modeliai ir jų integruota versija – ARIMA modeliai. Dėl savo universalumo, ARIMA modeliai įvertina tiek trumpalaikę duomenų dinamiką, tiek ilgalaikes nestacionarių laiko eilučių savybes, todėl jie yra vertinami kaip patikimas prognozavimo įrankis šiuolaikiniuose laiko eilučių tyrimuose. Vienas iš pagrindinių šių modelių pranašumų yra tai, jog jie leidžia prognozuoti kintamąjį remiantis tik jo istoriniais duomenimis, nereikalaujant papildomų kintamųjų duomenų [25].

ARMA modeliai susideda iš dviejų pagrindinių komponentų:

- autoregresinės (AR);
- slankiojo vidurkio (MA).

AR komponentė aprašo ryšį tarp dabartinės laiko eilutės reikšmės ir jos ankstesnių reikšmių, todėl yra tinkama procesams, kuriuose pastebimas inercijos efektas. Autoregresinio modelio AR(p) pateikiama (2.4.1) formulė:

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \varepsilon_t; \quad (2.4.1)$$

- čia c – pastovusis narys;
 p – autoregresijos eilė;
 ϕ_i – autoregresinis koeficientas;
 y_{t-i} – laiko eilutės reikšmė laiko momentu $t - i$;
 ε_t – atsitiktinė paklaida.

Skirtingai nei AR, slankiojo vidurkio modeliai grindžiami prielaida, kad dabartinė reikšmė priklauso nuo ankstesnių atsitiktinių šokų. Brockwellas ir Davis [25] teigia, kad MA modeliai yra ypač tinkami procesams, kuriuose stebimi trumpalaikiai, greitai išnykstantys šokai, tačiau kaip ir AR, MA modeliai reikalauja stacionarios laiko eilutės.. Slankiojo vidurkio modelio MA(q) matematinė išraiška pateikiama pagal (2.4.2) formulę:

$$y_t = \mu + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j}; \quad (2.4.2)$$

- čia μ – proceso vidurkis;
 ε_t – atsitiktinė paklaida;
 q – slankiojo vidurkio modelio eilė;
 j – vėlinimo indeksas;

θ_j – j-ojo slankiojo vidurkio parametro koeficientas;
 ε_{t-j} – ankstesnio laikotarpio paklaida.

Sujungus AR bei MA komponentes, gaunama galutinė ARMA(p, q) modelio matematinė išraiška pateikiama pagal (2.4.3) formulę:

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j}; \quad (2.4.3)$$

čia c – modelio konstanta;
 p – autoregresinės dalies eilė;
 ϕ_i – i-ojo autoregresinio parametro koeficientas;
 y_{t-i} – kintamojo reikšmė ankstesniu laikotarpiu;
 ε_t – atsitiktinė paklaida;
 q – slankiojo vidurkio modelio eilė;
 j – vėlinimo indeksas;
 θ_j – j-ojo slankiojo vidurkio parametro koeficientas;
 ε_{t-j} – ankstesnio laikotarpio paklaida.

Kadangi abi ARMA modelio dalys gali būti taikomos tik tais atvejais, kai nagrinėjama laiko eilutė yra stacionari, praktikoje dažnai naudojama šio modelio modifikacija. Ši modifikacija praplečia ARMA struktūrą, įvedant papildomą integruotumo (I) komponentę, kuri nurodo, kiek kartų laiko eilutė turi būti diferencijuota, kad taptų stacionaria. Įtraukus šį diferencijavimo žingsnį, ARMA modelis transformuojasi į ARIMA modelį, kuris efektyviai modeliuoja ir prognozuoja nestacionarias laiko eilutes.

Kai laiko eilutė diferencijuojama d kartų, ARIMA(p, d, q) modelis taikomas jau transformuotai (stacionariai) eilutei, o bendroji ARIMA modelio išraiška pateikiama pagal (2.4.4) formulę:

$$\Delta^d y_t = c + \sum_{i=1}^p \phi_i \Delta^d y_{t-i} + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j}; \quad (2.4.4)$$

čia d – diferencijavimo laipsnis;
 c – modelio konstanta;
 p – autoregresinės dalies eilė;
 ϕ_i – i-ojo autoregresinio parametro koeficientas;
 Δ^d – d-osios eilės diferencijavimo operatorius;
 y_{t-i} – kintamojo reikšmė ankstesniu laikotarpiu;
 ε_t – atsitiktinė paklaida;
 q – slankiojo vidurkio modelio eilė;
 j – vėlinimo indeksas;
 θ_j – j-ojo slankiojo vidurkio parametro koeficientas;
 ε_{t-j} – ankstesnio laikotarpio paklaida.

Hyndmanas ir Athanasopoulos [27] savo tyrime akcentuoja, jog diferencijuojant laiko eilutes yra svarbu nustatyti tinkamą diferencijavimo laipsnį, nes šis procesas padidina triukšmo lygį duomenyse, o tai lemia prastėjantį prognozių tikslumą.

ARIMA modelių sudarymas dažniausiai yra grindžiamas Box-Jenkins metodologija, kuri apima tris etapus:

1. modelio identifikavimą;
2. parametrų įvertinimą;
3. diagnostiką.

Identifikavimo etape analizuojamos autokoreliacijos (ACF) ir dalinės autokoreliacijos (PACF) funkcijos, kurios padeda nustatyti optimalias p ir q reikšmes, atitinkančias autoregresinę ir slankiojo vidurkio komponentes. Parametrų įvertinimas dažniausiai atliekamas taikant didžiausio tikėtimumo metodą. Galiausiai, diagnostikos etape yra įvertinama, ar modelio liekamosios paklaidos atitinka baltojo triukšmo prielaidas. Tsay [30] teigia, jog tik sėkmingai įvykdžius visus tris etapus yra užtikrinama, kad sudarytas ARIMA modelis yra tinkamas prognozavimui.

Nors ARIMA modeliai yra dažnai taikomi laiko eilučių prognozavimui, mokslinėje literatūroje yra išskiriami jų apribojimai. ARIMA modeliai nėra atsparūs staigiems struktūriniais duomenų pokyčiams, kurie gali kardinaliai pakeisti laiko eilutės elgseną ir lemti modelio parametrų nestabilumą, todėl ši modeliavimo technika prasčiau analizuoja netiesines duomenų struktūras [27].

Kadangi analizuojant ekonominių rodiklių laiko eilutes, jose dažnai pasireiškia sezoniniai svyravimai, ARIMA metodologija galima papildomai išplėsti į sezoninį ARIMA (SARIMA) modelį. SARIMA modeliai leidžia vienu metu vertinti tiek trumpalaikę autoregresinę ir slankiojo vidurkio struktūrą, tiek reguliariai pasikartojančius sezoninius ciklus. Bendroji SARIMA modelio specifikacija žymima kaip SARIMA(p,d,q)(P,D,Q) s , kur pirmasis parametrų rinkinys apibūdina ne sezoninę struktūrą, o antrasis – sezoninius procesus, tuo tarpu s parametras nurodo sezoniškumo periodo trukmę.

SARIMA modelio matematinė išraiška pateikiama pagal (2.4.5) formulę:

$$\Delta^d \Delta_s^D y_t = c + \sum_{i=1}^p \phi_i \Delta^d \Delta_s^D y_{t-i} + \sum_{l=1}^P \phi_l \Delta^d \Delta_s^D y_{t-ls} + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \sum_{J=1}^Q \theta_J \varepsilon_{t-Js}; \quad (2.4.5)$$

- čia (p, d, q) – ne sezoniniai AR, I, MA parametrai;
 (P, D, Q) – sezoniniai AR, I, MA parametrai;
 c – modelio konstanta;
 ϕ_i – i -ojo autoregresinio parametro koeficientas;
 Δ^d – ne sezoninis diferencijavimas;
 Δ_s^D – sezoninis diferencijavimas su periodu s ;
 y_{t-i} – kintamojo reikšmė ankstesniu laikotarpiu;
 p – autoregresinės dalies eilė;
 ϕ_l – l -ojo autoregresinio parametro koeficientas;
 ε_t – atsitiktinė paklaida;
 j – vėlinimo indeksas;

- θ_j – j-ojo slankiojo vidurkio parametro koeficientas;
- ε_{t-j} – ankstesnio laikotarpio paklaida;
- Θ_j – sezoniniai MA koeficientai;
- ε_{t-J_S} – sezoniniai paklaidų vėlinimai.

Kitas populiarus vienmačių laiko eilučių prognozavimo metodas yra eksponentinio glodinimo modeliai ir jų išplėstinė ETS forma. Šie modeliai pasižymi lankstumu ir gebėjimu modeliuoti pagrindines laiko eilučių komponentes be griežtų stacionarumo prielaidų.

Eksponentinio glodinimo metodų esmė yra dinamiška stebinių svorių struktūra, kuri naujausiems stebiniams suteikia didžiausią svorį, o senesnio laikotarpio duomenims priskiria eksponentiškai mažėjančius svorius. Pasak, Bernardi ir kt. [28] remiantis šia technika, natūraliai slopinamas seniausių reikšmių poveikis modelio rezultatams ir daugiausia dėmesio skiriama naujausioms duomenų tendencijoms, todėl ETS metodai itin greitai prisitaiko prie pokyčių laiko eilutėje, įskaitant netikėtus svyravimus ar struktūrinius lūžius, kurie tradiciniams ekonometriniais modeliams dažnai kelia papildomų iššūkių. ETS metodai gali būti taikomi modeliuojant paklaidų, trendo bei sezoniškumo komponentes, kurios aprašomos adityvia arba multiplikatyvia formomis, todėl šios technikos modeliai dažnai yra pasirenkami tais atvejais, kai nagrinėjami duomenys pasižymi nelygiais svyravimais arba sezoniškumo intensyvumo pokyčiais [33].

ETS modeliavimo logika yra pagrįsta trimis laiko eilučių komponentėmis:

- Paklaida – adityvi (A) arba multiplikatyvi (M).
- Trendas – be trendo (N), adityvus (A), adityvus slopintas (Ad).
- Sezoniškumas – be sezoniškumo (N), adityvus (A), multiplikatyvus (M).

Atsižvelgiant į pateiktas komponentių kombinacijas, ETS modelio struktūra žymima:

ETS(paklaida, trendas, sezoniškumas).

Toks klasifikatorius leidžia nustatyti iki 15 skirtingų modelių, pritaikytų specifinėms laiko eilučių savybėms ir charakteristikoms.

Paprasčiausia ETS forma ETS(A,N,N), yra taikoma tada, kai laiko eilutė neturi nei trendo, nei sezoniškumo. Šiuo atveju prognozė apskaičiuojama pagal (2.4.6) formulę:

$$\hat{y}_{t+1} = \alpha y_t + (1 - \alpha)\hat{y}_t; \quad (2.4.6)$$

- čia α – glodinimo parametras;
- \hat{y}_t – išlyginta reikšmė laiku t .

Šis modelis yra artimas eksponentiniam slankiajam vidurkiui (EMA) ir ypač tinkamas trumpalaikiams svyravimams fiksuoti.

Kai laiko eilutėje pastebimas nuoseklus didėjimas arba mažėjimas, elementaraus glodinimo nepakanka, todėl modelis yra praplečiamas įtraukiant trendo komponentę. Gaunama ETS(A,A,N) modelio forma, kuri dar yra vadinama Holt tiesinio trendo modeliu ir apibrėžiama lygtimis pagal (2.4.7) formulę:

$$\begin{aligned}
l_t &= \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}); \\
b_t &= \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1}; \\
\hat{y}_{t+h} &= l_t + hb_t;
\end{aligned}
\tag{2.4.7}$$

- čia l_t – bazinio lygmens komponentė laiku t ;
 α – lygio glodinimo parametras;
 y_t – stebima laiko eilutės reikšmė laiku t ;
 b_t – trendo komponentė laiku t ;
 β – trendo glodinimo parametras;
 \hat{y}_{t+h} – prognozuojama reikšmė h žingsnių į priekį;
 h – prognozavimo horizontas.

Tais atvejais, kai analizuojamoje laiko eilutėje trendas pradeda silpnėti, Holt modelis papildomas slopinimo parametru ϕ , kuris riboja trendo įtaką tolimesnėms prognozėms. Tokiu atveju, prognozė išreiškiama pagal (2.4.8) formulę:

$$\hat{y}_{t+h} = l_t + \left(\frac{1 - \phi^h}{1 - \phi} \right) b_t;
\tag{2.4.8}$$

- čia \hat{y}_{t+h} – prognozuojama reikšmė h žingsnių į priekį;
 l_t – bazinio lygmens komponentė laiku t ;
 ϕ – trendo slopinimo koeficientas;
 ϕ^h – slopinto trendo efektas didėjant prognozavimo horizontui;
 b_t – trendo komponentė laiku t .

Kai laiko eilutė pasižymi periodiniais svyravimais, į ETS modelius įvedama sezoniškumo komponentė. Sezoniškumas yra vertinamas adityviu, kai svyravimų amplitudė išlieka pastovi, arba multiplikatyviu, kai svyravimų dydis priklauso nuo bendro lygio. Adityvaus sezoniškumo (Holt–Winters) modelis ETS(A,A,A) apibrėžiamas lygtimis pagal (2.4.9) formulę:

$$\begin{aligned}
l_t &= \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1}); \\
b_t &= \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1}; \\
s_t &= \gamma(y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m}; \\
\hat{y}_{t+h} &= l_t + hb_t + s_{t-m+hm};
\end{aligned}
\tag{2.4.9}$$

- čia l_t – bazinio lygmens komponentė laiku t ;
 α – lygio glodinimo parametras;
 y_t – stebima laiko eilutės reikšmė laiku t ;
 s_t – sezoniškumo komponentė;
 m – sezoniškumo periodas;
 b_t – trendo komponentė laiku t ;
 β – trendo glodinimo parametras;
 γ – sezoniškumo glodinimo parametras;
 \hat{y}_{t+h} – prognozuojama reikšmė h žingsnių į priekį;

h – prognozavimo horizontas.

Be ETS modelių, vienmačių laiko eilučių prognozavimui taip pat yra taikomi paprastesni, tačiau praktikoje itin reikšmingi modeliai. Pasak Makridakis ir kt. [29], itin paprastų skaičiavimo algoritmų modeliai dažniausiai yra naudojami kaip etaloniniai modeliai, kurie padeda įvertinti sudėtingesnių prognozavimo algoritmų tikslumą, o jų efektyvumas ypač išryškėja trumpalaikėse prognozėse.

Vienas paprasčiausių laiko eilutės prognozavimo metodų yra naivios prognozės modelis, kuris remiasi prielaida, jog prognozuojamos reikšmės bus visada lygios paskutinei užfiksuotai laiko eilutės reikšmei. Šis metodas apibrėžiamas pagal (2.4.10) formulę:

$$\hat{y}_{t+1} = y_t; \quad (2.4.10)$$

čia y_t – stebima laiko eilutės reikšmė laiku t .

Dėl savo paprastumo ir stabilumo naivusis modelis dažnai naudojamas kaip bazinis palyginamasis dydis, ypač vertinant trumpalaikes prognozes [27]. Kai laiko eilutė pasižymi stipriu sezoniškumu, jai gali būti taikomas sezoninis naivios prognozės modelis, kuriame prognozė yra grindžiama visomis paskutinio sezono reikšmėmis pagal (2.4.11) formulę:

$$\hat{y}_{t+h} = y_{t+h-m}; \quad (2.4.11)$$

čia y_t – stebima laiko eilutės reikšmė laiku t ;
 h – prognozavimo horizontas;
 m – sezono ilgis.

Tais atvejais kai nagrinėjama laiko eilutė pasižymi trumpalaikiais svyravimais, jos prognozavimui galima taikyti slankiojo vidurkio modelį. Šio tipo modeliai dėka taikomos skaičiavimo technikos, išlygina nežymius stebinių svyravimus ir padeda nustatyti bendrą nagrinėjamų duomenų kryptį. Slankiojo vidurkio modeliuose, prognozuojama reikšmė yra apskaičiuojama kaip paskutinių k stebinių aritmetinis vidurkis pagal (2.4.12) formulę:

$$\hat{y}_{t+1} = \frac{1}{k} \sum_{i=0}^{k-1} y_{t-i}; \quad (2.4.12)$$

čia k – prognozavimo lango dydis;
 y_{t-i} – laiko eilutės reikšmės i žingsniu atgal.

Sekanti vienmačių laiko eilučių modeliavimo metodologija yra atsitiktinio pasivaikščiojimo modelis su nukrypimu (angl. *random walk with drift*). Šis modelis remiasi prielaida, kad būsima reikšmė yra lygi dabartinei reikšmei, kuri yra veikiamą pastovaus augimo arba mažėjimo parametru ir yra išreiškiamas pagal (2.4.13) formulę:

$$y_t = y_{t-1} + c + \varepsilon_t; \quad (2.4.13)$$

čia y_{t-1} – stebimos laiko eilutės praėjusio laikotarpio reikšmė;
 c – nukrypimo parametras;
 ε_t – atsitiktinė paklaida.

Prognozė tokiu atveju apskaičiuojama pagal (2.4.14) formulę:

$$\hat{y}_{t+h} = y_t + hc; \quad (2.4.14)$$

čia y_t – stebimos laiko eilutės reikšmė t laiko momentu;
 h – prognozavimo horizontas;
 c – nukrypimo parametras.

Tais atvejais, kai laiko eilutė rodo pastovų sezoniškumą, ir ilgalaikę kryptį, gali būti taikomas sezoninis pasivaikščiojimo modelis su nukrypimu. Šis metodas išplečia sezoninį naivųjį modelį, papildant jį nukrypimo komponentu, kuris leidžia įvertinti ilgalaikį augimo arba mažėjimo tempą. Modelio išraiška pateikiama pagal (2.4.15) formulę:

$$\hat{y}_{t+h} = y_{t+h-m} + hc; \quad (2.4.15)$$

čia y_t – stebimos laiko eilutės reikšmė t laiko momentu;
 h – prognozavimo horizontas;
 m – sezono ilgis;
 c – dreifo parametras.

Atsižvelgiant į išanalizuotus įvairių modelių teorinius aspektus, galima teigti, kad laiko eilučių prognozavimo metodai pasižymi skirtingomis, tačiau vienas kitą papildančiomis savybėmis. Paprasti vienmačiai modeliai atlieka etaloninę funkciją ir leidžia įvertinti, ar didesnio kompleksiško modelių taikymas suteikia reikšmingą prognozių tikslumo pagerėjimą, palyginti su baziniais metodais. Tuo tarpu ARIMA šeimos modeliai suteikia galimybę modeliuoti stochastinę laiko eilučių struktūrą. ETS metodai, priešingai, leidžia tiesiogiai modeliuoti pagrindines laiko eilutės komponentes be papildomų transformacijų, todėl yra ypač naudingi duomenims, kuriuose ryškūs struktūriniai dėsningumai. Mokslinėje literatūroje pabrėžiama, kad šių metodų efektyvumas priklauso nuo duomenų savybių ir prognozavimo horizonto, todėl praktiniuose tyrimuose rekomenduojama taikyti kelis modelius lygiagrečiai ir vertinti jų rezultatus remiantis objektyviais tikslumo kriterijais.

2.5. Daugiamačių laiko eilučių modelių teorinis pagrindas

Įvertinus vienmačių laiko eilučių modeliavimo technikas, toliau yra nagrinėjama daugiamačių laiko eilučių modelių metodologija. Daugiamačiai modeliai orientuojasi į sudėtingesnių ekonominių procesų vertinimą, kai prognozuojamo rodiklio dinamika priklauso ne tik nuo jo istorinių reikšmių, bet ir nuo kitų tarpusavyje susijusių kintamųjų poveikio. Pasitelkus šio tipo modelius galima analizuoti priežastinius, trumpalaikius ir ilgalaikius ryšius tarp kelių ekonominių veiksnių, todėl daugiamačiai modeliai yra ypač svarbūs vertinant išorinių šokų, makroekonominių rodiklių bei struktūrinių pokyčių įtaką prognozuojamam procesui. Šiame skyriuje pirmiausia aptariama Granger priežastingumo ryšių nustatymo metodika, kuri grindžiama VAR modelių pagrindu, o vėliau nagrinėjami pagrindiniai daugiamačių laiko eilučių prognozavimo modeliai – ARIMAX, Prophet bei ARDL.

2.5.1. Granger priežastingumo analizė laiko eilučių tyrimuose

Statistiniuose tyrimuose, kuriuose analizuojami keli kintamieji, viena pagrindinių užduočių yra nustatyti, ar tarp jų egzistuoja ryšys. Laiko eilučių analizėje šis ryšys dažniausiai vertinamas taikant koreliacijos koeficientą arba priežastingumo matą. Nors abu metodai nagrinėja sąsajas tarp kintamųjų, jie remiasi skirtingomis teorinėmis prielaidomis ir suteikia skirtingo pobūdžio informaciją. Koreliacija atskleidžia statistinį ryšį tarp kintamųjų, tačiau neatsako į klausimą apie jo kryptinį poveikį. Priežastingumo analizė siekia nustatyti, ar vieno proceso dinamika daro įtaką kito proceso pokyčiams, taip įvertinant, ar vieno kintamojo praeities informacija gali būti naudojama prognozuojant kito elgseną.

Vienas iš pagrindinių tokių metodų yra Granger priežastingumas, kuris padeda nustatyti, ar vieno kintamojo praeities informacija paaiškina kito kintamojo dinamiką. Granger priežastingumo analizė grindžiama idėja, jog vieno proceso praeities informacija gali turėti įtakos kito proceso prognozei. Hyndmanas ir Athanasopoulosas [27] teigia, kad kintamasis x_t laikomas Granger priežastimi kintamojo y_t atžvilgiu tais atvejais, kai tam tikrų vėlavimų x_t reikšmės statistiškai reikšmingai pagerina y_t prognozę, lyginant su modeliu, kuriame naudojama tik y_t istoriniai duomenys. Kadangi priežastingumas vertinamas pagal prognozavimo tikslumo pagerėjimą, šio rodiklio nereikėtų interpretuoti kaip tikro priežasties-pasekmės ryšio mato, nes jis tik atskleidžia informacijos perdavimo kryptį tarp nagrinėjamos kintamųjų poros.

Atliekant Granger priežastingumo analizę būtina atsižvelgti į dvi pagrindines metodologines prielaidas, kurios lemia gautų rezultatų patikimumą. Pirmiausia, analizuojamos laiko eilutės turi atitikti stacionarumo sąlygą, nes nestacionarūs procesai gali lemti klaidingas išvadas [27]. Modelyje taip pat turi būti tinkamai parinktas vėlinimų skaičius, kuris padeda išlaikyti pusiausvyrą tarp modelio lankstumo ir efektyvumo. Pasak Asteriou ir Halo [34], nepakankamą vėlinimų skaičių turintis modelis gali praleisti svarbią priežastingumo ryšio informaciją, o per didelis vėlinimų kiekis lemia parametrų perteklinį įvertinimą. Abi šios alternatyvos lemia sumažėjusį modelio prognozavimo tikslumą, todėl svarbu, jog atrinktas vėlinimų skaičius būtų optimaliausias konkretaus tyrimo atveju.

Granger priežastingumo analizė praktikoje dažniausiai atliekama taikant VAR modelius. VAR modeliai, tai vienas iš pagrindinių įrankių dinaminėms sąveikoms tarp kintamųjų tirti, nes jie leidžia kiekvieną kintamąjį modeliuoti kaip jo paties arba kitų nagrinėjamų kintamųjų vėlinimų reikšmių funkciją, iš anksto nereikalaujant nustatyti griežtų teorinių apribojimų [35]. Dviejų kintamųjų VAR(p) modelis pateikiamas pagal (2.5.1.1) formulę:

$$\begin{aligned} y_t &= \alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \sum_{i=1}^p \beta_i x_{t-i} + \varepsilon_{y,t}; \\ x_t &= \gamma_0 + \sum_{i=1}^p \gamma_i x_{t-i} + \sum_{i=1}^p \delta_i y_{t-i} + \varepsilon_{x,t}; \end{aligned} \tag{2.5.1.1}$$

čia y_t, x_t – analizuojami laiko eilučių kintamieji;
 α_0 – y lygties konstanta;
 p – vėlavimų skaičius;
 α_i – y autoregresiniai koeficientai;

β_i – x poveikio y koeficientai;
 γ_0 – x lygties konstanta;
 γ_i – x autoregresiniai koeficientai;
 δ_i – y poveikio x koeficientai;
 $\varepsilon_{y,t}, \varepsilon_{x,t}$ – atsitiktinės kintamųjų paklaidos.

Kintamasis x_t vertinamas y_t Granger priežastimi tada, kai bent vienas koeficientas β_i yra statistiškai reikšmingas.

Atliekant Granger priežastingumo testą yra keliami nulinė hipotezė, kuri teigia, kad x_t neturi Granger priežastingumo y_t atžvilgiu, Ši hipotezė gali būti pateikta ir matematine išraiška pagal (2.5.1.2) formulę:

$$H_0: \beta_1 = \beta_2 = \dots = \beta_p = 0; \quad (2.5.1.2)$$

čia β_i – x poveikio y koeficientai.

Alternatyvioji hipotezė teigia, kad bent vienas $\beta_i \neq 0$.

Hipotezių tikrinimui yra naudojamas F testas, pagal kurio (2.5.1.3) formulę yra lyginamas apribotas modelis (kur $\beta_i = 0$), su neapribotu modeliu, (kur β_i gali būti laisvai įvertinamas):

$$F = \frac{(RSS_r - RSS_{ur})/p}{RSS_{ur}/(T - 2p - 1)}; \quad (2.5.1.3)$$

čia RSS_r – apriboto modelio liekamųjų paklaidų kvadratų suma;
 RSS_{ur} – neapriboto modelio liekamųjų paklaidų kvadratų suma;
 p – vėlinimų skaičius modelyje;
 T – stebėjimų skaičius.

Jeigu apskaičiuota F statistikos reikšmė viršija kritinę reikšmę, nulinė hipotezė yra atmetama, ir konstatuojama, jog tarp kintamųjų poros egzistuoja Granger priežastingumas.

Nors Granger priežastingumo metodas yra lengvai pritaikomas ir plačiai naudojamas, jis turi keletą svarbių apribojimų, kuriuos būtina įvertinti prieš atliekant analizę. Netinkamai parinktas vėlavimų skaičius (p) gali lemti klaidingas išvadas, o nestacionarūs duomenys gali iškreipti testų rezultatus, sukuriant fiktyvias sąsajas tarp analizuojamų kintamųjų. Granger priežastingumo analizė taip pat neatsižvelgia į galimus struktūrinius lūžius ar netiesinius ryšius, kurie realiose laiko eilutėse pasitaiko gana dažnai [36]. Nepaisant šių apribojimų, Granger metodas išlieka svarbiu laiko eilučių analizės įrankiu, kuris papildoma koreliacinės analizės rezultatus ir leidžia identifikuoti prognozavimo požiūriu reikšmingus ryšius tarp kintamųjų.

2.5.2. ARIMAX modelių teorinis pagrindas

Atsižvelgiant į ARIMA apribojimus, atliekant sudėtingų ekonominių procesų modeliavimo uždavinius, yra pritaikomos modifikacijos, kurios išplečia ARIMA struktūrą. Vienas iš pagrindinių ARIMA plėtinių yra ARIMAX, kuris pasižymi egzogeninių, kintamųjų įtraukimu į modelį. ARIMAX

modeliai leidžia įvertinti laiko eilutės dinamiką remiantis ne tik istorine prognozuojamo kintamojo raida, bet ir tiesioginiu išorinių veiksnių poveikiu, kas ženkliai sumažina informacijos praradimą, ir didina modelio pritaikomumą nagrinėjamiems duomenims [27].

Matematinė prasme ARIMA(p, d, q) transformacija į ARIMAX(p, d, q) atliekama papildant modelį egzogeninių kintamųjų vektoriumi. ARIMAX modelio bendroji modelio išraiška pateikiama pagal (2.5.2.1) formulę:

$$\Delta^d y_t = c + \sum_{i=1}^p \phi_i \Delta^d y_{t-i} + \sum_{k=1}^K \beta_k x_{k,t} + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j}; \quad (2.5.2.1)$$

čia Δ^d – d-osios eilės diferencijavimo operatorius;
 c – modelio konstanta;
 p – autoregresinės dalies eilė;
 ϕ_i – i-ojo autoregresinio parametro koeficientas;
 y_{t-i} – kintamojo reikšmė ankstesniu laikotarpiu;
 K – į modelį įtrauktų išorinių kintamųjų skaičius;
 β_k – egzogeninio kintamojo poveikį apibūdinantis koeficientas;
 $x_{k,t}$ – k -tasis egzogeninis kintamasis laiko momentu t ;
 ε_t – atsitiktinė paklaida;
 q – slankiojo vidurkio modelio eilė;
 j – vėlinimo indeksas;
 θ_j – j-ojo slankiojo vidurkio parametro koeficientas;
 ε_{t-j} – ankstesnio laikotarpio paklaida.

ARIMAX modelių taikymas suteikia pagrindą nuosekliai laiko eilučių analizei, kurios metu yra įvertinamos tiek trumpalaikes, tiek ilgalaikes tendencijos. Šios grupės modeliai gali identifikuoti pagrindinius laiko eilučių struktūrinius elementus bei egzogeninių kintamųjų įtaką.

2.5.3. Prophet modelių teorinis pagrindas

Nors ARIMA, SARIMA ir ARIMAX modeliai leidžia detalai modeliuoti laiko eilučių dinamiką bei sezoniskumą, jų taikymas praktikoje dažnai reikalauja sudėtingų parametrų apskaičiavimo veiksmų, taip pat šie modeliai yra jautrūs struktūriniams procesų lūžiams. Atsižvelgiant į šiuos ARMA grupės modelių trūkumus mokslinėje literatūroje vis daugiau dėmesio yra skiriama alternatyviems laiko eilučių prognozavimo metodams, kurie pasižymi dar didesniu lankstumu prisitaikant prie realių ekonominių duomenų savybių. Vienas iš tokių metodų yra Prophet modeliavimas, kurio privalumai atsiskleidžia analizuojant laiko eilutes, pasižyminčias ryškiu sezoniskumu, nenumatytais trendų pokyčiais ir netikėtais struktūriniais lūžiais.

Prophet, tai adityvus prognozavimo modelis, kuris išsiskiria lengvu rezultatų interpretavimu ir praktiniu pritaikomumu, o vienas iš pagrindinių Prophet privalumų yra tai, jog jis nereikalauja sudėtingų parametrų įverčių skaičiavimų, kas yra būdinga klasikiniams ARIMA šeimos modeliams [37]. Be to, Prophet gali būti taikomas tiek modeliuojant laiko eilutę remiantis vien tik priklausomo kintamojo istorinėmis reikšmėmis, tiek plečiant modelį papildomais nepriklausomais kintamaisiais

ar iš anksto žinomais išoriniais įvykiais, todėl jis yra lankstus tiek vienmačių, tiek daugiamačių duomenų prognozavime. Bendroji Prophet modelio forma pateikiama pagal (2.5.3.1) formulę:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t; \quad (2.5.3.1)$$

čia $y(t)$ – prognozuojamos laiko eilutės reikšmė laiko momentu t ;
 $g(t)$ – trendo komponentė;
 $s(t)$ – sezoniškumo komponentė;
 $h(t)$ – vienkartinių įvykių poveikio komponentė;
 ε_t – atsitiktinė paklaida.

Trendo komponentė aprašo ilgalaikę laiko eilutės pokyčio kryptį ir gali būti modeliuojama naudojant linijinio arba logistinio trendo modelį. Linijinio trendo atveju Prophet suteikia galimybę tyrėjui papildomai į analizę įtraukti laiko eilutės struktūrinius lūžio taškus, kuriuose trendo komponentė gali pakeisti savo kryptį, priklausomai nuo skirtingų laiko momentų [37]. Tokia trendo forma išreiškiama pagal (2.5.3.2) formulę:

$$g(t) = (k + a(t)^T \delta)t + (m + a(t)^T \gamma); \quad (2.5.3.2)$$

čia $g(t)$ – trendo komponentė;
 k – pradinis augimo tempas;
 $a(t)$ – išorinių kintamųjų vektorius laiku t ;
 δ – trendo pokytis lūžio taške;
 m – pradinis trendo lygis;
 γ – regresorių poveikis baziniam lygiui.

Sezoniškumo komponentė Prophet modelyje aprašoma taikant Furjė eilučių aproksimaciją, kuri leidžia lanksčiai modeliuoti pasikartojančius ciklus be griežtų sezoniškumo prielaidų. Ši komponentė išreiškiama pagal (2.5.3.3) formulę:

$$s(t) = \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right); \quad (2.5.3.3)$$

čia $s(t)$ – sezoniškumo komponentė;
 N – Fourier harmonikų skaičius (sezoniškumo sudėtingumo laipsnis);
 a_n – kosinuso komponentės svoriai;
 n – harmonikos indeksas;
 t – laiko periodo indeksas;
 P – pradinis augimo tempas;
 b_n – sinuso komponentės svoriai.

Be trendo ir sezoniškumo komponentių, Prophet modeliai taip pat leidžia įvertinti iš anksto žinomų vienkartinių įvykių poveikį, į modelį įtraukiant specialias funkcijas. Tokie įvykiai gali būti šventinės

dienos, politiniai sprendimai, rinkodaros kampanijos ar kiti konkretūs veiksniai, kurie turi trumpą, tačiau reikšmingą poveikį laiko eilutės dinamikai [37].

Nors Prophet modelis suteikia galimybę į analizę įtraukti papildomus regresorius, jis tiesiogiai neįvertina jų statistinio reikšmingumo, kadangi vidiniai modelio koeficientai nėra interpretuojami klasikine ekonometrine prasme. Siekiant gauti statistiškai interpretuojamus parametrų įverčius bei jų p-reikšmes, Prophet metodologiją galima praplėsti pritaikant tiesinę regresiją:

Pirmiausia Prophet modelis įvertina trendo bei sezoniškumo komponentes ir panaudodamas jas nustato likusią laiko eilutės dalį pagal (2.5.3.4) formulę:

$$e(t) = y(t) - (g(t) + s(t)); \quad (2.5.3.4)$$

čia $e(t)$ – laiko eilutės dalis, kurios nepaaiškina trendo ir sezoniškumo komponentės;
 $y(t)$ – prognozuojamos laiko eilutės reikšmė laiko momentu t ;
 $g(t)$ – trendo komponentė;
 $s(t)$ – sezoniškumo komponentė.

Siekiant įvertinti papildomų regresorių poveikį likutinei laiko eilutės komponentei, taikoma tiesinės regresijos analizė pagal (2.5.3.5) formulę:

$$e(t) = \beta_1 X_1(t) + \beta_2 X_2(t) + \dots + \beta_k X_k(t) + \varepsilon_t; \quad (2.5.3.5)$$

čia $e(t)$ – laiko eilutės dalis, kurios nepaaiškina trendo ir sezoniškumo komponentės;
 β_k – regresijos koeficientai;
 X_k – egzogeniniai kintamieji momentu t ;
 ε_t – atsitiktinė paklaida.

Tokiu būdu gauti koeficientai β_k gali būti interpretuojami kaip regresijos parametrų įverčiai, kuriems taip pat apskaičiuojamos p-reikšmės. Šie įverčiai leidžia įvertinti kiekvieno regresoriaus poveikį priklausomo kintamojo dinamikai.

Nepaisant savo lankstumo ir paprastos struktūrinės interpretacijos, Prophet metodas ne visada tiksliai atspindi autokoreliacinę duomenų struktūrą, kuri yra ypač svarbi prognozuojant trumpalaikius svyravimus, todėl situacijose, kai yra vertinamos laiko eilutės reikšmių priklausomybės tarp artimų laikotarpių, tradiciniai statistiniai modeliai, tokie kaip SARIMAX, gali būti pranašesni, nes jie tiesiogiai modeliuoja autoregresinius ir slankiojo vidurkio procesus. Dėl šios priežasties Prophet dažniausiai yra vertinamas kaip universalesnė priemonė struktūrinei trendo ir sezoniškumo dekompozicijai atlikti, o SARIMAX yra tinkamesni analizuojant nedidelius, greitai kintančius laiko eilučių svyravimus, kuriems būtinas tikslus autokoreliacinio ryšio įvertinimas.

2.5.4. ARDL modelių teorinis pagrindas

Siekiant išvengti duomenų stacionarumo sąlygos, kuri yra griežtai taikoma ARMA modeliuose, tyrėjai dažnai naudoja autoregresinius su paskirstytais vėlavimais (ARDL) modelius. Šie modeliai pasižymi tuo, jog jie geba analizuoti tiek trumpalaikes, tiek ilgalaikes kintamųjų tendencijas neatsižvelgiant į jų integracijos laipsnį (I(0) arba I(1)). Pasak Baffeso ir kt. [26], vienas svarbiausių ARDL metodologijos privalumų yra tai, jog šio tipo modelių specifikacijose galima papildomai

įtraukti ne tik išorinius veiksnius, bet ir fiktyvius kintamuosius, kurie gali atspindėti reikšmingus duomenų struktūrinius lūžius. ARDL modelio matematinė išraiška yra pateikiama pagal (2.5.4.1) formulę:

$$y_t = \alpha_0 + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=0}^q \beta_j x_{t-j} + \varepsilon_t; \quad (2.5.4.1)$$

čia y_t – priklausomas kintamasis;
 α_0 – modelio konstanta;
 p – priklausomo kintamojo vėlinimų skaičius;
 ϕ_i – priklausomo kintamojo vėlinimų koeficientai;
 y_{t-i} – priklausomo kintamojo reikšmė ankstesniu laikotarpiu;
 q – nepriklausomo kintamojo vėlinimų skaičius;
 β_j – nepriklausomo kintamojo koeficientai;
 x_{t-j} – nepriklausomo kintamojo reikšmė esamu arba ankstesniu laikotarpiu;
 ε_t – atsitiktinė paklaida.

ARDL metodologijos lankstumą taip pat lemia tai, jog ji leidžia parinkti optimalų vėlinimų skaičių kiekvienam modelio kintamajam. Toks parametrų nustatymo principas padeda išvengti perteklinio arba nepakankamo vėlinimų skaičiaus įtraukimo, kuris gali iškraipyti modelio įverčius ir sumažinti prognozių tikslumą.

Sukūrus ir įvertinus ARDL modelius, pirmiausia yra analizuojamos jų ex-post paklaidos, kurios apskaičiuojamos naudojant faktines duomenų reikšmes. Šios paklaidos atspindi modelio gebėjimą atkurti priklausomo kintamojo reikšmes imties laikotarpiu ir leidžia įvertinti modelio optimalumą. Ex-post paklaidų analizė dažniausiai naudojama skirtingų modelių palyginimui bei tinkamiausios modelio specifikacijos parinkimui.

Įsitikinus, kad ARDL modeliai adekvačiai įvertina istorinius duomenis, o jų prognozės pasižymi priimtinu tikslumu, ex-post paklaidos yra perskaičiuojamos į ex-ante paklaidas. Ex-ante paklaidos vertinamos remiantis prognozuotomis priklausomo kintamojo reikšmėmis ateities laikotarpiams, kai faktinės reikšmės modelio įvertinimo metu nėra žinomos. Tokiu būdu ex-ante paklaidos leidžia objektyviau įvertinti ARDL modelių prognozavimo gebėjimus realiomis sąlygomis bei jų tinkamumą praktiniam taikymui, užtikrinant, jog modelio vertinimas neapsiriboja vien tik istorinių duomenų atkartojimu.

2.6. Prognozavimo klaidų įverčių teorinis pagrindas

Atrinkus laiko eilučių analizėje naudojamus modelius ir atlikus duomenų prognozę, skirtingų modelių rezultatai tarpusavyje yra palyginami remiantis prognozavimo tikslumo vertinimo rodikliais, kurių teikiama informacija tyrėjui padeda atrinkti tinkamiausią laiko eilutės duomenų prognozavimo modelį. Makridakis ir kt. [29] teigia, kad nagrinėjant modelių tikslumą vieno rodiklio nepakanka, todėl rekomenduojama naudoti kelis tarpusavyje papildančius tikslumo kriterijus.

Atsižvelgiant į tai, jog dauguma prognozavimo modelių pasižymi nevienodu jautrumu duomenų struktūrai ir dispersijai, tinkamai parinkti klaidų įverčiai gali padėti įvertinti ne tik absoliutų modelio tikslumą, bet ir jo stabilumą.

Vienas plačiausiai taikomų rodiklių prognozavimo klaidų įverčių yra RMSE, kuris įvertina prognozės paklaidų dispersiją ir yra ypač jautrus didelėms klaidoms. Rodiklio (2.6.1) formulė:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2};$$

(2.6.1)

čia n – stebėjimų skaičius;
 y_t – faktinė kintamojo reikšmė momentu t ;
 \hat{y}_t – prognozuota kintamojo reikšmė momentu t .

RMSE suteikia daugiausiai naudos tais atvejais, kai tyrimo strategija numato griežtas bausmes už didelius nukrypimus, tačiau šio rodiklio pagrindinis trūkumas yra jo priklausomybė nuo duomenų skalės, nes RMSE vertė tiesiogiai atspindi analizuojamo kintamojo vienetus, todėl skirtingų laiko eilučių ar skirtingų skalių duomenų palyginimas yra neįmanomas. Dėl šios priežasties RMSE dažnai naudojamas kartu su MAPE, SMAPE ar MASE rodikliais, kurie leidžia įvertinti prognozavimo modelių tikslumą įvairiuose kontekstuose Makridakis ir kt. [29].

Kitas dažnai naudojamas klaidų įverčių rodiklis yra MAPE, kuris pateikia prognozės tikslumą procentais. Rodiklio (2.6.2) formulė:

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|;$$

(2.6.2)

čia n – stebėjimų skaičius;
 y_t – faktinė kintamojo reikšmė momentu t ;
 \hat{y}_t – prognozuota kintamojo reikšmė momentu t .

MAPE rodiklis yra lengvai interpretuojamas, tačiau jo patikimumas mažėja, kai tikrosios reikšmės artėja prie nulio.

Kartu naudojami RMSE ir MAPE paklaidų rodikliai suteikia išsamius prognozavimo tikslumo rezultatus, leidžiančius įvertinti modelio efektyvumą lyginant su baziniais metodais. Kelių prognozavimo klaidų įverčių rodiklių taikymas praktikoje yra būtinas siekiant objektyviai įvertinti prognozavimo modelių kokybę, sumažinti vieno metrikos šališkumo riziką ir pasirinkti tinkamiausią modelį praktiniam pritaikymui realioje aplinkoje.

3. Tyrimo rezultatai

Šiame skyriuje aprašomi degalų kainų dinamikos modeliavimo ir prognozavimo tyrimo rezultatai, kurie padės nustatyti tinkamiausią vienmačių arba daugiamačių modelių techniką degalų kainų analizei. Tyrimo metu yra naudojami mokslinės literatūros apžvalgos metu atrinkti nepriklausomi kintamieji, taip pat, įvertinamas atrinktų šokų poveikis.

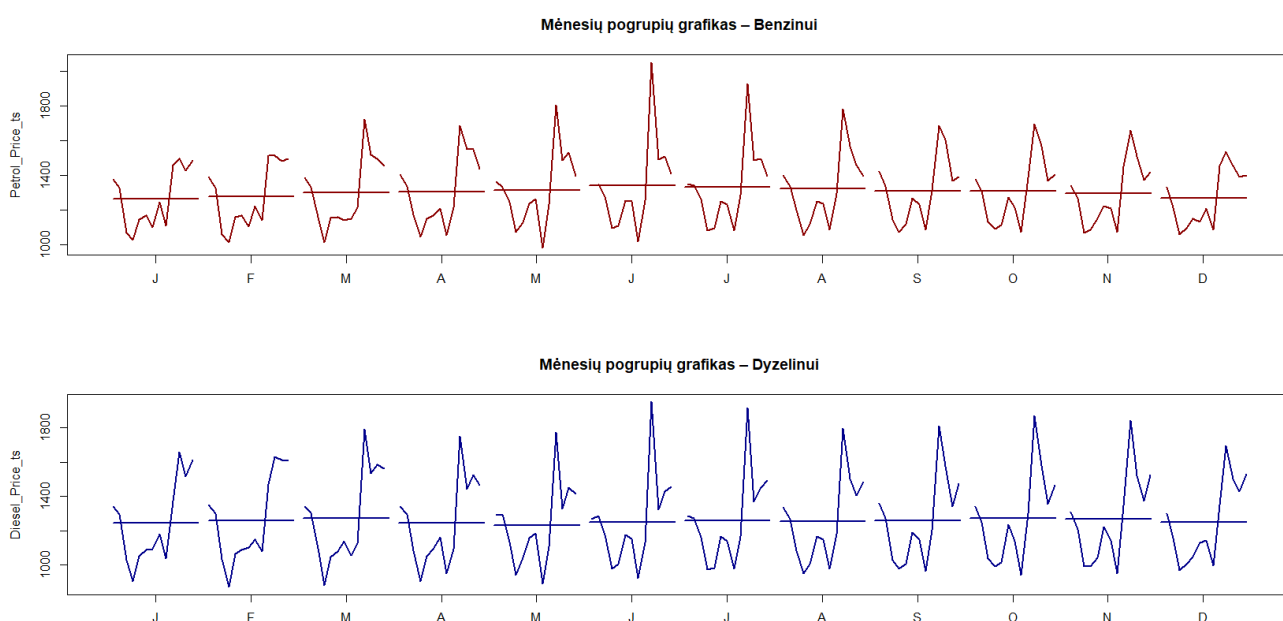
3.1. Priklausomų kintamųjų apžvalga

Prieš atliekant priklausomų kintamųjų analizę, tikslinga įvertinti pagrindines nagrinėjamų laiko eilučių statistines charakteristikas. Remiantis 5 lentelėje pateiktomis mažmeninių benzino ir dyzelino kainų laiko eilučių aprašomosios statistikos charakteristikomis, buvo įvertintas bendras šių degalų rūšių kainų lygis ir jų sklaida 2013-2025 m. laikotarpiu.

5 lentelė. Mažmeninių benzino ir dyzelino kainų kintamųjų aprašomoji statistika

Kintamasis	Minimali reikšmė	Maksimali reikšmė	Mediana	Vidurkis	Standartinis nuokrypis
Mažmeninė benzino mažmeninė kaina	984,25	2051,34	1271,02	1303,30	194,51
Mažmeninė dyzelino mažmeninė kaina	871,50	1952,90	1187,09	1255,07	244,46


Benzino kainoms buvo būdingos didesnės centrinės tendencijos reikšmės (vidurkis ir mediana), todėl galima teigti, jog nagrinėjamu laikotarpiu benzinas buvo vidutiniškai brangesnis už dyzeliną, tačiau dyzelino mažmeninė kaina pasižymėjo didesniu kintamumu, kurį atspindėjo didesnis standartinis nuokrypis bei platesnis stebinių reikšmių intervalas. Išanalizavus bazines priklausomų kintamųjų charakteristikas, toliau yra įvertinami priklausomų kintamųjų mėnesių pogrūpių grafikai, kurie yra pateikti 9 paveiksle. Šie grafikai detalizuoja benzino ir dyzelino kainų elgseną pagal atskirus kalendorinius mėnesius, leidžiančią identifikuoti sezoniškumo požymius bei kainų pasiskirstymo skirtumus metų eigoje.



9 pav. Mažmeninių benzino ir dyzelino kainų mėnesių pogrūpių grafikai

Benzino kainų mėnesių pogrūpių grafike galima pastebėti, jog vidutinis kainų lygis yra aukščiausias vasaros mėnesiais, kas gali būti siejama su padidėjusiu individualaus transporto naudojimu bei sezoniniu gyventojų mobilumo augimu. Tuo tarpu rudens ir žiemos mėnesiais benzino kainų pasiskirstymas pasižymi mažesne dispersija bei siauresniu svyravimų diapazonu nei šiltuoju metų laikotarpiu. Analizuojant dyzelino mėnesių pogrūpių grafiką, galima teigti, jog kainų lygis ir svyravimų amplitudė, kaip ir benzino atveju, nėra tolygūs visais metų mėnesiais. Pastebima, jog antroje metų pusėje, ypač vasaros ir rudens laikotarpiu, dyzelino kainos pasižymi didesniais maksimaliais pikais ir platesniu svyravimų diapazonu nei metų pradžioje. Ši tendencija gali būti siejama su intensyvesne ekonomine veikla šiltuoju metų laikotarpiu, kuri lemia išaugusią dyzelino paklausą transporto, logistikos bei žemės ūkio sektoriuose. Tuo tarpu žiemos mėnesiais dyzelino kainų pasiskirstymas yra labiau koncentruotas, o svyravimų amplitudės yra siauresnės, nors bendras kainų lygis išlieka santykinai aukštu.

Apibendrinant galima teigti, jog benzino ir dyzelino kainų mėnesių pogrūpių analizės rezultatai indikuoja galimą sezoniškumo egzistavimą nagrinėjamosiose laiko eilutėse. Siekiant tiksliau identifikuoti sezoniškumo bei trendo poveikį benzino ir dyzelino kainoms, toliau yra atliekama šių kintamųjų laiko eilučių dekompozicija, kurios rezultatai pateikiami 10 paveiksle.



10 pav. Mažmeninių benzino ir dyzelino kainų laiko eilučių dekompozicija

Išskaidžius benzino ir dyzelino kainų laiko eilutes į atskiras komponentes, detaliau įvertinamas ilgalaikio trendo, sezoniškumo bei atsitiktinių paklaidų poveikis bendrai kainų dinamikai. Analizuojant trendo komponentę, galima pastebėti, jog tiek benzino, tiek dyzelino kainų ilgalaikė dinamika pasižymi struktūriškai panašiomis tendencijomis. 2013-2016 metų laikotarpiu abiejų degalų rūšių kainos turėjo mažėjimo tendencija, kurią vėliau pakeitė santykinio stabilumo etapas, trukęs iki 2019 metų. Ryškus kainų trendo lūžis buvo užfiksuotas 2020 metų pradžioje, kai benzino ir dyzelino kainų dinamika pasižymėjo mažėjimo tendencijomis. Nuo 2021 metų antrosios pusės trendo komponentė indikuoja spartų degalų kainų augimą, kuris piką pasiekia 2022 metais ir vėliau stabilizuojasi.

Sezoniškumo dedamoji benzino ir dyzelino kainų laiko eilutėse yra silpna ir nepastovi, nes ją užgožia ilgalaikis trendas. Dyzelino kainų sezoniškumas pasireiškia dažnesniais svyravimais, kurių formos yra asimetriškos, o benzino kainų sezoniškumo komponentė atspindinti nuoseklesnį kainų pokytį skirtingais metų laikotarpiais. tačiau jie yra užgožiami ilgalaikių trendų ir išorinių šokų.

Galiausiai, yra įvertinamas benzino ir dyzelino kainų stacionarumas. Atsižvelgiant į 6 lentelėje pateiktas ADF testo p-dydžių reikšmes, galima konstatuoti, kad benzino ir dyzelino kainų kintamiesiems nulinė hipotezė apie vienietinės šaknies egzistavimą nėra atmetama, todėl galima teigti, kad abiejų degalų rūšių kainų laiko eilutės nėra stacionarios. KPSS testo rezultatai taip pat patvirtina šią prielaidą, nes benzino kainų ir dyzelino kainų laiko eilutėms nulinė hipotezė, kuri patvirtina laiko eilutės stacionarumą, yra atmetama.

6 lentelė. Mažmeninių benzino ir dyzelino kainų kintamųjų stacionarumo įvertinimas

Kintamasis	ADF testas		KPSS testas		Integracijos laipsnis
	p-dydis	Išvada	p-dydis	Išvada	
Mažmeninė benzino kaina	0,42	Laiko eilutė nestacionari	<0,01	Laiko eilutė nestacionari	I(1)
Mažmeninė dyzelino kaina	0,37	Laiko eilutė nestacionari	<0,01	Laiko eilutė nestacionari	I(1)

Kadangi abiejų stacionarumo testų rezultatai sutampa, galima teigti, jog benzino ir dyzelino kainų laiko eilutės neatitinka stacionarumo sąlygos. Atlikus diferencijavimą ir pakartotinai įvertinus stacionarumą, buvo nustatyta, jog benzino ir dyzelino kainų kintamieji yra integruoti pirmos eilės procesai I(1).

3.2. Nepriklausomų kintamųjų apžvalga

Kadangi degalų kainų pokyčius lemia ne tik vidiniai rinkos procesai, bet ir makroekonominiai bei energetikos sektoriaus veiksniai, remiantis išanalizuotais moksliniais tyrimais ir empirine praktika, buvo atrinkti nepriklausomi kintamieji, kurie gali turėti tiesioginį ar netiesioginį poveikį benzino ir dyzelino kainų susiformavimui. Nepriklausomų kintamųjų aprašomoji statistika yra pateikiama 7 lentelėje.

7 lentelė. Nepriklausomų kintamųjų aprašomoji statistika

Kintamasis	Minimali reikšmė	Maksimali reikšmė	Mediana	Vidurkis	Standartinis nuokrypis
Mokesčių dalis benzino kainoje	40,07	64,71	52,62	52,70	4,45
Mokesčių dalis dyzelino kainoje	36,42	59,05	47,64	47,22	4,76

Kintamasis	Minimali reikšmė	Maksimali reikšmė	Mediana	Vidurkis	Standartinis nuokrypis
Benzinui taikomas akcizas	434,40	466,00	434,43	449,00	15,79
Dyzelinui taikomas akcizas	330,14	466,00	347,00	362,22	38,39
Brent naftos kaina	18,38	122,71	71,14	72,19	22,29
Lietuvos benzino ištekliai	13,09	35,70	20,15	21,24	5,08
Lietuvos dyzelino ištekliai	65,50	177,50	134,55	130,17	26,28
Lietuvos žalios naftos ištekliai	143,10	926,00	776,10	735,37	138,74
Lietuvos naftos atsargos	84,00	108,00	92,00	92,48	3,96
Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje	-46,40	124,90	1,35	6,69	30,86
Pramonės sektoriaus produkcijos apimčių indeksas	57,20	124,60	82,20	85,56	17,52
Kelių transporto priemonių skaičius	1118,00	5690,00	2434,50	2656,94	969,10
Importas	1598025,90	5209212,50	2555931,05	2837236,17	766547,70
Lietuvos nedarbo lygis	5,10	13,40	7,30	7,82	1,87
Gamtinių dujų vartojimas Lietuvoje	1873,00	14549,00	6754,00	6930,25	2375,70
Elektros energijos pasiūla Lietuvos rinkoje	627,00	1171,38	893,95	896,06	99,43

Įvertinus nepriklausomų kintamųjų aprašomąją statistiką bei jų dinamikos grafikus, kurie pateikiami 1 priede, galima teigti, kad fiskalinę valstybės politiką degalų atžvilgiu apibūdinantys kintamieji (mokesčių dalis benzino ir dyzelino kainoje bei benzinui ir dyzelinui taikomi akcizai) analizuojamu laikotarpiu pasižymėjo ribota sklaida bei panašiomis vidurkio ir medianos reikšmėmis, kas indikuoja, jog nagrinėjamų duomenų pasiskirstymas nėra visiškai asimetriškas. Vis dėlto, įvertinus akcizų rodiklių variaciją, išryškėja tam tikri skirtumai – benzinui taikomas akcizas pasižymėjo mažesniu standartiniu nuokrypiu nei dyzelinui taikomas akcizas, o tai reiškia, jog analizuojamo laikotarpio metu, benzino akcizo lygis buvo pastovesnis ir kito nuosaikiau, nei dyzelino akcizas. Skirtingai nei fiskalinės politikos rodikliai, Brent naftos kainos kintamasis išsiskyrė gerokai didesne sklaida ir plačiu reikšmių intervalu. Aukštas naftos kainos kintamumas, atspindi globalių energetinių išteklių rinkų nepastovumą, kurį dažnai lemia geopolitiniai įvykiai, paklausos ir pasiūlos svyravimai bei tarptautinės ekonomikos ciklai.

Vertinant vidaus rinkos pasiūlos sąlygas apibūdinančius Lietuvos benzino ir dyzelino išteklių kintamuosius buvo nustatyta, jog jie pasižymėjo nuosaikesniu kintamumu nei Brent naftos kaina, taip pat, artimos vidurkio ir medianos reikšmės, kaip ir fiskalinės politikos kintamųjų atveju, nurodo, jog

Lietuvos išteklių rodiklių reikšmių pasiskirstymas nėra stipriai asimetriškas, o jų svyravimai tolygūs. Verta pastebėti, jog lyginant Lietuvos degalų išteklių rodiklius tarpusavyje, dyzelino išteklių kintamasis pasižymėjo gerokai didesne sklaida nei benzino ištekčiai, kaip ir akcizų kintamųjų atveju, kas rodo bendrą skirtingų su dyzelino degalų rūšimi susijusių kintamųjų tendenciją turėti platesnę stebinių sklaidą analizuojamu laikotarpiu. Lietuvos žalios naftos ištekčiai pasižymi dar didesniu reikšmių intervalo pločiu ir sklaida nei galutinių degalų išteklių rodikliai, todėl galima teigti, jog šio kintamojo reikšmių pokyčiai veikia intensyviau nei benzino ar dyzelino išteklių rodikliuose. Skirtingai nei žalios naftos išteklių rodiklis, Lietuvos naftos atsargų kintamasis pasižymi ganėtinai siauru reikšmių intervalu bei mažu standartiniu nuokrypiu, kas indikuoja, jog palaikomas naftos atsargų lygis Lietuvoje, analizuojamo laikotarpio metu išliko stabilus.

Analizuojant Lietuvos makroekonominės aplinkos rodiklius, pastebimas nevienodas reikšmių kintamumo profilis. Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje išsiskiria dideliu kintamumu ir itin plačiu reikšmių intervalu, apimančiu tiek neigiamus, tiek teigiamus stebinius, o vidurkio ir medianos atotrūkis indikuoja, jog šio kintamojo reikšmių pasiskirstymas yra asimetriškas. Tuo tarpu pramonės sektoriaus produkcijos apimčių indekso ir Lietuvos nedarbo lygio kintamieji pasižymi nuosaikesniu kintamumu, nes jų vidurkio ir medianos reikšmės yra gana artimos, o reikšmių intervalai yra santykinai siauresni nei harmonizuoto vartotojų kainų indekso atveju.

Vertinant kelių transporto priemonių skaičiaus ir importo rodiklius, matyti, kad abiem kintamiesiems būdingi platūs reikšmių intervalai ir didelė sklaida, todėl galima teigti, kad jų dinamika pasižymėjo reikšmingais pokyčiais. Galiausiai, energetikos sektoriaus kontekste gamtinių dujų vartojimo ir elektros energijos pasiūlos kintamieji rodo nevienodą stabilumo profilį: dujų vartojimas pasižymi didesne sklaida, o elektros energijos pasiūla – santykinai didesniu stabilumu, ką patvirtina siauresnis intervalo plotis ir artimos centrinės tendencijos reikšmės.

Atlikta nepriklausomų kintamųjų aprašomosios statistikos analizė atskleidžia analizuojamų rodiklių kintamumo struktūras ir leidžia identifikuoti stabilius arba reikšmingais svyravimais pasižyminčius kintamuosius. Nors daliai kintamųjų yra būdingas tolygus stebinių pasiskirstymas, kai kurie rodikliai išsiskiria didesne sklaida ir platesniais reikšmių intervalais, kas rodo intensyvesnius jų pokyčius analizuojamu laikotarpiu, o tai gali turėti tiesioginės įtakos kintamųjų stacionarumui. Nepriklausomų kintamųjų stacionarumo vertinimo rezultatai yra pateikiami 8 lentelėje.

8 lentelė. Nepriklausomų kintamųjų stacionarumo įvertinimas

Kintamasis	ADF testas		KPSS testas		Integracijos laipsnis
	p-dydis	Išvada	p-dydis	Išvada	
Mokesčių dalis benzino kainoje	0,48	Laiko eilutė nestacionari	0,04	Laiko eilutė nestacionari	I(1)
Mokesčių dalis dyzelino kainoje	0,48	Laiko eilutė nestacionari	0,10	Laiko eilutė stacionari	I(1)
Benzinui taikomas akcizas	0,55	Laiko eilutė nestacionari	<0,01	Laiko eilutė nestacionari	I(1)
Dyzelinui taikomas akcizas	0,96	Laiko eilutė nestacionari	<0,01	Laiko eilutė nestacionari	I(1)
Brent naftos kaina	0,43	Laiko eilutė nestacionari	0,10	Laiko eilutė stacionari	I(1)
Lietuvos benzino ištekčiai	<0,01	Laiko eilutė stacionari	<0,01	Laiko eilutė nestacionari	I(1)

Kintamasis	ADF testas		KPSS testas		Integracijos laipsnis
	p-dydis	Išvada	p-dydis	Išvada	
Lietuvos dyzelino ištekliai	<0,01	Laiko eilutė stacionari	<0,01	Laiko eilutė nestacionari	I(1)
Lietuvos žalios naftos ištekliai	<0,01	Laiko eilutė stacionari	0,10	Laiko eilutė stacionari	I(0)
Lietuvos naftos atsargos	0,33	Laiko eilutė nestacionari	0,02	Laiko eilutė nestacionari	I(1)
Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje	0,13	Laiko eilutė nestacionari	0,10	Laiko eilutė stacionari	I(1)
Pramonės sektoriaus produkcijos apimčių indeksas	0,17	Laiko eilutė nestacionari	<0,01	Laiko eilutė nestacionari	I(1)
Kelių transporto priemonių skaičius	0,43	Laiko eilutė nestacionari	0,02	Laiko eilutė nestacionari	I(1)
Importas	0,56	Laiko eilutė nestacionari	<0,01	Laiko eilutė nestacionari	I(1)
Lietuvos nedarbo lygis	0,44	Laiko eilutė nestacionari	<0,01	Laiko eilutė nestacionari	I(1)
Gamtinių dujų vartojimas Lietuvoje	<0,01	Laiko eilutė stacionari	<0,01	Laiko eilutė nestacionari	I(1)
Elektros energijos pasiūla Lietuvos rinkoje	<0,01	Laiko eilutė stacionari	0,10	Laiko eilutė stacionari	I(0)

Nepriklausomų kintamųjų stacionarumo vertinimo rezultatai parodė, kad iš visos rodiklių grupės stacionarumo sąlygą atitinka tik du kintamieji: Lietuvos žalios naftos ištekliai ir elektros energijos pasiūla Lietuvos rinkoje, todėl jie yra įvardijami kaip nulinės eilės integruoti procesai. Kadangi visi likę nepriklausomi kintamieji yra nestacionarūs, jiems yra taikomas diferencijavimas. Diferencijavus laiko eilutes vieną kartą, jos tenkina stacionarumo sąlygą, todėl nepriklausomi kintamieji: mokesčių dalis benzino kainoje, mokesčių dalis dyzelino kainoje, benziniui taikomas akcizas, dyzelinui taikomas akcizas, Brent naftos kaina, Lietuvos benzino ištekliai, Lietuvos dyzelino ištekliai, Lietuvos naftos atsargos, harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje, pramonės sektoriaus produkcijos apimčių indeksas, kelių transporto priemonių skaičius, importas, Lietuvos nedarbo lygis ir gamtinių dujų vartojimas Lietuvoje yra įvardijami kaip pirmos eilės integruoti procesai.

3.3. Benzino kainų modeliavimas ir prognozavimas

Šiame skyriuje atliekamas mažmeninių benzino kainų modeliavimas, prognozavimas ir šokų poveikio vertinimas, taikant tiek vienmačius laiko eilučių modelius, kurie remiasi tik istorinių benzino kainų duomenimis, tiek daugiamačius modelius, įtraukiančius išorinius veiksnius. Lyginant šiuos modelius, siekiama įvertinti, ar papildoma informacija apie išorinius faktorius reikšmingai pagerina prognozavimo tikslumą, taip identifikuojant geriausiai mažmeninių benzino kainų dinamiką prognozuojantį modelį.

3.3.1. Vienmačių benzino kainų modelių vertinimas

Šiame poskyryje yra vertinami vienmačiai mažmeninių benzino kainų prognozavimo modeliai, kurie įvertina benzino kainų dinamiką remiantis tik istoriniais kainų duomenimis. Benzino kainų modeliavimui taikomi naivus, sezoninis naivus, atsitiktinio pasivaikščiojimo su nukrypimu, sezoninio atsitiktinio pasivaikščiojimo su nukrypimu, ARIMA, SARIMA, ETS, slankiojo vidurkio ir Prophet modeliai. Kadangi vienmačių modelių analizė leidžia įvertinti, kiek informacijos apie benzino kainų raidą galima išgauti naudojant tik pačios kainos istorinius duomenis, vienmačių modelių rezultatai bus naudojami kaip bazinis atskaitos taškas daugiamačių modelių efektyvumo vertinimo metu.

Siekiant nustatyti tiksliausią vienmatį benzino kainų prognozavimo modelį, 9 lentelėje pateikiami skirtingų modelių prognozavimo paklaidų rezultatai.

9 lentelė. Vienmačių benzino kainų modelių paklaidų rezultatai

Modelio tipas	RMSE	MAPE
ARIMA(0,1,1)	42,07	1,84
SARIMA(0,1,1)(0,0,0)	42,07	1,84
Slankiojo vidurkio	46,92	3,08
Atsitiktinio pasivaikščiojimo su nukrypimu	47,34	2,13
Naivus	47,58	2,18
ETS(M,N,N)	47,58	2,18
Sezoninis naivus	73,48	4,34
Sezoninis atsitiktinio pasivaikščiojimo su nukrypimu	73,71	4,33
Prophet	213,00	14,34

Atsižvelgiant į vienmačių benzino kainų modelių prognozavimo rezultatus, galima teigti, kad ARIMA(0,1,1) modelis pasižymi mažiausiomis prognozavimo paklaidomis pagal abu vertinimo kriterijus (RMSE ir MAPE). Tokie rezultatai rodo, kad benzino kainų dinamika efektyviausiai modeliuojama taikant autoregresijos ir slankiojo vidurkio komponentus apjungiantį modelį, kuris geriausiai identifikuoja trumpalaikius kainų pokyčių dėsningumus. Tuo tarpu Prophet modelio reikšmingai didesnės paklaidos leidžia teigti, kad sudėtingesnės netiesinės struktūros modeliai nesuteikia papildomo pranašumo prognozuojant benzino kainų dinamiką.

Apibendrinant vienmačių mažmeninių benzino kainų modelių vertinimo rezultatus, galima teigti, kad benzino kainų dinamikoje sezoniškumo reikšmė yra ribota. Šią išvadą patvirtina tai, jog SARIMA modelio rezultatai buvo identiški ARIMA modeliui, o sezoninis naivus bei sezoninis atsitiktinio pasivaikščiojimo su nukrypimu modeliai pasižymėjo didesnėmis prognozavimo paklaidomis nei jų nesezoniniai atitikmenys. Tokie vienmačių modelių rezultatai rodo, kad periodiškai pasikartojantys sezoniniai dėsningumai benzino kainų dinamikoje nėra pakankamai stabilūs ir reikšmingi, kad suteiktų papildomos prognostinės vertės.

3.3.2. Benzino kainų ir išorinių veiksnių Granger priežastingumo ryšio vertinimas

Prieš pradėdant daugiamačių benzino kainų modelių analizę, būtina identifikuoti, kurie iš atrinktų nepriklausomų kintamųjų turi statistiškai reikšmingą priežastinį ryšį su mažmeninių benzino kainų dinamika. Priežastingumo ryšio identifikavimui yra naudojamas Granger priežastingumo testas, leidžiantis nustatyti, ar tam tikrų ekonominių, energetinių ar rinkos rodiklių istoriniai pokyčiai suteikia papildomos informacijos prognozuojant benzino kainų raidą.

Granger priežastingumo vertinimo rezultatai pateikiami 10 lentelėje, kurioje nurodytas kiekvieno nepriklausomo kintamojo poveikis benzino kainoms, priežastingumo ryšio statistinis reikšmingumas bei VAR modelio specifikacija, kurią naudojant šis ryšys buvo nustatytas.

10 lentelė. Benzino kainų Granger priežastingumo ryšio vertinimas

Nepriklausomas kintamasis	F statistikos p dydis	Poveikis benzino kainai	Ryšio reikšmingumas	VAR modelio vėlinimų skaičius
Mokesčių dalis benzino kainoje	0,11	Neigiamas	Nereikšmingas	3
Benzinui taikomas akcizas	0,39	Teigiamas	Nereikšmingas	3
Brent naftos kaina	0,00	Teigiamas	Reikšmingas	3
Lietuvos benzino išteklių	0,37	Neigiamas	Nereikšmingas	6
Lietuvos naftos išteklių	0,03	Neigiamas	Reikšmingas	3
Lietuvos naftos atsargos	0,23	Teigiamas	Nereikšmingas	4
Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje	0,02	Teigiamas	Reikšmingas	12
Kelių transporto priemonių skaičius	0,72	Neigiamas	Nereikšmingas	3
Lietuvos nedarbo lygis	0,06	Teigiamas	Reikšmingas	11
Gamtinių dujų vartojimas Lietuvoje	0,94	Teigiamas	Nereikšmingas	5
Elektros energijos pasiūla Lietuvos rinkoje	0,01	Teigiamas	Reikšmingas	5

Remiantis priežastingumo analizės rezultatais galima teigti, kad benzino kainas statistiškai reikšmingai veikia penki veiksniai: Brent naftos kaina, šalies naftos išteklių, harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje, nedarbo lygis ir elektros energijos pasiūla vietinėje rinkoje. Brent naftos kaina, kainų indeksas skystojo kuro rinkoje, nedarbo lygis ir elektros energijos pasiūla turėjo teigiamą poveikį benzino kainų dinamikai, kas indikuoja, jog šių rodiklių reikšmių didėjimas siejamas su benzino kainų augimu. Tuo tarpu Lietuvos naftos išteklių pasiūla turėjo neigiamą poveikį, kuris skatino benzino kainų mažėjimą šalies rinkoje. Visi kiti analizuoti veiksniai: mokesčių dalis benzino kainoje, benzino akcizas, benzino ir naftos atsargos, kelių transporto priemonių skaičius bei gamtinių dujų vartojimas statistiškai reikšmingo priežastinio ryšio su benzino kainomis neparodė, todėl galima teigti, jog šių kintamųjų pokyčiai analizuojamu laikotarpiu neturėjo įtakos benzino kainų dinamikai.

Atsižvelgiant į Granger priežastingumo ryšio analizės rezultatus, atrenkami reikšmingą priežastingumo ryšį su benzino kainų kintamuoju turintys veiksniai, kuriuos naudojant, sekančiame analizės etape bus formuojami daugiamačiai mažmeninių benzino kainų modeliai.

3.3.3. Daugiamačių benzino kainų modelių vertinimas

Šiame poskyryje yra atliekama daugiamačių modelių analizė, siekiant įvertinti, kaip Granger priežastingumo analizės metu identifikuoti išoriniai veiksniai lemia benzino kainų dinamikos pokyčius.

Daugiamačių modelių vertinimas pradedamas nuo VAR modelių atkūrimo. Atsižvelgiant į 11 lentelėje pateiktus rezultatus, sudaromi tik tie VAR modeliai, kuriuose Granger priežastingumo testas identifiko statistiškai reikšmingą ryšį tarp benzino kainų ir nepriklausomų kintamųjų. Kiekvienas

modelis atkuriamas naudojant tą patį vėlinimų skaičių, kuris buvo nustatytas atliekant priežastingumo analizę. Benzino kainų vertinimui bus sudaromi šie VAR modeliai:

- VAR(3) modelis su Brent naftos kaina
- VAR(3) modelis su Lietuvos naftos ištekliais
- VAR(12) modelis su harmonizuotu vartotojų kainų indeksu skystojo kuro rinkoje
- VAR(11) modelis su nedarbo lygiu
- VAR(5) modelis su elektros energijos pasiūla

Siekiant nustatyti, kuris iš sudarytų VAR modelių yra tinkamiausias benzino kainų prognozei, atliekamas kiekvieno modelio prognozavimo paklaidų vertinimas. Modelių tikslumas vertinamas pagal 11 lentelėje pateiktus RMSE ir MAPE paklaidų rodiklius.

11 lentelė. Benzino kainų VAR modelių rezultatai

Modelio tipas	Nepriklausomas kintamasis	RMSE	MAPE
VAR(3)	Lietuvos naftos ištekliai	58,85	3,81
VAR(12)	Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje	60,44	3,88
VAR(3)	Brent naftos kaina	87,23	5,70
VAR(5)	Elektros energijos pasiūla Lietuvos rinkoje	124,72	8,08
VAR(11)	Lietuvos nedarbo lygis	132,50	8,18

Lyginant RMSE ir MAPE rodiklius yra pastebima, kad iš visų modelių, mažiausias paklaidas generuoja VAR(3) modelis su Lietuvos naftos išteklių nepriklausomu kintamuoju, todėl jis yra vertinamas tinkamiausiu benzino kainų dinamikos modeliavimui.

Toliau yra analizuojami ARIMAX technikos modeliai, kurie papildomai gali įvertinti priklausomo kintamojo dinamiką kartu įtraukiant išorinius veiksnius. 12 lentelėje pateikiami dešimties geriausių benzino kainų ARIMAX modelių rezultatai.

12 lentelė. Benzino kainų ARIMAX modelių rezultatai

Modelio tipas	Nepriklausomi kintamieji	RMSE	MAPE
ARIMAX(1,1,1)	Lietuvos naftos ištekliai; Elektros energijos pasiūla Lietuvos rinkoje	40,16	2,14
ARIMAX(1,1,1)	Elektros energijos pasiūla Lietuvos rinkoje	40,16	2,14
ARIMAX(1,1,1)	Lietuvos naftos ištekliai; Elektros energijos pasiūla Lietuvos rinkoje; COVID-19 pandemijos šokas	40,41	2,18
ARIMAX(1,1,1)	Elektros energijos pasiūla Lietuvos rinkoje; COVID-19 pandemijos šokas	40,56	2,23
ARIMAX(1,1,1)	COVID-19 pandemijos šokas	40,60	1,80
ARIMAX(0,1,2)	Lietuvos nedarbo lygis; Elektros energijos pasiūla Lietuvos rinkoje	40,65	2,08
ARIMAX(0,1,2)	Lietuvos naftos ištekliai; Lietuvos nedarbo lygis; Elektros energijos pasiūla Lietuvos rinkoje	40,73	2,07
ARIMAX(0,1,2)	Lietuvos nedarbo lygis; Elektros energijos pasiūla Lietuvos rinkoje; COVID-19 pandemijos šokas	40,84	2,16
ARIMAX(1,1,1)	Elektros energijos pasiūla Lietuvos rinkoje; COVID-19 pandemijos šokas; Ukrainos karo šokas	40,89	2,24
ARIMAX(0,1,2)	Lietuvos naftos ištekliai; Lietuvos nedarbo lygis; Elektros energijos pasiūla Lietuvos rinkoje; Ukrainos karo šokas	40,94	2,09

Rezultatai parodė, kad mažiausias RMSE bei MAPE paklaidas benzino kainų prognozavimo atveju demonstruoja ARIMAX (1,1,1) modelis, į kurį buvo įtraukti Lietuvos naftos išteklių ir elektros energijos pasiūlos Lietuvos rinkoje nepriklausomi kintamieji. Analogišką rezultatą pagal paklaidų rodiklius taip pat pasiekė ARIMAX (1,1,1) modelis, kuriame buvo naudojamas tik elektros energijos pasiūlos Lietuvos rinkoje nepriklausomas kintamasis. Gauti rezultatai leidžia teigti, kad pagal ARIMAX modeliavimo metodiką statistiškai reikšmingai poveikį benzino kainų dinamikai turi Lietuvos naftos išteklių ir elektros energijos pasiūlos rodikliai, o papildomų šoko ar makroekonominių kintamųjų įtraukimas benzino kainų prognozavimo tikslumo reikšmingai nepagerina.

Identifikavus optimaliausius ARIMAX modelius, toliau analizėje taikoma Prophet laiko eilučių modeliavimo metodika. Prophet metodas buvo pasirinktas siekiant įvertinti, ar automatizuotas trendų, sezoniškumo bei išorinių veiksnių modeliavimas gali tiksliau prognozuoti benzino ir dyzelino kainų pokyčius. Skirtingai nei VAR ar ARIMAX modeliai, Prophet metodika orientuojasi ne tik į išorinių veiksnių identifikavimą, bet ir atsižvelgia į laiko eilutės trendo bei sezoniškumo komponentes, o tai leidžia įvertinti benzino kainų dinamiką iš kitos modeliavimo perspektyvos.

Siekiant nustatyti, kuri nepriklausomų kintamųjų, trendo ir sezoniškumo kombinacija geriausiai paaiškina benzino kainų svyravimus 13 lentelėje pateikiami skirtingų Prophet modelių paklaidų rodikliai.

13 lentelė. Benzino kainų Prophet modelių rezultatai

Nepriklausomi kintamieji	RMSE	MAPE
Brent naftos kaina; Lietuvos nedarbo lygis	33,37	2,00
Brent naftos kaina; Lietuvos naftos ištekliai; Lietuvos nedarbo lygis	33,71	2,03
Brent naftos kaina; Lietuvos naftos ištekliai; Lietuvos nedarbo lygis; Ukrainos karo šokas	35,87	1,90
Brent naftos kaina; Lietuvos nedarbo lygis; COVID-19 pandemijos šokas; Ukrainos karo šokas	36,51	1,97
Brent naftos kaina; Lietuvos nedarbo lygis; Ukrainos karo šokas	36,73	1,97
Brent naftos kaina; Lietuvos naftos ištekliai; Lietuvos nedarbo lygis; COVID-19 pandemijos šokas	37,55	2,16
Brent naftos kaina; Lietuvos naftos ištekliai; Lietuvos nedarbo lygis; COVID-19 pandemijos šokas; Ukrainos karo šokas	37,99	2,21
Brent naftos kaina; Lietuvos naftos ištekliai; Ukrainos karo šokas	40,25	2,26
Brent naftos kaina; COVID-19 pandemijos šokas; Ukrainos karo šokas	41,47	2,31
Brent naftos kaina; Lietuvos nedarbo lygis; COVID-19 pandemijos šokas	41,53	2,30

Remiantis gautais rezultatais, buvo nustatyta, kad tiksliausias benzino kainų prognozes, pagal Prophet metodologiją, pateikė modelis, į kurį buvo įtraukti Brent naftos kainos ir Lietuvos nedarbo lygio nepriklausomi kintamieji. Šis modelis pasižymėjo mažiausia RMSE reikšme (33,37) ir viena mažiausių MAPE reikšmių (2,00). Papildomų kintamųjų, tokių kaip Lietuvos naftos ištekliai ar struktūriniai COVID-19 pandemijos bei Ukrainos karo šokai, įtraukimas ne tik nepagerino prognozavimo tikslumo, tačiau daugeliu atvejų netgi padidino paklaidų dydį. Tai indikuoja, kad perteklinis kintamųjų skaičius Prophet modelyje mažina benzino kainų dinamikos prognozavimo efektyvumą.

Įvertinus VAR, ARIMAX ir Prophet modelių tinkamumą benzino kainų prognozavimui, galiausiai analizuojama ARDL modeliavimo metodika. Skirtingai nei anksčiau taikytos metodikos, ARDL leidžia vienu metu analizuoti tiek trumpalaikius svyravimus, tiek ilgalaikius pusiausvyros ryšius tarp priklausomo kintamojo ir pasirinktų egzogeninių veiksnių, todėl suteikia papildomą galimybę kompleksiška įvertinti degalų kainų formavimosi mechanizmus. 14 lentelėje pateikiami benzino kainų ARDL modelių rezultatai.

14 lentelė. Benzino kainų ARDL modelių ex-post rezultatai

Nepriklausomi kintamieji	Ex-post	
	RMSE	MAPE
Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; Brent naftos kaina; Lietuvos naftos ištekliai; COVID-19 pandemijos šokas; Ukrainos karo šokas	33,16	1,80
Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; Ukrainos karo šokas	33,91	1,66
Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; Brent naftos kaina; Ukrainos karo šokas	36,80	2,13
Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; Lietuvos naftos ištekliai; COVID-19 pandemijos šokas; Ukrainos karo šokas	37,13	2,08
Lietuvos naftos ištekliai; Brent naftos kaina; COVID-19 pandemijos šokas; Ukrainos karo šokas	37,67	2,00
Lietuvos naftos ištekliai; COVID-19 pandemijos šokas; Ukrainos karo šokas	44,76	2,46
Brent naftos kaina; Ukrainos karo šokas	47,21	2,85
Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; Lietuvos nedarbo lygis; COVID-19 pandemijos šokas; Ukrainos karo šokas	56,67	3,45
Lietuvos naftos ištekliai; Elektros energijos pasiūla Lietuvos rinkoje; COVID-19 pandemijos šokas; Ukrainos karo šokas	80,08	5,24
Lietuvos nedarbo lygis; COVID-19 pandemijos šokas; Ukrainos karo šokas	115,12	7,41

Benzino kainų ARDL modelių paklaidų vertinimo rezultatai rodo, jog didžiausiu kainų prognozavimo tikslumu pasižymi modelis, į kurį yra įtraukti harmonizuoto vartotojų kainų indekso skystojo kuro rinkoje, Brent naftos kainos ir Lietuvos naftos išteklių kintamieji. Verta pastebėti ir tai, jog tiksliausias ARDL modelis papildomai įvertina COVID-19 bei karo Ukrainoje šokų poveikį benzino kainoms. Atrinkus tiksliausią ARDL modelį pagal ex-post paklaidas, šio modelio tikslumas yra pakartotinai įvertinamas taikant ex-ante paklaidų rodiklius, kurie pateikiami 15 lentelėje.

15 lentelė. Tiksliausio benzino kainų ARDL modelio ex-ante rezultatai

Nepriklausomi kintamieji	Ex-ante	
	RMSE	MAPE
Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; Brent naftos kaina; Lietuvos naftos ištekliai; COVID-19 pandemijos šokas; Ukrainos karo šokas	40,65	2,00

Perskaičius tiksliausio mažmeninių benzino kainų ARDL modelio paklaidas iš ex-post į ex-ante, nustatyta, kad RMSE padidėjo nuo 33,16 iki 40,65, o MAPE išaugo nuo 1,80 iki 2,00. Šis paklaidų padidėjimas nurodo, jog prognozuojant ateities laikotarpių reikšmes ARDL modelio tikslumas sumažėja, tačiau svarbu atkreipti dėmesį į tai, kad sudėtingesnės daugiamatės struktūros modeliai, pasižymintys didesniu nagrinėjamų kintamųjų skaičiumi, dažnai yra jautresni duomenų struktūros pokyčiams už vertinamos imties ribų. Tokie modeliai gali itin tiksliai atspindėti istorinius ryšius tarp kintamųjų, tačiau jų prognozinis efektyvumas ateities laikotarpiuose natūraliai sumažėja dėl didėjančio neapibrėžtumo, kurį lemia besikeičiančios rinkos sąlygos ar išorinių šokų poveikis. Vis

dėlto ex-ante paklaidų padidėjimas nėra drastiškas, todėl galima teigti, kad atrinktas ARDL modelis išlaiko pakankamai aukštą benzino kainų prognozavimo stabilumą ir geba efektyviai perkelti identifikuotus ryšius į ateities laikotarpių prognozes.

3.3.4. Benzino kainų dinamikos prognozavimas

Šiame poskyryje atliekamas benzino kainų dinamikos prognozavimas ir išorinių šokų poveikio vertinimas, integruojant ankstesniuose analizės etapuose gautus vienmačių ir daugiamačių modeliavimo rezultatų išvadas. Siekiama kompleksiskai įvertinti skirtingų modelių prognozavimo gebėjimus bei nustatyti, kurie metodai tiksliausiai atspindi benzino kainų dinamiką, įskaitant tiek vidinius rinkos procesus, tiek išorinių veiksnių sukeltus struktūrinius pokyčius.

Įvertinus skirtingų modeliavimo technikų rezultatus, atliekamas galutinis benzino kainų prognozavimo modelių palyginimas. Remiantis 16 lentelėje pateiktais modelių rezultatais, nustatoma didžiausiu prognozavimo tikslumu pasižyminti modeliavimo metodika.

16 lentelė. Benzino kainų modelių rezultatų palyginimas

Modelio tipas	Nepriklausomi kintamieji	RMSE	MAPE
Prophet	Brent naftos kaina; Lietuvos nedarbo lygis	33,37	2,00
ARIMAX(1,1,1)	Lietuvos naftos išteklių; Elektros energijos pasiūla Lietuvos rinkoje	40,16	2,14
ARIMAX(1,1,1)	Elektros energijos pasiūla Lietuvos rinkoje	40,16	2,14
ARDL	Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; Brent naftos kaina; Lietuvos naftos išteklių; COVID-19 pandemijos šokas; Ukrainos karo šokas	40,65	2,00
ARIMA(0,1,1)	-	42,07	1,84
VAR(3)	Lietuvos naftos išteklių	58,85	3,81

Analizuojant vienmačių ir daugiamačių benzino kainų modelių rezultatus, nustatyta, kad pagal RMSE paklaidų rodiklį tiksliausiai benzino kainų dinamiką prognozuoja Prophet modelis, į kurį įtraukti Brent naftos kainos ir Lietuvos nedarbo lygio nepriklausomi kintamieji. Tuo tarpu pagal MAPE rodiklį mažiausiomis paklaidomis pasižymėjo ARIMA(0,1,1) modelis, kuris prognozes grindžia tik pačios benzino kainų laiko eilutės dinamika, neįtraukiant išorinių veiksnių. Kadangi šiame tyrime prioritetas teikiamas RMSE rodikliui, nes jis geriau atspindi absoliutų prognozės nuokrypį ir leidžia tiksliau įvertinti bendrą modelio efektyvumą, mažmeninių benzino kainų dinamikos prognozavimui 2026 metams pasirinktas Prophet modelis, kurio (3.3.4.1) formulė:

Benzino kaina = $(-0,15 \cdot t + 0,65) + s(t) + 5,67 \cdot \text{Brent naftos kaina} - 36,08 \cdot \text{Lietuvos nedarbo lygis}$;

$$s(t) = \sum_{n=1}^{10} \left(a_n \cos\left(\frac{2\pi n t}{365,25}\right) + b_n \sin\left(\frac{2\pi n t}{365,25}\right) \right); \quad (3.3.4.1)$$

- čia t – laiko indeksas (mėnesio eilės numeris, skaičiuojant nuo duomenų rinkinio pradžios);
 $s(t)$ – sezoniškumo komponentė t laiko momentu;
 a_n – kosinusinės dalies koeficientas, n -tajai harmonikai (žr. 9 priedą);
 n – harmonikos indeksas;
 b_n – sinusinės dalies koeficientas, n -tajai harmonikai (žr. 9 priedą).

Remiantis benzino kainų dinamikos Prophet modelio išsklotine, kuri pateikta 9 priede, galima teigti, kad mažmeninei benzino kainai Lietuvos rinkoje didžiausią poveikį daro Brent naftos kainos pokyčiai ir Lietuvos nedarbo lygio svyravimai. Teigiamas Brent naftos kainos koeficientas ($\beta = 5,67$; $p = <0,01$) rodo, kad Brent naftos kainai didėjant 1 JAV doleriu už barelį, benzino kainos kaina vidutiniškai padidėja apie 5,67 eurų už 1000 l, kai jokie kiti veiksniai nekinta, todėl galima teigti, kad tarptautinės žaliavinės naftos rinkos pokyčiai tiesiogiai veikia Lietuvos mažmeninę degalų rinką. Tuo tarpu neigiamas Lietuvos nedarbo lygio koeficientas ($\beta = -36,08$; $p = <0,01$) nurodo, kad nedarbo lygiui padidėjus 1 procentiniu punktu, benzino kaina vidutiniškai sumažėja apie 36,08 eurų už 1000 l, kitoms sąlygoms nekintant, todėl galima teigti, kad vietinės darbo rinkos pokyčiai irgi yra tiesiogiai susiję su benzino kainų dinamika, tačiau jų poveikis silpnesnis nei Brent naftos kainų. Tokių neigiamą ryšį tarp nedarbo lygio ir benzino kainų kintamųjų galima logiškai paaiškinti tuo, jog didėjantis nedarbo lygis dažniausiai atspindi lėtėjančią ekonominę veiklą ir mažėjančią gyventojų vartojimą. Ekonominio neapibrėžtumo laikotarpiais rinkos vartotojai rečiau naudojami transporto priemonėmis taip pat mažėja bendras degalų poreikis, todėl silpnėjanti paklausa prisideda prie benzino kainų mažėjimo. Taigi, nors Brent naftos kainos išlieka pagrindiniu degalų kainas formuojančiu veiksnium, vidaus darbo rinkos būklė taip pat turi reikšmingą poveikį benzino kainų dinamikai per paklausos pokyčių mechanizmą.

Atsižvelgiant į abiejų kintamųjų beta koeficientų p reikšmes, galima teigti, jog šių veiksnių poveikis mažmeninėms benzino kainoms prie 0,95 pasikliautinumo lygmens laikomas statistiškai reikšmingu. Svarbu atkreipti dėmesį į tai, jog į tiksliausią mažmeninių benzino kainų modelį nebuvo įtraukti COVID-19 pandemijos ir Ukrainos karo šokai, todėl galima teigti, kad nagrinėjamų išorinių sukrėtimų poveikis galutinėms benzino kainoms nėra reikšmingas.

Gauta Prophet modelio struktūra taip pat parodo, kad mažmeninių benzino kainų susiformavimui Lietuvos rinkoje svarbūs ne tik išoriniai makroekonominiai veiksniai, bet ir ilgalaikė kainų tendencija bei sezoniniai svyravimai. Neigiama trendo komponentės reikšmė ($k = -0,15$) rodo, kad analizuojamu laikotarpiu, kitoms sąlygoms nekintant, benzino kainų baziniam lygiui būdinga mažėjimo tendencija, todėl ilgalaikėje perspektyvoje modelis fiksuoja bendrą kainų mažėjimą.

Galiausiai, pasitelkus atrinktą Prophet modelį, 17 lentelėje yra pateikiamos 2026 metų mažmeninių benzino kainų prognozės. Kadangi tyrimo metu jau yra žinomos realios 2026 metų sausio-balandžio mėnesių benzino kainų reikšmės, jos yra palyginamos su prognozuotomis reikšmėmis, siekiant įvertinti prognozuotų reikšmių tikslumą.

17 lentelė. Mažmeninių benzino prognozuojamų bei realių kainų reikšmių palyginimas (Sudaryta pagal [8])

Data	Prognozuojama reikšmė	Reali reikšmė	Skirtumas	RMSE	MAPE
2026-01	1448,36	1419,79	28,57	189,65	8,36
2026-02	1425,73	1445,99	-20,26		
2026-03	1455,19	1629,30	-174,11		
2026-04	1399,04	1734,19	-335,15		
2026-05	1362,98	-	-	-	-
2026-06	1424,93	-	-	-	-
2026-07	1417,42	-	-	-	-

Data	Prognozuojama reikšmė	Reali reikšmė	Skirtumas	RMSE	MAPE
2026-08	1400,28	-	-	-	-
2026-09	1418,26	-	-	-	-
2026-10	1380,58	-	-	-	-
2026-11	1366,65	-	-	-	-
2026-12	1362,34	-	-	-	-

Analizuojant 2026 metų mažmeninių benzino kainų prognozes ir jų grafikus (žr. 11 priedą), pastebima, kad Prophet modelio prognozuojama kainų dinamika pasižymi mėnesiniais svyravimais, tačiau išlaiko gana stabilią bendrą kainų dinamikos trajektoriją visų metų laikotarpiu. Metų pradžioje yra prognozuojamas nuoseklus mažmeninių benzino kainų mažėjimas, kuris pereina į trumpalaikį augimą vasaros mėnesiais, o vėliau metų pabaigoje vėl fiksuojama mažėjimo tendencija. Vis dėlto, palyginus prognozuotas reikšmes su realiais 2026 metų sausio-balandžio mėnesių duomenimis, matyti, kad modelio prognozavimo tikslumas metų pradžioje buvo nevienodas. Sausio ir vasario mėnesiais prognozuotos benzino kainos buvo pakankamai artimos faktinėms reikšmėms, tačiau kovo ir balandžio mėnesiais skirtumas tarp prognozuojamų ir realių kainų ženkliai padidėjo: kovo mėnesį jis siekė 174,11 eurų, o balandžio mėnesį išaugo iki 335,15 eurų. Apibendrinus keturių pirmųjų 2026 metų mėnesių prognozavimo rezultatus, Prophet modelio prognozavimo paklaidos siekė 189,65 (RMSE) ir 8,36 (MAPE), todėl galima teigti, kad nors bendroji prognozių kryptis buvo identifikuota, faktiniai kainų šuoliai nebuvo tiksliai įvertinti. Reikšmingas kovo ir balandžio mėnesių prognozių nuokrypis rodo, kad 2026 metų pavasarį reali mažmeninių benzino kainų dinamika patyrė staigų augimą, kurio Prophet modelis nesugebėjo tiksliai prognozuoti. Toks prognozuojamų reikšmių netikslumas gali būti siejamas su 2026 metų kovo mėnesį prasidėjusiais geopolitiniais neramumais Artimuosiuose Rytuose, kurie reikšmingai padidino neapibrėžtumą pasaulinėse energetikos rinkose. Dėl šių įvykių sutrikus naftos tiekimo grandinėms, buvo stebimas spartus žaliavinės naftos kainų augimas, kuris tiesiogiai paveikė ir mažmenines benzino kainas. Kadangi Prophet modelis grindžiamas istorinių tendencijų tęstinumo logika, toks netikėtas ir staigus išorinis geopolitinis šokas nebuvo pilnai įtrauktas į prognozavimo struktūrą, todėl modelio gebėjimas tiksliai atspindėti kainų pokyčius ekstremaliomis rinkos sąlygomis išliko ribotas.

3.4. Dyzelino kainų modeliavimas ir prognozavimas

Šiame skyriuje atliekamas dyzelino kainų modeliavimas, prognozavimas ir šokų poveikio vertinimas, taikant vienmačius ir daugiamačius laiko eilučių modelius. Įvertinus šių modelių rezultatus, bus nustatytas dyzelino kainų dinamikos prognozei tinkamiausias modelis.

3.4.1. Vienmačių dyzelino kainų modelių vertinimas

Šiame poskyryje analizuojami vienmačiai dyzelino kainų prognozavimo modeliai, siekiant nustatyti, kuris metodas tiksliausiai prognozuoja dyzelino kainų dinamiką remiantis tik istoriniais kainų duomenimis. Dyzelino kainų modeliavimui taikomi analogiški metodai kaip ir benzino kainų analizėje: vertinami naivus, sezoninis naivus, atsitiktinio pasivaikščiojimo su nukrypimu, sezoninio atsitiktinio pasivaikščiojimo su nukrypimu, ARIMA, SARIMA, ETS, slankiojo vidurkio ir Prophet modeliai. Šiame poskyryje aptariami rezultatai sudarys bazinį atskaitos tašką vėlesniam daugiamačių modelių vertinimui, kuriame bus analizuojama, ar papildoma išorinių veiksnių informacija reikšmingai pagerina mažmeninių dyzelino kainų prognozavimo kokybę.

Siekiant nustatyti tiksliausią vienmatį dyzelino kainų prognozavimo modelį, 18 lentelėje pateikiami skirtingų modelių prognozavimo paklaidų rezultatai.

18 lentelė. Vienmačių dyzelino kainų modelių rezultatai

Modelio tipas	RMSE	MAPE
ETS(M,Ad,N)	74,93	3,56
ARIMA(0,1,1)	76,97	3,69
SARIMA(0,1,1)(0,0,0)	76,97	3,69
Slankiojo vidurkio	77,75	3,74
Sezoninis atsitiktinio pasivaikščiojimo su nukrypimu	81,36	4,63
Sezoninis naivus	84,80	4,80
Atsitiktinio pasivaikščiojimo su nukrypimu	94,50	4,94
Naivus	97,05	5,17
Prophet	146,22	8,98

Remiantis vienmačių dyzelino kainų modelių rezultatais, galima teigti, kad mažiausiomis prognozavimo paklaidomis pagal abu vertinimo kriterijus pasižymėjo ETS(M,Ad,N) modelis. Šios modeliavimo metodologijos pranašumas prieš ARIMA, SARIMA bei kitus bazinius vienmačius modelius rodo, kad dyzelino kainų dinamika efektyviausiai prognozuojama naudojant modelius, kurie geba lanksčiai prisitaikyti prie kintančio kainų dinamikos trendo. Atsižvelgiant į šias įžvalgas, galima teigti, kad nagrinėjant dyzelino kainų pokyčius, svarbu įvertinti ne tik trumpalaikius kainų svyravimus, bet ir palaiptnui besikeičiančius laiko eilučių struktūrinius pokyčius, kuriuos adaptyvus eksponentinio glodinimo metodas identifikuoja tiksliau nei tradiciniai autoregresiniai modeliai. Tuo tarpu Prophet modelio santykinai didelės prognozavimo paklaidos leidžia teigti, kad ši modeliavimo technika nepasižymi dideliu efektyvumu, vertinant dyzelino kainų raidą.

Apibendrinant vienmačių dyzelino kainų modelių vertinimo rezultatus, galima teigti, kad dyzelino kainų dinamikoje, kaip ir benzino kainų atveju, sezoniškumo poveikis nėra dominuojantis. Nors sezoninis naivus ir sezoninis atsitiktinio pasivaikščiojimo su nukrypimu modeliai demonstravo geresnius rezultatus nei jų nesezoniniai atitikmenys, tiksliausiai dyzelino kainas prognozavo ETS(M,Ad,N) modelis. SARIMA modelio paklaidų rezultatai sutampa su ARIMA modelio paklaidų reikšmėmis, o tai vėlgi patvirtina, kad sezoniniai dyzelino kainų svyravimai nėra pakankamai stiprūs, jog taptų reikšmingu, dyzelino kainų dinamikos prognozavimo tikslumą lemiančiu, veiksnium.

3.4.2. Dyzelino kainų ir išorinių veiksnių Granger priežastingumo ryšio vertinimas

Įvertinus vienmačių modelių rezultatus, toliau yra ruošiamasi daugiamačių dyzelino kainų modelių analizei. Siekiant įvertinti, kokie išoriniai veiksniai turi reikšmingą poveikį dyzelino kainų dinamikai, yra atliekama Granger priežastingumo ryšio analizė, kurios rezultatai pateikiami 19 lentelėje.

19 lentelė. Dyzelino kainų Granger priežastingumo ryšio vertinimas

Nepriklausomas kintamasis	F statistikos p dydis	Poveikis dyzelino kainai	Ryšio reikšmingumas	VAR modelio vėlinimų skaičius
Mokesčių dalis dyzelino kainoje	0,04	Neigiamas	Reikšmingas	3
Dyzelinui taikomas akcizas	0,04	Teigiamas	Reikšmingas	5
Brent naftos kaina	0,00	Teigiamas	Reikšmingas	3
Lietuvos dyzelino ištekliai	0,23	Teigiamas	Nereikšmingas	5
Lietuvos naftos ištekliai	0,05	Neigiamas	Reikšmingas	3
Lietuvos naftos atsargos	0,75	Teigiamas	Nereikšmingas	4

Nepriklausomas kintamasis	F statistikos p dydis	Poveikis dyzelino kainai	Ryšio reikšmingumas	VAR modelio vėlinimų skaičius
Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje	0,02	Teigiamas	Reikšmingas	5
Pramonės sektoriaus produkcijos apimčių indeksas	0,00	Teigiamas	Reikšmingas	4
Kelių transporto priemonių skaičius	0,83	Neigiamas	Nereikšmingas	4
Importas	0,10	Teigiamas	Reikšmingas	5
Lietuvos nedarbo lygis	0,15	Teigiamas	Nereikšmingas	11
Gamtinių dujų vartojimas Lietuvoje	0,97	Teigiamas	Nereikšmingas	5
Elektros energijos pasiūla Lietuvos rinkoje	0,13	Teigiamas	Nereikšmingas	13

Dyzelino kainų priežastingumo analizės rezultatai atskleidė, jo šios degalų rūšies kainų pokyčius Lietuvoje statistiškai reikšmingai lemia mokesčių dalis dyzelino kainoje, dyzelinui taikomas akcizas, Brent naftos kaina, šalies naftos išteklių, harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje, pramonės produkcijos apimčių indeksas ir importas. Mokesčių dalis bei Lietuvos naftos išteklių turėjo neigiamą poveikį dyzelino kainoms, o akcizas, Brent naftos kaina, kainų indeksas skystojo kuro rinkoje, pramonės sektoriaus aktyvumo rodikliai ir importo apimtys pasižymėjo teigiamu poveikiu, kas įrodo, jog šių veiksnių augimas siejamas su dyzelino kainų didėjimu. Likę analizuoti kintamieji: Lietuvos dyzelino išteklių, naftos atsargos, kelių transporto priemonių skaičius, nedarbo lygis, gamtinių dujų vartojimas ir elektros energijos pasiūla, statistiškai reikšmingo priežastinio ryšio su dyzelino kainomis neparodė, todėl galima teigti, kad jų pokyčiai analizuojamu laikotarpiu neturėjo poveikio dyzelino kainų dinamikai.

Apibendrinant dyzelino kainų ir išorinių veiksnių Granger priežastingumo analizės rezultatus, galima teigti, kad dyzelino kainų dinamiką statistiškai reikšmingai lemia platesnis ir labiau diversifikuotas veiksnių spektras nei benzino kainų atveju, o tai įrodo, jog dyzelino kainos yra labiau jautrios įvairių išorinių veiksnių pokyčiams. Atrinkus nepriklausomus kintamuosius, kurie pasižymi statistiškai reikšmingu priežastingumo ryšiu su dyzelino kainų kintamuoju, sekančiame tyrimo etape yra formuojami daugiamačiai mažmeninių dyzelino kainų modeliai.

3.4.3. Mažmeninių dyzelino kainų modelių vertinimas

Šiame poskyryje yra atliekama daugiamačių modelių analizė, siekiant įvertinti, kaip Granger priežastingumo analizės metu identifikuoti išoriniai veiksniai prisideda prie dyzelino kainų dinamikos pokyčių.

Kaip ir benzino kainų atveju, daugiamačių dyzelino kainų modelių vertinimas pradedamas nuo VAR modelių atkūrimo. Atsižvelgiant į 20 lentelėje pateiktus rezultatus, atkuriami statistiškai reikšmingą priežastingumo ryšį tarp dyzelino kainų ir išorinių veiksnių identifikavę VAR modeliai. Kiekvienas modelis atkuriamas naudojant tą patį vėlinimų skaičių, kuris buvo nustatytas atliekant priežastingumo analizę. Dyzelino kainų vertinimui bus sudaromi šie VAR modeliai:

- VAR(3) modelis su mokesčių dalimi dyzelino kainoje
- VAR(5) modelis su dyzelinui taikomu akcizu
- VAR(3) modelis su Brent naftos kaina
- VAR(3) modelis su Lietuvos naftos ištekliais

- VAR(5) modelis su harmonizuotu vartotojų kainų indeksu skystojo kuro rinkoje
- VAR(4) modelis su pramonės produkcijos apimčių indeksu
- VAR(5) modelis su importu

Siekiant nustatyti, kuris iš sudarytų VAR modelių yra tinkamiausias dyzelino kainų prognozei, įvertinamos 20 lentelėje pateiktos kiekvieno VAR modelio paklaidų rodiklių reikšmės.

20 lentelė. Dyzelino kainų VAR modelių rezultatai

Modelio tipas	Nepriklausomas kintamasis	RMSE	MAPE
VAR(4)	Pramonės sektoriaus produkcijos apimčių indeksas	65,95	3,12
VAR(5)	Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje	70,13	3,22
VAR(3)	Mokesčių dalis dyzelino kainoje	71,38	3,27
VAR(3)	Lietuvos naftos ištekliai	73,73	3,26
VAR(3)	Brent naftos kaina	76,17	3,30
VAR(5)	Importas	76,60	3,71
VAR(5)	Dyzelinui taikomas akcizas	144,07	9,23

Vertinant dyzelino kainų VAR modelių prognozavimo tikslumą, iš visų įvertintų alternatyvų tinkamiausias modelis yra VAR(4) su pramonės sektoriaus produkcijos apimčių indekso nepriklausomu kintamuoju, kurio prognozavimo paklaidos yra mažiausios.

Identifikavus geriausiai veikiančią VAR modelį, toliau yra vertinama alternatyvi duomenų modeliavimo technika – ARIMAX. 21 lentelėje pateikiami dešimties geriausių mažmeninių dyzelino kainų ARIMAX modelių rezultatai.

21 lentelė. Dyzelino kainų ARIMAX modelių rezultatai

Modelio tipas	Nepriklausomi kintamieji	RMSE	MAPE
ARIMAX(0,1,1)	Pramonės sektoriaus produkcijos apimčių indeksas; Importas; Ukrainos karo šokas	66,29	3,26
ARIMAX(0,1,1)	Pramonės sektoriaus produkcijos apimčių indeksas; Ukrainos karo šokas	66,31	3,27
ARIMAX(0,1,1)	Pramonės sektoriaus produkcijos apimčių indeksas; Importas; COVID-19 pandemijos šokas; Ukrainos karo šokas	66,39	3,26
ARIMAX(0,1,1)	Pramonės sektoriaus produkcijos apimčių indeksas; Importas	66,41	3,26
ARIMAX(0,1,1)	Pramonės sektoriaus produkcijos apimčių indeksas; COVID-19 pandemijos šokas; Ukrainos karo šokas	66,45	3,27
ARIMAX(0,1,1)	Pramonės sektoriaus produkcijos apimčių indeksas; Importas; COVID-19 pandemijos šokas	66,54	3,26
ARIMAX(0,1,1)	Pramonės sektoriaus produkcijos apimčių indeksas	66,55	3,27
ARIMAX(0,1,1)	Pramonės sektoriaus produkcijos apimčių indeksas; COVID-19 pandemijos šokas	66,73	3,28
ARIMAX(0,1,1)	Lietuvos naftos ištekliai; Pramonės sektoriaus produkcijos apimčių indeksas; Ukrainos karo šokas	66,90	3,38
ARIMAX(0,1,1)	Lietuvos naftos ištekliai; Pramonės sektoriaus produkcijos apimčių indeksas; COVID-19 pandemijos šokas; Ukrainos karo šokas	67,16	3,39

Dyzelino kainų ARIMAX modelių rezultatai atskleidė, kad mažiausios RMSE ir MAPE rodiklių reikšmės dyzelino kainų prognozavimo atveju buvo pasiektos naudojant ARIMAX (0,1,1) modelį, į

kurį buvo įtraukti pramonės sektoriaus produkcijos apimčių indekso, importo ir Ukrainos karo šoko poveikį apibūdinantys nepriklausomi kintamieji. Verta pastebėti, kad panašius rezultatus taip pat parodė ARIMAX(0,1,1) modelis, kuriame buvo naudojami pramonės sektoriaus produkcijos apimčių indekso ir Ukrainos karo šoko kintamieji, tačiau papildomas importo nepriklausomo kintamojo įtraukimas leido pasiekti geresnį prognozavimo tikslumą.

Įvertinus gautus rezultatus, galima teigti, kad pagal ARIMAX modeliavimo metodiką didžiausią poveikį dyzelino kainų dinamikai turi pramonės sektoriaus aktyvumą atspindintys rodikliai, importo apimtys bei geopolitiniai veiksniai, ypač Ukrainos karo šokas. Tuo tarpu papildomas COVID-19 pandemijos šoko ar Lietuvos naftos išteklių kintamųjų įtraukimas prognozavimo rezultatų reikšmingai nepagerina, o kai kuriais atvejais net sumažina ARIMAX modelio tikslumą.

Sekančiame tyrimo etape atliekamas dyzelino kainų prognozavimas pasitelkiant Prophet modelius, į kuriuos integruojami ne tik pačios kainų laiko eilutės duomenys, bet ir atrinkti išoriniai veiksniai. Siekiant nustatyti tiksliausią Prophet modelį mažmeninių dyzelino kainų prognozavimui, 22 lentelėje pateikiami įvairių Prophet modelių variacijų paklaidų rezultatai.

22 lentelė. Dyzelino kainų Prophet modelių rezultatai

Nepriklausomi kintamieji	RMSE	MAPE
Brent naftos kaina; Lietuvos naftos ištekliai; Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; COVID-19 pandemijos šokas; Ukrainos karo šokas	47,37	2,49
Brent naftos kaina; Lietuvos naftos ištekliai; Pramonės sektoriaus produkcijos apimčių indeksas; Ukrainos karo šokas	47,94	2,16
Brent naftos kaina; Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; COVID-19 pandemijos šokas	48,56	2,58
Brent naftos kaina; Lietuvos naftos ištekliai; Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; COVID-19 pandemijos šokas	48,62	2,65
Brent naftos kaina; Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; COVID-19 pandemijos šokas; Ukrainos karo šokas	49,25	2,61
Brent naftos kaina; Lietuvos naftos ištekliai; Pramonės sektoriaus produkcijos apimčių indeksas; COVID-19 pandemijos šokas; Ukrainos karo šokas	50,44	2,15
Brent naftos kaina; Pramonės sektoriaus produkcijos apimčių indeksas; COVID-19 pandemijos šokas; Ukrainos karo šokas	51,50	2,27
Brent naftos kaina; COVID-19 pandemijos šokas; Ukrainos karo šokas	51,53	2,28
Brent naftos kaina; Lietuvos naftos ištekliai; COVID-19 pandemijos šokas; Ukrainos karo šokas	51,54	2,23
Brent naftos kaina; Pramonės sektoriaus produkcijos apimčių indeksas; COVID-19 pandemijos šokas	51,97	2,45

Pagal RMSE, tiksliausias dyzelino kainų prognozes, remiantis Prophet metodologija, pateikė modelis, į kurį buvo įtraukti Brent naftos kainos, Lietuvos naftos išteklių, harmonizuoto vartotojų kainų indekso skystojo kuro rinkoje, COVID-19 pandemijos šoko ir Ukrainos karo šoko nepriklausomi kintamieji. Vis dėlto pagal MAPE paklaidų rodiklį, geriausias rezultatus parodė modelis, kuriame buvo naudojami Brent naftos kainos, Lietuvos naftos išteklių, pramonės sektoriaus produkcijos apimčių indekso, COVID-19 pandemijos šoko ir Ukrainos karo šoko nepriklausomi kintamieji. Šie rezultatai rodo, kad dyzelino kainų prognozavimo tikslumas Prophet modeliuose priklauso nuo pasirinkto vertinimo kriterijaus, nes pagal bendrą prognozės paklaidą tikslesnius rezultatus užtikrina energetinių, kainų ir šoko veiksnių derinys, o pagal santykinę paklaidą,

optimaliausi yra tie modeliai, kuriuose papildomai įtraukiami pramonės sektoriaus aktyvumą apibūdinantys rodikliai. Galutinis tiksliausio modelio pasirinkimas vis dėlto atliekamas remiantis RMSE rodikliu, kadangi jis jautriau reaguoja į didesnius prognozės nuokrypius ir geriau atspindi bendrą modelio gebėjimą tiksliai rekonstruoti realią dyzelino kainų dinamiką.

Identifikavus tiksliausią Prophet modelį, toliau dyzelino kainų dinamika yra modeliuojama pagal ARDL metodologiją. Skirtingų ARDL modelių ex post paklaidų vertinimo rezultatai pateikiami 23 lentelėje.

23 lentelė. Dyzelino kainų ARDL ex-post modelių rezultatai

Nepriklausomi kintamieji	Ex-post	
	RMSE	MAPE
Lietuvos naftos ištekliai; Pramonės sektoriaus produkcijos apimčių indeksas; Brent naftos kaina; Ukrainos karo šokas; COVID-19 pandemijos šokas	91,25	5,03
Lietuvos naftos ištekliai; Pramonės sektoriaus produkcijos apimčių indeksas; Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; Ukrainos karo šokas	105,76	5,90
Importas; Ukrainos karo šokas	113,31	6,47
Brent naftos kaina; Ukrainos karo šokas	113,95	6,89
Pramonės sektoriaus produkcijos apimčių indeksas; Ukrainos karo šokas	114,70	6,61
Mokesčių dalis dyzelino kainoje; Dyzelinui taikomas akcizas; Ukrainos karo šokas	115,61	7,15
Lietuvos naftos ištekliai; Pramonės sektoriaus produkcijos apimčių indeksas; Ukrainos karo šokas	123,51	7,24
Dyzelinui taikomas akcizas; Ukrainos karo šokas	125,92	7,37
Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; Ukrainos karo šokas	154,19	9,75
Pramonės sektoriaus produkcijos apimčių indeksas; Dyzelinui taikomas akcizas; Ukrainos karo šokas	241,22	15,88
Lietuvos naftos ištekliai; Pramonės sektoriaus produkcijos apimčių indeksas; Dyzelinui taikomas akcizas; Ukrainos karo šokas	249,25	14,15
Mokesčių dalis dyzelino kainoje; Ukrainos karo šokas	308,70	20,47

Remiantis pateiktais skirtingų ARDL modelių RMSE ir MAPE paklaidų rodikliais, galima teigti, kad tiksliausiai dyzelino kainas prognozuoja modelis, apimantis Lietuvos naftos išteklių, pramonės sektoriaus produkcijos apimčių indekso ir Brent naftos kainos kintamuosius kartu su COVID-19 pandemijos ir Ukrainos karo šokų pseudo kintamaisiais. Šis modelis pasižymi mažiausiomis paklaidomis tarp visų nagrinėtų specifikacijų, kas indikuoja, kad dyzelino kainų dinamika geriausiai paaiškinama kompleksiniu energetikos rinkos, pramonės aktyvumo ir struktūrinių šokų poveikiu. Pastebėtina, kad dyzelino kainų atžvilgiu, ARDL modeliai, kuriuose įtraukiamas tik ribotas kintamųjų skaičius, dažniausiai pasižymi ženkliai didesnėmis prognozavimo paklaidomis, ypač tais atvejais, kai naudojami pavieniai mokesčių ar akcizo rodikliai. Remiantis šiuo faktu, galima konstatuoti, jog dyzelino kainų atveju paprastesnės ARDL specifikacijos yra mažiau informatyvios, o didesnį prognozavimo tikslumą užtikrina modeliai, integruojantys kelių skirtingų ekonominių ir struktūrinių veiksnių sąveiką.

Toliau, tiksliausio ARDL modelio ex-post paklaidos yra perskaičiuojamos į ex-ante paklaidas, o galutiniai modelio paklaidų rodiklių rezultatai pateikiami 24 lentelėje.

24 lentelė. Tiksliausio dyzelino kainų ARDL modelio ex-ante rezultatai

Nepriklausomi kintamieji	Ex-ante	
	RMSE	MAPE
Lietuvos naftos ištekliai; Pramonės sektoriaus produkcijos apimčių indeksas; Brent naftos kaina; Ukrainos karo šokas; COVID-19 pandemijos šokas	80,79	4,21

Perskaičius tiksliausio dyzelino kainų ARDL modelio paklaidas iš ex-post į ex-ante, nustatyta, kad RMSE sumažėjo nuo 91,25 iki 80,79, o MAPE – nuo 5,03 iki 4,21. Šie rezultatai rodo, kad prognozuojant ateities laikotarpius modelio tikslumas pagerėjo, todėl galima teigti, kad ARDL modelis pasižymi aukštu dyzelino kainų prognozavimo stabilumu. Atsižvelgiant į gautus rezultatus galima teigti, kad Lietuvos naftos išteklių, pramonės sektoriaus produkcijos apimčių indekso, Brent naftos kainos bei COVID-19 ir Ukrainos karo šokų kintamieji išlieka reikšmingi ne tik vertinant istorinius dyzelino kainų pokyčius, bet ir prognozuojant jų dinamiką ateityje.

3.4.4. Dyzelino kainų dinamikos prognozavimas ir išorinių šokų poveikio vertinimas

Šiame poskyryje atliekamas dyzelino kainų dinamikos prognozavimas ir išorinių šokų poveikio vertinimas, apjungiant ankstesniuose analizės etapuose gautus vienmačių ir daugiamačių modeliavimo rezultatų vertinimus. Siekiama sistemiskai palyginti skirtingų modeliavimo metodų prognozavimo efektyvumą bei nustatyti, kurie iš jų tiksliausiai atspindi dyzelino kainų dinamiką, įvertinant ne tik vidinius kainų formavimosi mechanizmus, bet ir išorinių ekonominių bei geopolitinių veiksnių sukeltus struktūrinius pokyčius. Remiantis 25 lentelėje pateiktais dyzelino kainų modelių rezultatais, nustatoma, kuri modeliavimo metodika tiksliausiai prognozuoja kainų dinamiką.

25 lentelė. Dyzelino kainų modelių rezultatai

Modelio tipas	Nepriklausomi kintamieji	RMSE	MAPE
Prophet	Brent naftos kaina; Lietuvos naftos ištekliai; Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje; COVID-19 pandemijos šokas; Ukrainos karo šokas	47,37	2,49
VAR(4)	Pramonės sektoriaus produkcijos apimčių indeksas	65,95	3,12
ARIMAX(0,1,1)	Pramonės sektoriaus produkcijos apimčių indeksas; Importas; Ukrainos karo šokas	66,29	3,26
ETS(M,Ad,N)	-	74,93	3,56
ARDL	Lietuvos naftos ištekliai; Pramonės sektoriaus produkcijos apimčių indeksas; Brent naftos kaina; Ukrainos karo šokas; COVID-19 pandemijos šokas	80,79	4,21

Vertinant dyzelino kainų modelių rezultatus, nustatyta, kad pagal abu paklaidų rodiklius, geriausiai kainų dinamiką prognozuoja Prophet modelis, į kurį įtraukiami Brent naftos kainos, Lietuvos naftos išteklių, harmonizuoto vartotojų kainų indekso skystojo kuro rinkoje nepriklausomi kintamieji bei COVID-19 ir Ukrainos karo šokų kintamieji. Pateikiama minėto modelio (3.4.4.1) formulė:

$$\begin{aligned} \text{Dyzelino kaina} = & (-0,003 \cdot t + 0,59) + s(t) + 5,12 \cdot \text{Brent naftos kaina} + 0,02 \cdot \text{Lietuvos naftos ištekliai} \\ & + 1,92 \cdot \text{Harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje} - 60,41 \\ & \cdot \text{COVID 19 pandemijos šokas} + 47,99 \cdot \text{Ukrainos karo šokas}; \end{aligned}$$

$$s(t) = \sum_{n=1}^{10} \left(a_n \cos\left(\frac{2\pi n t}{365,25}\right) + b_n \sin\left(\frac{2\pi n t}{365,25}\right) \right);$$

(3.4.4.1)

čia t – laiko indeksas (mėnesio eilės numeris, skaičiuojant nuo duomenų rinkinio pradžios);

$s(t)$ – sezoniškumo komponentė, t laiko momentui;
 a_n – kosinusinės dalies koeficientas, n -tajai harmonikai (žr. 10 priedą);
 n – harmonikos indeksas;
 b_n – sinusinės dalies koeficientas, n -tajai harmonikai (žr. 10 priedą).

Remiantis dyzelino kainų dinamikos Prophet modelio išsklotine, kuri pateikta 10 priede, galima teigti, kad statistiškai reikšmingą poveikį mažmeninių dyzelino kainų dinamikai Lietuvos rinkoje turėjo Brent naftos kainos, harmonizuoto vartotojų kainų indekso skystojo kuro rinkoje bei COVID-19 pandemijos šoko kintamieji. Teigiamas Brent naftos kainos koeficientas ($\beta = 5,12$; $p = <0,01$) rodo, kad Brent naftos kainai padidėjus 1 JAV doleriu už barelį, dyzelino kaina vidutiniškai padidėja apie 5,12 eurų už 1000 l, kitoms sąlygoms nekintant. Tuo tarpu harmonizuoto vartotojų kainų indekso skystojo kuro rinkoje teigiamas koeficientas ($\beta = 1,92$; $p = <0,01$) indikuoja tiesioginį ryšį su mažmeninių dyzelino kainų dinamika. Indeksui padidėjus 1 punktu, dyzelino kaina vidutiniškai padidėja apie 1,92 eurų už 1000 l, kitoms sąlygoms nekintant. Toks rezultatas leidžia teigti, kad bendras kainų lygio augimas skystojo kuro rinkoje yra susijęs ir su dyzelino kainų didėjimu. Ekonominė prasme tai gali būti paaiškinama tuo, jog didėjantis kainų indeksas atspindi infliacinius procesus, augančias energijos išteklių, logistikos bei kuro tiekimo sąnaudas, kurios skatina galutinių dyzelino kainų augimą mažmeninėje rinkoje. COVID-19 pandemijos pseudo kintamojo neigiamas ir statistiškai reikšmingas koeficientas ($\beta = -60,41$; $p = 0,03$) leidžia teigti, kad pandemijos laikotarpiu dyzelino kainos buvo vidutiniškai apie 60,41 eurų už 1000 l mažesnės nei laikotarpiais be pandeminio šoko, kitoms sąlygoms nekintant. Tokį poveikį galima pagrįsti reikšmingu pasaulinės ir vietinės ekonominės veiklos sulėtėjimu pandemijos metu. Karantino ribojimai, sumažėję transporto ir logistikos srautai ir pramonės sektoriaus veiklos sulėtėjimas sumažino dyzelino paklausą taip pat ankstyvuojų pandemijos laikotarpiu pasaulinėje naftos rinkoje buvo stebimas staigus paklausos kritimas, dėl kurio smuko ir žaliavinės naftos kainos. Kadangi dyzelinas glaudžiai susijęs su ekonominiu aktyvumu, pandemijos laikotarpiu sumažėjusi verslo veikla natūraliai prisidėjo prie mažesnio dyzelino kainų lygio.

Lietuvos naftos išteklių ($\beta = 0,02$; $p = 0,74$) ir Ukrainos karo šoko ($\beta = 47,99$; $p = 0,30$) kintamųjų p reikšmės rodo, kad jų poveikis, esant 0,95 pasikliautinumo lygmeniui, nėra statistiškai reikšmingas, todėl galima teigti, jog šie veiksniai nagrinėjamu laikotarpiu neturėjo poveikio mažmeninių dyzelino kainų dinamikai.

Prophet modelio struktūra taip pat nurodo, jog dyzelino kainų ilgalaikio trendo komponentė ($k = -0,003$) atspindi neigiamą bazinės dyzelino kainos tendenciją, todėl, kitoms sąlygoms nekintant, dyzelino kainos analizuojamu laikotarpiu turėjo silpną mažėjimo tendenciją. Lyginant su benzino kainomis, dyzelino kainų ilgalaikio pokyčio kryptis yra gerokai stabilesnė, o tai gali rodyti didesnę dyzelino kainų priklausomybę nuo išorinių struktūrinių veiksnių nei nuo vidinės ilgalaikės tendencijos.

Galiausiai, pasitelkus atrinktą Prophet modelį, atliekamas 2026 metų mažmeninių dyzelino kainų prognozavimas. Prognozuojamos reikšmės pateikiamos 26 lentelėje kartu su realiomis 2026 metų sausio-balandžio mėnesių mažmeninių dyzelino kainų reikšmėmis, siekiant įvertinti modelio prognozavimo tikslumą ir nustatyti, kaip efektyviai pasirinkta modeliavimo metodika atspindi faktinę dyzelino kainų dinamiką.

26 lentelė. Mažmeninių dyzelino prognozuojamų bei realių kainų reikšmių palyginimas (Sudaryta pagal [8])

Data	Prognozuojama reikšmė	Reali reikšmė	Skirtumas	RMSE	MAPE
2026-01	1608,65	1551,34	57,31	333,13	12,68
2026-02	1574,80	1605,48	-30,68		
2026-03	1586,88	1943,71	-356,83		
2026-04	1530,90	2089,78	-558,88		
2026-05	1495,66	-	-	-	-
2026-06	1559,24	-	-	-	-
2026-07	1571,30	-	-	-	-
2026-08	1577,98	-	-	-	-
2026-09	1593,99	-	-	-	-
2026-10	1584,34	-	-	-	-
2026-11	1599,72	-	-	-	-
2026-12	1580,21	-	-	-	-

Analizuojant 2026 metų mažmeninių dyzelino kainų prognozes, pastebima, kad atrinktas Prophet modelis prognozuoja nuosaikią kainų dinamiką su ribotais mėnesiniais svyravimais (žr.11 priedą). Modelio rezultatai rodo, kad metų pradžioje numatomas kainų mažėjimas, kuris gegužės mėnesį pasiekia žemiausią prognozuojamą tašką, po kurio dyzelino kainų dinamikoje prognozuojamas augimo laikotarpis iki spalio mėnesio. Paskutiniais trimis metų mėnesiais prognozuojama kainų kryptis keičiasi kelis kartus, o tai indikuoja didesnę trumpalaikį kainų nepastovumą metų pabaigoje. Tokia Prophet modelio prognozuojama mažmeninių dyzelino kainų trajektorija leidžia teigti, kad modelis kainų raidą vertina remdamasis ilgalaikėmis rinkos tendencijomis ir išorinių veiksnių poveikiu. Vis dėlto, palyginus prognozuotas reikšmes su realiais 2026 metų sausio-balandžio mėnesių duomenimis, matyti, kad modelio prognozavimo tikslumas, kaip ir benzino atveju, pavasario laikotarpiu reikšmingai suprastėjo. Sausio ir vasario mėnesiais prognozuotos dyzelino kainos buvo pakankamai artimos faktinėms reikšmėms – skirtumai sudarė atitinkamai 57,31 ir -30,68 eurų, todėl metų pradžioje modelis dar gana tiksliai atspindėjo realią kainų dinamiką. Kovo ir balandžio mėnesiais skirtumas tarp prognozuojamų ir realių kainų ženkliai išaugo – kovą jis siekė -356,83 eurų, o balandį net -558,88 eurų. Apibendrinus pirmųjų keturių 2026 metų mėnesių prognozavimo rezultatus, nustatyta, kad Prophet modelio paklaidos sudarė 333,13 (RMSE) ir 12,68 (MAPE). Toks ryškus prognozių nuokrypis rodo, kad 2026 metų pavasarį reali dyzelino kainų dinamika patyrė itin staigų augimą, kurio modelis nesugebėjo tinkamai įvertinti. Lyginant su benzino kainų prognozėmis, dyzelino atveju prognozių nuokrypis buvo dar didesnis, o tai leidžia daryti prielaidą, kad mažmeninės dyzelino kainos buvo jautresnės 2026 metų pavasarį sustiprėjusiems geopolitiniams neramumams Artimųjų Rytų regione. Šie įvykiai tikėtina stipriau paveikė pasaulines naftos tiekimo grandines, logistinius srautus ir pramonės sektoriaus aktyvumą, todėl dyzelino kainų reakcija į šį šoką buvo intensyvesnė nei benzino rinkoje.

Išvados

1. Išanalizavus mokslinėje literatūroje nagrinėjamą degalų sampratą bei benzino ir dyzelino kainų formavimosi mechanizmus, buvo nustatyta, kad degalų sąvoka apibūdina daugialypę ir struktūriškai sudėtingą energijos išteklių grupę, kurioje didžiausia paklausa pasižymi benzino ir dyzelino degalų rūšys. Mokslinių tyrimų analizės metu taip pat buvo nustatyta, kad benzino kainos pasižymi sezoniniais pokyčiais, kuriuos lemia šiltuoju metų laikotarpiu intensyvesnis transporto priemonių naudojimas ir turizmo aktyvumas. Dyzelino kainoms taip pat yra būdingas sezoniškumas, tačiau jis labiau yra susijęs su pramonės ir transporto sektorių ciklais.
2. Identifikavus pagrindinius išorinius veiksnius bei šokus, lemiančius benzino ir dyzelino kainų dinamiką, buvo nustatyta, kad nagrinėjant šių degalų rūšių kainas, būtina įvertinti žaliavinės naftos rinkos, ekonominio augimo, politinio stabilumo, naftos gamybos bei atsinaujinančios energijos šaltinių naudojimo rodiklius. Nepaisant to, atliekant detalesnę kainų dinamikos analizę svarbu atsižvelgti ir į egzistuojančius papildomus kuro gamybos, tiekimo, vartojimo faktorius bei mokestinius aspektus, kurie yra taikomi išskirtinai benzino arba dyzelino produkcijai ir ženkliai prisideda prie galutinio vartojimo kainų susiformavimo. Įvertinus WTI kainų dinamiką, buvo išskirti COVID-19 pandemijos ir Ukrainos karo šokai, kurie 2013-2025 m. laikotarpiu lėmė benzino bei dyzelino kainų dinamiką.
3. Aprašius ir teoriškai pagrindus tyrime taikomus laiko eilučių analizės metodus bei prognozavimo modelius, buvo aptarti laiko eilučių stacionarumo vertinimo metodai, Granger priežastingumo ryšio nustatymo principai, taip pat vienmačių ir daugiamačių laiko eilučių modelių metodologijos, atskleidžiant jų pritaikomumą skirtingose prognozavimo situacijose, priklausomai nuo duomenų struktūros, sezoniškumo, išorinių veiksnių ir struktūrinių lūžių poveikio. Papildomai aptarti prognozavimo tikslumo vertinimo rodikliai sudarė pagrindą objektyviam modelių palyginimui bei tinkamiausio prognozavimo metodo parinkimui benzino ir dyzelino kainų modeliavimui.
4. Įvertinus Granger priežastingumo ryšius tarp mažmeninių benzino bei dyzelino kainų ir mokslinėje literatūroje identifikuotų, jų dinamiką lemiančių, veiksnių, buvo nustatyta, kad abiejų degalų rūšių kainos pasižymi statistiškai reikšmingu priežastingumo ryšiu su Brent naftos kainos, Lietuvos naftos išteklių ir harmonizuoto vartotojų kainų indekso skystojo kuro rinkoje rodikliais, todėl galima teigti, jog šie kintamieji yra pagrindiniai, degalų kainų dinamiką formuojantys, veiksniai. Ryšių analizė taip pat parodė, kad dyzelino kainos yra jautrios makroekonominiams (pramonės sektoriaus produkcijos apimčių indekso, importo) ir fiskaliniams (mokesčių dalies dyzelino kainoje, dyzelinui taikomo akcizo) veiksniams. Tuo tarpu benzino kainų dinamika labiau siejasi su vidaus rinkos ekonominiais (Lietuvos nedarbo lygio) ir energetiniais (elektros energijos pasiūlos Lietuvos rinkoje) rodikliais, kas atspindi didesnę priklausomybę nuo vidaus ekonominės aplinkos ir vartojimo sąlygų.
5. Sudarius mažmeninių benzino ir dyzelino kainų prognozavimo modelius, paaiškėjo, kad tiksliausiai degalų kainų dinamiką įvertina Prophet modeliai. Įvertinus išorinių veiksnių bei šokų poveikį benzino ir dyzelino kainų dinamikai, tyrimo rezultatai atskleidė, jog abiejų degalų rūšių kainas lemiančiai Brent naftos kainai padidėjus 1 JAV doleriu už barelį, benzino kaina vidutiniškai padidėja apie 5,67 eurų už 1000 l, o dyzelino kaina išauga apie 5,12 eurų už 1000 l. Benzino kainų atveju papildomai reikšmingas buvo Lietuvos nedarbo lygio kintamasis, kuriam padidėjus 1 procentiniu punktu, benzino kaina vidutiniškai sumažėja apie 36,08 eurų už 1000 l, kas leidžia teigti, jog vidaus ekonominės situacijos blogėjimas ir susitraukęs vartojimas prisideda prie degalų kainų mažėjimo. Tuo tarpu dyzelino kainų dinamiką, be Brent naftos kainos, reikšmingai veikia harmonizuotas vartotojų kainų indeksas skystojo kuro rinkoje, o šiam indeksui

padidėjus 1 punktu, dyzelino kaina vidutiniškai išauga apie 1,92 eurų už 1000 l, taip atspindėdama infliacinių procesų, augančių energijos išteklių bei logistikos sąnaudų poveikį degalų kainoms. Įvertinus šokų poveikį mažmeninių benzino ir dyzelino kainų dinamikai, galima teigti, kad jų reikšmė skirtingų degalų rūšių kainų modeliavime pasireiškia nevienodai. Tyrimo rezultatai parodė, jog COVID-19 pandemijos ir Ukrainos karo išorinių šokų poveikis benzino kainų dinamikai analizuojamu laikotarpiu buvo statistiškai nereikšmingas. Tuo tarpu dyzelino kainos, pasižymėjo statistiškai reikšmingu neigiamu ryšiu su COVID-19 šoko pseudo kintamuoju. Atsižvelgiant į neigiamą COVID-19 šoko koeficiento reikšmę, galima teigti, jog pandemijos laikotarpiu dyzelino kainos buvo vidutiniškai apie 60,41 eurų už 1000 l mažesnės nei įprastomis rinkos sąlygomis. Toks šoko poveikis dyzelino kainų kintamajam yra siejamas su reikšmingu ekonominės veiklos sulėtėjimu, sumažėjusiais transporto ir logistikos srautais bei bendru degalų paklausos susitraukimu COVID-19 pandemijos metu. Atlikus degalų kainų 2026 metų prognozes, buvo nustatyta, kad benzino kainų prognozuojamoms reikšmėms buvo būdingos mažesnės paklaidos (RMSE = 189,65; MAPE = 8,36), nei dyzelino kainų prognozėms (RMSE = 333,13; MAPE = 12,68), kas indikuoja, jog dyzelino kainų dinamika analizuojamu laikotarpiu pasižymėjo didesniu jautrumu išorinių veiksnių pokyčiams ir sudėtingesne kainų formavimosi struktūra, ypač reaguojant į geopolitinius neramumus Artimuosiuose Rytuose, kurie didino kainų svyravimus ir apsunkino tikslų prognozių sudarymą.

Rekomendacijos

Atsižvelgiant į atlikto tyrimo rezultatus, rekomenduojama tobulinti degalų kainų prognozavimo modelius, papildomai integruojant ne tik tradicinius makroekonominis rodiklius, bet ir geopolitinius, fiskalinius bei energetikos rinkų dinamiką atspindinčius veiksnius, taip pat, siekiant tiksliau užfiksuoti staigius kainų pokyčius ir trumpalaikius rinkos svyravimus patariama naudoti aukštesnio dažnio duomenis. Kadangi tyrimo metu buvo nustatyta, jog Prophet modelių prognozavimo tikslumas reikšmingai sumažėja ekstremalių ekonominių ir geopolitinių sukrėtimų laikotarpiais, ateities tyrimuose rekomenduojama šiuos modelius papildyti struktūrinių lūžių, režimų kaitos arba scenarijų analizės metodais, kurie leistų geriau adaptuoti modelius prie nestabilių rinkos sąlygų ir padidintų prognozių patikimumą šokų poveikio metu.

Atsižvelgiant į tai, kad benzino ir dyzelino kainų dinamiką lemia skirtingi veiksnių rinkiniai, rekomenduojama šias degalų rūšis modeliuoti atskirai, taikant individualizuotas specifikacijas kiekvienai rinkai. Tolimesniuose tyrimuose taip pat patariama palyginti tradicinius statistinius metodus su pažangesniais mašininio mokymosi algoritmais, kurie pasižymi geresniu gebėjimu modeliuoti netiesinius ryšius ir sėkmingiau prisitaiko prie struktūrinių duomenų pokyčių.

Galiausiai, atlikto tyrimo rezultatai gali prisidėti prie darnaus vystymosi tikslų įgyvendinimo, suteikdami tikslesnius degalų kainų prognozavimo rezultatus, kurie leidžia efektyviau planuoti energetikos išteklių vartojimą, mažina ekonominę neapibrėžtumą bei skatina racialesnę transporto ir pramonės sektorių resursų naudojimą, taip prisidedant prie tvaresnės ir efektyvesnės energijos rinkos plėtros.

Literatūros sąrašas


1. INTERNATIONAL ENERGY AGENCY (IEA). *Oil 2024: Analysis and forecast to 2030*. Prieiga per internetą: <https://iea.blob.core.windows.net/assets/493a4f1b-c0a8-4bfc-be7b-b9c0761a3e5e/Oil2024.pdf> [žiūrėta 2025-12-28].
2. ENERGY INSTITUTE (EI). *2024 Statistical Review of World Energy*. Prieiga per internetą: https://www.energyinst.org/_data/assets/pdf_file/0006/1542714/684_EI_Stat_Review_V16_DIGITAL.pdf [žiūrėta 2025-12-28].
3. HAMILTON, James D. *The Changing Face of World Oil Markets*. Cambridge [MA]: National Bureau of Economic Research, 2014. Prieiga per internetą: <https://doi.org/10.3386/w20355>.
4. KAISER, Mark J.; Arno de KLERK; James H. GARY ir Glenn E. HANDWERK. *Petroleum Refining Technology, Economics, and Markets*. 6-oji laida. Boca Raton [FL]: CRC Press, 2020.
5. INTERNATIONAL ENERGY AGENCY (IEA). *Global Energy Review 2025*. Prieiga per internetą: <https://www.iea.org/reports/global-energy-review-2025> [žiūrėta 2025-12-28].
6. EUROPEAN COMMISSION. *Energy consumption for transport activities stable in 2023*. Prieiga per internetą: <https://ec.europa.eu/eurostat/web/products-eurostat-news/w/ddn-20251128-1> [žiūrėta 2025-12-28].
7. KILIAN, Lutz ir Xiaoqing ZHOU. *Oil Prices, Gasoline Prices and Inflation Expectations: A New Model and New Facts*. Dallas [TX]: Federal Reserve Bank of Dallas, 2020. Prieiga per internetą: <https://doi.org/10.24149/wp2025>.
8. EUROPEAN COMMISSION. *Weekly Oil Bulletin*. Prieiga per internetą: https://energy.ec.europa.eu/data-and-analysis/weekly-oil-bulletin_en?prefLang=lt [žiūrėta 2025-12-28].
9. FATTOUH, Bassam ir Lavan MAHADEVA. OPEC: What Difference Has it Made?. *Annual Review of Resource Economics*, 5, 2013, 1, 427-443. Prieiga per internetą: <https://dx.doi.org/10.1146/annurev-resource-091912-151901>.
10. ZHANG, Qi; Yi HU; Jianbin JIAO ir Shouyang WANG. The impact of Russia-Ukraine war on crude oil prices: an EMC framework. *Humanities and Social Sciences Communications*, 11, 2024, 8, 1-12. Prieiga per internetą: <https://doi.org/10.1057/s41599-023-02526-9>.
11. INTERNATIONAL MONETARY FUND. *Global price of WTI Crude*. Prieiga per internetą: Federal Reserve Bank of St. Louis, <https://fred.stlouisfed.org/series/POILWTIUSDM> [žiūrėta 2026-03-21].
12. ALHAED, Sajjad S. ir Baidaa R. HUSSEIN. Oil market dynamics in the 21st century: analyzing trends, challenges, and opportunities. *Manager-The British Journal of Administrative Management*, 59, 2023, 169, 13-22.
13. HOSSEINI, Seyed H.; Hamed S. G ir Adel PEIGHAMI. A conceptual framework for the oil market dynamics: A systems approach. *Energy Exploration & Exploitation*, 34, 2016, 2, 171-198. Prieiga per internetą: <https://doi.org/10.1177/0144598716631656>.
14. ANTONAKAKIS, Nikolaos; Juncal CUNADO; George FILIS; David GABAUER ir Fernando P. DE GRACIA. Oil volatility, oil and gas firms and portfolio diversification. *Energy Economics*, 70, 2018, 499-515. Prieiga per internetą: <https://doi.org/10.1016/j.eneco.2018.01.023>.
15. ALQUIST, Ron; Lutz KILIAN ir Robert J. VIGFUSSON. Chapter 8 - Forecasting the Price of Oil. *Handbook of Economic Forecasting*, 2, 2013, 427-507. Prieiga per internetą: <https://doi.org/10.1016/B978-0-444-53683-9.00008-6>.





16. READY, Robert C. Oil Prices and the Stock Market. *Review of Finance*, 22, 2018, 1, 155-176. Prieiga per internetą: <https://doi.org/10.1093/rof/rfw071>.
17. LIU, Zhenhua; Zhinhua DING; Tao LV; Jy S. WU ir Wei QIANG. Financial factors affecting oil price change and oil-stock interactions: a review and future perspectives. *Natural Hazards*, 95, 2019, 207-225. Prieiga per internetą: <https://doi.org/10.1007/s11069-018-3473-y>.
18. CALDARA, Dario ir Matteo IACOVIELLO. Measuring Geopolitical Risk. *American Economic Review*, 112, 2022, 4, 1194-1225. Prieiga per internetą: <https://doi.org/10.1257/aer.20191823>.
19. GYAGRI, Mina; Eric M. AMARFIO ir Solomon A. MARFO. Determinants of Global Pricing of Crude Oil - A Theoretical Review. *International Journal of Petroleum and Petrochemical Engineering (IJPPE)*, 3, 2017, 3, 7-15. Prieiga per internetą: <http://doi.org/10.20431/2454-7980.0303002>.
20. BAUMEISTER, Christiane ir Lutz KILIAN. Forty Years of Oil Price Fluctuations: Why the Price of Oil May Still Surprise Us. *Journal of Economic Perspectives*, 30, 2016, 1, 60-139. Prieiga per internetą: <https://doi.org/10.1257/jep.30.1.139>.
21. BORENSTEIN, Severin; Colin A. CAMERON ir Richard GILBERT. Do Gasoline Prices Respond Asymmetrically to Crude Oil Price Changes?. *The Quarterly Journal of Economics*, 112, 1997, 1, 305-339. Prieiga per internetą: <https://doi.org/10.1162/003355397555118>.
22. MARIN, Giovanni ir Antonello ZANFEI. Does host market regulation induce cross-border environmental innovation?. *The World Economy*, 42, 2019, 7, 2089-2119. Prieiga per internetą: <https://doi.org/10.1111/twec.12784>.
23. EDERINGTON, Louis H.; Chitru S. FERNANO; Thomas K. LEE; Scott C. LINN ir Anthony D. MAY. *Factors Influencing Oil Prices: A Survey of the Current State of Knowledge in the Context of the 2007-08 Oil Price Volatility*. Washington [DC]: U.S. Energy Information Administration, 2011. Prieiga per internetą: https://www.eia.gov/workingpapers/pdf/factors_influencing_oil_prices.pdf.
24. BOX, George E. P.; Gwilym M. JENKINS; Gregory C. REINSEL ir Greta M. LJUNG. *Time Series Analysis: Forecasting and Control*. 5-oji laida. Hoboken [NJ]: John Wiley and Sons Inc, 2015.
25. BROCKWELL, Peter J. ir Richard A. DAVIS. *Introduction to Time Series and Forecasting*. 3-oji laida. Switzerland: Springer, 2016. Prieiga per internetą: https://doi.org/10.1007/978-3-319-29854-2_1.
26. BAFFES, John; Ayhan M. KOSE; Franziska OHNSORGE ir Marc STOCKER. *The Great Plunge in Oil Prices: Causes, Consequences, and Policy Responses*. World Bank, 2015. Prieiga per internetą: <https://doi.org/10.1596/23611>.
27. HYNDMAN, Rob J. ir George ATHANASOPOULOS. *Forecasting: Principles and Practice*. 3-oji laida. Melbourne: OTexts, 2021. Prieiga per internetą: <https://otexts.com/fpp3/>.
28. BERNARDI, Enrico; Alberto LANCONELLI ir Christopher S. A. LAURIA. *A Novel Theoretical Framework for Exponential Smoothing*. arXiv, 2024. Prieiga per internetą: <https://doi.org/10.48550/arXiv.2403.04345>.
29. MAKRIDAKIS, Spyros; Evangelos SPILIOTIS ir Vassilios ASSIMAKOPOULOS. The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36, 2020, 1, 54-74. Prieiga per internetą: <https://doi.org/10.1016/j.ijforecast.2019.04.014>.

30. TSAY, Ruey S. *Analysis of Financial Time Series*. Hoboken [NJ]: John Wiley and Sons Inc, 2010. Prieiga per internetą: <https://doi.org/10.1002/9780470644560>.
31. HAMILTON, James D. *Time Series Analysis*. Princeton [NJ]: Princeton University Press, 1994. Prieiga per internetą: <https://doi.org/10.1515/9780691218632>.
32. ENDERS, Walter. *Applied Econometric Time Series*. 4-oji spauda. Hoboken [NJ]: John Wiley and Sons Inc, 2014.
33. HYNDMAN, Rob J.; Anne B. KOEHLER; Keith J. ORD ir Ralph D. SNYDER. *Forecasting with Exponential Smoothing: The State Space Approach*. 1-oji spauda. Berlin: Springer, 2008. Prieiga per internetą: <https://doi.org/10.1007/978-3-540-71918-2>.
34. ASTERIOU, Dimitrios ir Stephen G. HALL. *Applied Econometrics*. 4-oji spauda. Bloomsbury Publishing, 2021.
35. BRUNS, Martin ir Helmut LÜTKEPOHL. Have the Effects of Shocks to Oil Price Expectations Changed?: Evidence from Heteroskedastic Proxy Vector Autoregressions. *Discussion Papers of DIW Berlin*, 2036. Berlin: DIW Berlin, 2023. Prieiga per internetą: <https://dx.doi.org/10.2139/ssrn.4455121>.
36. KILIAN, Lutz. Not All Oil Price Shocks Are Alike: Disentangling Demand and Supply Shocks in the Crude Oil Market. *The American Economic Review*, 99, 2009, 3, 1053-1069. Prieiga per internetą: <https://doi.org/10.1257/aer.99.3.1053>.
37. TAYLOR, Sean J. ir Benjamin LETHAM. Forecasting at Scale. *The American Statistician*, 72, 2018, 1, 37-45. Prieiga per internetą: <https://doi.org/10.1080/00031305.2017.1380080>.


Priedai

1 priedas. Nepriklausomų kintamųjų dinamikos grafikai







Pramonės sektoriaus sukurtos produkcijos indeksas




Naujai registruotų transporto priemonių skaičius




Lietuvos importas




Lietuvos nedarbo lygis (vyrai ir moterys 15-74)



Gamtinių dujų vartojimas Lietuvoje



Elektrinės energijos pasiūla Lietuvos rinkoje



2 priedas. Vienmačių modelių rezultatai

– Benzino

> results_petro1

	Modelis	RMSE	MAPE
1	Naive	47.57798	2.180822
2	Seasonal Naive	73.48173	4.336514
3	RWD	47.33472	2.132574
4	Seasonal RWD	73.70591	4.329130
5	ARIMA: ARIMA(0,1,1)	42.06906	1.838968
6	SARIMA: ARIMA(0,1,1)	42.06906	1.838968
7	ETS: ETS(M,N,N)	47.57911	2.180941
8	MA(12)	46.91948	3.082039
9	Prophet	212.99485	14.336580

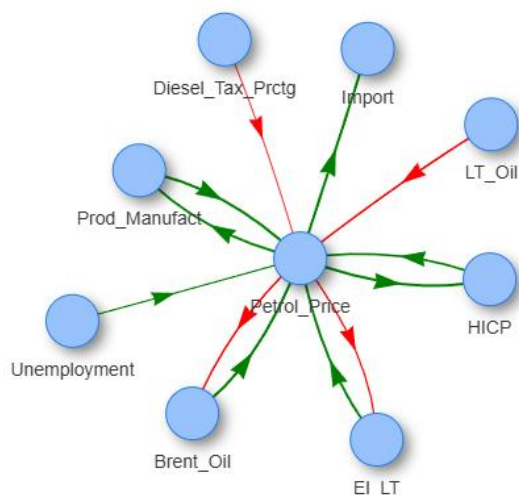
– Dyzelino

> results_diesel

	Modelis	RMSE	MAPE
1	Naive	97.05140	5.172817
2	Seasonal Naive	84.80262	4.801493
3	RWD	94.49671	4.943048
4	Seasonal RWD	81.36329	4.631694
5	ARIMA: ARIMA(0,1,1)	76.96508	3.689808
6	SARIMA: ARIMA(0,1,1)	76.96508	3.689808
7	ETS: ETS(M,Ad,N)	74.93362	3.555347
8	MA(12)	77.74554	3.741786
9	Prophet	146.21755	8.977906

3 priedas. Granger priežastingumo analizės rezultatai

– Benzino kainų atžvilgiu



AR(8+1)
 (coefs): Petrol_Price {0.371} & Diesel_Price {-0.224}
 (chi2): Petrol_Price [0.131] ◆ Diesel_Price [0.245]
 (Ftest): Petrol_Price [0.143] ◆ Diesel_Price [0.256]

AR(2+1)
 (coefs): Petrol_Price {-0.000} & Petrol_Tax_Prctg {-2.233}
 (chi2): Petrol_Price [0.582] ◆ Petrol_Tax_Prctg [0.106]
 (Ftest): Petrol_Price [0.583] ◆ Petrol_Tax_Prctg [0.110]

AR(2+1)
 (coefs): Petrol_Price {-0.002} & Diesel_Tax_Prctg {-2.864}
 (chi2): Petrol_Price [0.600] ◆ Diesel_Tax_Prctg [0.093]
 (Ftest): Petrol_Price [0.601] ◆ Diesel_Tax_Prctg [0.096]

AR(2+1)
 (coefs): Petrol_Price {-0.000} & Petrol_Excises {0.529}
 (chi2): Petrol_Price [0.999] ◆ Petrol_Excises [0.385]
 (Ftest): Petrol_Price [0.999] ◆ Petrol_Excises [0.388]

AR(2+1)
 (coefs): Petrol_Price {-0.001} & Diesel_Excises {-0.106}
 (chi2): Petrol_Price [0.822] ◆ Diesel_Excises [0.529]
 (Ftest): Petrol_Price [0.822] ◆ Diesel_Excises [0.531]

AR(2+1)
 (coefs): Petrol_Price {-0.011} & Brent_Oil {1.032}
 (chi2): Petrol_Price [0.032] ◆ Brent_Oil [0.000]
 (Ftest): Petrol_Price [0.034] ◆ Brent_Oil [0.000]

AR(5+1)
 (coefs): Petrol_Price {0.004} & LT_Petr {-1.000}
 (chi2): Petrol_Price [0.713] ◆ LT_Petr [0.362]
 (Ftest): Petrol_Price [0.713] ◆ LT_Petr [0.367]

AR(4+1)
 (coefs): Petrol_Price {-0.023} & LT_D {-0.209}
 (chi2): Petrol_Price [0.725] ◆ LT_D [0.166]
 (Ftest): Petrol_Price [0.725] ◆ LT_D [0.173]

AR(2+1)
 (coefs): Petrol_Price {-0.010} & LT_oil {-0.028}
 (chi2): Petrol_Price [0.299] ◆ LT_oil [0.027]
 (Ftest): Petrol_Price [0.302] ◆ LT_oil [0.029]

AR(3+1)
 (coefs): Petrol_Price {-0.001} & Emergency_oil {0.852}
 (chi2): Petrol_Price [0.122] ◆ Emergency_oil [0.225]
 (Ftest): Petrol_Price [0.127] ◆ Emergency_oil [0.229]

AR(11+1)
 (coefs): Petrol_Price {0.004} & HICP {0.950}
 (chi2): Petrol_Price [0.000] ◆ HICP [0.014]
 (Ftest): Petrol_Price [0.000] ◆ HICP [0.021]

AR(3+1)
 (coefs): Petrol_Price {0.006} & Prod_Manufact {1.743}
 (chi2): Petrol_Price [0.010] ◆ Prod_Manufact [0.001]
 (Ftest): Petrol_Price [0.011] ◆ Prod_Manufact [0.001]

AR(2+1)
 (coefs): Petrol_Price {-0.496} & Transp_Nbr {-0.007}
 (chi2): Petrol_Price [0.968] ◆ Transp_Nbr [0.719]
 (Ftest): Petrol_Price [0.968] ◆ Transp_Nbr [0.719]

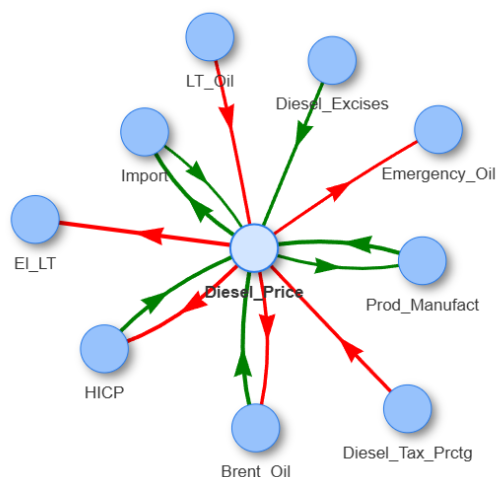
AR(1+1)
 (coefs): Petrol_Price {820.549} & Import {0.000}
 (chi2): Petrol_Price [0.001] ◆ Import [0.944]
 (Ftest): Petrol_Price [0.001] ◆ Import [0.944]

AR(10+1)
 (coefs): Petrol_Price {0.000} & Unemployment {3.394}
 (chi2): Petrol_Price [0.734] ◆ Unemployment [0.050]
 (Ftest): Petrol_Price [0.731] ◆ Unemployment [0.062]

AR(4+1)
 (coefs): Petrol_Price {-2.345} & Gass_LT {0.004}
 (chi2): Petrol_Price [0.372] ◆ Gass_LT [0.938]
 (Ftest): Petrol_Price [0.376] ◆ Gass_LT [0.937]

AR(4+1)
 (coefs): Petrol_Price {-0.073} & EI_LT {0.096}
 (chi2): Petrol_Price [0.049] ◆ EI_LT [0.007]
 (Ftest): Petrol_Price [0.054] ◆ EI_LT [0.009]

– Dyzelino kainų atžvilgiu



AR(2+1)
 (coefs): Diesel_Price {-0.000} & Petrol_Tax_Prctg {-5.475}
 (chi2): Diesel_Price [0.887] ◆ Petrol_Tax_Prctg [0.617]
 (Ftest): Diesel_Price [0.887] ◆ Petrol_Tax_Prctg [0.618]

AR(2+1)
 (coefs): Diesel_Price {0.000} & Diesel_Tax_Prctg {-2.162}
 (chi2): Diesel_Price [0.229] + Diesel_Tax_Prctg [0.032]
 (Ftest): Diesel_Price [0.232] + Diesel_Tax_Prctg [0.035]

AR(4+1)
 (coefs): Diesel_Price {-0.000} & Petrol_Excises {0.785}
 (chi2): Diesel_Price [1.000] ◆ Petrol_Excises [0.244]
 (Ftest): Diesel_Price [1.000] ◆ Petrol_Excises [0.249]

AR(4+1)
 (coefs): Diesel_Price {-0.000} & Diesel_Excises {0.143}
 (chi2): Diesel_Price [0.952] + Diesel_Excises [0.038]
 (Ftest): Diesel_Price [0.952] + Diesel_Excises [0.042]

AR(2+1)
 (coefs): Diesel_Price {-0.010} & Brent_Oil {1.319}
 (chi2): Diesel_Price [0.038] + Brent_Oil [0.000]
 (Ftest): Diesel_Price [0.041] + Brent_Oil [0.000]

AR(4+1)
 (coefs): Diesel_Price {0.003} & LT_Petr {2.559}
 (chi2): Diesel_Price [0.985] ◆ LT_Petr [0.372]
 (Ftest): Diesel_Price [0.985] ◆ LT_Petr [0.377]

AR(4+1)
 (coefs): Diesel_Price {-0.020} & LT_D {0.082}
 (chi2): Diesel_Price [0.115] ◆ LT_D [0.221]
 (Ftest): Diesel_Price [0.121] ◆ LT_D [0.227]

AR(2+1)
 (coefs): Diesel_Price {-0.019} & LT_oil {-0.032}
 (chi2): Diesel_Price [0.216] + LT_oil [0.045]
 (Ftest): Diesel_Price [0.220] + LT_oil [0.048]

AR(3+1)
 (coefs): Diesel_Price {-0.001} & Emergency_oil {1.039}
 (chi2): Diesel_Price [0.062] + Emergency_oil [0.749]
 (Ftest): Diesel_Price [0.067] + Emergency_oil [0.749]

AR(4+1)
 (coefs): Diesel_Price {-0.008} & HICP {0.298}
 (chi2): Diesel_Price [0.014] + HICP [0.014]
 (Ftest): Diesel_Price [0.017] + HICP [0.016]

AR(3+1)
 (coefs): Diesel_Price {0.003} & Prod_Manufact {3.191}
 (chi2): Diesel_Price [0.057] + Prod_Manufact [0.000]
 (Ftest): Diesel_Price [0.061] + Prod_Manufact [0.000]

AR(3+1)
 (coefs): Diesel_Price {-0.306} & Transp_Nbr {-0.009}
 (chi2): Diesel_Price [0.611] ◆ Transp_Nbr [0.829]
 (Ftest): Diesel_Price [0.612] ◆ Transp_Nbr [0.829]

AR(4+1)
 (coefs): Diesel_Price {265.880} & Import {0.000}
 (chi2): Diesel_Price [0.004] + Import [0.090]
 (Ftest): Diesel_Price [0.006] + Import [0.096]

AR(10+1)
 (coefs): Diesel_Price {0.000} & Unemployment {2.556}
 (chi2): Diesel_Price [0.278] ◆ Unemployment [0.132]
 (Ftest): Diesel_Price [0.290] ◆ Unemployment [0.147]

AR(4+1)
 (coefs): Diesel_Price {-1.959} & Gass_LT {0.000}
 (chi2): Diesel_Price [0.879] ◆ Gass_LT [0.968]
 (Ftest): Diesel_Price [0.878] ◆ Gass_LT [0.968]

AR(12+1)
 (coefs): Diesel_Price {-0.096} & E1_LT {0.111}
 (chi2): Diesel_Price [0.000] + E1_LT [0.111]
 (Ftest): Diesel_Price [0.001] + E1_LT [0.129]>

4 priedas. VAR modelių išsklotinės

– Benzino kainų

VAR system, lag order 3
 OLS estimates, observations 2013:04-2024:12 (T = 141)
 Log-likelihood = -1139,0959
 Determinant of covariance matrix = 35654,634
 AIC = 16,3843
 BIC = 16,7189
 HQC = 16,5203
 Portmanteau test: LB(35) = 119,935, df = 128 [0,6820]

Equation 1: Petrol_Price

	coefficient	std. error	t-ratio	p-value	
const	101,845	35,8295	2,842	0,0052	***
Petrol_Price_1	0,878706	0,113763	7,724	2,42e-012	***
Petrol_Price_2	-0,0711202	0,158740	-0,4480	0,6549	
Petrol_Price_3	0,0390901	0,102002	0,3832	0,7022	
Brent_Oil_1	4,30977	0,836270	5,154	9,03e-07	***
Brent_Oil_2	-3,34160	1,21784	-2,744	0,0069	***
Brent_Oil_3	0,0122094	0,899298	0,01358	0,9892	
time	0,361261	0,155397	2,325	0,0216	**
Mean dependent var	1291,330	S.D. dependent var	200,6339		
Sum squared resid	257809,6	S.E. of regression	44,02747		
R-squared	0,954253	Adjusted R-squared	0,951845		
F(7, 133)	396,3282	P-value(F)	8,47e-86		
rho	0,010304	Durbin-Watson	1,970138		

Forecast evaluation statistics using 12 observation

Mean Error	-50,251
Root Mean Squared Error	87,225
Mean Absolute Error	80,718
Mean Percentage Error	-3,6476
Mean Absolute Percentage Error	5,6966
Theil's U2	4,5641
Bias proportion, UM	0,33189
Regression proportion, UR	0,61879
Disturbance proportion, UD	0,049311

VAR system, lag order 3
 OLS estimates, observations 2013:04-2024:12 (T = 141)
 Log-likelihood = -1619,4006
 Determinant of covariance matrix = 32425867
 AIC = 23,1972
 BIC = 23,5318
 HQC = 23,3331
 Portmanteau test: LB(35) = 150,671, df = 128 [0,0835]

Equation 1: Petrol_Price

	coefficient	std. error	t-ratio	p-value	
const	73,0139	42,5260	1,717	0,0883	*
Petrol_Price_1	1,27589	0,0894378	14,27	1,37e-028	***
Petrol_Price_2	-0,410040	0,142450	-2,878	0,0047	***
Petrol_Price_3	0,0779549	0,0879975	0,8859	0,3773	
LT_Oil_1	-0,0810865	0,0323214	-2,509	0,0133	**
LT_Oil_2	0,0597066	0,0345029	1,730	0,0859	*
LT_Oil_3	0,00276503	0,0324070	0,08532	0,9321	
time	0,177817	0,113386	1,568	0,1192	
Mean dependent var	1291,330	S.D. dependent var	200,6339		
Sum squared resid	300442,9	S.E. of regression	47,52861		
R-squared	0,946688	Adjusted R-squared	0,943882		
F(7, 133)	337,3925	P-value(F)	2,18e-81		
rho	0,009373	Durbin-Watson	1,972544		

Forecast evaluation statistics using 12 observations

Mean Error	-15,825
Root Mean Squared Error	58,852
Mean Absolute Error	54,446
Mean Percentage Error	-1,2054
Mean Absolute Percentage Error	3,8116
Theil's U2	2,848
Bias proportion, UM	0,072305
Regression proportion, UR	0,79713
Disturbance proportion, UD	0,13057

VAR system, lag order 3
 OLS estimates, observations 2013:04-2024:12 (T = 141)
 Log-likelihood = -1619,4006
 Determinant of covariance matrix = 32425867
 AIC = 23,1972
 BIC = 23,5318
 HQC = 23,3331
 Portmanteau test: LB(35) = 150,671, df = 128 [0,0835]

Equation 1: Petrol_Price

	coefficient	std. error	t-ratio	p-value	
const	73,0139	42,5260	1,717	0,0883	*
Petrol_Price_1	1,27589	0,0894378	14,27	1,37e-028	***
Petrol_Price_2	-0,410040	0,142450	-2,878	0,0047	***
Petrol_Price_3	0,0779549	0,0879975	0,8859	0,3773	
LT_Oil_1	-0,0810865	0,0323214	-2,509	0,0133	**
LT_Oil_2	0,0597066	0,0345029	1,730	0,0859	*
LT_Oil_3	0,00276503	0,0324070	0,08532	0,9321	
time	0,177817	0,113386	1,568	0,1192	
Mean dependent var	1291,330	S.D. dependent var	200,6339		
Sum squared resid	300442,9	S.E. of regression	47,52861		
R-squared	0,946688	Adjusted R-squared	0,943882		
F(7, 133)	337,3925	P-value(F)	2,18e-81		
rho	0,009373	Durbin-Watson	1,972544		

Forecast evaluation statistics using 12 observations

Mean Error	-15,825
Root Mean Squared Error	58,852
Mean Absolute Error	54,446
Mean Percentage Error	-1,2054
Mean Absolute Percentage Error	3,8116
Theil's U2	2,848
Bias proportion, UM	0,072305
Regression proportion, UR	0,79713
Disturbance proportion, UD	0,13057

VAR system, lag order 12
 OLS estimates, observations 2014:01-2024:12 (T = 132)
 Log-likelihood = -1111,4749
 Determinant of covariance matrix = 70599,265
 AIC = 17,6284
 BIC = 18,7641
 HQC = 18,0899
 Portmanteau test: LB(33) = 115,085, df = 84 [0,0121]

Equation 1: Petrol_Price

	coefficient	std. error	t-ratio	p-value	
const	120,620	46,5711	2,590	0,0109	**
Petrol_Price_1	1,09850	0,127691	8,603	7,70e-014	***
Petrol_Price_2	-0,485420	0,172417	-2,815	0,0058	***
Petrol_Price_3	0,407837	0,180021	2,265	0,0255	**
Petrol_Price_4	-0,376501	0,191493	-1,966	0,0519	*
Petrol_Price_5	0,196495	0,198043	0,9922	0,3234	
Petrol_Price_6	-0,0943206	0,190159	-0,4960	0,6209	
Petrol_Price_7	-0,0691498	0,189940	-0,3641	0,7165	
Petrol_Price_8	0,128474	0,190072	0,6759	0,5006	
Petrol_Price_9	-0,0926737	0,190847	-0,4856	0,6283	
Petrol_Price_10	0,150435	0,193140	0,7789	0,4378	
Petrol_Price_11	-0,201385	0,183452	-1,098	0,2748	
Petrol_Price_12	0,218696	0,130041	1,682	0,0956	*
HICP_1	2,00117	0,646091	3,097	0,0025	***
HICP_2	-1,20079	0,776305	-1,547	0,1249	
HICP_3	-0,224647	0,782640	-0,2870	0,7746	
HICP_4	0,505682	0,775209	0,6523	0,5156	
HICP_5	-0,214696	0,781086	-0,2749	0,7840	
HICP_6	-0,954603	0,789006	-1,210	0,2290	
HICP_7	1,98998	0,779106	2,554	0,0121	**
HICP_8	-0,720128	0,816479	-0,8820	0,3798	
HICP_9	-0,569599	0,799987	-0,7120	0,4780	
HICP_10	0,292868	0,788955	0,3712	0,7112	
HICP_11	0,202377	0,793233	0,2551	0,7991	
HICP_12	-0,106855	0,532870	-0,2005	0,8415	
time	0,331385	0,143123	2,315	0,0225	**
Mean dependent var	1285,954	S.D. dependent var	206,1489		
Sum squared resid	237018,3	S.E. of regression	47,28659		
R-squared	0,957426	Adjusted R-squared	0,947384		
F(25, 106)	95,35036	P-value(F)	2,36e-61		
rho	0,014862	Durbin-Watson	1,966097		

Forecast evaluation statistics using 12 observations

Mean Error	-24,279
Root Mean Squared Error	60,441
Mean Absolute Error	55,172
Mean Percentage Error	-1,7958
Mean Absolute Percentage Error	3,8784
Theil's U2	2,9835
Bias proportion, UM	0,16136
Regression proportion, UR	0,66391
Disturbance proportion, UD	0,17473

VAR system, lag order 11
 OLS estimates, observations 2013:12-2024:12 (T = 133)
 Log-likelihood = -759,64746
 Determinant of covariance matrix = 313,41117
 AIC = 12,1451
 BIC = 13,1882
 HQC = 12,5690
 Portmanteau test: LB(33) = 123,266, df = 88 [0,0078]

Equation 1: Petrol_Price

	coefficient	std. error	t-ratio	p-value
const	36,2686	42,4838	0,8537	0,3951
Petrol_Price_1	1,26471	0,0968044	13,06	4,82e-024 ***
Petrol_Price_2	-0,542284	0,155594	-3,485	0,0007 ***
Petrol_Price_3	0,395140	0,163262	2,420	0,0172 **
Petrol_Price_4	-0,287823	0,169861	-1,694	0,0930 *
Petrol_Price_5	0,200720	0,170883	1,175	0,2427
Petrol_Price_6	-0,200958	0,170963	-1,175	0,2424
Petrol_Price_7	0,159861	0,170137	0,9396	0,3495
Petrol_Price_8	-0,00265154	0,167857	-0,01580	0,9874
Petrol_Price_9	-0,146011	0,162532	-0,8984	0,3710
Petrol_Price_10	0,209137	0,152208	1,374	0,1723
Petrol_Price_11	-0,136668	0,0929648	-1,470	0,1444
Unemployment_1	-18,5518	9,90977	-1,872	0,0639 *
Unemployment_2	2,84680	14,6162	0,1948	0,8459
Unemployment_3	25,7690	14,8989	1,730	0,0865 *
Unemployment_4	-13,9536	15,0104	-0,9296	0,3546
Unemployment_5	7,19824	14,7153	0,4892	0,6257
Unemployment_6	-0,878751	14,4358	-0,06087	0,9516
Unemployment_7	14,2184	14,5820	0,9751	0,3317
Unemployment_8	-13,9221	14,8705	-0,9362	0,3512
Unemployment_9	-21,7119	14,9139	-1,456	0,1483
Unemployment_10	15,3950	14,9032	1,033	0,3039
Unemployment_11	8,28332	10,2735	0,8063	0,4218
time	0,480043	0,205620	2,335	0,0214 **
Mean dependent var	1286,288	S.D. dependent var	205,4027	
Sum squared resid	245696,8	S.E. of regression	47,47735	
R-squared	0,955882	Adjusted R-squared	0,946573	
F(23, 109)	102,6810	P-value(F)	3,45e-63	
rho	-0,004138	Durbin-Watson	2,002033	

VAR system, lag order 5
 OLS estimates, observations 2013:06-2024:12 (T = 139)
 Log-likelihood = -1457,1946
 Determinant of covariance matrix = 4373503,6
 AIC = 21,3122
 BIC = 21,8188
 HQC = 21,5181
 Portmanteau test: LB(34) = 202,362, df = 116 [0,0000]

Equation 1: Petrol_Price

	coefficient	std. error	t-ratio	p-value
const	-65,8098	90,2445	-0,7292	0,4672
Petrol_Price_1	1,33181	0,0881563	15,11	3,78e-030 ***
Petrol_Price_2	-0,594282	0,143503	-4,141	6,25e-05 ***
Petrol_Price_3	0,357000	0,143044	2,496	0,0139 **
Petrol_Price_4	-0,242071	0,139650	-1,733	0,0855 *
Petrol_Price_5	0,108492	0,0834844	1,300	0,1961
El_LT_1	-0,138482	0,0805313	-1,720	0,0879 *
El_LT_2	0,156453	0,0897546	1,743	0,0837 **
El_LT_3	0,194867	0,0920864	2,116	0,0363 **
El_LT_4	-0,203578	0,0890344	-2,287	0,0239 **
El_LT_5	0,105896	0,0850241	1,245	0,2152
time	0,173485	0,113471	1,529	0,1288
Mean dependent var	1289,979	S.D. dependent var	201,7475	
Sum squared resid	266495,4	S.E. of regression	45,80817	
R-squared	0,952555	Adjusted R-squared	0,948445	
F(11, 127)	231,7965	P-value(F)	2,09e-78	
rho	-0,006601	Durbin-Watson	2,006163	

Forecast evaluation statistics using 12 observations

Mean Error	-98,796
Root Mean Squared Error	132,5
Mean Absolute Error	115,17
Mean Percentage Error	-7,0805
Mean Absolute Percentage Error	8,1793
Theil's U2	7,1891
Bias proportion, UM	0,55596
Regression proportion, UR	0,4151
Disturbance proportion, UD	0,02894

Forecast evaluation statistics using 12 observations

Mean Error	-86,924
Root Mean Squared Error	124,72
Mean Absolute Error	114,03
Mean Percentage Error	-6,2591
Mean Absolute Percentage Error	8,0794
Theil's U2	6,7024
Bias proportion, UM	0,48576
Regression proportion, UR	0,50638
Disturbance proportion, UD	0,0078624

– Dyzelino kainų

VAR system, lag order 3
 OLS estimates, observations 2013:04-2024:12 (T = 141)
 Log-likelihood = -836,80626
 Determinant of covariance matrix = 489,72217
 AIC = 12,0965
 BIC = 12,4312
 HQC = 12,2325
 Portmanteau test: LB(35) = 166,009, df = 128 [0,0134]

Equation 1: Diesel_Price

	coefficient	std. error	t-ratio	p-value
const	294,966	268,359	1,099	0,2737
Diesel_Price_1	0,981755	0,187366	5,240	6,14e-07 ***
Diesel_Price_2	-0,307963	0,278045	-1,108	0,2700
Diesel_Price_3	0,206321	0,185638	1,111	0,2684
Diesel_Tax_Prcv_1	-19,9997	9,27176	-2,157	0,0328 **
Diesel_Tax_Prcv_2	16,3527	14,5386	1,125	0,2627
Diesel_Tax_Prcv_3	-0,0474302	9,26396	-0,005120	0,9959
time	0,367367	0,214291	1,714	0,0888 *

Mean dependent var 1231,685 S.D. dependent var 244,3111
 Sum squared resid 337768,4 S.E. of regression 50,39456
 R-squared 0,959579 Adjusted R-squared 0,957452
 F(7, 133) 451,0552 P-value(F) 2,20e-89
 rho 0,044331 Durbin-Watson 1,904280

Forecast evaluation statistics using 12 observations

Mean Error 15,426
 Root Mean Squared Error 71,383
 Mean Absolute Error 50,471
 Mean Percentage Error 0,85531
 Mean Absolute Percentage Error 3,273
 Theil's U2 1,2958
 Bias proportion, UM 0,046701
 Regression proportion, UR 0,3765
 Disturbance proportion, UD 0,5768

VAR system, lag order 5
 OLS estimates, observations 2013:06-2024:12 (T = 139)
 Log-likelihood = -1121,9062
 Determinant of covariance matrix = 35128,958
 AIC = 16,4879
 BIC = 16,9945
 HQC = 16,6938
 Portmanteau test: LB(34) = 136,741, df = 116 [0,0916]

Equation 1: Diesel_Price

	coefficient	std. error	t-ratio	p-value
const	-64,3291	150,930	-0,4262	0,6707
Diesel_Price_1	1,36864	0,0883111	15,50	4,58e-031 ***
Diesel_Price_2	-0,660805	0,149228	-4,428	2,03e-05 ***
Diesel_Price_3	0,464182	0,155056	2,994	0,0033 ***
Diesel_Price_4	-0,208329	0,147872	-1,409	0,1613
Diesel_Price_5	-0,0174318	0,0866086	-0,2013	0,8408
Diesel_Excises_1	0,917041	1,06945	0,8575	0,3928
Diesel_Excises_2	-2,58900	1,45613	-1,778	0,0778 *
Diesel_Excises_3	0,348962	1,47295	0,2369	0,8131
Diesel_Excises_4	0,0234740	1,47213	0,01595	0,9873
Diesel_Excises_5	1,66514	1,10047	1,513	0,1327
time	0,0635060	0,281188	0,2258	0,8217

Forecast evaluation statistics using 12 observations

Mean Error -88,71
 Root Mean Squared Error 144,07
 Mean Absolute Error 138,27
 Mean Percentage Error -6,138
 Mean Absolute Percentage Error 9,2295
 Theil's U2 3,3629
 Bias proportion, UM 0,37914
 Regression proportion, UR 0,50447
 Disturbance proportion, UD 0,11639

VAR system, lag order 3
 OLS estimates, observations 2013:04-2024:12 (T = 141)
 Log-likelihood = -1148,6927
 Determinant of covariance matrix = 40853,986
 AIC = 16,5205
 BIC = 16,8551
 HQC = 16,6564
 Portmanteau test: LB(35) = 128,18, df = 128 [0,4789]

Equation 1: Diesel_Price

	coefficient	std. error	t-ratio	p-value
const	60,9203	23,7994	2,560	0,0116 **
Diesel_Price_1	0,995058	0,112901	8,814	5,83e-015 ***
Diesel_Price_2	-0,164983	0,162283	-1,017	0,3112
Diesel_Price_3	0,0224017	0,101298	0,2211	0,8253
Brent_Oil_1	4,05833	0,890977	4,555	1,17e-05 ***
Brent_Oil_2	-4,13136	1,30055	-3,177	0,0019 ***
Brent_Oil_3	1,28212	0,928223	1,381	0,1695
time	0,472209	0,160317	2,945	0,0038 ***

Mean dependent var 1231,685 S.D. dependent var 244,3111
 Sum squared resid 293453,3 S.E. of regression 46,97250
 R-squared 0,964082 Adjusted R-squared 0,963034
 F(7, 133) 522,0394 P-value(F) 2,01e-93
 rho 0,005149 Durbin-Watson 1,979634

Forecast evaluation statistics using 12 observations

Mean Error 25,873
 Root Mean Squared Error 76,169
 Mean Absolute Error 51,246
 Mean Percentage Error 1,5456
 Mean Absolute Percentage Error 3,3005
 Theil's U2 1,3544
 Bias proportion, UM 0,11538
 Regression proportion, UR 0,39242
 Disturbance proportion, UD 0,4922

Equation 1: Diesel_Price

	coefficient	std. error	t-ratio	p-value
const	48,6029	39,4219	1,233	0,2198
Diesel_Price_1	1,35254	0,0867136	15,60	7,87e-032 ***
Diesel_Price_2	-0,541548	0,139375	-3,886	0,0002 ***
Diesel_Price_3	0,145383	0,0854602	1,701	0,0912 *
LT_Oil_1	-0,0734644	0,0331924	-2,213	0,0286 **
LT_Oil_2	0,0642290	0,0358961	1,789	0,0758 *
LT_Oil_3	-0,00323359	0,0340665	-0,09492	0,9245
time	0,199307	0,120140	1,659	0,0995 *

Mean dependent var 1231,685 S.D. dependent var 244,3111
 Sum squared resid 336967,5 S.E. of regression 50,33478
 R-squared 0,959675 Adjusted R-squared 0,957553
 F(7, 133) 452,1724 P-value(F) 1,95e-89
 rho 0,027194 Durbin-Watson 1,934199

Forecast evaluation statistics using 12 observations

Mean Error 22,833
 Root Mean Squared Error 73,727
 Mean Absolute Error 50,469
 Mean Percentage Error 1,3467
 Mean Absolute Percentage Error 3,2569
 Theil's U2 1,3207
 Bias proportion, UM 0,095911
 Regression proportion, UR 0,36609
 Disturbance proportion, UD 0,538

VAR system, lag order 5
 OLS estimates, observations 2013:06-2024:12 (T = 139)
 Log-likelihood = -1211,8103
 Determinant of covariance matrix = 128074,25
 AIC = 17,7814
 BIC = 18,2881
 HQC = 17,9873
 Portmanteau test: LB(34) = 157,421, df = 116 [0,0063]

Equation 1: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	62,3445	29,1444	2,139	0,0343	**
Diesel_Price_1	1,29047	0,108368	11,91	2,03e-022	***
Diesel_Price_2	-0,658325	0,168458	-3,908	0,0002	***
Diesel_Price_3	0,653821	0,173237	3,774	0,0002	***
Diesel_Price_4	-0,448979	0,170965	-2,626	0,0097	***
Diesel_Price_5	0,0986050	0,111099	0,8875	0,3765	
HICP_1	0,980860	0,535208	1,833	0,0692	*
HICP_2	-0,230558	0,741726	-0,3108	0,7564	
HICP_3	-1,97441	0,743333	-2,656	0,0089	***
HICP_4	1,77533	0,756356	2,347	0,0205	**
HICP_5	-0,296939	0,519973	-0,5711	0,5690	
time	0,211969	0,121514	1,744	0,0835	*
Mean dependent var	1230,485	S.D. dependent var	245,8491		
Sum squared resid	302866,3	S.E. of regression	48,83415		
R-squared	0,963689	Adjusted R-squared	0,960544		
F(11, 127)	306,4173	P-value(F)	9,27e-86		
rho	0,003589	Durbin-Watson	1,981227		

VAR system, lag order 4
 OLS estimates, observations 2013:05-2024:12 (T = 140)
 Log-likelihood = -1149,4337
 Determinant of covariance matrix = 46384,782
 AIC = 16,7062
 BIC = 17,1264
 HQC = 16,8770
 Portmanteau test: LB(35) = 190,891, df = 124 [0,0001]

Equation 1: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	-69,5227	47,5183	-1,463	0,1459	
Diesel_Price_1	1,36528	0,0904890	15,09	2,36e-030	***
Diesel_Price_2	-0,705962	0,143934	-4,905	2,74e-06	***
Diesel_Price_3	0,393463	0,143089	2,750	0,0068	***
Diesel_Price_4	-0,149208	0,0847371	-1,761	0,0806	*
Prod_Manufact_1	-1,57400	0,831442	-1,893	0,0606	*
Prod_Manufact_2	2,48738	0,892467	2,787	0,0061	***
Prod_Manufact_3	1,84725	0,906411	2,038	0,0436	**
Prod_Manufact_4	0,148960	0,857787	0,1737	0,8624	
time	-0,711015	0,351650	-2,022	0,0452	**
Mean dependent var	1230,911	S.D. dependent var	245,0149		
Sum squared resid	287602,0	S.E. of regression	47,03534		
R-squared	0,965534	Adjusted R-squared	0,963148		
F(9, 130)	404,6469	P-value(F)	1,62e-90		
rho	0,015832	Durbin-Watson	1,959368		

Forecast evaluation statistics using 12 observations

Mean Error	34,347
Root Mean Squared Error	70,131
Mean Absolute Error	49,997
Mean Percentage Error	2,1272
Mean Absolute Percentage Error	3,2204
Theil's U2	1,2856
Bias proportion, UM	0,23986
Regression proportion, UR	0,11456
Disturbance proportion, UD	0,64558

Forecast evaluation statistics using 12 observations

Mean Error	38,657
Root Mean Squared Error	65,949
Mean Absolute Error	48,404
Mean Percentage Error	2,4337
Mean Absolute Percentage Error	3,1188
Theil's U2	1,2369
Bias proportion, UM	0,34358
Regression proportion, UR	0,14288
Disturbance proportion, UD	0,51353

VAR system, lag order 5
 OLS estimates, observations 2013:06-2024:12 (T = 139)
 Log-likelihood = -2634,6493
 Determinant of covariance matrix = 9,9668327e+013
 AIC = 38,2539
 BIC = 38,7606
 HQC = 38,4598
 Portmanteau test: LB(34) = 161,609, df = 116 [0,0033]

Equation 1: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	49,4596	23,3177	2,121	0,0359	*
Diesel_Price_1	1,40916	0,0954829	14,76	2,53e-029	*
Diesel_Price_2	-0,730645	0,155999	-4,684	7,13e-06	*
Diesel_Price_3	0,398049	0,160385	2,482	0,0144	*
Diesel_Price_4	-0,138286	0,152915	-0,9043	0,3675	
Diesel_Price_5	-0,0314768	0,0922038	-0,3414	0,7334	
Import_1	-5,79446e-06	2,02206e-05	-0,2866	0,7749	
Import_2	1,24491e-05	2,35041e-05	0,5297	0,5973	
Import_3	4,20670e-05	2,35170e-05	1,789	0,0760	*
Import_4	-4,11366e-05	2,38697e-05	-1,723	0,0873	*
Import_5	1,74400e-05	2,06788e-05	0,8434	0,4006	
time	-0,0438305	0,254666	-0,1721	0,8636	
Mean dependent var	1230,485	S.D. dependent var	245,8491		
Sum squared resid	317610,3	S.E. of regression	50,00869		
R-squared	0,961922	Adjusted R-squared	0,958623		
F(11, 127)	291,6569	P-value(F)	1,88e-84		
rho	0,002434	Durbin-Watson	1,983255		

Forecast evaluation statistics using 12 observations

Mean Error	50,233
Root Mean Squared Error	76,602
Mean Absolute Error	57,515
Mean Percentage Error	3,1907
Mean Absolute Percentage Error	3,7058
Theil's U2	1,4768
Bias proportion, UM	0,43002
Regression proportion, UR	0,0073724
Disturbance proportion, UD	0,5626

5 priedas. ARDL benzino kainų modelių išsklotinės

– Su Brent naftos kainų kintamuoju

Test on Model 100:

Null hypothesis: the regression parameters are zero for the variables
 D1_Covid, Brent_Oil_1, Brent_Oil_3, Petrol_Price_2, Petrol_Price_3
 Test statistic: $F(5, 130) = 1,73987$, p-value 0,129957
 Omitting variables improved 3 of 3 information criteria.

Model 101: OLS, using observations 2013:04-2024:12 (T = 141)
 Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value
const	104,836	24,8257	4,223	4,41e-05 ***
time	0,261742	0,103718	2,524	0,0128 **
D2_UKR	87,4045	16,1166	5,423	2,62e-07 ***
Brent_Oil	3,42381	0,290752	11,78	1,84e-022 ***
Brent_Oil_2	-2,42019	0,366132	-6,610	8,18e-010 ***
Petrol_Price_1	0,846813	0,0353396	23,96	1,79e-050 ***
Mean dependent var	1291,330	S.D. dependent var	200,6339	
Sum squared resid	129042,2	S.E. of regression	30,91712	
R-squared	0,977102	Adjusted R-squared	0,976254	
F(5, 135)	1152,149	P-value(F)	8,0e-109	
Log-likelihood	-680,8194	Akaike criterion	1373,639	
Schwarz criterion	1391,331	Hannan-Quinn	1380,828	
rho	0,062406	Durbin's h	0,816387	

Forecast evaluation statistics using 12 observations

Mean Error	40,988
Root Mean Squared Error	47,21
Mean Absolute Error	40,988
Mean Percentage Error	2,8476
Mean Absolute Percentage Error	2,8476
Theil's U2	2,2237
Bias proportion, UM	0,7538
Regression proportion, UR	0,022211
Disturbance proportion, UD	0,22399

– Su Lietuvos naftos išteklių kintamuoju

Test on Model 98:

Null hypothesis: the regression parameters are zero for the variables
 LT_Oil_1, LT_Oil_2, LT_Oil_3, Petrol_Price_3
 Test statistic: $F(4, 130) = 1,77363$, p-value 0,137995
 Omitting variables improved 3 of 3 information criteria.

Model 99: OLS, using observations 2013:04-2024:12 (T = 141)
 Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value
const	200,350	36,4513	5,496	1,89e-07 ***
time	0,296612	0,108205	2,741	0,0070 ***
D1_Covid	-37,1080	14,9787	-2,477	0,0145 **
D2_UKR	116,668	21,5734	5,408	2,84e-07 ***
LT_Oil	-0,0849099	0,0280672	-3,025	0,0030 ***
Petrol_Price_1	1,13201	0,0726059	15,59	6,70e-032 ***
Petrol_Price_2	-0,256706	0,0707035	-3,631	0,0004 ***
Mean dependent var	1291,330	S.D. dependent var	200,6339	
Sum squared resid	229682,7	S.E. of regression	41,40108	
R-squared	0,959244	Adjusted R-squared	0,957419	
F(6, 134)	525,6435	P-value(F)	1,65e-90	
Log-likelihood	-721,4668	Akaike criterion	1456,934	
Schwarz criterion	1477,575	Hannan-Quinn	1465,321	
rho	0,033765	Durbin's h	0,791334	

Forecast evaluation statistics using 12 observations

Mean Error	6,3723
Root Mean Squared Error	44,758
Mean Absolute Error	35,602
Mean Percentage Error	0,37524
Mean Absolute Percentage Error	2,4609
Theil's U2	1,8991
Bias proportion, UM	0,02027
Regression proportion, UR	0,54468
Disturbance proportion, UD	0,43506

– Su Lietuvos Harmonizuotu vartotojų kainų indekso skystojo kuro rinkoje kintamuoju

Test on Model 102:

Null hypothesis: the regression parameters are zero for the variables
D1_Covid, HICP_2, HICP_3, HICP_4, HICP_5, HICP_8, HICP_10, HICP_11,
Petrol_Price_3, Petrol_Price_4, Petrol_Price_5, Petrol_Price_6,
Petrol_Price_7, Petrol_Price_8, Petrol_Price_10, Petrol_Price_11
Test statistic: $F(16, 103) = 0,43617$, p-value 0,969155
Omitting variables improved 3 of 3 information criteria.

Model 103: OLS, using observations 2014:01-2024:12 (T = 132)
Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value
const	131,262	30,6488	4,283	3,76e-05 ***
time	0,298983	0,0953555	3,135	0,0022 ***
D2_UKR	90,8264	18,1915	4,993	2,06e-06 ***
HICP	2,63169	0,304150	8,653	2,84e-014 ***
HICP_1	-0,816077	0,357795	-2,281	0,0243 **
HICP_6	-1,30671	0,299679	-4,360	2,78e-05 ***
HICP_7	1,41764	0,337554	4,200	5,19e-05 ***
HICP_9	-0,638294	0,241831	-2,639	0,0094 ***
HICP_12	0,367819	0,175016	2,102	0,0377 **
Petrol_Price_1	0,810787	0,0750321	10,81	2,21e-019 ***
Petrol_Price_2	-0,210856	0,0579793	-3,637	0,0004 ***
Petrol_Price_9	0,103473	0,0383489	2,698	0,0080 ***
Petrol_Price_12	0,165362	0,0500896	3,301	0,0013 ***

Mean dependent var	1285,954	S.D. dependent var	206,1489
Sum squared resid	120258,0	S.E. of regression	31,78948
R-squared	0,978399	Adjusted R-squared	0,976220
F(12, 119)	449,1600	P-value(F)	5,68e-93
Log-likelihood	-637,0630	Akaike criterion	1300,126
Schwarz criterion	1337,602	Hannan-Quinn	1315,355
rho	0,047966	Durbin's h	1,087341

Forecast evaluation statistics using 12 observations

Mean Error	7,3526
Root Mean Squared Error	33,912
Mean Absolute Error	24,034
Mean Percentage Error	0,46542
Mean Absolute Percentage Error	1,6613
Theil's U2	1,2584
Bias proportion, UM	0,04701
Regression proportion, UR	0,0031929
Disturbance proportion, UD	0,9498

– Su Lietuvos nedarbo lygio kintamuoju

Test on Model 104:

Null hypothesis: the regression parameters are zero for the variables
Unemployment, Unemployment_1, Unemployment_2, Unemployment_4,
Unemployment_5, Unemployment_6, Unemployment_7, Unemployment_8,
Unemployment_9, Unemployment_10, Unemployment_11, Petrol_Price_3,
Petrol_Price_4, Petrol_Price_5, Petrol_Price_6, Petrol_Price_7,
Petrol_Price_8, Petrol_Price_9, Petrol_Price_10, Petrol_Price_11
Test statistic: $F(20, 106) = 1,22816$, p-value 0,246542
Omitting variables improved 3 of 3 information criteria.

Model 105: OLS, using observations 2013:12-2024:12 (T = 133)
Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value
const	73,6007	34,9099	2,108	0,0370 **
time	0,725339	0,167240	4,337	2,93e-05 ***
D1_Covid	-45,2775	15,3042	-2,958	0,0037 ***
D2_UKR	146,220	20,6019	7,097	8,19e-011 ***
Unemployment_3	9,96181	2,99141	3,330	0,0011 ***
Petrol_Price_1	1,05925	0,0740804	14,30	3,74e-028 ***
Petrol_Price_2	-0,220478	0,0704537	-3,129	0,0022 ***

Mean dependent var	1286,288	S.D. dependent var	205,4027
Sum squared resid	212922,3	S.E. of regression	41,10790
R-squared	0,961767	Adjusted R-squared	0,959947
F(6, 126)	528,2684	P-value(F)	9,51e-87
Log-likelihood	-679,3780	Akaike criterion	1372,756
Schwarz criterion	1392,988	Hannan-Quinn	1380,978
rho	0,035196	Durbin's h	0,781003

Forecast evaluation statistics using 12 observations

Mean Error	-80,957
Root Mean Squared Error	115,12
Mean Absolute Error	104,61
Mean Percentage Error	-5,8228
Mean Absolute Percentage Error	7,4097
Theil's U2	6,17
Bias proportion, UM	0,49457
Regression proportion, UR	0,48158
Disturbance proportion, UD	0,023852

– Su Lietuvos elektros energijos pasiūlos Lietuvos rinkoje kintamuoju

Test on Model 110:

Null hypothesis: the regression parameters are zero for the variables
time, D1_Covid, El_LT, El_LT_1, El_LT_2, El_LT_3, El_LT_4, El_LT_5,
Petrol_Price_4, Petrol_Price_5
Test statistic: F(10, 124) = 1,89452, p-value 0,0518767
Omitting variables improved 3 of 3 information criteria.

Model 111: OLS, using observations 2013:06-2024:12 (T = 139)
Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value	
const	92,1386	24,8742	3,704	0,0003	***
D2_UKR	139,007	21,1080	6,586	9,45e-010	***
Petrol_Price_1	1,19776	0,0770866	15,54	9,01e-032	***
Petrol_Price_2	-0,451791	0,118631	-3,808	0,0002	***
Petrol_Price_3	0,178890	0,0740736	2,415	0,0171	**
Mean dependent var	1289,979	S.D. dependent var	201,7475		
Sum squared resid	241375,0	S.E. of regression	42,44180		
R-squared	0,957027	Adjusted R-squared	0,955744		
F(4, 134)	746,0573	P-value(F)	1,73e-90		
Log-likelihood	-715,6770	Akaike criterion	1441,354		
Schwarz criterion	1456,026	Hannan-Quinn	1447,316		
rho	0,026636	Durbin's h	0,752808		

Forecast evaluation statistics using 12 observations

Mean Error	98,682
Root Mean Squared Error	100,49
Mean Absolute Error	98,682
Mean Percentage Error	6,9189
Mean Absolute Percentage Error	6,9189
Theil's U2	5,1538
Bias proportion, UM	0,96441
Regression proportion, UR	2,4773e-008
Disturbance proportion, UD	0,035589

– Su Lietuvos Harmonizuotu vartotojų kainų indekso skystojo kuro rinkoje ir Brent naftos kainų kintamaisiais

Test on Model 35:

Null hypothesis: the regression parameters are zero for the variables
HICP_1, HICP_2, HICP_3, HICP_4, HICP_5, HICP_8, HICP_10, HICP_11,
D1_Covid, Brent_Oil_1, Brent_Oil_3, Brent_Oil_4, Brent_Oil_5,
Brent_Oil_7, Brent_Oil_8, Brent_Oil_9, Brent_Oil_10, Brent_Oil_11,
Petrol_Price_2, Petrol_Price_3, Petrol_Price_4, Petrol_Price_5,
Petrol_Price_6, Petrol_Price_7, Petrol_Price_8, Petrol_Price_10,
Petrol_Price_11, Petrol_Price_12
Test statistic: F(28, 90) = 0,432367, p-value 0,993156
Omitting variables improved 3 of 3 information criteria.

Model 36: OLS, using observations 2014:01-2024:12 (T = 132)
Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value	
const	148,136	32,6211	4,541	1,36e-05	***
time	0,378367	0,118630	3,189	0,0018	***
D2_UKR	58,9386	14,8908	3,958	0,0001	***
HICP	1,19527	0,193501	6,177	9,58e-09	***
HICP_6	-0,944411	0,245951	-3,840	0,0002	***
HICP_7	1,34367	0,260670	5,155	1,03e-06	***
HICP_9	-0,935310	0,192302	-4,864	3,59e-06	***
HICP_12	0,438806	0,127395	3,444	0,0008	***
Brent_Oil	3,03014	0,261638	11,58	3,50e-021	***
Brent_Oil_2	-1,78410	0,340086	-5,246	6,93e-07	***
Brent_Oil_6	-0,894579	0,262343	-3,410	0,0009	***
Brent_Oil_12	0,833168	0,238610	3,492	0,0007	***
Petrol_Price_1	0,667181	0,0419046	15,92	3,63e-031	***
Petrol_Price_9	0,123371	0,0297555	4,146	6,40e-05	***
Mean dependent var	1285,954	S.D. dependent var	206,1489		
Sum squared resid	71761,15	S.E. of regression	24,66060		
R-squared	0,987110	Adjusted R-squared	0,985690		
F(13, 118)	695,1012	P-value(F)	7,6e-105		
Log-likelihood	-602,9875	Akaike criterion	1233,975		
Schwarz criterion	1274,334	Hannan-Quinn	1250,375		
rho	0,004857	Durbin's h	0,063667		

Forecast evaluation statistics using 12 observations

Mean Error	24,579
Root Mean Squared Error	36,799
Mean Absolute Error	30,768
Mean Percentage Error	1,6874
Mean Absolute Percentage Error	2,1311
Theil's U2	1,5225
Bias proportion, UM	0,44612
Regression proportion, UR	0,015898
Disturbance proportion, UD	0,53798

– Su Lietuvos Harmonizuotu vartotojų kainų indekso skystojo kuro rinkoje ir Lietuvos naftos išteklių kintamaisiais

Test on Model 42:

Null hypothesis: the regression parameters are zero for the variables
HICP_1, HICP_2, HICP_3, HICP_4, HICP_5, HICP_8, HICP_9, HICP_10,
HICP_11, HICP_12, LT_Oil_1, LT_Oil_2, LT_Oil_3, LT_Oil_4, LT_Oil_5,
LT_Oil_6, LT_Oil_7, LT_Oil_8, LT_Oil_9, LT_Oil_10, LT_Oil_11,
Petrol_Price_3, Petrol_Price_4, Petrol_Price_5, Petrol_Price_6,
Petrol_Price_7, Petrol_Price_8, Petrol_Price_9, Petrol_Price_11
Test statistic: $F(29, 90) = 0,620762$, p-value 0,926966
Omitting variables improved 3 of 3 information criteria.

Model 43: OLS, using observations 2014:01-2024:12 (T = 132)
Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value	
const	167,196	36,6534	4,562	1,24e-05	***
time	0,458525	0,101044	4,538	1,37e-05	***
D2_UKR	93,3454	18,1730	5,137	1,11e-06	***
D1_Covid	-23,8938	12,0014	-1,991	0,0488	**
HICP	2,17936	0,240503	9,062	3,11e-015	***
HICP_6	-1,18248	0,288597	-4,097	7,66e-05	***
HICP_7	0,920855	0,277312	3,321	0,0012	***
LT_Oil	-0,0658090	0,0226492	-2,906	0,0044	***
LT_Oil_12	0,0635610	0,0206689	3,075	0,0026	***
Petrol_Price_1	0,780537	0,0678932	11,50	4,97e-021	***
Petrol_Price_2	-0,264131	0,0583731	-4,525	1,44e-05	***
Petrol_Price_10	0,0845920	0,0392626	2,155	0,0332	**
Petrol_Price_12	0,231937	0,0426904	5,433	2,98e-07	***
Mean dependent var	1285,954	S.D. dependent var	206,1489		
Sum squared resid	115282,6	S.E. of regression	31,12494		
R-squared	0,979292	Adjusted R-squared	0,977204		
F(12, 119)	468,9725	P-value(F)	4,62e-94		
Log-likelihood	-634,2743	Akaike criterion	1294,549		
Schwarz criterion	1332,025	Hannan-Quinn	1309,777		
rho	0,081971	Durbin's h	1,505066		

Forecast evaluation statistics using 12 observations	
Mean Error	-9,8579
Root Mean Squared Error	37,127
Mean Absolute Error	29,847
Mean Percentage Error	-0,74258
Mean Absolute Percentage Error	2,0843
Theil's U2	1,6109
Bias proportion, UM	0,070501
Regression proportion, UR	0,095401
Disturbance proportion, UD	0,8341

– Su Lietuvos Harmonizuotu vartotojų kainų indekso skystojo kuro rinkoje ir Lietuvos nedarbo lygio kintamaisiais

Test on Model 44:

Null hypothesis: the regression parameters are zero for the variables
HICP_2, HICP_3, HICP_4, HICP_5, HICP_8, HICP_9, HICP_10, HICP_11,
Unemployment, Unemployment_1, Unemployment_2, Unemployment_4,
Unemployment_5, Unemployment_6, Unemployment_8, Unemployment_10,
Unemployment_11, Unemployment_12, Petrol_Price_2, Petrol_Price_3,
Petrol_Price_4, Petrol_Price_5, Petrol_Price_6, Petrol_Price_7,
Petrol_Price_8, Petrol_Price_9, Petrol_Price_10, Petrol_Price_11
Test statistic: $F(28, 90) = 0,631097$, p-value 0,916363
Omitting variables improved 3 of 3 information criteria.

Model 45: OLS, using observations 2014:01-2024:12 (T = 132)
Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value	
const	172,162	29,7006	5,797	5,76e-08	***
time	0,982616	0,199387	4,928	2,74e-06	***
D2_UKR	81,4497	17,0136	4,787	4,95e-06	***
D1_Covid	-56,2086	12,8697	-4,368	2,71e-05	***
HICP	2,60199	0,279457	9,311	8,57e-016	***
HICP_1	-0,768424	0,332072	-2,314	0,0224	**
HICP_6	-1,21793	0,276149	-4,410	2,29e-05	***
HICP_7	1,05127	0,271450	3,873	0,0002	***
HICP_12	0,521729	0,169067	3,086	0,0025	***
Unemployment_3	17,7542	3,40112	5,220	7,77e-07	***
Unemployment_7	13,7905	4,14546	3,327	0,0012	***
Unemployment_9	-16,4565	3,58328	-4,593	1,10e-05	***
Petrol_Price_1	0,592633	0,0483348	12,26	8,66e-023	***
Petrol_Price_12	0,114650	0,0475506	2,411	0,0174	**
Mean dependent var	1285,954	S.D. dependent var	206,1489		
Sum squared resid	102926,0	S.E. of regression	29,53396		
R-squared	0,981512	Adjusted R-squared	0,979475		
F(13, 118)	481,8837	P-value(F)	1,29e-95		
Log-likelihood	-626,7915	Akaike criterion	1281,583		
Schwarz criterion	1321,942	Hannan-Quinn	1297,983		
rho	0,078468	Durbin's h	1,084040		

Forecast evaluation statistics using 12 observations	
Mean Error	-19,44
Root Mean Squared Error	56,67
Mean Absolute Error	49,12
Mean Percentage Error	-1,4513
Mean Absolute Percentage Error	3,4459
Theil's U2	2,6977
Bias proportion, UM	0,11768
Regression proportion, UR	0,64269
Disturbance proportion, UD	0,23963

- Su Lietuvos harmonizuotu vartotojų kainų indekso skystojo kuro rinkoje, Lietuvos naftos išteklių ir Brent naftos kainų kintamaisiais

Test on Model 48:

Null hypothesis: the regression parameters are zero for the variables
HICP_1, HICP_2, HICP_3, HICP_4, HICP_5, HICP_8, HICP_10, HICP_11,
LT_Oil_1, LT_Oil_2, LT_Oil_3, LT_Oil_4, LT_Oil_5, LT_Oil_6, LT_Oil_7,
LT_Oil_8, LT_Oil_9, LT_Oil_10, LT_Oil_11, LT_Oil_12, Brent_Oil_1,
Brent_Oil_3, Brent_Oil_4, Brent_Oil_5, Brent_Oil_7, Brent_Oil_8,
Brent_Oil_9, Brent_Oil_10, Brent_Oil_11, Petrol_Price_2, Petrol_Price
Petrol_Price_4, Petrol_Price_5, Petrol_Price_6, Petrol_Price_7,
Petrol_Price_8, Petrol_Price_10, Petrol_Price_11, Petrol_Price_12
Test statistic: F(39, 77) = 0,474961, p-value 0,99395
Omitting variables improved 3 of 3 information criteria.

Model 49: OLS, using observations 2014:01-2024:12 (T = 132)
Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value
const	195,877	37,8141	5,180	9,46e-07 ***
time	0,458264	0,123988	3,696	0,0003 ***
D2_UKR	61,4961	14,7044	4,182	5,63e-05 ***
D1_Covid	-18,4774	9,22791	-2,002	0,0476 **
HICP	1,11927	0,193233	5,792	6,06e-08 ***
HICP_6	-0,886235	0,244920	-3,618	0,0004 ***
HICP_7	1,30518	0,257218	5,074	1,49e-06 ***
HICP_9	-0,908358	0,189642	-4,790	4,98e-06 ***
HICP_12	0,441141	0,125556	3,514	0,0006 ***
LT_Oil_1	-0,0348475	0,0171980	-2,026	0,0450 **
Brent_Oil	2,91947	0,262159	11,14	4,94e-020 ***
Brent_Oil_2	-1,69940	0,338513	-5,020	1,88e-06 ***
Brent_Oil_6	-0,897373	0,258258	-3,475	0,0007 ***
Brent_Oil_12	0,801914	0,239069	3,354	0,0011 ***
Petrol_Price_1	0,658973	0,0414570	15,90	6,66e-031 ***
Petrol_Price_9	0,114032	0,0297011	3,839	0,0002 ***

Mean dependent var 1285,954 S.D. dependent var 206,1489
Sum squared resid 68311,40 S.E. of regression 24,26708
R-squared 0,987730 Adjusted R-squared 0,986143
F(15, 116) 622,5079 P-value(F) 3,1e-103
Log-likelihood -599,7359 Akaike criterion 1231,472
Schwarz criterion 1277,597 Hannan-Quinn 1250,215
rho -0,033328 Durbin's h -0,435487

Forecast evaluation statistics using 12 observations

Mean Error	16,629
Root Mean Squared Error	33,162
Mean Absolute Error	25,978
Mean Percentage Error	1,1245
Mean Absolute Percentage Error	1,7949
Theil's U2	1,3131
Bias proportion, UM	0,25146
Regression proportion, UR	0,035894
Disturbance proportion, UD	0,71265

- Perskaičiuotos modelio ex-ante paklaidos

Model 150: OLS, using observations 2014:01-2024:12 (T = 132)
Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value
const	195,865	37,8133	5,180	9,47e-07 ***
time	0,458252	0,123984	3,696	0,0003 ***
D1_Covid	-18,4788	9,22764	-2,003	0,0476 **
D2_UKR	61,4920	14,7040	4,182	5,64e-05 ***
Ex_Ante_Brent_Oil	2,91972	0,262167	11,14	4,92e-020 ***
Ex_Ante_Brent_~_2	-1,69986	0,338534	-5,021	1,88e-06 ***
Ex_Ante_Brent_~_6	-0,897237	0,258261	-3,474	0,0007 ***
Ex_Ante_Brent_~_12	0,801978	0,239063	3,355	0,0011 ***
Ex_Ante_LT_Oil_1	-0,0348473	0,0171974	-2,026	0,0450 **
Ex_Ante_HICP	1,11921	0,193229	5,792	6,06e-08 ***
Ex_Ante_HICP_6	-0,886220	0,244910	-3,619	0,0004 ***
Ex_Ante_HICP_7	1,30510	0,257209	5,074	1,50e-06 ***
Ex_Ante_HICP_9	-0,908276	0,189638	-4,790	4,98e-06 ***
Ex_Ante_HICP_12	0,441092	0,125552	3,513	0,0006 ***
Petrol_Price_1	0,659003	0,0414565	15,90	6,63e-031 ***
Petrol_Price_9	0,114015	0,0297006	3,839	0,0002 ***

Mean dependent var 1285,954 S.D. dependent var 206,1489
Sum squared resid 68307,12 S.E. of regression 24,26632
R-squared 0,987730 Adjusted R-squared 0,986144
F(15, 116) 622,5474 P-value(F) 3,0e-103
Log-likelihood -599,7317 Akaike criterion 1231,463
Schwarz criterion 1277,588 Hannan-Quinn 1250,206
rho -0,033371 Durbin's h -0,436041

Forecast evaluation statistics using 12 observations

Mean Error	8,199
Root Mean Squared Error	40,65
Mean Absolute Error	29,031
Mean Percentage Error	0,51042
Mean Absolute Percentage Error	2,0025
Theil's U2	1,5463
Bias proportion, UM	0,040682
Regression proportion, UR	0,3005
Disturbance proportion, UD	0,65882

– Su Lietuvos naftos išteklių ir Brent naftos kainų kintamaisiais

Test on Model 114:

Null hypothesis: the regression parameters are zero for the variables
 LT_Oil_1, LT_Oil_2, LT_Oil_3, Brent_Oil_1, Brent_Oil_3, Petrol_Price_2,
 Petrol_Price_3
 Test statistic: F(7, 126) = 1,33178, p-value 0,240679
 Omitting variables improved 3 of 3 information criteria.

Model 115: OLS, using observations 2013:04-2024:12 (T = 141)
 Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value
const	157,138	29,1775	5,386	3,17e-07 ***
time	0,308347	0,104880	2,940	0,0039 ***
D1_Covid	-28,1321	10,8639	-2,589	0,0107 **
D2_UKR	75,7795	16,3545	4,634	8,47e-06 ***
LT_Oil	-0,0567319	0,0207902	-2,729	0,0072 ***
Brent_Oil	3,39673	0,282505	12,02	5,37e-023 ***
Brent_Oil_2	-2,56459	0,359857	-7,127	5,88e-011 ***
Petrol_Price_1	0,847572	0,0355622	23,83	7,56e-050 ***
Mean dependent var	1291,330	S.D. dependent var	200,6339	
Sum squared resid	119904,9	S.E. of regression	30,02566	
R-squared	0,978724	Adjusted R-squared	0,977604	
F(7, 133)	874,0045	P-value(F)	7,0e-108	
Log-likelihood	-675,6418	Akaike criterion	1367,284	
Schwarz criterion	1390,874	Hannan-Quinn	1376,870	
rho	0,028684	Durbin's h	0,375755	

Forecast evaluation statistics using 12 observations

Mean Error	26,916
Root Mean Squared Error	37,667
Mean Absolute Error	29,069
Mean Percentage Error	1,85
Mean Absolute Percentage Error	2,0043
Theil's U2	1,6228
Bias proportion, UM	0,51062
Regression proportion, UR	0,10377
Disturbance proportion, UD	0,38561

– Su Lietuvos naftos išteklių ir elektros energijos pasiūlos Lietuvos rinkoje kintamaisiais

Test on Model 120:

Null hypothesis: the regression parameters are zero for the variables
 El_LT_1, El_LT_2, El_LT_5, LT_Oil, LT_Oil_2, LT_Oil_3, LT_Oil_4,
 LT_Oil_5, Petrol_Price_3, Petrol_Price_4, Petrol_Price_5
 Test statistic: F(11, 118) = 0,908225, p-value 0,534889
 Omitting variables improved 3 of 3 information criteria.

Model 121: OLS, using observations 2013:06-2024:12 (T = 139)
 Dependent variable: Petrol_Price

	coefficient	std. error	t-ratio	p-value
const	370,005	89,4515	4,136	6,32e-05 ***
time	0,336505	0,110287	3,051	0,0028 ***
D1_Covid	-35,1656	14,4447	-2,434	0,0163 **
D2_UKR	139,840	21,6045	6,473	1,83e-09 ***
El_LT	-0,134566	0,0456998	-2,945	0,0038 ***
El_LT_3	0,176037	0,0662965	2,655	0,0089 ***
El_LT_4	-0,200853	0,0684595	-2,934	0,0040 ***
LT_Oil_1	-0,0785062	0,0269607	-2,912	0,0042 ***
Petrol_Price_1	1,07045	0,0759939	14,09	7,27e-028 ***
Petrol_Price_2	-0,222219	0,0737012	-3,015	0,0031 ***
Mean dependent var	1289,979	S.D. dependent var	201,7475	
Sum squared resid	207237,4	S.E. of regression	40,08106	
R-squared	0,963105	Adjusted R-squared	0,960530	
F(9, 129)	374,1519	P-value(F)	6,81e-88	
Log-likelihood	-705,0791	Akaike criterion	1430,158	
Schwarz criterion	1459,503	Hannan-Quinn	1442,083	
rho	0,087880	Durbin's h	2,332764	

Forecast evaluation statistics using 12 observations

Mean Error	-51,701
Root Mean Squared Error	80,082
Mean Absolute Error	74,064
Mean Percentage Error	-3,735
Mean Absolute Percentage Error	5,2356
Theil's U2	4,2226
Bias proportion, UM	0,41681
Regression proportion, UR	0,53209
Disturbance proportion, UD	0,051095

6 priedas. ARDL dyzelino kainų modelių išsklotinės

– Su mokesčių dalies dyzelino kainoje kintamuoju

Test on Model 122:

Null hypothesis: the regression parameter is zero for D1_Covid
 Test statistic: $F(1, 130) = 2,40989$, p-value 0,123002
 Omitting variables improved 2 of 3 information criteria.

Model 123: OLS, using observations 2013:04-2024:12 (T = 141)
 Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	391,941	109,855	3,568	0,0005	***
time	0,278601	0,0877336	3,176	0,0019	***
D2_UKR	66,8290	11,1897	5,972	2,07e-08	***
Diesel_Tax_Prcvtg	-40,4192	1,86147	-21,71	3,09e-045	***
Diesel_Tax_Prcv_1	46,4164	5,02296	9,241	5,79e-016	***
Diesel_Tax_Prcv_2	-19,2887	6,17321	-3,125	0,0022	***
Diesel_Tax_Prcv_3	7,97250	3,80574	2,095	0,0381	**
Diesel_Price_1	1,05558	0,0795304	13,27	5,24e-026	***
Diesel_Price_2	-0,412364	0,113915	-3,620	0,0004	***
Diesel_Price_3	0,223754	0,0771871	2,899	0,0044	***
Mean dependent var	1231,685	S.D. dependent var	244,3111		
Sum squared resid	55672,91	S.E. of regression	20,61514		
R-squared	0,993338	Adjusted R-squared	0,992880		
F(9, 131)	2170,182	P-value(F)	6,0e-138		
Log-likelihood	-621,5538	Akaike criterion	1263,108		
Schwarz criterion	1292,595	Hannan-Quinn	1275,090		
rho	-0,008782	Durbin's h	-0,317069		
					Forecast evaluation statistics using 12 observations
					Mean Error
					308,52
					Root Mean Squared Error
					308,7
					Mean Absolute Error
					308,52
					Mean Percentage Error
					20,474
					Mean Absolute Percentage Error
					20,474
					Theil's U2
					7,0417
					Bias proportion, UM
					0,99883
					Regression proportion, UR
					0,00083553
					Disturbance proportion, UD
					0,00033653

– Su dyzelinui taikomo akcizo kintamuoju

Test on Model 124:

Null hypothesis: the regression parameters are zero for the variables
 time, D1_Covid, Diesel_Excises, Diesel_Excises_1, Diesel_Excises_3,
 Diesel_Excises_4, Diesel_Price_4, Diesel_Price_5
 Test statistic: $F(8, 124) = 0,839485$, p-value 0,569668
 Omitting variables improved 3 of 3 information criteria.

Model 125: OLS, using observations 2013:06-2024:12 (T = 139)
 Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	-49,3883	61,1269	-0,8080	0,4206	
D2_UKR	132,186	22,9294	5,765	5,50e-08	***
Diesel_Excises_2	-1,13215	0,560666	-2,019	0,0455	**
Diesel_Excises_5	1,50566	0,595512	2,528	0,0126	**
Diesel_Price_1	1,22065	0,0781764	15,61	8,79e-032	***
Diesel_Price_2	-0,526400	0,120868	-4,355	2,65e-05	***
Diesel_Price_3	0,237636	0,0759608	3,128	0,0022	***
Mean dependent var	1230,485	S.D. dependent var	245,8491		
Sum squared resid	269008,4	S.E. of regression	45,14358		
R-squared	0,967749	Adjusted R-squared	0,966283		
F(6, 132)	660,1392	P-value(F)	7,83e-96		
Log-likelihood	-723,2101	Akaike criterion	1460,420		
Schwarz criterion	1480,962	Hannan-Quinn	1468,768		
rho	0,025772	Durbin's h	0,783247		
					Forecast evaluation statistics using 12 observations
					Mean Error
					111,37
					Root Mean Squared Error
					125,92
					Mean Absolute Error
					111,37
					Mean Percentage Error
					7,3704
					Mean Absolute Percentage Error
					7,3704
					Theil's U2
					2,7811
					Bias proportion, UM
					0,78218
					Regression proportion, UR
					0,085419
					Disturbance proportion, UD
					0,1324

– Su Brent naftos kainos kintamuoju

Test on Model 126:

Null hypothesis: the regression parameters are zero for the variables
D1_Covid, Brent_Oil_2, Brent_Oil_3
Test statistic: $F(3, 130) = 1,49526$, p-value 0,218897
Omitting variables improved 3 of 3 information criteria.

Model 127: OLS, using observations 2013:04-2024:12 (T = 141)
Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value		
const	52,0518	17,6217	2,954	0,0037	***	
time	0,327180	0,109746	2,981	0,0034	***	
D2_UKR	78,8132	18,3288	4,300	3,28e-05	***	
Brent_Oil	4,56193	0,505940	9,017	1,85e-015	***	
Brent_Oil_1	-3,41975	0,604892	-5,653	9,19e-08	***	
Diesel_Price_1	1,13431	0,0712738	15,91	1,37e-032	***	
Diesel_Price_2	-0,439962	0,0913521	-4,816	3,92e-06	***	
Diesel_Price_3	0,176186	0,0576146	3,058	0,0027	***	
Mean dependent var	1231,685	S.D. dependent var	244,3111			
Sum squared resid	153638,1	S.E. of regression	33,98785			
R-squared	0,981614	Adjusted R-squared	0,980646			
F(7, 133)	1014,401	P-value(F)	4,3e-112			
Log-likelihood	-693,1188	Akaike criterion	1402,238			
Schwarz criterion	1425,828	Hannan-Quinn	1411,824			
rho	-0,021389	Durbin's h	-0,476816			
					Forecast evaluation statistics using 12 observations	
					Mean Error	105,14
					Root Mean Squared Error	113,95
					Mean Absolute Error	105,14
					Mean Percentage Error	6,8876
					Mean Absolute Percentage Error	6,8876
					Theil's U2	2,5055
					Bias proportion, UM	0,85139
					Regression proportion, UR	0,008097
					Disturbance proportion, UD	0,14051

– Su Lietuvos naftos išteklių kintamuoju

Test on Model 128:

Null hypothesis: the regression parameters are zero for the variables
time, D1_Covid, LT_Oil, LT_Oil_1, LT_Oil_2, LT_Oil_3
Test statistic: $F(6, 130) = 1,46318$, p-value 0,195812
Omitting variables improved 3 of 3 information criteria.

Model 129: OLS, using observations 2013:04-2024:12 (T = 141)
Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value		
const	62,0325	20,9158	2,966	0,0036	***	
D2_UKR	136,709	23,2478	5,880	3,01e-08	***	
Diesel_Price_1	1,25140	0,0785089	15,94	6,44e-033	***	
Diesel_Price_2	-0,564194	0,121902	-4,628	8,51e-06	***	
Diesel_Price_3	0,258970	0,0766985	3,376	0,0010	***	
Mean dependent var	1231,685	S.D. dependent var	244,3111			
Sum squared resid	286645,0	S.E. of regression	45,90952			
R-squared	0,965697	Adjusted R-squared	0,964688			
F(4, 136)	957,1716	P-value(F)	1,68e-98			
Log-likelihood	-737,0857	Akaike criterion	1484,171			
Schwarz criterion	1498,915	Hannan-Quinn	1490,163			
rho	0,025152	Durbin's h	0,825406			
					Forecast evaluation statistics using 12 observations	
					Mean Error	163,16
					Root Mean Squared Error	171
					Mean Absolute Error	163,16
					Mean Percentage Error	10,742
					Mean Absolute Percentage Error	10,742
					Theil's U2	3,881
					Bias proportion, UM	0,91032
					Regression proportion, UR	0,0034383
					Disturbance proportion, UD	0,086244

– Su harmonizuotu vartotojų kainų indekso skystojo kuro rinkoje kintamuoju

Test on Model 130:

Null hypothesis: the regression parameters are zero for the variables
time, D1_Covid, HICP_2, HICP_3, HICP_4, HICP_5, Diesel_Price_4,
Diesel_Price_5
Test statistic: $F(8, 124) = 1,32916$, p-value 0,235146
Omitting variables improved 3 of 3 information criteria.

Model 131: OLS, using observations 2013:06-2024:12 (T = 139)
Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value		
const	45,0863	21,1024	2,137	0,0345	**	
D2_UKR	73,0118	21,5816	3,383	0,0009	***	
HICP	2,60189	0,336848	7,724	2,50e-012	***	
HICP_1	-2,29707	0,336375	-6,829	2,83e-010	***	
Diesel_Price_1	1,19618	0,0689149	17,36	7,07e-036	***	
Diesel_Price_2	-0,502587	0,102682	-4,895	2,82e-06	***	
Diesel_Price_3	0,266632	0,0653558	4,080	7,76e-05	***	
Mean dependent var	1230,485	S.D. dependent var	245,8491			
Sum squared resid	195772,4	S.E. of regression	38,51135			
R-squared	0,976529	Adjusted R-squared	0,975462			
F(8, 132)	915,3191	P-value(F)	6,2e-105			
Log-likelihood	-701,1237	Akaike criterion	1416,247			
Schwarz criterion	1436,789	Hannan-Quinn	1424,595			
rho	-0,042006	Durbin's h	-0,849529			
					Forecast evaluation statistics using 12 observations	
					Mean Error	148,15
					Root Mean Squared Error	154,19
					Mean Absolute Error	148,15
					Mean Percentage Error	9,7494
					Mean Absolute Percentage Error	9,7494
					Theil's U2	3,4703
					Bias proportion, UM	0,92327
					Regression proportion, UR	0,003868
					Disturbance proportion, UD	0,072862

– Su pramonės sektoriaus produkcijos apimčių indekso kintamuoju

Test on Model 132:

Null hypothesis: the regression parameters are zero for the variables
D1_Covid, Prod_Manufact_3, Prod_Manufact_4, Diesel_Price_4
Test statistic: $F(4, 127) = 1,06561$, p-value 0,376375
Omitting variables improved 3 of 3 information criteria.

Model 133: OLS, using observations 2013:05-2024:12 (T = 140)
Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value		
const	-41,5504	42,4874	-0,9779	0,3299		
time	-0,583033	0,293934	-1,984	0,0494	**	
D2_UKR	118,225	22,7695	5,192	7,73e-07	***	
Prod_Manufact	2,69507	0,710218	3,795	0,0002	***	
Prod_Manufact_1	-2,14428	0,782219	-2,741	0,0070	***	
Prod_Manufact_2	1,76522	0,772950	2,284	0,0240	**	
Diesel_Price_1	1,22602	0,0783830	15,64	9,26e-032	***	
Diesel_Price_2	-0,614255	0,116966	-5,252	5,93e-07	***	
Diesel_Price_3	0,296400	0,0724611	4,090	7,47e-05	***	
Mean dependent var	1230,911	S.D. dependent var	245,0149			
Sum squared resid	236791,0	S.E. of regression	42,51546			
R-squared	0,971623	Adjusted R-squared	0,969890			
F(8, 131)	560,6783	P-value(F)	2,20e-97			
Log-likelihood	-718,9817	Akaike criterion	1455,963			
Schwarz criterion	1482,438	Hannan-Quinn	1466,722			
rho	0,027681	Durbin's h	0,875811			
					Forecast evaluation statistics using 12 observations	
					Mean Error	101,42
					Root Mean Squared Error	114,7
					Mean Absolute Error	101,42
					Mean Percentage Error	6,606
					Mean Absolute Percentage Error	6,606
					Theil's U2	2,4637
					Bias proportion, UM	0,78191
					Regression proportion, UR	0,0079389
					Disturbance proportion, UD	0,21015

– Su importo kintamuju

Test on Model 134:

Null hypothesis: the regression parameters are zero for the variables
time, D1_Covid, Import_2, Import_3, Import_4, Import_5, Diesel_Price_4,
Diesel_Price_5
Test statistic: $F(8, 124) = 0,901427$, p-value 0,517642
Omitting variables improved 3 of 3 information criteria.

Model 135: OLS, using observations 2013:06-2024:12 (T = 139)
Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	62,2962	20,0822	3,102	0,0024	***
D2_UKR	124,855	22,1875	5,627	1,05e-07	***
Import	6,09838e-05	1,54004e-05	3,960	0,0001	***
Import_1	-3,78562e-05	1,58146e-05	-2,394	0,0181	**
Diesel_Price_1	1,16230	0,0788126	14,75	1,08e-029	***
Diesel_Price_2	-0,515307	0,116126	-4,437	1,90e-05	***
Diesel_Price_3	0,246589	0,0727270	3,391	0,0009	***
Mean dependent var	1230,485	S.D. dependent var	245,8491		
Sum squared resid	249388,7	S.E. of regression	43,46618		
R-squared	0,970101	Adjusted R-squared	0,968742		
F(8, 132)	713,8038	P-value(F)	5,31e-98		
Log-likelihood	-717,9469	Akaike criterion	1449,894		
Schwarz criterion	1470,435	Hannan-Quinn	1458,241		
rho	0,043914	Durbin's h	1,400780		

Forecast evaluation statistics using 12 observations		
Mean Error		99,405
Root Mean Squared Error		113,31
Mean Absolute Error		99,405
Mean Percentage Error		6,4714
Mean Absolute Percentage Error		6,4714
Theil's U2		2,3918
Bias proportion, UM		0,76969
Regression proportion, UR		0,0023183
Disturbance proportion, UD		0,22799

– Su Lietuvos naftos išteklių ir pramonės sektoriaus produkcijos apimčių indekso kintamaisiais

Test on Model 136:

Null hypothesis: the regression parameters are zero for the variables
D1_Covid, LT_Oil_1, LT_Oil_2, LT_Oil_3, LT_Oil_4, Prod_Manufact_3,
Prod_Manufact_4, Diesel_Price_4
Test statistic: $F(8, 122) = 1,01327$, p-value 0,429683
Omitting variables improved 3 of 3 information criteria.

Model 137: OLS, using observations 2013:05-2024:12 (T = 140)
Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	-23,1472	42,4345	-0,5455	0,5864	
time	-0,782723	0,300486	-2,605	0,0103	**
D2_UKR	97,5325	23,9711	4,069	8,15e-05	***
LT_Oil	-0,0680346	0,0283485	-2,400	0,0178	**
Prod_Manufact	3,27219	0,737938	4,434	1,95e-05	***
Prod_Manufact_1	-2,24335	0,769492	-2,915	0,0042	***
Prod_Manufact_2	1,93840	0,762701	2,541	0,0122	**
Diesel_Price_1	1,24006	0,0772186	16,06	1,18e-032	***
Diesel_Price_2	-0,643564	0,115544	-5,570	1,40e-07	***
Diesel_Price_3	0,305301	0,0712760	4,283	3,55e-05	***
Mean dependent var	1230,911	S.D. dependent var	245,0149		
Sum squared resid	226744,9	S.E. of regression	41,76352		
R-squared	0,972827	Adjusted R-squared	0,970946		
F(9, 130)	517,1286	P-value(F)	3,23e-97		
Log-likelihood	-715,9471	Akaike criterion	1451,894		
Schwarz criterion	1481,311	Hannan-Quinn	1463,848		
rho	0,029457	Durbin's h	0,857474		

Forecast evaluation statistics using 12 observations		
Mean Error		110,92
Root Mean Squared Error		123,51
Mean Absolute Error		110,92
Mean Percentage Error		7,2386
Mean Absolute Percentage Error		7,2386
Theil's U2		2,6867
Bias proportion, UM		0,80659
Regression proportion, UR		0,0003423
Disturbance proportion, UD		0,19307

- Su Lietuvos naftos išteklių, pramonės sektoriaus produkcijos apimčių indekso ir dyzelinui taikomo akcizo kintamaisiais

Test on Model 138:

Null hypothesis: the regression parameters are zero for the variables
D1_Covid, LT_Oil_1, LT_Oil_2, LT_Oil_3, LT_Oil_4, LT_Oil_5, Prod_Manufact_3,
Prod_Manufact_4, Prod_Manufact_5, Diesel_Excises_1, Diesel_Excises_3,
Diesel_Excises_4, Diesel_Excises_5, Diesel_Price_4, Diesel_Price_5
Test statistic: F(15, 112) = 0,738074, p-value 0,741311
Omitting variables improved 3 of 3 information criteria.

Model 139: OLS, using observations 2013:06-2024:12 (T = 139)
Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value
const	141,678	132,074	1,073	0,2854
time	-0,848111	0,359523	-2,359	0,0199 ***
D2_UKR	88,6971	23,5484	3,767	0,0003 ***
LT_Oil	-0,0940170	0,0296534	-3,171	0,0019 ***
Prod_Manufact	4,08163	0,754877	5,407	3,06e-07 ***
Prod_Manufact_1	-1,90409	0,755455	-2,520	0,0130 ***
Prod_Manufact_2	1,84379	0,740736	2,489	0,0141 **
Diesel_Excises	1,64166	0,674350	2,434	0,0163 **
Diesel_Excises_2	-2,28071	0,696201	-3,276	0,0014 ***
Diesel_Price_1	1,20509	0,0757867	15,90	5,28e-032 ***
Diesel_Price_2	-0,624471	0,112274	-5,562	1,51e-07 ***
Diesel_Price_3	0,316947	0,0692256	4,578	1,10e-05 ***
Mean dependent var	1230,485	S.D. dependent var	245,8491	
Sum squared resid	206687,4	S.E. of regression	40,34179	
R-squared	0,975220	Adjusted R-squared	0,973074	
F(11, 127)	454,3765	P-value(F)	2,84e-96	
Log-likelihood	-704,8944	Akaike criterion	1433,789	
Schwarz criterion	1469,003	Hannan-Quinn	1448,099	
rho	0,031061	Durbin's h	0,815526	

Forecast evaluation statistics using 12 observations

Mean Error	212,27
Root Mean Squared Error	249,25
Mean Absolute Error	212,27
Mean Percentage Error	14,154
Mean Absolute Percentage Error	14,154
Theil's U2	6,0146
Bias proportion, UM	0,72529
Regression proportion, UR	0,2351
Disturbance proportion, UD	0,039609

- Su Lietuvos naftos išteklių ir dyzelinui taikomo akcizo kintamaisiais

Test on Model 140:

Null hypothesis: the regression parameters are zero for the variables
time, D1_Covid, Diesel_Excises, Diesel_Excises_1, Diesel_Excises_2,
Diesel_Excises_3, Diesel_Excises_4, Diesel_Excises_5, LT_Oil,
LT_Oil_1, LT_Oil_2, LT_Oil_3, LT_Oil_4, LT_Oil_5, Diesel_Price_4,
Diesel_Price_5
Test statistic: F(16, 118) = 1,23863, p-value 0,24949
Omitting variables improved 3 of 3 information criteria.

Model 141: OLS, using observations 2013:06-2024:12 (T = 139)
Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value
const	61,6283	21,0109	2,933	0,0039 ***
D2_UKR	136,368	23,3509	5,840	3,75e-08 ***
Diesel_Price_1	1,25308	0,0788199	15,90	1,22e-032 ***
Diesel_Price_2	-0,567429	0,122417	-4,635	8,36e-06 ***
Diesel_Price_3	0,261019	0,0770163	3,389	0,0009 ***
Mean dependent var	1230,485	S.D. dependent var	245,8491	
Sum squared resid	284538,4	S.E. of regression	46,08059	
R-squared	0,965887	Adjusted R-squared	0,964868	
F(4, 134)	948,5196	P-value(F)	3,34e-97	
Log-likelihood	-727,1108	Akaike criterion	1464,222	
Schwarz criterion	1478,894	Hannan-Quinn	1470,184	
rho	0,026383	Durbin's h	0,842062	

Forecast evaluation statistics using 12 observations

Mean Error	161,59
Root Mean Squared Error	169,47
Mean Absolute Error	161,59
Mean Percentage Error	10,637
Mean Absolute Percentage Error	10,637
Theil's U2	3,8423
Bias proportion, UM	0,90917
Regression proportion, UR	0,0030334
Disturbance proportion, UD	0,087792

– Su pramonės sektoriaus produkcijos apimčių indekso ir dyzelinui taikomo akcizo kintamaisiais

Test on Model 96:

Null hypothesis: the regression parameters are zero for the variables
time, Prod_Manufact_2, Prod_Manufact_3, Prod_Manufact_4, Prod_Manufact_5,
Diesel_Excises, Diesel_Excises_1, Diesel_Excises_3, Diesel_Excises_4,
D1_Covid, Diesel_Price_4, Diesel_Price_5
Test statistic: $F(12, 118) = 1,40902$, p-value 0,171182
Omitting variables improved 3 of 3 information criteria.

Model 97: OLS, using observations 2013:06-2024:12 (T = 139)

Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	56,5547	93,5933	0,6043	0,5467	
Prod_Manufact	2,98558	0,663524	4,500	1,49e-05	***
Prod_Manufact_1	-2,13952	0,689914	-3,101	0,0024	***
Diesel_Excises_2	-1,58279	0,535955	-2,953	0,0037	***
Diesel_Excises_5	1,46657	0,620312	2,364	0,0195	**
D2_UKR	131,750	21,7111	6,068	1,32e-08	***
Diesel_Price_1	1,18691	0,0755059	15,72	7,43e-032	***
Diesel_Price_2	-0,514913	0,113286	-4,545	1,24e-05	***
Diesel_Price_3	0,255934	0,0722924	3,540	0,0006	***
Mean dependent var	1230,485	S.D. dependent var	245,8491		
Sum squared resid	232532,8	S.E. of regression	42,29319		
R-squared	0,972122	Adjusted R-squared	0,970406		
F(8, 130)	566,6382	P-value(F)	4,04e-97		
Log-likelihood	-713,0832	Akaike criterion	1444,166		
Schwarz criterion	1470,577	Hannan-Quinn	1454,899		
rho	0,100677	Durbin's h	2,605475		
					Forecast evaluation statistics using 12 observations
				Mean Error	238,23
				Root Mean Squared Error	241,22
				Mean Absolute Error	238,23
				Mean Percentage Error	15,88
				Mean Absolute Percentage Error	15,88
				Theil's U2	5,7275
				Bias proportion, UM	0,97535
				Regression proportion, UR	0,016584
				Disturbance proportion, UD	0,0080673

– Su Lietuvos naftos išteklių, pramonės sektoriaus produkcijos apimčių indekso ir Brent naftos kainos kintamaisiais

Test on Model 144:

Null hypothesis: the regression parameters are zero for the variables
time, LT_Oil, LT_Oil_1, LT_Oil_2, LT_Oil_3, Prod_Manufact_2,
Prod_Manufact_4, Brent_Oil_2, Brent_Oil_3, Brent_Oil_4, Diesel_Price_4
Test statistic: $F(11, 117) = 0,893946$, p-value 0,548514
Omitting variables improved 3 of 3 information criteria.

Model 145: OLS, using observations 2013:05-2024:12 (T = 140)

Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	63,9061	24,1461	2,647	0,0091	***
D1_Covid	-22,9410	10,5132	-2,182	0,0309	**
D2_UKR	70,1524	17,4597	4,018	9,95e-05	***
LT_Oil_4	-0,0614135	0,0207021	-2,967	0,0036	***
Prod_Manufact	1,28133	0,498273	2,572	0,0113	**
Prod_Manufact_1	-1,67244	0,538320	-3,107	0,0023	***
Prod_Manufact_3	1,51730	0,512548	2,960	0,0037	***
Brent_Oil	4,40974	0,479977	9,187	9,23e-016	***
Brent_Oil_1	-3,48729	0,561360	-6,212	6,76e-09	***
Diesel_Price_1	1,13861	0,0670864	16,97	1,45e-034	***
Diesel_Price_2	-0,416965	0,0854473	-4,880	3,10e-06	***
Diesel_Price_3	0,134086	0,0561156	2,389	0,0183	**
Mean dependent var	1230,911	S.D. dependent var	245,0149		
Sum squared resid	126520,8	S.E. of regression	31,43953		
R-squared	0,984838	Adjusted R-squared	0,983535		
F(11, 128)	755,8224	P-value(F)	1,1e-110		
Log-likelihood	-675,1078	Akaike criterion	1374,216		
Schwarz criterion	1409,515	Hannan-Quinn	1388,560		
rho	-0,011435	Durbin's h	-0,222453		
					Forecast evaluation statistics using 12 observations
				Mean Error	77,231
				Root Mean Squared Error	91,251
				Mean Absolute Error	77,231
				Mean Percentage Error	5,0318
				Mean Absolute Percentage Error	5,0318
				Theil's U2	1,979
				Bias proportion, UM	0,71634
				Regression proportion, UR	0,00088025
				Disturbance proportion, UD	0,28278

– Perskaičiuotos modelio ex-ante paklaidos

Model 153: OLS, using observations 2013:05-2024:12 (T = 140)

Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	63,8987	24,1467	2,646	0,0092	***
D2_UKR	70,1439	17,4607	4,017	9,98e-05	***
Ex_Ante_LT_Oil_4	-0,0614084	0,0207026	-2,966	0,0036	***
Ex_Ante_Prod_Man~	1,28114	0,498292	2,571	0,0113	**
Ex_Ante_Prod_Mw_1	-1,67232	0,538336	-3,106	0,0023	***
Ex_Ante_Prod_Mw_3	1,51739	0,512562	2,960	0,0037	***
Ex_Ante_Brent_Oil	4,40988	0,480051	9,186	9,29e-016	***
Ex_Ante_Brent_~_1	-3,48731	0,561448	-6,211	6,80e-09	***
D1_Covid	-22,9376	10,5135	-2,182	0,0310	**
Diesel_Price_1	1,13863	0,0670902	16,97	1,45e-034	***
Diesel_Price_2	-0,416991	0,0854497	-4,880	3,10e-06	***
Diesel_Price_3	0,134088	0,0561172	2,389	0,0183	**
Mean dependent var	1230,911	S.D. dependent var	245,0149		
Sum squared resid	126527,7	S.E. of regression	31,44039		
R-squared	0,984837	Adjusted R-squared	0,983534		
F(11, 128)	755,7803	P-value(F)	1,1e-110		
Log-likelihood	-675,1116	Akaike criterion	1374,223		
Schwarz criterion	1409,523	Hannan-Quinn	1388,568		
rho	-0,011549	Durbin's h	-0,224705		
					Forecast evaluation statistics using 12 observations
				Mean Error	59,929
				Root Mean Squared Error	80,79
				Mean Absolute Error	65,134
				Mean Percentage Error	3,8458
				Mean Absolute Percentage Error	4,214
				Theil's U2	1,5569
				Bias proportion, UM	0,55025
				Regression proportion, UR	0,038102
				Disturbance proportion, UD	0,41165

- Su Lietuvos naftos išteklių, pramonės sektoriaus produkcijos apimčių indekso ir harmonizuoto vartotojų kainų indekso skystojo kuro rinkoje kintamaisiais

Test on Model 146:

Null hypothesis: the regression parameters are zero for the variables
 D1_Covid, LT_Oil_1, LT_Oil_3, LT_Oil_4, LT_Oil_5, Prod_Manufact_2,
 Prod_Manufact_4, Prod_Manufact_5, HICP_2, HICP_3, HICP_4, HICP_5,
 Diesel_Price_4, Diesel_Price_5
 Test statistic: F(14, 112) = 0,600205, p-value 0,859982
 Omitting variables improved 3 of 3 information criteria.

Model 147: OLS, using observations 2013:06-2024:12 (T = 139)
 Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	-54,7017	45,1754	-1,211	0,2282	
time	-0,570293	0,282329	-2,020	0,0455	**
D2_UKR	44,4102	21,9138	2,027	0,0448	**
LT_Oil	-0,0516898	0,0250518	-2,063	0,0411	**
LT_Oil_2	0,0489134	0,0230143	2,125	0,0355	**
Prod_Manufact	2,90429	0,640685	4,533	1,33e-05	***
Prod_Manufact_1	-2,22490	0,632959	-3,515	0,0006	***
Prod_Manufact_3	1,42965	0,621759	2,299	0,0231	**
HICP	2,36946	0,315439	7,512	9,41e-012	***
HICP_1	-2,15237	0,313757	-6,860	2,77e-010	***
Diesel_Price_1	1,19406	0,0665765	17,94	1,72e-036	***
Diesel_Price_2	-0,489318	0,0955011	-5,124	1,10e-06	***
Diesel_Price_3	0,230533	0,0621957	3,707	0,0003	***
Mean dependent var	1230,485	S.D. dependent var	245,8491		
Sum squared resid	154536,3	S.E. of regression	35,02111		
R-squared	0,981473	Adjusted R-squared	0,979708		
F(12, 126)	556,2285	P-value(F)	7,1e-103		
Log-likelihood	-684,6853	Akaike criterion	1395,371		
Schwarz criterion	1433,519	Hannan-Quinn	1410,873		
rho	-0,001305	Durbin's h	-0,024827		

Forecast evaluation statistics using 12 observations		
Mean Error		90,686
Root Mean Squared Error		105,76
Mean Absolute Error		90,686
Mean Percentage Error		5,8986
Mean Absolute Percentage Error		5,8986
Theil's U2		2,2425
Bias proportion, UM		0,73528
Regression proportion, UR		0,00031074
Disturbance proportion, UD		0,26441

- Su mokesčių dalies dyzelino kainoje ir dyzelinui taikomo akcizo kintamaisiais

Test on Model 148:

Null hypothesis: the regression parameters are zero for the variables
 time, D1_Covid, Diesel_Tax_Prcgt_4, Diesel_Excises_1, Diesel_Excises_3,
 Diesel_Excises_4, Diesel_Excises_5, Diesel_Price_4
 Test statistic: F(8, 118) = 0,80088, p-value 0,602967
 Omitting variables improved 3 of 3 information criteria.

Model 149: OLS, using observations 2013:06-2024:12 (T = 139)
 Dependent variable: Diesel_Price

	coefficient	std. error	t-ratio	p-value	
const	317,053	74,1721	4,275	3,75e-05	***
D2_UKR	65,5802	10,2397	6,405	2,72e-09	***
Diesel_Tax_Prcgt	-40,7443	1,63053	-24,99	1,17e-050	***
Diesel_Tax_Prcw_1	40,8215	4,49545	9,081	1,87e-015	***
Diesel_Tax_Prcw_2	-12,8747	5,69886	-2,259	0,0256	**
Diesel_Tax_Prcw_3	10,3459	4,05793	2,550	0,0120	**
Diesel_Tax_Prcw_5	-4,21799	1,97268	-2,138	0,0344	**
Diesel_Excises	1,78445	0,279588	6,382	3,04e-09	***
Diesel_Excises_2	-1,22335	0,312214	-3,918	0,0001	***
Diesel_Price_1	0,943606	0,0718483	13,13	2,35e-025	***
Diesel_Price_2	-0,285523	0,103530	-2,758	0,0067	***
Diesel_Price_3	0,293473	0,0774359	3,790	0,0002	***
Diesel_Price_5	-0,118159	0,0433337	-2,727	0,0073	***
Mean dependent var	1230,485	S.D. dependent var	245,8491		
Sum squared resid	40781,32	S.E. of regression	17,99059		
R-squared	0,995111	Adjusted R-squared	0,994645		
F(12, 126)	2137,055	P-value(F)	2,7e-139		
Log-likelihood	-592,0971	Akaike criterion	1210,194		
Schwarz criterion	1248,342	Hannan-Quinn	1225,697		
rho	-0,097527	Durbin's h	-2,163495		

Forecast evaluation statistics using 12 observations		
Mean Error		108,69
Root Mean Squared Error		115,61
Mean Absolute Error		108,69
Mean Percentage Error		7,1498
Mean Absolute Percentage Error		7,1498
Theil's U2		2,2505
Bias proportion, UM		0,88387
Regression proportion, UR		0,00078188
Disturbance proportion, UD		0,11534

7 priedas. ARIMAX modelių rezultatai

– Benzino kainų

```
> head(arimax_petrol_results, 10)
```

	X_combination	Model	RMSE	MAPE
16	LT_Oil + E1_LT	ARIMA(1,1,1)	40.16178	2.135027
5	E1_LT	ARIMA(1,1,1)	40.16297	2.134572
51	LT_Oil + E1_LT + D1_Covid	ARIMA(1,1,1)	40.40519	2.182528
26	E1_LT + D1_Covid	ARIMA(1,1,1)	40.55517	2.230476
6	D1_Covid	ARIMA(1,1,1)	40.60119	1.803712
23	Unemployment + E1_LT	ARIMA(0,1,2)	40.65317	2.074985
48	LT_Oil + Unemployment + E1_LT	ARIMA(0,1,2)	40.73228	2.070138
60	Unemployment + E1_LT + D1_Covid	ARIMA(0,1,2)	40.83763	2.162469
63	E1_LT + D1_Covid + D2_UKR	ARIMA(1,1,1)	40.88918	2.234644
91	LT_Oil + Unemployment + E1_LT + D2_UKR	ARIMA(0,1,2)	40.94220	2.093632

– Dyzelino kainų

```
> head(arimax_diesel_results, 10)
```

	X_combination	Model	RMSE	MAPE
127	Prod_Manufact + Import + D2_UKR	ARIMA(0,1,1)	66.28917	3.256860
42	Prod_Manufact + D2_UKR	ARIMA(0,1,1)	66.30803	3.264731
255	Prod_Manufact + Import + D1_Covid + D2_UKR	ARIMA(0,1,1)	66.38687	3.256827
40	Prod_Manufact + Import	ARIMA(0,1,1)	66.41002	3.261459
128	Prod_Manufact + D1_Covid + D2_UKR	ARIMA(0,1,1)	66.44690	3.265275
126	Prod_Manufact + Import + D1_Covid	ARIMA(0,1,1)	66.53612	3.262421
6	Prod_Manufact	ARIMA(0,1,1)	66.54905	3.272947
41	Prod_Manufact + D1_Covid	ARIMA(0,1,1)	66.72803	3.274709
116	LT_Oil + Prod_Manufact + D2_UKR	ARIMA(0,1,1)	66.90119	3.377010
249	LT_Oil + Prod_Manufact + D1_Covid + D2_UKR	ARIMA(0,1,1)	67.15578	3.390869

8 priedas. Prophet modelių rezultatai

– Benzino kainų

```
> head(prophet_petrol_results, 10)
```

	X_combination	RMSE	MAPE
10	Brent_Oil + Unemployment	33.36751	2.003059
30	Brent_Oil + LT_Oil + Unemployment	33.70524	2.032676
70	Brent_Oil + LT_Oil + Unemployment + D2_UKR	35.86975	1.900176
82	Brent_Oil + Unemployment + D1_Covid + D2_UKR	36.51254	1.971408
40	Brent_Oil + Unemployment + D2_UKR	36.72489	1.967890
69	Brent_Oil + LT_Oil + Unemployment + D1_Covid	37.54651	2.157644
107	Brent_Oil + LT_Oil + Unemployment + D1_Covid + D2_UKR	37.98845	2.210575
33	Brent_Oil + LT_Oil + D2_UKR	40.24601	2.255901
43	Brent_Oil + D1_Covid + D2_UKR	41.47134	2.314292
39	Brent_Oil + Unemployment + D1_Covid	41.53003	2.298340

– Dyzelino kainų

```
> head(prophet_diesel_results, 10)
```

	X_combination	RMSE	MAPE
366	Brent_Oil + LT_Oil + HICP + D1_Covid + D2_UKR	47.36505	2.491158
227	Brent_Oil + LT_Oil + Prod_Manufact + D2_UKR	47.93578	2.156696
102	Brent_Oil + HICP + D1_Covid	48.55842	2.574754
223	Brent_Oil + LT_Oil + HICP + D1_Covid	48.61493	2.650094
236	Brent_Oil + HICP + D1_Covid + D2_UKR	49.25247	2.608782
369	Brent_Oil + LT_Oil + Prod_Manufact + D1_Covid + D2_UKR	50.43655	2.151742
239	Brent_Oil + Prod_Manufact + D1_Covid + D2_UKR	51.49808	2.268195
109	Brent_Oil + D1_Covid + D2_UKR	51.53261	2.276683
230	Brent_Oil + LT_Oil + D1_Covid + D2_UKR	51.54307	2.231460
105	Brent_Oil + Prod_Manufact + D1_Covid	51.96772	2.445342

9 priedas. Tiksliausio benzino kainos modelio (Prophet) išsklotinė

```
=== Regresorių koeficientai (beta) ===
  Regressor      Beta
  Brent_Oil  0.010062
  Unemployment 0.005077

=== Likučių regresija (aproksimacija): Beta_lm ir p-reiškšmės ===
  Regressor      Beta_lm StdError   t_value   p_value
  Brent_Oil    5.665477  0.223156  25.38798  1.901e-54
  Unemployment -36.081850  2.681588 -13.45541  4.580e-27

=== Trend parametrai (apytiksliai) ===
k = -0.147676
m = 0.649702

=== Sezoniškumo nustatymai ===
$yearly
$yearly$period
[1] 365.25

$yearly$fourier.order
[1] 10

$yearly$prior.scale
[1] 10

$yearly$mode
[1] "additive"

$yearly$condition.name
NULL

> print(petrol_fourier, row.names = FALSE)
  n      a_n      b_n amplitude  phase
1  10.502825  20.59466  23.11816  1.099198
2 -33.845857 -126.88777 131.32421 -1.831466
3  83.075196 -11.73624  83.90010 -0.140344
4  17.718278  40.84361  44.52121  1.161489
5 -36.125310 -11.45966  37.89936 -2.834414
6   4.145717  92.46713  92.56002  1.525992
7  31.965680 -17.75340  36.56485 -0.506972
8 -11.114521  45.87622  47.20339  1.808488
9 -91.523478  11.32762  92.22181  3.018451
10  8.991664 -137.69827 137.99153 -1.505589
```

10 priedas. Tiksliausio dyzelino kainos modelio (Prophet) išsklotinė

```
=== Regresorių koeficientai (beta) ===
Regressor      Beta
Brent_oil      0.001590
  LT_oil        0.012065
    HICP        -0.036453
D1_Covid       -0.001789
D2_UKR         -0.008633

=== Likučių regresija (aproksimacija): beta_lm ir p-reikšmės ===
Regressor      Beta_lm StdError  t_value  p_value
Brent_oil      5.119910  0.361853  14.149133  1.207e-28
  LT_oil        0.018233  0.054491  0.334612  7.384e-01
    HICP        1.916709  0.281591  6.806717  2.803e-10
D1_Covid      -60.413241  27.949836  -2.161488  3.238e-02
D2_UKR        47.985274  45.658574  1.050959  2.951e-01

=== Trend parametrai (apytiksliai) ===
k = -0.002942
m = 0.589984

=== Sezoniškumo nustatymai ===
$yearly
$yearly$period
[1] 365.25

$yearly$fourier.order
[1] 10

$yearly$prior.scale
[1] 10

$yearly$mode
[1] "additive"

$yearly$condition.name
NULL

> print(diesel_fourier, row.names = FALSE)
  n      a_n      b_n amplitude  phase
1  23.574517  3.004679  23.76523  0.126771
2  -4.104964 -71.156685  71.27499 -1.628422
3  59.136902 -17.624718  61.70741 -0.289651
4  33.429588  22.032956  40.03734  0.582736
5 -10.735217  5.421162  12.02638  2.673962
6  3.112433  61.536547  61.61521  1.520261
7  10.118995  3.549641  10.72353  0.337378
8 -28.322702  28.100582  39.89760  2.360131
9 -72.305027 -5.247092  72.49517 -3.069151
10 -16.955393 -86.536690  88.18211 -1.764278
```


11 priedas. Prognozuojamos 2026 metų mažmeninių kainų reikšmės ir jų grafikai

– Benzino

=== Prognozės 2026 (yhat, lower, upper) ===

Date	yhat	yhat_lower	yhat_upper
2026-01-01	1448.359	1370.688	1518.772
2026-02-01	1425.725	1353.366	1498.143
2026-03-01	1455.192	1384.387	1534.501
2026-04-01	1399.036	1322.994	1472.378
2026-05-01	1362.984	1291.528	1439.050
2026-06-01	1424.934	1346.371	1498.696
2026-07-01	1417.417	1337.500	1500.842
2026-08-01	1400.276	1321.436	1479.476
2026-09-01	1418.262	1339.990	1501.600
2026-10-01	1380.582	1306.322	1461.786
2026-11-01	1366.649	1283.355	1448.064
2026-12-01	1362.342	1280.568	1441.553

Mažmeninių benzino kainų 2026 m. prognozė



– Dyzelino

=== Prognozės 2026 (yhat, lower, upper) ===

Date	yhat	yhat_lower	yhat_upper
2026-01-01	1608.651	1511.286	1704.613
2026-02-01	1574.801	1475.158	1666.528
2026-03-01	1586.879	1494.429	1690.773
2026-04-01	1530.895	1427.460	1629.425
2026-05-01	1495.658	1394.936	1587.337
2026-06-01	1559.242	1466.838	1664.946
2026-07-01	1571.297	1470.894	1661.993
2026-08-01	1577.984	1484.551	1681.816
2026-09-01	1593.986	1489.276	1700.764
2026-10-01	1584.343	1486.954	1682.142
2026-11-01	1599.717	1496.476	1705.551
2026-12-01	1580.214	1475.621	1674.951

Mažmeninių dyzelino kainų 2026 m. prognozė

