

Aleksejus SOSIDKO

DAKTARO DISERTACIJA

**MAKROEKONOMINIŲ RODIKLIŲ
NETIKĖTUMŲ POVEIKIO AKCIJŲ
GRAŽAI MODELIAVIMAS**

SOCIALINIAI MOKSLAI,
EKONOMIKA (S 004)
VILNIUS, 2022

MYKOLO ROMERIO UNIVERSITETAS

Aleksejus Sosidko

MAKROEKONOMINIŲ RODIKLIŲ
NETIKĖTUMŲ POVEIKIO AKCIJŲ GRAŽAI
MODELIAVIMAS

Daktaro disertacija
Socialiniai mokslai, ekonomika (S 004)

Vilnius, 2022

Mokslo daktaro disertacija rengta 2017–2021 metais Mykolo Romerio universitete pagal Vytauto Didžiojo universitetui su ISM Vadybos ir ekonomikos universitetu, Mykolo Romerio universitetu ir Vilniaus universitetu Lietuvos Respublikos švietimo, mokslo ir sporto ministro 2019 m. vasario 22 d. įsakymu Nr. V-160 suteiktą doktorantūros teisę.

Mokslinė vadovė:

prof. dr. Ligita Gasparėnienė (Mykolo Romerio universitetas, socialiniai mokslai, ekonomika S 004).

TURINYS

PAVEIKSLAI.....	5
LENTELĖS	7
PRIEDAI	11
PAGRINDINĖS SANTRUMPOS.....	12
PAGRINDINIŲ SĄVOKŲ ŽODYNAS.....	14
ĮVADAS	16
I.AKCIJŲ GRĄŽĄ NAGRINĖJANČIOS TEORIJOS IR JŲ SĄSAJOS SU MAKROEKONOMINIŲ RODIKLIŲ NETIKĖTUMAIS	27
1.1 Akcijų grąžą analizuojantys tyrimai fundamentaliosios analizės aspektu . . .	27
1.1.1 Fundamentaliosios analizės veiksnių ypatumai	27
1.1.2 Makroekonominių rodiklių poveikio akcijų grąžai tyrimų analizė . . .	32
1.2 Akcijų grąžos analizavimo tyrimai efektyvios rinkos hipotezės aspektu	49
1.2.1 Efektyvios rinkos hipotezės teoriniai aspektai.	49
1.2.2 Silpnos formos efektyvios rinkos hipotezės tyrimų analizė.	52
1.2.3 Vidutiniškai stiprios formos efektyvios rinkos hipotezės tyrimų analizė	55
1.3 Akcijų grąžos analizavimo aspektai finansų elgsenos teorijos aspektu	60
1.4 Makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tyrimų analizė ir sąsajos su išanalizuotomis teorijomis	66
II.MAKROEKONOMINIŲ RODIKLIŲ NETIKĖTUMŲ POVEIKIO AKCIJŲ GRĄŽAI MODELIAVIMO METODIKA.....	74
2.1 Makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tirti konceptualaus modelio formavimas	74
2.2 Makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tirti tyrimo metodikos pagrindimas.	78
2.2.1 Tyrimo hipotezių formavimas ir pagrindimas.	78
2.2.2 Tyrimo logika ir specifika.	78
2.3 Tradicinių metodų sudarymo ypatumai.	85
2.4 Dirbtinio intelekto taikymas modeliuojant akcijų grąžą	91
2.5 Statistinio modeliavimo ir mašininio mokymosi skirtumai	97
2.6 Mašininio ir giliojo mokymosi metodų ypatumai	100
2.7 Tyrimo apribojimai	107

III.MAKROEKONOMINIŲ RODIKLIŲ NETIKĖTUMŲ POVEIKIO EURO STOXX 50 AKCIJŲ GRAŽAI MODELIAVIMAS	108
3.1 EURO STOXX 50 akcijų indekso aprašomoji analizė	109
3.2 Makroekonominių rodiklių duomenų analizė.	110
3.3 I tyrimo etapas	119
3.3.1 Regresijos modelių sudarymas ir atranka pagal kriterijus.	119
3.3.2 Sukurtų regresijos modelių prielaidų tikrinimas.	126
3.4 II tyrimo etapas: daigianarės regresijos modelių sudarymas	135
3.5 III tyrimo etapas.	137
3.5.1 Regresijos modelių patikrinimas, ieškant ARCH efektų, ir GARCH modelių sudarymas	137
3.5.2. Mašininio mokymosi modelių sudarymas ir palyginimas su sudarytais tradiciniais modeliais.	142
3.5.3 Modelių tikslumo ir EURO STOXX 50 gražos sąryšio laiko eilutėje analizė	150
MOKSLINĖ DISKUSIJA	154
IŠVADOS.	158
LITERATŪROS SĄRAŠAS.	162
PRIEDAI	173
SANTRAUKA.	205
MOKSLINIŲ PUBLIKACIJŲ SĄRAŠAS	223
SUMMARY	225

PAVEIKSLAI

1 pav.	Disertacinio tyrimo loginė schema	24
2 pav.	Fundamentaliosios analizės kategorijos pagal analizės kryptį	28
3 pav.	Dažniausiai nagrinėjami makroekonominiai rodikliai	32
4 pav.	Akcijų rinkos efektyvumo formos	51
5 pav.	Sprendimų priėmimas pagal finansų elgsenos teoriją	61
6 pav.	Makroekonominių rodiklių netikėtumo tyrimų susietumas su fundamentaliosios analizės, ERH ir finansų elgsenos teorijomis ir jų tyrimais.	67
7 pav.	Akcijų grąžą analizuojančių teorijų ir jų veiksmų santrauka	75
8 pav.	Konceptualus teorinės dalies makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tirti modelis	76
9 pav.	Tyrimo etapai	81
10 pav.	Pagrindinės dirbtinio intelekto šakos	92
11 pav.	Mašininio mokymosi modelių kategorijos	93
12 pav.	Prižiūravimo mokymosi metodų tipai	97
13 pav.	Vienasluoksnio perceptrono pavyzdys	99
14 pav.	Sprendimų medžio metodo loginės schemos pavyzdys	100
15 pav.	GBR modelio loginės schemos pavyzdys	104
16 pav.	EURO STOXX 50 kainos ir grąžos judėjimas nuo 2008 iki 2019 metų	110
17 pav.	Autokoreliacijos ir dalinės autokoreliacijos testai RBVP modeliui, esant scenarijui > 0	137
18 pav.	Ljung-Box testo p-reikšmės RBVP modeliui, esant scenarijui > 0	138
19 pav.	Autokoreliacijos ir dalinės autokoreliacijos testai PP indekso modeliui, esant scenarijui > 0	138
20 pav.	Ljung-Box testo p-reikšmės PP indekso modeliui, esant scenarijui > 0	138
21 pav.	Autokoreliacijos ir dalinės autokoreliacijos testai PP indekso modeliui, esant scenarijui ≥ 0	139
22 pav.	Ljung-Box testo p-reikšmės PP indekso modeliui, esant scenarijui ≥ 0	139
23 pav.	Autokoreliacijos ir dalinės autokoreliacijos testai preliminarių duomenų VKI modeliui, esant scenarijui > 0	140

24 pav.	Ljung-Box testo p-reikšmės preliminarių duomenų VKI modeliui, esant scenarijui > 0	140
25 pav.	Autokoreliacijos ir dalinės autokoreliacijos testai VKI, išskyrus energiją, maistą, alkoholį ir tabaką modeliui, esant scenarijui < 0	141
26 pav.	Ljung-Box testo p-reikšmės VKI, išskyrus energiją, maistą, alkoholį ir tabaką modeliui, esant scenarijui < 0	141
27 pav.	Tradicinio tiesinės regresijos (kairėje) ir atsitiktinio miško (dešinėje) modeliai	143
28 pav.	Tradicinio tiesinės regresijos (kairėje) ir ML tiesinės regresijos (dešinėje) modeliai	144
29 pav.	Tradicinio tiesinės regresijos (kairėje) ir ML tiesinės regresijos (dešinėje) modeliai	145
30 pav.	Tradicinio tiesinės regresijos (kairėje) ir ML tiesinės regresijos (dešinėje) modeliai	146
31 pav.	Tradicinio tiesinės regresijos (kairėje) ir Sprendimų medžio (dešinėje) modeliai	147
32 pav.	EURO STOXX 50 grąžos ir determinacijos koeficientų analizė RBVP rodiklio atveju, esant netikėtumo scenarijui > 0	150
33 pav.	EURO STOXX 50 grąžos ir determinacijos koeficientų analizė pramonės produkcijos rodiklio atveju, esant netikėtumo scenarijui > 0	151
34 pav.	EURO STOXX 50 grąžos ir determinacijos koeficientų analizė pramonės produkcijos rodiklio atveju, esant netikėtumo scenarijui ≥ 0	151
35 pav.	EURO STOXX 50 grąžos ir determinacijos koeficientų analizė preliminarių duomenų VKI rodiklio atveju, esant netikėtumo scenarijui > 0	152
36 pav.	EURO STOXX 50 grąžos ir determinacijos koeficientų analizė preliminarių duomenų VKI išskyrus energiją, maistą, alkoholį ir tabaką (m./m.) rodiklio atveju, esant netikėtumo scenarijui < 0	153

LENTELĖS

1 lentelė. Fundamentaliosios analizės atlikimo būdai	30
2 lentelė. Fundamentaliosios analizės privalumai ir trūkumai.	31
3 lentelė. Vartotojų kainų indekso poveikio akcijų rinkoms apžvalga	33
4 lentelė. Vartotojų kainų indekso empirinių tyrimų atlikimo metodikos charakteristika.	34
5 lentelė. Valiutų kursų poveikio akcijų rinkoms apžvalga.	35
6 lentelė. Valiutų kursų empirinių tyrimų atlikimo metodikos charakteristika.	36
7 lentelė. Palūkanų normos poveikio akcijų rinkoms apžvalga.	37
8 lentelė. Palūkanų normos empirinių tyrimų atlikimo metodikos charakteristika.	38
9 lentelė. Pinigų pasiūlos poveikio akcijų rinkoms apžvalga.	39
10 lentelė. Pinigų pasiūlos empirinių tyrimų atlikimo metodikos charakteristika	40
11 lentelė. BVP poveikio akcijų rinkoms apžvalga	40
12 lentelė. BVP empirinių tyrimų atlikimo metodikos charakteristika.	41
13 lentelė. Nedarbo lygio poveikio akcijų rinkoms apžvalga.	42
14 lentelė. Nedarbo lygio empirinių tyrimų atlikimo metodikos charakteristika	43
15 lentelė. Pramonės produkcijos indekso poveikio akcijų rinkoms apžvalga.	44
16 lentelė. Pramonės produkcijos indekso empirinių tyrimų atlikimo metodikos charakteristika.	45
17 lentelė. Kitų rodiklių poveikio akcijų rinkoms apžvalga.	45
18 lentelė. Kitų rodiklių empirinių tyrimų atlikimo metodikos charakteristika	47
19 lentelė. Makroekonominių rodiklių poveikio akcijų rinkoms apibendrinimas	48
20 lentelė. Silpnos formos efektyvios rinkos hipotezės naujausių mokslinių tyrimų išvados	52
21 lentelė. Silpnos formos efektyvios rinkos hipotezės nustatymo metodai naujausiuose moksliniuose tyrimuose.	53
22 lentelė. Vidutiniškai stiprios formos efektyvios rinkos hipotezės naujausių mokslinių tyrimų išvados	55
23 lentelė. Vidutiniškai stiprios formos efektyvios rinkos hipotezės nustatymo metodai naujausiuose moksliniuose tyrimuose.	57
24 lentelė. Dažniausiai naudojami įvykių tyrimų metodai, susiję su vidutiniškai stipria ERH	58

25 lentelė. Sentimentų sampratos	62
26 lentelė. Lūkesčių sampratos	64
27 lentelė. Sentimentų ir lūkesčių sampratos kertinių žodžių sąsajos	65
28 lentelė. Akcijų kainų ir gražos analizavimo tyrimai makroekonominių rodiklinetikėtumo aspektu	69
29 lentelė. Akcijų gražų analizavimo tyrimų metodai makroekonominių rodiklių netikėtumu aspektu	72
30 lentelė. Makroekonominiai rodikliai ir jų suskirstymas	80
31 lentelė. Regresijos modelių pavyzdžiai iš paminėtų tyrimų	86
32 lentelė. Akcijų gražų modeliavimo tyrimų, taikant mašininio mokymosi metodus, kryptys	94
33 lentelė. Dažniausiai naudojami mašininio mokymosi metodai prognozuojant akcijų gražą	95
34 lentelė. Pagrindiniai sprendimų medžio parametrai ir jų paskirtis	101
35 lentelė. Pagrindiniai atsitiktinio miško parametrai ir jų paskirtis	102
36 lentelė. Sprendimų medžio ir atsitiktinio miško privalumai ir trūkumai	103
37 lentelė. GBR parametrai ir jų paskirtis	105
38 lentelė. Regresijos parametrai ir jų paskirtis	106
39 lentelė. Pinigų rinkos rodiklių duomenų charakteristikos (I dalis)	111
40 lentelė. Pinigų rinkos rodiklių duomenų charakteristikos (II dalis)	112
41 lentelė. Pagrindinių ekonomikos rodiklių duomenų charakteristikos (I dalis) ..	112
42 lentelė. Pagrindinių makroekonominių rodiklių duomenų charakteristikos (II dalis)	113
43 lentelė. Sektorinių makroekonominių rodiklių duomenų charakteristikos (I dalis)	114
44 lentelė. Sektorinių makroekonominių rodiklių duomenų charakteristikos (II dalis)	115
45 lentelė. Vartotojų kainų indeksų rodiklių duomenų charakteristikos (I dalis) ..	116
46 lentelė. Vartotojų kainų indeksų rodiklių duomenų charakteristikos (II dalis) ..	116
47 lentelė. Rinkos nuotaikų ir lūkesčių rodiklių duomenų charakteristikos (I dalis)	117
48 lentelė. Rinkos nuotaikų ir lūkesčių rodiklių duomenų charakteristikos (II dalis)	119

49 lentelė. EURO STOXX 50 gražų modeliai pagal makroekonominių rodiklių netikėtumus su visomis netikėtumo rodiklio reikšmėmis	120
50 lentelė. EURO STOXX 50 gražų modeliai pagal makroekonominių netikėtumų rodiklių netikėtumus, kai netikėtumo rodiklio reikšmės > 0	121
51 lentelė. EURO STOXX 50 gražų modeliai pagal makroekonominių netikėtumų rodiklių netikėtumus, kai netikėtumo rodiklio reikšmės ≥ 0	122
52 lentelė. EURO STOXX 50 gražų modeliai pagal makroekonominių netikėtumų rodiklių netikėtumus kai netikėtumo rodiklio reikšmės < 0	123
53 lentelė. EURO STOXX 50 gražų modeliai pagal makroekonominių netikėtumų rodiklių netikėtumus, kai netikėtumo rodiklio reikšmės ≤ 0	124
54 lentelė. Atrinkti modeliai I tyrimo etapo penktajam žingsniui	125
55 lentelė. RBVP (m./m.) rodiklio regresijos modelio prielaidų tikrinimas, esant > 0 scenarijui	126
56 lentelė. Pramonės produkcijos (m./m.) rodiklio regresijos modelio prielaidų tikrinimas, esant > 0 scenarijui.	127
57 lentelė. Pramonės produkcijos (m./m.) rodiklio regresijos modelio prielaidų tikrinimas, esant ≥ 0 scenarijui.	127
58 lentelė. Preliminarių duomenų vartotojų kainų indekso (m./m.) rodiklio regresijos modelio prielaidų tikrinimas, esant > 0 scenarijui	128
59 lentelė. Vartotojų kainų indekso (m./m.), išskyrus energiją, maistą, alkoholį ir tabaką, rodiklio regresijos modelio prielaidų tikrinimas, esant < 0 scenarijui.	129
60 lentelė. Palūkanų normos rodiklio regresijos modelio prielaidų tikrinimas, esant visiems netikėtumo rodiklio scenarijams	129
61 lentelė. Palūkanų normos rodiklio regresijos modelio prielaidų tikrinimas, esant ≥ 0 scenarijui	130
62 lentelė. Regresijos modelių prielaidų tenkinimo apžvalga	131
63 lentelė. Modelių su mažesnėmis determinacijos reikšmėmis sudarymo apžvalga.	131
64 lentelė. RBVP (m./m.) rodiklio regresijos modelio prielaidų tikrinimas, esant > 0 scenarijui	132
65 lentelė. Preliminarių duomenų vartotojų kainų indekso (m/m) rodiklio regresijos modelio prielaidų tikrinimas, esant > 0 scenarijui	133

66 lentelė. Vartotojų kainų indekso (m./m.), išskyrus energiją, maistą, alkoholį ir tabaką, rodiklio regresijos modelio prielaidų tikrinimas, esant 0 scenarijui	134
67 lentelė. Galutiniai modeliai, kurie tenkina I tyrimo etapo kriterijus ir prielaidas	134
68 lentelė. Daugianariai regresijos modeliai ir jų tikrinimas.	135
69 lentelė. Sukurtų regresijos modelių charakteristikos.	142
70 lentelė. RBVP (m./m.) rodiklio modeliai 4 minutę, kai netikėtumo reikšmės daugiau už 0	143
71 lentelė. Pramonės produkcijos (m./m.) rodiklio modeliai 40 minutę, kai netikėtumo reikšmės daugiau už 0.	144
72 lentelė. Pramonės produkcijos (m./m.) rodiklio modeliai 42 minutę, kai netikėtumo reikšmės daugiau arba lygios už 0.	145
73 lentelė. Preliminarių duomenų vartotojų kainų indekso (m/m) rodiklio modeliai 36 minutę, kai netikėtumo reikšmės daugiau už 0.	146
74 lentelė. Vartotojų kainų indekso (m./m.), išskyrus energiją, maistą, alkoholį ir tabaką, rodiklio modeliai 10 minutę, kai netikėtumo reikšmės mažiau už 0	147
75 lentelė. Tiesinės regresijos ir pagrindinių ML modelių charakteristikos	148
76 lentelė. Hipotezių tikrinimo apibendrinti rezultatai	149
77 lentelė. EURO STOXX 50 pardavimo momento nustatymas	153

PRIEDAI

1 Priedas.	RBVP koreliacinė matrica scenarijui >0 ir EURO STOXX 50 grąžos. . .	173
2 Priedas.	Pramonės produkcijos koreliacinė matrica scenarijui >0 ir EURO STOXX 50 grąžos.	174
3 Priedas.	Pramonės produkcijos koreliacinė matrica scenarijui ≥ 0 ir EURO STOXX 50 grąžos.	175
4 Priedas.	Preliminarių duomenų VKI koreliacinė matrica scenarijui >0 ir EURO STOXX 50 grąžos.	176
5 Priedas.	VKI, išskyrus energiją, maistą, alkoholį ir tabaką, koreliacinė matrica scenarijui <0 ir EURO STOXX 50 grąžos.	177
6 Priedas.	Neuronų tinklo modelio architektūra.	178
7 Priedas.	Atsitiktinio miško modelio architektūra.	179
8 Priedas.	Sprendimų medžio modelio architektūra.	180
9 Priedas.	GBR modelio architektūra	181
10 Priedas.	RBVP ir EURO STOXX 50 duomenų analizė, tvarkymas, koreliacinių matricų sudarymas, modeliavimas, tikrinimas, lyginimas – kodas . . .	182
11 Priedas.	RBVP ir EURO STOXX 50 modeliavimo dalis – kodas	193

PAGRINDINĖS SANTRUMPOS

- AB** – Adaptyvus išpūstų medžių metodas (angl. Adaptive Boosting)
- ARCH** – Autoregresinis sąlyginis heteroskedastiškumo modelis (angl. Auto-Regressive Conditional Heteroskedasticity)
- ARDL** – Autoregresinė paskirstymo atsilikimo procedūra (angl. Autoregressive Distributed Lag)
- ARMA** – Autoregresinis slankiojo vidurkio laiko eilučių modelis (angl. Auto-Regressive Moving Average)
- BPKF** – Bendojo pagrindinio kapitalo formavimo rodiklis
- BRT** – Išpūstų regresijos medžių metodas (angl. Boosted Regression Tree)
- BVAR** – Bayes vektorinės autoregresijos metodas (angl. Bayesian Vector Autoregressive)
- DBN** – Gilusis įsitikinimo neuroninis tinklas (angl. Deep Belief Network)
- DL** – Gilusis mokymasis (angl. Deep learning)
- DT** – Sprendimų medis (angl. Decision Tree)
- ECB** – Europos centrinis bankas
- EGARCH** – Eksponentinis autoregresinis sąlyginio heteroskedastiškumo modelis (angl. Exponential General Auto-Regressive Conditional Heteroskedasticity)
- ELM** – Ekstremalaus mokymosi mašina (angl. Extreme Learning Machine)
- ERH** – Efektyvios rinkos hipotezė
- ES** – Įvykių studijos (angl. Event studies)
- FNN** – Tiesioginio sklidimo neuroniniai tinklai (angl. FeedForward Neural Network)
- GARCH** – Apibendrintas autoregresinis sąlyginio heteroskedastiškumo modelis (angl. Generalized Auto-Regressive Conditional Heteroskedasticity)
- GBR** – Išpūstų medžių metodas (angl. Gradient Boosting Regressor)
- GJD** – Bendrinis difuzijos metodas (angl. Generic jump-diffusion)
- GJR-GARCH** – Glosten, Jagannathan ir Runkle apibendrintas autoregresinis sąlyginio heteroskedastiškumo modelis (angl. Glosten, Jagannathan, and Runkle Generalized Auto-Regressive Conditional Heteroskedasticity)
- GMM** – Apibendrintas momentų metodas (angl. Generalized Method of Moments)
- GRU** – Vartiniai rekurentiniai neuroniniai tinklai (angl. Gated Recurrent Unit)
- HONN** – Didesnių kombinacijų neuroniniai tinklai (angl. Higher Order Neural Network)
- KNN** – K-artimiausių kaimynų metodas (angl. K-Nearest Neighbors)

LDA – Latentinis Dirichlet paskirstymas (angl. Latent Dirichlet allocation)

LR – Tiesinė regresija (angl. Linear Regression)

LRR – Logistinė regresija (angl. Logistic Regression)

LSTM – Ilgos trumpalaikės atminties neuroniniai tinklai (angl. Long Short Term Memory)

MAR – Koreguotasis vidurkio gražos modelis (angl. mean adjusted return model)

MKAR – Koreguotasis rinkos gražos modelis (angl. market adjusted return model)

ML – Mašininis mokymasis (angl. Machine learning)

MSE – Vidutinė kvadratinė paklaida (angl. Mean square error)

NB – Naivus Bajesas (angl. Naive Bayes)

NLP – Natūralios kalbos apdorojimas (angl. Natural language processing)

PC – Pirsono koreliacijos koeficientas (angl. Pearson Correlation)

PCA – Principinių komponentų analizė (angl. Principal Component Analysis)

PMG – Jungiamasis vidurkių grupių metodas (angl. Pooled mean group)

PP – Pramonės produkcija

RA – Regresijos analizė (angl. Regression Analysis)

RAR – Koreguotasis rizikos gražos modelis (angl. risk adjusted return model)

RBVP – Realus bendrasis vidaus produktas

RF – Atsitiktinis miškas (angl. Random Forest)

RMSE – Šaknis iš vidutinės kvadratinės paklaidos (angl. Root mean square error)

RNN – Rekurentiniai neuroniniai tinklai (angl. Recurrent Neural Networks)

SV – Tikimybinis kintamumo metodas (angl. Stochastic Volative)

SVM – Atraminiai vektoriai (angl. Support Vector Machine)

VECM – Vektorinės klaidos taisymo modelių metodas (angl. Vector error Correction Models)

VKI – Vartotojų kainų indeksas (angl. Consumer price index)

VP – Vertybiniai popieriai

PAGRINDINIŲ SĄVOKŲ ŽODYNAS

Akcijos grąža – tai procentinis dydis, rodantis akcijos pelningumą. Apskaičiuojama pagal formulę, iš pardavimo kainos atėmus pirkimo kainą, pridėdant per laikotarpį gautus dividendus ir viską dalinant iš pirkimo kainos. Nuoroda: <https://financeformulas.net/Total-Stock-Return.html>.

Atsitiktinis miškas (angl. Random Forest), sprendimų medis (angl. Decision Tree), GBR – mašininio mokymosi metodai.

Daugialypis, daugianaris (angl. multiple) regresijos modelis skirtas tirti vieno kintamojo priklausomybę nuo kelių nepriklausomų kintamųjų ir prognozuoti vėlesnes vidutines kintamųjų reikšmes.

Determinacijos koeficientas šiame tyrime traktuojamas, kaip modelio tikslumo matas, kuriuo paaiškinama, kiek procentais nepriklausomi kintamieji paaiškina priklausomojo kintamojo reikšmę.

Didelių duomenų dažnių analizė (angl. High frequency data analysis) – akcijų ar kitų VP kainos ar grąžos analizė ir apskaičiavimas dienos, valandos, minutės, sekundės tikslumu.

Dirbtinis intelektas (angl. Artificial Intelligence) – pagal LR ekonomikos ir inovacijų ministerijos dirbtinio intelekto strategijos dokumentą dirbtinis intelektas yra sistemos, kurios demonstruoja protinę ir sumanų elgesį, analizuodamos savo aplinką ir darydamos gana savarankiškus sprendimus tikslui pasiekti. Nuoroda: [https://eimin.lrv.lt/uploads/eimin/documents/files/DI_strategija_LT\(1\).pdf](https://eimin.lrv.lt/uploads/eimin/documents/files/DI_strategija_LT(1).pdf).

Efektyvios rinkos hipotezė – rinka, kuri staigiai reaguoja į naujausią informaciją, o tai reiškia, kad VP kainų prognozavimas ilguoju laikotarpiu neatneštų daugiau grąžos nei bendra finansų rinkos finansinio priemonių krepšelio kaina (Fama, 1965).

Makroekonominio rodiklio netikėtumo matas – tai išvestinis rodiklis, kuris reprezentuoja makroekonominių rodiklių netikėtumą reiškinį. Rodiklio reikšmė apskaičiuojama, iš makroekonominio rodiklio faktinės reikšmės atėmus prognozinę reikšmę, dalinant iš jų skirtumo standartinio nuokrypio.

Makroekonominio rodiklio netikėtumo reikšmės scenarijai – scenarijai pagal netikėtumo reikšmę, kai reikšmės >0 , ≥ 0 , <0 , ≤ 0 ir su visais duomenimis.

Etalonas – standartas, pagal kurį galima įvertinti vertybinių popierių, investicinio fondo ar investicijų valdytojo veiklą. Paprastai šiam tikslui naudojami platūs rinkos ir rinkos segmentų akcijų ir obligacijų indeksai. Šiame tyrime etalonas yra priskiriamas

EURO STOXX 50 indeksui.

EURO STOXX 50 indekso grąža – indekso grąža, apskaičiuojama iš uždarymo kainos atėmus atidarymo kainą ir dalinant iš atidarymo kainos bei dauginant iš 100.

Finansų elgsenos teorija (angl. Behavioral finance) apibrėžiama, kaip mokslas apie finansų rinkų dalyvio psichologijos įtaką priiminėjant finansinius sprendimus (Chandra, 2008).

Fundamentalioji analizė – vertybinio popieriaus įvertinimo metodas, kuriuo siekiama išmatuoti jo vertę, ištyrus susijusius ekonominius, finansinius ir kitus kokybinius bei kiekybinius veiksnius (Sloan, 2019).

Įvykių tyrimai (angl. Event studies) – tyrimai, kurie analizuoja, kaip greitai akcijų kainos prisitaiko prie naujos informacijos apie svarbius ekonominius įvykius pasirinktoje rinkoje (Fama, 1991).

Lūkesčiai (angl. expectations, beliefs, forecasts) šiame darbe traktuojami, kaip makroekonominių rodiklių prognozinės reikšmės.

Mašininis mokymasis – dirbtinio intelekto metodų šaka, kuri apima kūrimą metodų, mokinančių kompiuterius „mąstyti“; tai yra algoritmų/metodų kūrimo būdas, kai sukurta sistema mokosi iš duomenų. Nuoroda: <https://www.expert.ai/blog/machine-learning-definition/>.

Modeliavimas – tai įvairių matematinių ir mašininio mokymosi modelių sukūrimas, siekiant atrasti geriausią modelį, paaiškinantį EURO STOXX 50 grąžos ir makroekonominių rodiklių netikėtumų sąsajas. Kartu su modeliavimu atliekamas ir prognozavimas, siekiant įvertinti, kaip tas modelis veikia.

Neuroninis tinklas (angl. Neural Network) – giliojo mokymosi metodas, kuris buvo sukurtas remiantis žmogaus biologiniu neuroniniu tinklu. Nuoroda: <https://www.investopedia.com/terms/n/neuralnetwork.asp>.

Vidutiniškai stiprios formos efektyvios rinkos hipotezė – hipotezė, kurios VP kainose jau atsispindi visa istorinė VP kainų informacija kartu su viešai prieinama įvykių apie VP informacija (Fama, 1970).

Sentimentai (angl. sentiment) apima bendruosius finansų rinkos dalyvių psichologinius aspektus (nuotaiką, emociją, nusiteikimą) praeities ar ateities laikotarpiu.

Tradicinis statistinis regresijos modelis skirtas tirti vieno kintamojo priklausomybę nuo kito nepriklausomo kintamojo ir prognozuoti vėlesnes vidutines kintamųjų reikšmes.

ĮVADAS

Temos aktualumas. Spartus finansų rinkų vystymasis ir lengvai prieinami finansiniai produktai formuoja vis didesnę mokslininkų, profesionalių ir neprofesionalių investuotojų susidomėjimą vertybinių popierių gražomis ir jas lemiančiais veiksniais. Vienos populiariausios – įmonių akcijos (remiantis Pasaulio banko statistika, akcijų kapitalizacija, apimant visą pasaulį, nuo 2010 metų išaugo ~1,72 karto, ir 2020 m. sudarė ~92 trilijonų JAV dolerių), o jų kainų, gražų pokyčių priežasčių identifikavimas, analizė, prognozavimas ir vertinimas traktuojama, kaip atskira mokslinių tyrinėjimų sritis.

Vieni iš mokslinių tyrinėjimų, kuriais siekiama išprognuoti akcijų gražą, pagrįsti fundamentaliosios analizės koncepcija. Svarbiausia šios analizės prielaida ta, kad rinkoje akcijų gražų pasikeitimus sąlygoja makroekonominiai, ūkio šakos arba sektoriaus, įmonės veiklos ir kt. veiksniai, o šių veiksnių rodiklių kaitos reikšmių analizė yra svarbi dedamoji prognozuojant akcijų gražą. Tuo tarpu kituose moksliniuose tyrinėjimuose teigiama, kad akcijų gražų dinamikai įtakos turi finansų rinkos dalyvių racionali arba (ir) iracionali elgsena. Racionalios elgsenos atstovai yra efektyvios rinkos hipotezės teorijos šalininkai, o iracionalios elgsenos tyrinėtojų atstovai priklauso finansų elgsenos mokslo sričiai.

Dažniausiai finansų rinkos dalyviai labiau linkę patikėti savo investicijas efektyvioms akcijų rinkoms, kurios yra stabilios, patikimos ir kuriomis sunku manipuluoti spekuliaciniais tikslais (darant prielaidą, kad efektyvios rinkos yra išsivysčiusiose šalyse, ir atvirkščiai, tai remiantis Pasaulio banko 2020 m. statistika, išsivysčiusių šalių akcijų rinkų bendra kapitalizacija yra ~2,5 karto didesnė nei besivystančių šalių: atitinkamai ~66 ir ~26 trilijonų JAV dolerių). Nors kiekviena arbitražo galimybė ir gali išbalansuoti net ir vidutiniškai stiprios formos efektyvią akcijų rinką, tačiau tokie veiksniai, kaip informacijos prieinamumas internete, inovatyvūs informaciniai technologiniai sprendimai bei egzistuojantis aukštas elektroninių pinigų mobilumas, tokią tikimybę akivaizdžiai sumažina. Antra vertus, finansų rinkų dalyviai siekia uždirbti kuo didesnę gražą savo rizikos tolerancijos ribose, dėl to skirtingas informacijos apdorojimo lygis, skirtingas galingų analitinių programų turėjimo skaičius, skirtingas gražos ir rizikos suvokimo laipsnis, emocijos ir kt. mažina akcijų rinkų efektyvumą. Esant skirtingam akcijų rinkų efektyvumo lygiui, skirtingam finansų rinkos dalyvių elgsenos tipui, skirtingam finansų rinkos dalyvių gražos poreikiui ir rizikos tolerancijos lygiui, neužtenka taikyti tik fundamentalios arba tik finansų elgsenos, arba tik efektyvios rinkos hipote-

zės teorijų analizių ir modeliavimo metodikų.

Šis supratimas paskatino ieškoti ekonominio reiškinių, kuris įtrauktų ne tik šių teorijų požiūrius teoriniu aspektu, bet ir jas sujungtų, papildytų bei panaikintų jų ribotumus. Taip buvo pastebėtas makroekonominių rodiklių netikėtumų reiškinys, kurio poveikio modeliavimas akcijų grąžai yra mažai plėtojama sritis. Visų pirma, tai lemia duomenų gavimo ribotumas, kai tokio pobūdžio tyrimuose dažniausiai renkami aukšto dažnio akcijų kainų duomenys, o tokių duomenų gavimas tampa sudėtingas, nes reikia mokėti programavimo kalbą ar žinoti, kaip naudotis didelėmis duomenų šaltinių bazėmis. Antra, dėl paprastumo vis dar atliekama daug tyrimų, kurie remiasi vienos akcijų grąžą nagrinėjančios teorijos gairėmis bei specifika, ir pamirštama, kad akcijų rinkos dėl vis didėjančių informacijos srautų tampa vis kompleksiškesnės ir vis sunkiau nuspėjamos. Trečia, kyla dvejonių dėl to, ar tradiciniai metodai, kurie dažniausiai grindžiami viena teorija, vis dar yra tinkami tokio tipo tyrimuose, o naujų metodų paieška ir atranka neretai būna sunkus uždavinys. Taigi duomenų gavimo ribotumas, neaiškus teorijų susietumo, kompleksškumo ir metodų parinkimo klausimas daro makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tematiką itin sudėtingą ir kompleksišką, bet kartu aktualią ir įdomią.

Problemos ištyrimo lygis. Akcijų grąžą aiškinti ir prognozuoti bandoma jau kelis dešimtmečius, ir yra daug tyrimų, kuriuose ieškoma pagrindinių akcijų grąžų pokyčius sąlygojančių veiksnių.

Neretai moksliniai darbai, tyrinėjantys akcijų grąžą, yra grįsti fundamentaliais veiksniais – makroekonomiais ((Graham ir Dodd 1934), Panfil ir Szablewski 2013), (Gurgul ir Wójtowicz 2014), (Sinha ir Kohli 2015), Figurska ir Wisniewski 2016) (Pražak ir Stavarek, 2017), (Pooja ir Giri, 2017), (Chamdrashekar, Sakthivel, Sampath ir Chittedi, 2018), (Ho, 2018), (Abed, Zardoub 2019), (Tetteh, Adenutsi, Amoah 2019), (Erol ir Aytekin 2019) ir kt.), ūkio šakos arba sektoriaus ((Panfil ir Szablewski 2013, (Borowski 2014) ir kt.), įmonės veiklos analizės ((Graham ir Dodd 1934), Figurska ir Wisniewski 2016) ir kt.). Analizuojant makroekonominių rodiklių poveikio akcijų grąžai tyrimus buvo pastebėta, kad mokslininkai dažniausiai tiria mėnesines akcijų indeksų grąžas. Nors rodiklių poveikis nustatytas kaip statistiškai reikšmingas, tačiau neretai akcijų indeksui per mėnesio laikotarpį turi įtakos ir kiti rodikliai, kurie nenagrinėjami. Antras pastebėjimas tas, kad mokslininkai dažniausiai orientuojasi į makroekonominių rodiklių faktines reikšmes, neįvertindami tuo metu rinkoje vyraujančių lūkesčių, kurie taip pat galėtų paveikti akcijų grąžą.

Kiti moksliniai tyrinėjimai, analizuojantys akcijų grąžą, grindžiami racionalia arba iracionalia finansų rinkos dalyvių elgsena. Racionaliosios elgsenos atstovai yra efektyvios rinkos hipotezės šalininkai ((Fama, 1965, 1970), (Malkiel, 1992), (Yen ir Lee, 2008), (Fama ir French, 2015), (Altinkilic, Hansen ir Ye, 2015), (Singh, Leepsa ir Kushwaha 2016), (Sofat, 2016), (Mackey ir Macon, 2017), (Andrade ir Santos, 2017), (Jose ir Suresh, 2017), (Barghouthi ir Ehsan, 2017), (Nagpal ir Jain, 2018) ir kt.). Šios teorijos tyrimai paprastai vadinami įvykių tyrimais. Šiais tyrimais siekiama nustatyti, kaip greitai (minučių, valandos, dienos tikslumu) akcijų kainos prisitaiko prie naujos informacijos apie svarbius makroekonominis įvykius pasirinktoje rinkoje. Tačiau neretai tokio pobūdžio tyrimų modeliuose pasigendama finansų elgsenos elementų, kai modelis apima ne tik faktines bet ir prognozes makroekonominių rodiklių reikšmes.

Iracionaliosios elgsenos tyrinėtojai ((Kahneman ir Tversky 1979), (Shefrin, 2001), (Leipus ir Norvaiša, 2004), Fischer ir Gerhardt, 2007), (Chandra 2008), (De-Bondt, Forbes ir kt., 2010) (Kartašova, 2016, 2012) (Das ir Panja 2019), (Nasiri, Sarraf, Nourollahzadeh, Hamidian, Noorifard 2021) ir kt.) analizuoja psichologinę aspektų įtaką akcijų grąžai ir yra priskiriami finansų elgsenos teorijai. Šiuose tyrimuose akcentuojama, kad sprendimo priėmimas vertybinių popierių aplinkoje yra sudėtingas procesas, kuriam įtakos turi šie veiksniai: asmeniniai, techniniai ir psichologiniai, iš kurių į psichologinius veiksnius įeina sentimentai, o į šiuos ir lūkesčiai. Nors tyrimų kryptį įvairovė, pritaikomumas ir metodų panaudojimų naujumas didelis, tačiau šiuose tyrimuose trūksta to, kas laikoma EHR tyrimų lauko privalumu: didelių dažnių duomenų analizė ir akcijų grąžų modeliavimas per trumpą laiką tarpą.

Minėtų teorijų ir tyrimų ribotumai, taip pat žinojimas, kad laikui bėgant akcijų rinkos tampa vis kompleksiškesnės su vis labiau didėjančiais informacijos srautais, paskatino ieškoti naujo požiūrio ir tyrimų. Taip buvo atrasti makroekonominių rodiklių netikėtumo tyrimai, kurie, autoriaus manymu, ne tik jungia šių teorijų principus, bet ir leidžia atsirasti diskusijai dėl naujo įnašo vystant šias teorijas ir praktiką.

Tokie tyrimai, kurie analizuoja netikėtumo reiškinio poveikį akcijų grąžai, mokslinėje ir nemokslinėje literatūroje paprastai vadinami makroekonominių naujienų, pranešimų, netikėtumų, lūkesčių tyrimais: (Hussain 2010), (Gupta, Reid 2012), (Harju, Hussain 2011), (Gurgul, Wójtowicz 2014), (Miao, Ramchander, Zumwalt 2014), (Chen, Liu, Lu, Tang 2015), (Nadleri, ir Schmidt 2016), (Cakan, Gupta 2017), (Alexiou, Vogiazas ir Taqvi 2018) ir kt. Šie tyrimai įvertina ne tik faktines, bet ir prognozes makroekonominių rodiklių reikšmes, taip sukurdami netikėtumo rodiklį,

kuris ir yra pagrindinis kintamasis modeliuojant akcijų grąžą per trumpą laiko tarpą.

Tačiau atlikta šių tyrimų analizė parodė:

- Nėra pakankamai išplėtota didelių dažnių duomenų analizė, t. y. mokslininkai tokiuose tyrimuose vis dar pasirenka tirti dienes akcijų grąžas, todėl vis dar tampa neaišku, kaip greitai (minučių tikslumu) nagrinėjama vertybinių popierių rinka prisitaiko prie makroekonominių rodiklių netikėtumų;

- trūksta tyrimų, nagrinėjančių euro zonos akcijų rinką, o dažniausiai sutinkami tyrimai buvo atlikti JAV rinkai;

- nė viename darbe nebuvo pastebėta, kad siekiant sukurti tikslesnius prognozavimo modelius, makroekonominių rodiklių netikėtumų reikšmės būtų suskaidytos į įvairius scenarijus.

- vis dar naudojami tradiciniai akcijų grąžų modeliavimo metodai ir atsiribojama nuo naujesnių ir inovatyvių mašininio mokymosi metodų;

- mokslininkų darbuose trūko gerųjų modeliavimo praktikų taikymo, kai remiantis skirtingais metodais sukuriama daugiau nei keli modeliai ir vėliau lyginami tarpusavyje, taip siekiant rasti geriausią.

Būtent dėl šių neišplėtotų požiūrių ir minėtų teorijų bei su jomis susijusių darbų ribotumų yra atliekamas šis tyrimas ir formuluojama mokslinė problema.

Mokslinė problema: kokia yra makroekonominių rodiklių netikėtumų reiškinio esmė, kaip ją įvertinti ir kaip modeliuoti makroekonominių rodiklių netikėtumų poveikį akcijų grąžai tradiciniais ir mašininio mokymosi metodais.

Mokslinio tyrimo objektas – makroekonominių rodiklių netikėtumų poveikis akcijų grąžai.

Tyrimo tikslas – ištirti makroekonominių rodiklių netikėtumų reiškinį ir jo sąsajas su akcijų grąža bei sudaryti ir empiriškai patikrinti makroekonominių rodiklių netikėtumų poveikio akcijų grąžai prognozavimo modelius, panaudojant tradicinius ir mašininio mokymosi metodus.

Tyrimo uždaviniai:

1. Išanalizuoti akcijų grąžą nagrinėjančias teorijas, susijusias su makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliavimo tyrimais.

2. Atskleisti makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliavimo tyrimų metodus.

3. Parengti metodiką makroekonominių rodiklių netikėtumų poveikio akcijų

grąžai modeliuoti.

4. Atskleisti mašininio mokymosi naudojamus metodus, modeliuojant akcijų grąžą, ir jų skirtumą nuo tradicinių metodų.

5. Patikrinti metodiką makroekonominių rodiklių netikėtumų poveikio EURO STOXX 50 grąžai prognozuoti, taikant tradicinius metodus.

6. Patikrinti metodiką makroekonominių rodiklių netikėtumų poveikio EURO STOXX 50 grąžai prognozuoti, taikant mašininio mokymosi metodus.

7. Palyginti gautus empirinius rezultatus, taikant tradicinius ir mašininio mokymosi metodus, makroekonominių rodiklių netikėtumų poveikio EURO STOXX 50 grąžai prognozuoti tarpusavyje bei atlikti modelių tikslumo ir EURO STOXX 50 grąžos sąryšio analizę laiko eilutėje.

Mokslinio tyrimo metodai. Mokslinės literatūros analizės ir sintezės, apibendrinimo, lyginimo ir grafiniai metodai buvo taikomi, siekiant nustatyti dažniausiai sutinkamus požiūrius ir tyrimus analizuojant akcijų grąžą, prognozavimo modelių analizei pateikti ir ribotumams išskirti, netikėtumo rodikliui apibrėžti.

Rengiant metodologinę-empirinę tyrimo dalį, taikyta skaitinė ir grafinė makroekonominių rodiklių duomenų analizė. Indekso grąžos minutei nustatyti naudotos koreliacinės matricos. Tradiciniams modeliams sudaryti naudota regresijos analizė, patikrinti ARCH efektai. Inovatyviems modeliams sudaryti naudoti mašininio mokymosi metodai: regresijos, atsitiktinio miško, sprendimų medžio, GBR ir neuroninių tinklų. Modeliams palyginti tarpusavyje naudoti: determinacijos koeficientai, mažiausių kvadratų paklaidų metodai. Modelių tikslumo ir EURO STOXX 50 grąžos sąryšio analizė atlikta, naudojant lyginamuosius, skaitinius ir grafinius metodus.

Duomenims analizuoti buvo naudojamas programinis paketas „Microsoft Excel“, kuris taikytas makroekonominių rodiklių grafikams sudaryti bei modelio tikslumo EURO STOXX 50 grąžos sąryšio grafikams sukurti. Modeliams atlikti buvo naudojamas „Jupyter Notebook“ paketas. Užklausoms, analizei ir modeliams sukurti naudojama „Python“ programavimo kalba. Pagrindinis makroekonominių rodiklių duomenų šaltinis – „Bloomberg“ duomenų bazė.

Tyrimo apribojimai. Akcijų grąžą paprastai veikia daug reiškinių, tačiau šiame tyrime pasirinktas tik makroekonominių rodiklių netikėtumo reiškinys, darant prielaidą, kad niekas kitas, išskyrus minėtą reiškinį, neveikia pasirinkto akcijų indekso per

trumpą laiko tarpą iki 45 minučių po makroekonominio rodiklio realizacijos momento.

Makroekonominių rodiklių netikėtumų reiškinio sandara šiame tyrime argumentuojama trijų akcijų grąžą nagrinėjančių teorijų atžvilgiu. Yra sakoma, kad reiškinio charakterizuojantis kintamasis turi fundamentalios analizės, finansų elgsenos ir efektyvios rinkos hipotezės elementų. Tai yra unikalus šio tyrimo autoriaus požiūris, kuris gali būti tiek teisingas, tiek neteisingas.

Tyrime darome prielaidą, kad makroekonominių rodiklių netikėtumų poveikis nesitęsia ilgiau nei 45 minutes. Ši prielaida argumentuojama tuo, kad dažniausiai makroekonominių rodiklių realizacija vyksta kas valandą, taip siekiama išvengti akcijų indekso grąžos svyravimo įtraukimo į modelį, kuriam įtakos gali turėti dar nerealizuoti, bet labai finansų rinkose laukiami rodikliai.

Nors tyrimo laikotarpis ir yra reprezentatyvus – 12 metų, tačiau patys makroekonominiai rodikliai pasirodo vidutiniškai maždaug kas mėnesį. Todėl prognozavimo modeliai nėra sudaryti iš daug duomenų, kas gali paveikti modelių tikslumo pasikeitimą, įtraukiant naujų duomenų. Tyrimo laikotarpio parinkimas susijęs ir su duomenų gavimo galimybėmis. Senesnių nei 2008 m. duomenų gauti nepavyko, kas taip pat yra šio tyrimo ribotumas, nes:

- a) neleidžia įvertinti, kaip kito akcijų grąža prieš finansų krizę;
- b) mažiau duomenų, kas daro prognozavimo modelius nestabilius ir mažiau patikimus;
- c) mažiau galimybių sudaryti daugiau modeliavimo scenarijų, pavyzdžiui, kokią poveikį makroekonominių rodiklių netikėtumai turėjo prieš finansų krizę ir po jos.

Prognozavimo modeliai sukurti ne akcijai ar indeksui, kuriuo yra prekiaujama biržoje, o etalonui (akcijų indeksui EURO STOXX 50). Etalonais paprastai nėra prekiaujama akcijų biržose, bet būna sukurti juos „sekantys“ fondai. Tačiau fondų ir etalonų kainų įverčiai ar jų procentiniai pokyčiai ne visada sutampa ar turi sutapti, todėl tai šiek tiek trukdo gautus tyrimų rezultatus paimti ir iškart pritaikyti juos investicinėje veikloje, nebent naudojamas ETF, kuris 100 % sinchronizuojasi su EURO STOXX 50 etalonu. Verta paminėti, kad EURO STOXX 50 indeksas yra išvestinis iš 19 bendrų EURO STOXX regioninių kategorinių sektorių indeksų ir yra didžiausias kategorinis sektoriaus lyderis euro zonoje laisvosios rinkos kapitalizacijos prasme. Indeksas užfiksuoja apie 60 % visos EURO STOXX bendrosios rinkos indekso kapitalizacijos, kuri savo ruožtu apima apie 95 % atstovaujamų šalių laisvosios rinkos kapitalizacijos.

Mokslinė disertacijos vertė ir taikomoji darbo reikšmė.

1. Išanalizavus pagrindines akcijų grąžą aiškinančias teorijas, pateikti šių teorijų tyrimų ribotumai, taip pereinant prie makroekonominių rodiklių netikėtumo reiškinio tyrimų ir jų įnašo vystant šias teorijas ir praktiką. Pastebėta, kad fundamentalios analizės teorijos tyrimai gali būti praplečiami, analizuojant VP grąžą ne mėnesio, bet dienos, minučių ir kitu dažnumu. Galima praplėsti ar modifikuoti fundamentaliosios analizės ir ERH teorijų suvokimą ir į tyrimus įtraukti ne tik faktines rodiklių reikšmes, bet ir prognozes reikšmes, kurios bent iš dalies atspindėtų rinkos lūkesčius, kas yra svarbi dedamoji, parodanti finansų rinkos dalyvių psichologinę būklę. Finansų elgsenos tyrimai gali būti praplečiami, analizuojant ne tik tekstinę informaciją, kuria remiantis kuriami sentimentų rodikliai ir modeliuojamas jų poveikis akcijų grąžai, bet paimant ir makroekonominius rodiklius.

2. Tyrimų, susijusių su makroekonominių rodiklių netikėtumų poveikiu akcijų grąžai, buvo rasta mažai. Todėl šis tyrimas praplečia panašių tyrimų lauką ir įneša naujų rezultatų bei įžvalgų analizuojama tematika. Svarbiausi šio tyrimo išskirtinimai, lyginant su kitais panašios tematikos tyrimais:

a) akcijų grąžą analizuojama labai trumpą laiko tarpą (minutės dažnumu iki 45 minučių);

b) akcijų grąžą analizuojama pagal įvairius makroekonominių rodiklių netikėtumų reikšmių scenarijus;

c) modeliams sudaryti naudojami ne tik tradiciniai, bet ir inovatyvūs – mašininio ir giliojo mokymosi – metodai.

3. Atlikus makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tyrimų analizę buvo nustatyta, kad trūksta tyrimų, nagrinėjančių euro zonos akcijų rinką. Todėl tyrimui atlikti buvo pasirinktas EURO STOXX 50 indeksas – etalonas, taip praplečiant tyrimų rinkas analizuojama tematika.

4. Sukūrus makroekonominių rodiklių netikėtumų poveikio EURO STOXX 50 grąžai prognozavimo modelius tiek tradiciniais, tiek mašininio mokymosi metodais buvo nustatyta, kad mašininio mokymosi modeliai yra kur kas tikslesni. Dėl šio fakto disertacija gali būti naudinga panašios tematikos tyrėjams, pavyzdžiui, tiriant makroekonominių rodiklių netikėtumų poveikį kitoje akcijų rinkoje ir kaip vieną iš metodų pasirenkant mašininio mokymosi metodą.

5. Atlikus modelių tikslumo ir EURO STOXX 50 grąžos sąryšio analizę nustatyta, kokios akumuliuotos grąžos su tam tikru tikslumu galima tikėtis konkrečių par-

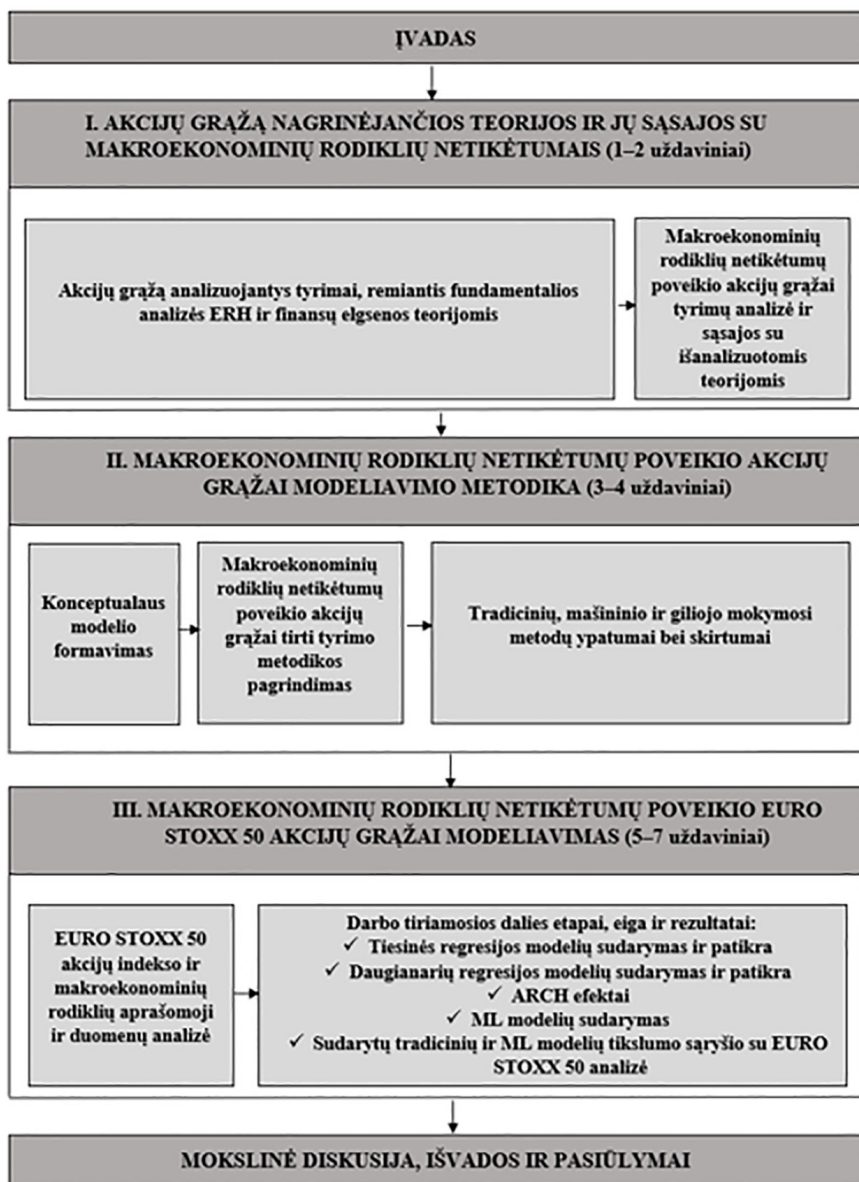
davimo minutę, todėl disertacija gali būti naudinga tiek profesionaliems, tiek neprofesionaliems investuotojams.

Ginamieji disertacijos teiginiai:

- Makroekonominių rodiklių netikėtumo reiškinys jungia fundamentalios analizės, efektyvios rinkos hipotezės ir finansų elgsenos teorijų principus bei leidžia atsirasti diskusijai dėl naujo įnašo vystant šias teorijas ir praktiką.
- Modeliuojant akcijų grąžą per trumpą laiką tikslinga įtraukti makroekonominių rodiklių netikėtumų poveikį.
- Taikant mašininio mokymosi metodus akcijų grąžai prognozuoti, gaunami tikslesni modeliai, nei taikant tradicinius metodus.

Loginė disertacijos struktūra. Disertaciją sudaro įvadas, trys skyriai, mokslinė diskusija, išvados, literatūros sąrašas ir priedai. Disertacijos apimtis – 172 psl. (su priedais – 204 psl.). Naudotasi 137 šaltiniais.

Disertacinio tyrimo loginė schema pateikta 1 paveiksle.



Šaltinis: sudaryta autoriaus

1 pav. Disertacinio tyrimo loginė schema

Pirmajame disertacijos skyriuje išanalizuotos su makroekonominė rodiklių netikėtumais susijusios teorijos, su jomis susiję tyrimai, nagrinėjantys akcijų grąžą. Pateikti fundamentaliosios analizės lygiai, specifika, atlikimo būdai bei privalumai ir trūkumai. Nustatyti dažniausiai naudojami makroekonominiai rodikliai ir pateikti apibendrinti tyrimų rezultatai akcijų grąžai prognozuoti. Pristatyta efektyvios rinkos hipotezės teorija, jos formos ir su teorija susiję tyrimai, nagrinėjantys akcijų grąžą. Atskleista finansų elgsenos teorijos esmė, jos vaidmuo investicinių sprendimo priėmimo procese. Palygintos lūkesčių ir sentimentų sampratos, paaiškinta, kodėl tarp šių sąvokų negalima dėti lygybės ženklą. Pateikta sąsaja tarp makroekonominė rodiklių netikėtumų ir išanalizuotų fundamentaliosios analizės, ERH, finansų elgsenos teorijomis, jų tyrimais. Pateikta, kaip makroekonominė rodiklių netikėtumų tyrimai galėtų praplėsti ar modifikuoti esančias teorijas, jų požiūrius, taikomas praktikas, sumažinti taikomų tyrimų ribotumus. Galiausiai atskleisti makroekonominė rodiklių netikėtumų poveikio akcijų grąžai modeliuoti tyrimuose dažniausiai naudojami metodai.

Antrasis skyrius skirtas makroekonominė rodiklių netikėtumų poveikio akcijų grąžai modeliuoti metodikai parengti bei atskleidžia mašininio mokymosi naudojamus metodus, modeliuojant akcijų grąžą, ir jų skirtumą nuo tradicinių metodų. Skyriaus pradžioje sukuriama makroekonominė rodiklių netikėtumų poveikio akcijų grąžai tirti konceptualusis modelis. Sudaroma ir pagrindžiama tyrimo metodika: formuojamos ir argumentais pagrindžiamos tyrimo hipotezės, paaiškinama sudaryta tyrimo loginė schema ir specifika. Remiantis mokslinių tyrimų analize, pateikiami labiausiai su analizuojama tematika susiję tradicinių metodų ypatumai. Atrandama, kokiose tyrimų kryptyse dažniausiai naudojami dirbtinio intelekto metodai akcijų grąžai modeliuoti. Atskleidžiami statistinio modeliavimo ir mašininio mokymosi skirtumai. Išanalizuojami svarbiausi mašininio ir giliojo mokymosi metodai, ypatumai. Gale pateikiami tyrimo apribojimai.

Trečiasis skyrius modeliuoja makroekonominė rodiklių netikėtumų poveikį EURO STOXX 50 akcijų grąžai. Skyriaus pradžioje pateikiama EURO STOXX 50 akcijų indekso aprašomoji ir pasirinktų makroekonominė rodiklių duomenų analizė. Pirmajame empirinio tyrimo etape sudaromi ir atrenkami tiesinės regresijos modeliai, tikrinamos šių modelių prielaidos. Antrajame empirinio tyrimo etape keliamas klausimas, ar galima sukurti daugianarius regresijos modelius. Trečiajame tyrimo etape patikrinami likę regresijos modeliai, ieškant ARCH efektų, ir, esant poreikiui, kuriami GARCH modeliai. Tada tiems patiems duomenų rinkiniams yra kuriami mašininio

mokymosi metodais pagrįsti modeliai. Gauti tiek tradicinių, tiek mašininio mokymosi modelių rezultatai lyginami tarpusavyje ir nustatoma, kuris modelis geriausiai paaiškina EURO STOXX 50 indekso grąžą konkrečiu atveju. Skyriaus pabaigoje atliekama sukurėtų modelių tikslumo ir EUTO STOXX grąžos sąryšio laiko eilutėje analizė grafiniu metodu. Pateikiama mokslinė diskusija, susijusi su tyrimo rezultatais.

Mokslinių publikacijų disertacijos tema sąrašas

Ligita Gasparėnienė; Rita Remeikienė; Aleksejus Sosidko; Vigita Vėbraitė; Evaldas Raistenskis. Modeling of EURO STOXX 50 index price returns based on industrial production surprises: basic and machine learning approach. *Entrepreneurship and sustainability issues*, vol. 8, no. 2. S1. 2020. Straipsnis DB Clarivate Analytics Web of Science. Vilniaus universitetas

Ligita Gasparėnienė; Rita Remeikienė; Aleksejus Sosidko; Vigita Vėbraitė. A Modelling of S&P 500 Index Price Based on U.S. Economic Indicators: Machine Learning Approach. *Inžinerine Ekonomika-Engineering Economics*, 2021, 32(4), 362–375. DOI: <https://doi.org/10.5755/j01.ee.32.4.27985>

Ligita Gasparėnienė; Aleksejus Sosidko. Evaluation of the unemployment rate announcement impact on Euro Stoxx 50 index returns based on semi-strong efficient market hypothesis. *Whither our economies - 2019 : International scientific conference : conference proceedings*, [vol.] 6. P1c - Straipsnis konferencijos medžiagoje kitose duomenų bazėse. Mykolo Romerio universitetas

Pranešimai mokslinėse konferencijose disertacijos tema

Aleksejus Sosidko. Modeling of Euro stoxx 50 price returns based on core CPI Surprises: Basic and machine learning approach. at the 7th International Scientific Conference “WHITHER OUR ECONOMIES – 2020” held on 17 September, 2020 at Mykolas Romeris University, Lithuania

Aleksejus Sosidko. Evaluation of the unemployment rate announcement impact on Euro Stoxx 50 index returns based on semi-strong efficient market hypothesis. at the 6th International Scientific Conference “WHITHER OUR ECONOMIES – 2019” held on 19-20 September, 2019 at Mykolas Romeris University, Lithuania

I. AKCIJŲ GRAŽĄ NAGRINĖJANČIOS TEORIJOS IR JŲ SĄSAJOS SU MAKROEKONOMINIŲ RODIKLIŲ NETIKĖTUMAIS

1.1 Akcijų grąžą analizuojantys tyrimai fundamentaliosios analizės aspektu

1.1.1 Fundamentaliosios analizės veiksnių ypatumai

Vieni iš mokslinių tyrinėjimų, kuriais siekiama analizuoti akcijų grąžą, yra pagrįsti fundamentaliosios analizės teorija. Anot Klačok ir Kvietkauskienės (2018), kiekvienas investuotojas, sudarydamas investicinį portfelį, siekia maksimizuoti gaunamą grąžą, atsižvelgdamas į prisiimamą rizikos lygį. Mokslininkų teigimu, vienas iš pagrindinių metodų, taikomų vertybinių popierių atrankai, portfelio formavimui bei jo valdymui atlikti yra fundamentalioji analizė.

Fundamentaliosios analizės ištakos siekia 1934 metus, kai Graham ir Dodd išleido knygą, kuri aiškino Didžiosios 1929–1933 metų depresijos laikotarpiu įvykusią akcijų krizę ir investuotojų spekuliatyvų elgesį (Sloan, 2019). Anot Graham ir Dodd (1934), fundamentalioji analizė yra procesas, kurio metu nustatoma, kokie vertybiniai popieriai tinkami investicijoms. Tinkamą investiciją autoriai įvardija, kaip saugumo užuovėją, kuri papildomai generuoja ir priimtina grąžą iš investuoto turto. Pasak Sloan (2019), Graham ir Dodd pasiūlyti fundamentinės analizės metodai stipriai išpopuliarėjo ir padėjo pamatus finansų analitiko profesijos formavimuisi. Iki pat aštuntojo dešimtmečio fundamentaliosios analizės prielaidos ir metodai buvo pagrindinis investavimo būdas. Tik vėliau, atsiradus ir išpopuliarėjus naujoms akcijų grąžą aiškinančioms teorijomis (portfelio teorija, turto įkainojimo teorija, efektyvios rinkos hipotezės teorija ir kt.), atsirado daugiau kritikos šios teorijos atžvilgiu.

Nuo 1934 m. fundamentaliosios analizės samprata kažkiek keitėsi, ir priimtinausi apibrėžimai yra tokie:

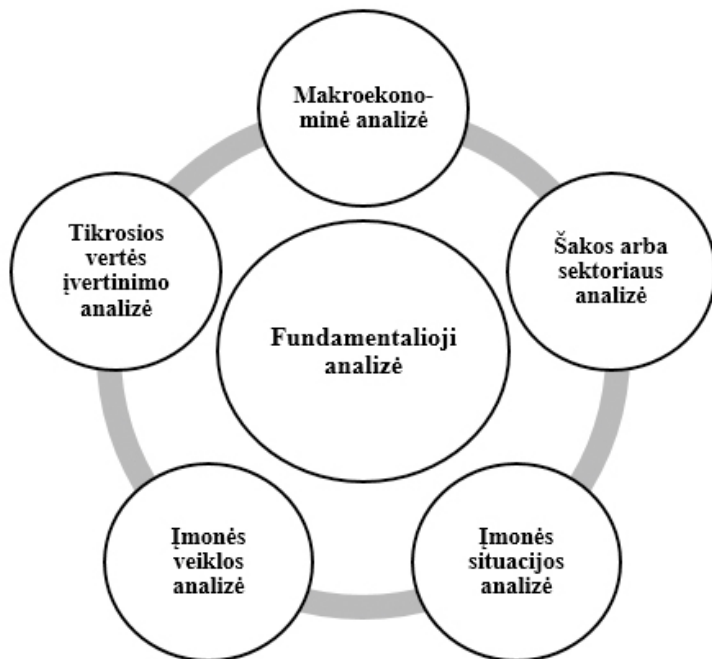
Fundamentalioji analizė yra vertybinio popieriaus įvertinimo metodas, kuriuo siekiama išmatuoti jo vertę, ištyrus susijusius ekonominius, finansinius ir kitus kokybinius bei kiekybinius veiksnius (Sloan, 2019).

Fundamentalioji analizė yra siekis nustatyti skirtumą tarp realios turto vertės ir jos kainos akcijų biržoje (Spahija, Xhaferi, 2019).

Fundamentalioji analizė yra tokia, kuri apibūdina akcijų pasirinkimo metodus,

kurie apima viešai prieinamą duomenų analizės informaciją, kuri skirta įvertinti įmonės veiklos rezultatus ir numatyti jos ateities perspektyvas (Grimm, 2012).

Fundamentaloji analizė yra analizė, kurios tikslas nustatyti VP tikrąją kainą (Damodarand, (2012). Anot Klačok ir Kvietkauskienės (2018), paprastai fundamentaliąją analizę sudaro trijų lygių analizė: makroekonominė, šakos ir įmonės veiklos. Tačiau mokslininkai Figurska, Wisniewski (2016) papildomai išskiria dar du lygius: įmonės situacijos ir tikrosios vertės įvertinimo analizes (žr. 2 pav.).



Šaltinis: sudarytas autoriaus, remiantis Figurska ir Wisniewski (2016).

2 pav. Fundamentaliosios analizės kategorijos pagal analizės kryptį

1. Makroekonominė analizė.

Pasak Figurska ir Wisniewski (2016), į šį etapą įeina tiek išmatuojami makroekonominiai rodikliai (BVP augimo tempas, infliacija, nedarbo lygis, palūkanų norma), tiek ir sunkiai išmatuojami reiškiniai, tokie kaip politinis nestabilumas, mokesčių politika, įdarbinimo taisyklės, mokslinis potencialas, infrastruktūra, demografinė padėtis, socialiniai-kultūriniai įpročiai. Anot Panfil ir Szablewski (2013), kuo geresni konkrečios šalies makroekonominės padėties vertinimo rezultatai, tuo didesnis jos kapitalo rinkos patrauklumas investicijoms.

2. Šakos arba sektoriaus analizė.

Anot Borowski (2014), ši analizė – tai panašių sektorių grupės tyrimas pagal jiems būdingus veiksnius, į kuriuos įeina:

- » istorinė ir numatoma investicijų graža,
- » su investicijomis susijusios rizikos lygis,
- » jautrumas ekonominei padėčiai,
- » padėtis pramonės gyvavimo ciklo žemėlapyje (pradžia, augimas, spartėjimas, branda ir nuosmukis),
- » pokyčių mastas, kryptys ir tempas bei jų priežastys,
- » pirkėjų reakcija į produktų kainų ir kokybės pokyčius,
- » rinkos prisotinimo lygis,
- » paklausos kainų elastingumas.

Panfil ir Szablewski (2013) papildo, kad pagrindinis šios analizės tikslas yra nustatyti aplinkos ir jos pokyčių įtakos konkrečios verslo įmonės ekonominiams rezultatams ir plėtros galimybėms dydį.

3. Įmonės situacijos analizė.

Kaip rašo Figurska ir Wisniewski (2016), įmonės situacijos analizė daugiausia atliekama remiantis nefinansiniais aspektais (vadinamaisiais minkštaisiais veiksniais). Atliekant šią analizę, dažniausiai naudojama SSGG analizė, nagrinėjanti įmonės stipriąsias ir silpnąsias puses, taip pat galimybes ir grėsmes, kylančias dėl aplinkos, kurioje ji egzistuoja, skirstant jas į vidinius ir išorinius veiksnius. Tačiau neįmanoma viena-reikšmiškai įvertinti tokios informacijos poveikio vidinei įmonės vertei, nes tikslų šios procedūros algoritmų dar nėra sukurta. Šių veiksnių svarbos nustatymas, net ir kaip apytikslis, gali padėti objektyvizuoti vidinės vertės vertinimo procesus.

4. Įmonės veiklos analizė.

Tie patys mokslininkai Figurska ir Wisniewski (2016) rašo, kad kitaip nei įmo-

nės situacijos analizė, įmonės veiklos analizė daugiausiai grindžiama kiekybiniais duomenimis ir įvertina bendrą įmonės veiklą (jos ekonominę ir finansinę būklę), remiantis paskelbtų ataskaitų duomenimis: prospekto, periodinių, balanso, pelno ir nuostolių, pinigų srautų, nuosavo kapitalo pokyčių, valdybos posėdžių protokolų ir kontrolės protokolų. Panfil ir Szablewski (2013) papildė, kad be pirmiau minėtų ataskaitų, šiame etape taip pat naudojama per interviu gauta informacija ir išorinė medžiaga, susijusi su įmonės aplinka.

5. Tikrosios vertės įvertinimo analizė.

Anot Figurska ir Wisniewski (2016), galutinis rezultatas ir pagrindinis fundamentinės analizės tikslas yra pasirinkto turto tikrosios vertės įvertinimas. Kaip teigia Panfil ir Szablewski (2013), dėl dviprasmiško suvokimo ir skirtingų tikrosios vertės kategorijų, bei taip pat dėl daugelio veiksnių, turinčių įtakos tam, buvo sukurta daugybė vertinimo metodų: turto ir pajamų, lyginamasis ir mišrusis; tačiau skirtingi požiūriai garantuoja skirtingus rezultatus.

Anot Grimm (2012), fundamentalioji analizė paprastai atliekama vienu iš dviejų būdų: iš apačios į viršų arba iš viršaus į apačią (žr. 1 lent.).

1 lentelė. Fundamentaliosios analizės atlikimo būdai

Analizės atlikimo būdas	Analizės eiga
„Iš viršaus į apačią“ metodas	Visų pirma investuotojai analizuoja ir prognozuoja bendrą šalies ekonomikos būklę, tada pramonės šakų situaciją ir galiausiai įmonės veiklą. Pramonės šakų analizė grindžiama bendra ekonomikos analize, o įmonės veiklos analizė – tiek pramonės šakų, tiek bendros ekonomikos analize.
„Iš apačios į viršų“ metodas	Investuotojai pirmiausia analizuoja ir prognozuoja įmonių veiklą, tada analizuoja pramonės šakas ir bendrą šalies ekonominę būklę.

Šaltinis. Sudaryta autoriaus, remiantis Grimm (2012).

Metodas „iš apačios į viršų“ orientuotas į įmonės, kaip atskiro subjekto, analizę. Ši procedūra neapima išsamios makroekonominių, rinkos ar pramonės sąlygų analizės, bet sutelkia dėmesį į konkrečiai įmonei būdingus požymius, tokius kaip valdymo kokybė, produkto ar paslaugos savybės, sąnaudos, veiklos efektyvumas ir kiti verslo pagrindai. Metodas „iš viršaus į apačią“ yra pati išsamiausia fundamentaliosios analizės forma. Šis metodas prasideda nuo pasaulinės ekonomikos analizės, po to įvertinama rinka, pramonė ir atskiros įmonės sąlygos. Pasirinkimas iš dviejų metodų priklauso

nuo analitikų ar investuotojo pageidavimų ir mokymo. Graham, Dodda ir Buffett naudoja „iš apačios į viršų“ metodą. Tyrimų analitikai, dirbantys vertybinių popierių maklerio įmonėse, paprastai taiko metodą „iš viršaus į apačią“ (Grimm, 2012).

Šio tyrimo autoriaus nuomone, fundamentaliosios analizės atlikimo būdo tinkamumas priklauso nuo investicijos trukmės. Jei investuotojas planuoja pirkti ir laikyti įmonės akcijas trumpą laiką, tada „iš apačios į viršų“ metodas būtų tinkamesnis sprendimas. Jei norima laikyti akcijas ilgesnį laiką, tada svarbu įsivertinti makroekonominius aplinkos veiksnius, ypač teisinius ir politinius, nuo kurių priklauso įmonės mokami mokesčiai ir gaunamos lengvatos. Tokiu atveju rekomenduojamas „iš viršaus į apačią“ būdas.

Klačok ir Kvietkauskienė (2018), vadovaudamosi Lileikienės ir Dervinienės darbu, išskiria fundamentaliosios analizės atlikimo privalumus ir trūkumus (žr. 2 lent.).

2 lentelė. Fundamentaliosios analizės privalumai ir trūkumai

Privalumai	Trūkumai
Apima daug kintamųjų, kurie veikia pasirinktus vertybinius popierius, todėl turimas didelis informacijos kiekis investiciniam sprendimui priimti.	Atliekama analizė yra plati, todėl investuotojui gali būti sunku nustatyti, kokie rodikliai turi stipresnį poveikį vertybinių popierių kainai, o kurie – silpnesnį.
Galima taikyti analizės priemones įvairiems vertybiniams popieriams.	Dėl didžiulio informacijos srauto apdorojimo fundamentalioji analizė tinkamesnė ilgo laikotarpio investiciniams sprendimams priimti. Dažnas analizės naudojimas reikalauja daug išteklių.
Padedą surasti nepakankamai įvertintus vertybinius popierius.	Įmonės darbuotojų pranašumas prieš išorinius investuotojus, kurie portfelyje turi tos įmonės akcijas. Galimai tos įmonės darbuotojai disponuoja vadinamąja „vidine informacija“.

Šaltinis. Sudaryta autoriaus, remiantis Klačok ir Kvietkauskiene (2018).

Apibendrintai galima sakyti, kad pagrindinis šios analizės privalumas yra jos daugialypumas. Tačiau kartu tai yra ir jos trūkumas, nes reikalinga išanalizuoti daug kintamųjų, kas dažnai būna gana sudėtinga. Todėl investuotojai dažnai pasirenka vieną iš 3 ar 5 fundamentaliosios analizės kategorijų ir nagrinėja tik jos poveikį vertybinių popierių kainai.


Išanalizavus įvairių mokslininkų tyrimus matoma, kad fundamentalioji analizė

yra išsamus vertybinių popierių analizės būdas racionaliems investiciniams sprendimams priimti. Dėl tobulėjančių duomenų analizės metodų, jų gausos ir kompiuterinių išteklių šią analizę atlikti tampa vis paprasčiau. Fundamentalioji analizė pagal kryptį skaidoma į penkias kategorijas: makroekonominę analizę, sektoriaus analizę, įmonės situacijos analizę, įmonės veiklos analizę ir tikrosios vertės įvertinimo analizę. Vieni objektyviausių rodiklių, kuriais galima paaiškinti akcijų kainų svyravimus, vadinami makroekonominiais rodikliais, kurie analizuojami tolimesniame skyriuje.

1.1.2 Makroekonominių rodiklių poveikio akcijų grąžai tyrimų analizė

Tyrinėjant VP grąžą analizuojama, kas juos veikia ir kokie procesai aprašo jų kitimą. Kaip buvo aprašyta, vienas iš racionalių akcijų kainų pokyčius aiškinančių būdų yra fundamentalioji analizė. Mokslinėje literatūroje skiriamas didelis dėmesys makroekonominių veiksmų identifikacijai, kuriais remiantis galima objektyviai paaiškinti vertybinių popierių kainų kitimą. Šiuos makroekonominius veiksmus charakterizuoja rodikliai, kurių poveikis akcijų kainai bus analizuojamas šiame skyriuje.

Analizuojant užsienio ir Lietuvos mokslininkų tyrimus šia tematika buvo pastebėta, kad mokslininkai dažnai pasirenka tuos pačius rodiklius savo modeliams sudaryti (žr. 3 pav.).



Šaltinis: sudaryta autoriaus, remiantis 3–18 lentelėse nurodytais mokslininkais.

3 pav. Dažniausiai nagrinėjami makroekonominiai rodikliai

Kaip rodo 3 paveikslas, dažniausiai yra sutinkami 7 makroekonominiai rodikliai.

Toliau tyrime bus aprašomas kiekvienas makroekonominis rodiklis eilės tvarka, kaip nurodyta 3 paveiksle. Prie „kitų“ makroekonominių rodiklių yra priskirti ne taip dažnai sutinkami rodikliai.

Pirmasis makroekonominis rodiklis, nuo kurio pradedama ši analizė, yra

infliacija (žr. 3 lent.). Infliacija vadinamas bendrojo kainų lygio kilimas, dėl kurio krinta piniginio vieneto perkamoji galia. Ji paprastai matuojama santykinu rodikliu, vadinamu vartotojų kainų indeksu (VKI). Šiuo rodikliu išreiškiamas vartojimo prekių ir paslaugų, kurias namų ūkiai perka vartojimo reikmėms, bendras kainų pokytis per tam tikrą laikotarpį. VKI gali būti suprantamas kaip rodiklis, parodantis pinigų sumą, kurią vidutinis vartotojas išleistų ataskaitiniais metais pirkdamas tą patį kiekį tų pačių prekių ir paslaugų, už kurį baziniais metais būtų sumokėjęs 100 piniginių vienetų.

3 lentelė. Vartotojų kainų indekso poveikio akcijų rinkoms apžvalga

Metai	Autorius (-iai)	Poveikis rinkai	Šalis (-ys)
2019	Tetteh J.E., Adenutsi D.E., Amoah A.	-	Gana
2019	Abed R.E., Zardoub A.	+	Vokietija
2019	Erol A.F., Aytekin S.	+	Turkija
2018	Chamdrashekar R., Sakthivel P., Sampath T., Chittedi K.R.	-	Indija, Brazilija
2018	Ho S.Y.	-	Pietų Afrika
2018	Garg K., Kalra R.	-	Indija
2018	Celebi K., Honig M.	-	Vokietija
2017	Alam N.	+	Indija
2017	Giri A.K., Pooja J.	+	Indija
2017	Jurkšas L., Paškevičius A.	-	Lietuva

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktų tyrimų matoma, kad rodiklio poveikis VP kainoms gali būti dvejopas: teigiamas arba neigiamas. Teigiamas reikštų, kad rodiklio didėjimas turi teigiamą poveikį nagrinėjamos akcijų rinkoms. Dažniausiai tai siejasi su išaugusiu vartojimu. Žmonės aktyviau leidžia pinigus arba investuoja, kadangi žino, kad pinigai esamu metu turi didesnę perkamąją galią nei turės artimiausiu metu. Kuo didesnis vartojimas, tuo labiau įmonių pajamos auga, tuo lemdamos akcijų kainų kilimą. Neigiamas reikštų, kad rodiklio didėjimas turi neigiamą (dar vadinamą atvirkštiniu) poveikį. Tyrimai rodo, kad per aukštą infliaciją nėra traktuojama kaip geras ženklas ekonomikai. Paprastai tai siejama su per dideliais pinigų nuvertėjimo tempais. Siekiant mažesnio pinigų nuvertėjimo poveikio, paprastai atliekamos investicijos, o per dideli infliacijos šuoliai gali paskatinti iki galo neapgalvotus įmonių investicinius sprendimus.

Taip pat pastebima, kad analizei atlikti mokslininkai dažniausiai pasirenka vienos šalies vertybinius popierius. Paprastai šalies vertybinių popierių rinką atspindi akcijų indeksai, dėl to daugelyje darbų nagrinėjamos ne atskiros įmonės, o vienas ar keli akcijų indeksai. Pavyzdžiui, Celebi, Honig (2018) tyrinėjo DAX 30 indeksą, Jurkšas, Paškevičius (2017) – NASDAQ OMX Vilnius indeksą ir t. t.

Pereinant prie detalesnės VKI tyrimų analizės, verta pateikti, kokiais metodais mokslininkai vadovaujasi, modeliudami rodiklio poveikį akcijų rinkoms (žr. 4 lent.).

4 lentelė. Vartotojų kainų indekso empirinių tyrimų atlikimo metodikos charakteristika

Metai	Autorius (-iai)	Tyrimo imtis (nuo-iki) m.	Duomenų dažnumo tipas	Tyrimo metodai modeliui sudaryti
2019	Tetteh J.E., Adenutsi D.E., Amoah A.	2001–2016	Mėnesinis	RA
2019	Abed R.E., Zardoub A.	1990–2016	Ketvirtinis	ARDL
2019	Erol A.F., Aytekin S.	2009–2018	Ketvirtinis	RA
2018	Chamdrashekar R., Sakthivel P., Sampath T., Chittedi K.R.	2000–2016	Mėnesinis	RA
2018	Ho S.Y.	1975–2015	Metinis	ARDL
2018	Garg K., Kalra R.	1991–2017	Mėnesinis	PC
2018	Celebi K., Honig M.	1991–2016	Metinis	RA GARCH
2017	Alam N.	2005–2013	Mėnesinis	RA GARCH
2017	Giri A.K., Pooja J.	1979–2014	Metinis	ARDL VECM
2017	Jurkšas L., Paškevičius A.	2000–2013	Ketvirtinis	ARDL

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktos lentelės matoma, kad vidutinė tyrimų apimtis yra 18 metų. Taigi sukurti modeliai apima kelis ekonominio ciklo periodus, kas yra gerai, nes įvertinami

pakilimai ir nuosmukiai.

Pagal duomenų tipą autoriai renka mėnesinius, ketvirtinius, metinius akcijų indeksų kainų duomenis. Duomenų dažnumo tipo pasirinkimas dažniausiai priklauso nuo to, ar pavyksta gauti duomenis. Kuo duomenys dažnesni, tuo patikimesnis modelis. Taigi pagal minėtus tyrimus objektyviausi modeliai yra sudaryti pagal mėnesio akcijų indekso kainų duomenis.

Skirtingų metodų modeliams sudaryti buvo rasta 7 metodai. Dažniausiai naudojamas yra regresijos analizės metodas. Metodas daugiausia naudojamas sudarant paprastos tiesinės ir daugialypės regresijos modelius.

Antrasis makroekonominis rodiklis yra valiutos kursas (žr. 5 lent.). Valiutos kursas – kaina, kuri mokama šalies valiuta už kitos šalies piniginių vienetą. Lietuvos atveju valiutos kursas parodo užsienio valiutos kiekį už 1 Eur.

5 lentelė. Valiutų kursų poveikio akcijų rinkoms apžvalga

Metai	Autorius (-iai)	Poveikis rinkai	Šalis (-ys)
2019	Tetteh J.E., Adenutsi D.E., Amoah A.	-	Gana
2019	Naseem S., Rizwan F., Abbas Z., Rehman M.Z.	+	Pakistanas
2018	Hashim S.L.M., Mohammad H.R., Rosly A.M.	-	Malaizija
2018	Chamdrashekar R., Sakthivel P., Sampath T., Chittedi K.R.	+	Indija, Brazilija
2018	Sousa A.M., Noriller A.M., Huppess C.M., Lopes A.C.V., Meurer R.M.	+	Argentina, Brazilija, Meksika, Čilė, Peru
2018	Garg K., Kalra R.	+	Indija
2018	Celebi K., Honig M.	+	Vokietija
2017	Alam N.	-	Indija
2017	Giri A.K., Pooja J.	+	Indija
2014	Alam A., Rashid k.	-	Pakistanas

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktų tyrimų matoma, kad rodiklio poveikis vertybinių popierių kainoms gali būti dvejopas: teigiamas arba neigiamas. Teigiamas poveikis dažniausiai būdingas

į importą orientuotoms įmonėms. Jei valiutų kursas yra sustiprėjęs, tada importu užsiimančių įmonių veiklos rezultatai tikėtina gerės, nes prekių už tą pačią sumą galės įsigyti daugiau nei kad anksčiau. Neigiamas poveikis dažniausiai būdingas atviroms, į eksportą orientuotoms įmonėms. Jei valiutų kursas yra sustiprėjęs, tada eksportu užsiimančių įmonių veiklos rezultatai tikėtina blogės, nes įeiti į rinką su aukštesnėmis kainomis gali būti keblu.

Kaip ir su VKI rodikliu, tyrimui atlikti mokslininkai dažniausiai pasirenka tirti vienos šalies akcijų indeksą.

Pereinant prie detalesnės valiutų kursų tyrimų analizės, verta pateikti, kokiais metodais mokslininkai vadovaujasi, modeliudami rodiklio poveikį akcijų rinkoms (žr. 6 lent.).

6 lentelė. Valiutų kursų empirinių tyrimų atlikimo metodikos charakteristika

Metai	Autorius (-iai)	Tyrimo imtis (nuo-iki) m.	Duomenų dažnumo tipas	Tyrimo metodai modeliui sudaryti
2019	Tetteh J.E., Adenutsi D.E., Amoah A.	2000–2016	Mėnesinis	RA
2019	Naseem S., Rizwan F, Abbas Z., Rehman M.Z.	2011–2018	Mėnesinis	RA
2018	Hashim S.L.M., Mohamad H.R., Rosly A.M.	2010–2014	Mėnesinis	RA
2018	Chamdrashekar R., Sakthivel P., Sampath T., Chittedi K.R.	2000–2016	Mėnesinis	RA
2018	Sousa A.M., Noriller A.M., Huppes C.M., Lopes A. C.V., Meurer R.M.	2010–2017	Metinis	GMM
2018	Garg K., Kalra R.	1991–2017	Mėnesinis	PC
2018	Celebi K., Honig M.	1991–2016	Metinis	GARCH RA
2017	Alam N.	2005–2013	Mėnesinis	GARCH RA
2017	Giri A.K., Pooja J.	1979–2014	Metinis	ARDL VECM
2014	Alam A., Rashid k.	2001–2011	Mėnesinis	GARCH

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktos lentelės matoma, kad vidutinė tyrimų apimtis yra 15 metų, taigi sukurti modeliai apima kelis ekonominius ciklo periodus. Pagal duomenų tipą autoriai renkami mėnesinius ir metinius akcijų indeksų kainų duomenis, taigi tikėtina, kad objektyviausi modeliai buvo sudaryti pagal mėnesio akcijų indekso kainų duomenis. Skirtingų metodų modeliams sudaryti buvo rasti 8 metodai. Dažniausiai naudojamas yra regresijos analizės metodas.

Trečiasis makroekonominis rodiklis yra palūkanų norma (žr. 7 lent.). Palūkanų norma – mažiausia pinigų skolinimosi kaina konkrečiu momentu, kurią nustato centriniai bankai (Europos atveju Europos centrinis bankas, JAV atveju – Federalinis rezervų bankas). Kuo ji mažesnė, tuo daugiau pinigų išleidžiama į apyvartą, tuo pigiau galima pasiskolinti finansų rinkoje, ir atvirkščiai, kuo ji didesnė, tuo mažiau pinigų įliejama į finansų rinkas, tuo didesni skolinimosi kaštai tampa.

7 lentelė. Palūkanų normos poveikio akcijų rinkoms apžvalga

Metai	Autorius (-iai)	Poveikis rinkai	Šalis (-ys)
2019	Tetteh J.E., Adenutsi D.E., Amoah A.	-	Gana
2019	Abed R.E., Zardoub A.	-	Vokietija
2018	Hashim S.L.M., Mohammad H.R., Rosly A.M.	-	Malaizija
2018	Chamdrashekar R., Sakthivel P., Sampath T., Chittedi K.R.	-	Indija, Brazilija
2018	Ho S.Y.	-	Pietų Afrika
2018	Celebi K., Honig M.	-	Vokietija
2017	Alam N.	-	Indija
2017	Pražak T., Stavrek D.	-	Vengrija, Čekija, Slovakija, Lenkija
2014	Alam A., Rashid k.	-	Pakistanas

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktų tyrimų matoma, kad rodiklio didėjimas turi neigiamą poveikį vertybinių popierių kainoms. Esant didėjimo tendencijai, brangsta skolinimosi kaštai, o tai koreliuoja su mažėjančiu vartojimu. Mažesnis vartojimas mažina įmonių pajamas ir kartu akcijų kainas.

Kaip ir su VKI ir valiutos kurso rodikliais, tyrimui atlikti mokslininkai dažniau-

siai pasirenka tirti vienos šalies akcijų indeksą.

Pereinant prie detalesnės palūkanų normos tyrimų analizės, verta pateikti, kokiais metodais mokslininkai vadovaujasi, modeliuodami rodiklio poveikį akcijų rinkoms (žr. 8 lent.).

8 lentelė. Palūkanų normos empirinių tyrimų atlikimo metodikos charakteristika

Metai	Autorius (-iai)	Tyrimo imtis (nuo-iki) m.	Duomenų dažnumo tipas	Tyrimo metodai modeliui sudaryti
2019	Tetteh J.E., Adenutsi D.E., Amoah A.	2000–2016	Mėnesinis	RA
2019	Abed R.E., Zardoub A.	1990–2016	Ketvirtinis	ARDL
2018	Hashim S.L.M., Mohammad H.R., Rosly A.M.	2010–2014	Mėnesinis	RA
2018	Chamdrashekar R., Sakthivel P., Sampath T., Chittedi K.R.	2000–2016	Mėnesinis	RA
2018	Ho S.Y.	1975–2015	Metinis	ARDL
2018	Celebi K., Honig M.	1991–2016	Metinis	GARCH RA
2017	Alam N.	2005–2013	Mėnesinis	GARCH RA
2017	Pražak T., Stavrek D.	2005–2014	Ketvirtinis	VECM
2014	Alam A., Rashid k.	2001–2011	Mėnesinis	GARCH

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktos lentelės matoma, kad vidutinė tyrimų apimtis yra 17 metų. Taigi sukurti modeliai apima kelis ekonominius ciklo periodus. Pagal duomenų tipą autoriai renkasi mėnesinius, ketvirtinius, metinius akcijų indeksų kainų duomenis, taigi tikėtina, kad objektyviausi modeliai buvo sudaryti pagal mėnesio akcijų indekso kainų duomenis. Skirtingų metodų modeliams sudaryti buvo rasti 6 metodai. Dažniausiai naudojamas yra regresijos analizės metodas.

Ketvirtasis makroekonominis rodiklis yra pinigų pasiūla (žr. 9 lent.). Pinigų

pasiūla – valiutos ir kitų likvidžių priemonių atsargos, cirkuliuojančios šalies ekonomikoje tam tikru metu. Pinigų pasiūlą gali sudaryti gryniesi pinigai, monetos, kelionės čekiai, taupomieji indėliai, trumpalaikiai terminuoti ir ilgalaikiai terminuoti indėliai, banko vekseliai, obligacijos ir kt.

9 lentelė. Pinigų pasiūlos poveikio akcijų rinkoms apžvalga

Metai	Autorius (-iai)	Poveikis rinkai	Šalis (-ys)
2018	Hashim S.L.M., Mohammad H.R., Rosly A.M.	+	Malaizija
2018	Celebi K., Honig M.	+	Vokietija
2017	Alam N.	+	Indija
2017	Pražak T., Stavrek D.	+	Vengrija, Čekija, Slovakija, Lenkija
2017	Jurkšas L., Paškevičius A.	+	Lietuva
2015	Singh G.	+	Indija
2013	Forson J.A., Janrattanagul A.	+	Tailandas

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktų tyrimų matoma, kad rodiklio didėjimas turi teigiamą poveikį vertybinių popierių kainoms. Paprastai tai aiškinama tuo, kad fiziniai ir juridiniai asmenys disponuoja vadinamaisiais papildomais pinigais, kuriuos dažnai nori panaudoti investicijoms į vertybinius popierius.

Kaip ir su VKI ir valiutos kurso bei palūkanų normos rodikliais, tyrimui atlikti mokslininkai dažniausiai pasirenka tirti vienos šalies akcijų indeksą.

Pereinant prie detalesnės pinigų pasiūlos tyrimų analizės, verta pateikti, kokiais metodais mokslininkai vadovaujasi, modeliudami rodiklio poveikį akcijų rinkoms (žr. 10 lent.).

10 lentelė. Pinigų pasiūlos empirinių tyrimų atlikimo metodikos charakteristika

Metai	Autorius (-iai)	Tyrimo imtis (nuo-iki) m.	Duomenų dažnumo tipas	Tyrimo metodai modeliui sudaryti
2018	Hashim S.L.M., Mohammad H.R., Rosly A.M.	2010–2014	Mėnesinis	RA
2018	Celebi K., Honig M.	1991–2016	Metinis	GARCH RA
2017	Alam N.	2005–2013	Mėnesinis	GARCH RA
2017	Pražak T., Stavrek D.	2005–2014	Ketvirtinis	VECM
2017	Jurkšas L., Paškevičius A.	2000–2013	Ketvirtinis	ARDL
2015	Singh G.	2007–2014	Mėnesinis	VECM
2013	Forson J.A., Janrattanagul A.	1990–2009	Mėnesinis	VECM

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktos lentelės matoma, kad vidutinė tyrimų apimtis yra 11 metų. Taigi sukurti modeliai apima kelis ekonominio ciklo periodus (išskyrus pirmąjį). Pagal duomenų tipą autoriai renkasi mėnesinius, ketvirtinius, metinius akcijų indeksų kainų duomenis, taigi tikėtina, kad objektyviausi modeliai buvo sudaryti pagal mėnesio akcijų indekso kainų duomenis. Skirtingų metodų modeliams sudaryti buvo rasta 4 metodai. Dažniausiai naudojamas yra regresijos analizės metodas.

Penktasis makroekonominis rodiklis yra bendrasis vidaus produktas (žr. 11 lent.). Bendrasis vidaus produktas (BVP) yra vienas iš pagrindinių rodiklių, rodančių šalies ekonomikos išsivystymo lygį. Bendrasis vidaus produktas yra apibrėžiamas, kaip galutinė prekių ir paslaugų, sukurtų šalyje, rinkos vertė per tam tikrą laiko tarpą.

11 lentelė. BVP poveikio akcijų rinkoms apžvalga

Metai	Autorius (-iai)	Poveikis rinkai	Šalis (-ys)
2019	Tetteh J.E., Adenutsi D.E., Amoah A.	+	Gana
2018	Ho A.Y.	+	Pietų Afrika

Lentelės tęsinys 41 psl

Lentelė atkelta iš 40 psl.

2018	Sousa A.M., Noriller A.M., Huppes C.M., Lopes A.C.V., Meurer R.M.	-	Argentina, Brazilija, Meksika, Čilė, Peru
2018	Garg K., Kalra R.	+	Indija
2017	Pražak T., Stavarek D.	+	Vengrija, Čekija, Slovakija, Lenkija
2017	Giri A.K., Pooja J.	+	Indija
2017	Jurkšas L., Paškevičius A.	-	Lietuva
2016	Jareno F., Negrut L.	+	JAV

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktų tyrimų matoma, kad rodiklio poveikis vertybinių popierių kainoms gali būti dvejopas: teigiamas arba neigiamas. Teigiamas poveikis dažniausiai pasireiškia per investuotojų pasitikėjimą šalies ekonomika, kuris išreiškiamas BVP dydžio absoliutine reikšme arba procentine reikšme, kuri parodo šalies augimo tempą praėjusiu periodu. Kuo didesnis BVP absoliutinė reikšmė arba augimo tempas, lyginant su kitomis šalimis, tuo šalis yra patrauklesnė vidaus ir užsienio investuotojams, kas ir veikia vertybinių popierių kainų didėjimą. Jurkšas ir Paškevičius (2017) teigia, kad neigiamą poveikį lemia investuotojai, kurie prieš pat rodiklio paskelbimą parduoda akcijas. Tokius veiksmus lemia pačių investuotojų suprognuozuoti BVP įverčiai.

Kaip ir su VKI ir valiutos kurso, palūkanų normos ir pinigų pasiūlos rodikliais, tyrimui atlikti mokslininkai dažniausiai pasirenka tirti vienos šalies akcijų indeksą.

Pereinant prie detalesnės BVP tyrimų analizės, verta pateikti, kokiais metodais mokslininkai vadovaujasi, modeliudami rodiklio poveikį akcijų rinkoms (žr. 12 lent.).

12 lentelė. BVP empirinių tyrimų atlikimo metodikos charakteristika

Metai	Autorius (-iai)	Tyrimo imtis (nuo iki) m.	Duomenų dažnumo tipas	Tyrimo metodai modeliui sudaryti
2019	Tetteh J.E., Adenutsi D.E., Amoah A.	2000–2016	Mėnesinis	RA
2018	Ho A.Y.	1975–2015	Metinis	ARDL

Lentelės tęsinys 42 psl.

Lentelė atkelta iš 41 psl.

2018	Sousa A.M., Noriller A.M., Huppes C.M., Lopes A. C.V., Meurer R.M.	2010–2017	Metinis	GMM
2018	Garg K., Kalra R.	1991–2017	Mėnesinis	PC
2017	Pražak T., Stavarek D.	2005–2014	Ketvirtinis	VECM
2017	Giri A.K., Pooja J.	1979–2014	Metinis	ARDL VECM
2017	Jurkšas L., Paškevičius A.	2000–2013	Ketvirtinis	ARDL
2016	Jareno F., Negrut L.	2008–2014	Ketvirtinis	PC

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktos lentelės matoma, kad vidutinė tyrimų apimtis yra 19 metų. Taigi sukurti modeliai apima kelis ekonominius ciklo periodus. Pagal duomenų tipą autoriai renkasi mėnesinius, ketvirtinius, metinius akcijų indeksų kainų duomenis, taigi tikėtina, kad objektyviausi modeliai buvo sudaryti pagal mėnesio akcijų indekso kainų duomenis. Skirtingų metodų modeliams sudaryti buvo rasti 7 metodai. Dažniausiai naudojamas yra vektorinės klaidos taisymo metodas.

Šeštasis makroekonominis rodiklis yra nedarbo lygis (žr. 13 lent.). Nedarbo lygis – nedirbančių asmenų, kurie galėtų ir norėtų dirbti (bedarbių), tačiau neturi tokios galimybės, santykis su visais darbingais asmenimis, išreikštas procentais.

13 lentelė. Nedarbo lygio poveikio akcijų rinkoms apžvalga

Metai	Autorius (-iai)	Poveikis rinkai	Šalis (-ys)
2019	Celebi K., Honig M.	+	Vokietija
2018	Garg K., Kalra R.	-	Indija
2018	Celebi K., Honig M.	+	Vokietija
2018	Umar B., Nayan S.	+	Afrika (12 šalių)
2017	Pražak T., Stavarek D.	-	Vengrija, Čekija, Slovakija, Lenkija
2016	Jareno F., Negrut L.	-	JAV
2016	Filip B.F	-	ES (28 šalių)

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktų tyrimų matoma, kad rodiklio poveikis vertybinių popierių kainoms gali būti dvejopas: neigiamas arba teigiamas. Paprastai didesnis nedarbo lygis turi įtakos mažėjančiam vartojimui ir smukusioms investicijoms. Šie veiksniai mažina įmonių pelną ir akcijų kainas. Anot Celebi ir Honig (2019, 2018), teigiamą rodiklio poveikį gali skatinti rinkos dalyvių lūkesčiai dėl ekspansyvos fiskalinės ir monetarinės politikos, pavyzdžiui, suteikiant subsidijas verslui ir pan. Panašiai rašo ir Umar bei Nayan (2018). Pasak mokslininkų, didėjantis nedarbo lygis gali skatinti rinkos dalyvių lūkesčius dėl palūkanų normos mažėjimo, kas lemtų mažesnius skolinimosi kaštus.

Kaip ir su VKI ir valiutos kurso, palūkanų normos, pinigų pasiūlos rodikliais ir BVP tyrimui atlikti mokslininkai dažniausiai pasirenka tirti vienos šalies akcijų indeksą.

Pereinant prie detalesnės nedarbo lygio tyrimų analizės, verta pateikti, kokiais metodais mokslininkai vadovaujasi, modeliuodami rodiklio poveikį akcijų rinkoms (žr. 14 lent.).

14 lentelė. Nedarbo lygio empirinių tyrimų atlikimo metodikos charakteristika

Metai	Autorius (-iai)	Tyrimo imtis (nuo-iki) m.	Duomenų dažnumo tipas	Tyrimo metodai modeliui sudaryti
2019	Celebi K., Honig M.	1991–2018	Mėnesinis	RA
2018	Garg K., Kalra R.	1991–2017	Mėnesinis	PC
2018	Celebi K., Honig M.	1991–2016	Metinis	GARCH RA
2018	Umar B., Nayan S.	1996–2016	Metinis	PMG
2017	Pražak T., Stavarek D.	2005–2014	Ketvirtinis	VECM
2016	Jareno F., Negrut L.	2008–2014	Ketvirtinis	PC
2016	Filip B.F	2000–2013	Metinis	RA

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktos lentelės matoma, kad vidutinė tyrimų apimtis yra 16 metų. Taigi sukurti modeliai apima kelis ekonominius ciklo periodus. Pagal duomenų tipą auto

Septintasis makroekonominis rodiklis yra pramonės produkcijos pokyčiai (žr. 15 lent.). Pramonės produkcijos pokyčių pasikeitimas matuojamas pramonės produkcijos indeksu, kuris parodo produkcijos apimtį pokyčius per tam tikrą laikotarpį. Mėnesiniai rezultatai lyginami su iki ataskaitinių ir ankstesnių metų atitinkamu mėnesiu bei su bazinių metų vidutiniu mėnesiu. Sezono ir darbo dienų įtaka pašalinama (žr. 15 lent.).

15 lentelė. Pramonės produkcijos indekso poveikio akcijų rinkoms apžvalga

Metai	Autorius (-iai)	Poveikis rinkai	Šalis (-ys)
2019	Erol A.F., Aytekin S.	+	Turkija
2018	Chandrasekar R., Sakthivel P., Sampath T., Chittedi K.R.	+	Indija, Brazilija
2018	Tiryaki H.N., Tiryaki A.	+	Turkija
2017	Alam N.	+	Indija
2016	Jareno F., Negrut L.	+	JAV
2014	Alam Z., Rashif K.	+	Pakistanas
2013	Forson J.A., Janrattanagul J.	-	Tailandas

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktų tyrimų matoma, kad rodiklio poveikis vertybinių popierių kainoms gali būti dvejopas: teigiamas arba neigiamas. Teigiamam pokyčiui turi įtakos didėjančios pramonės produkcijos užsakymo apimtys, kurios sukuria papildomas darbo vietas, skatina įmonių plėtojimąsi, kas lemia įmonių didėjančius pelnus ir akcijų kainas. Neigiamo pokyčio atvejis buvo užfiksuotas Pakistane. Autoriai ekonominio paaiškinimo tam neturėjo, todėl priėjo prie išvados, kad neigiama įtaka buvo gauta dėl to, kad šalyje pramonės produkcijos indeksas skaičiuojamas kiek kitokiu metodu nei kitur.

Kaip ir su VKI ir valiutos kurso, palūkanų normos, pinigų pasiūlos rodikliais, BVP ir nedarbo lygio tyrimui atlikti mokslininkai dažniausiai pasirenka tirti vienos šalies akcijų indeksą.

Pereinant prie detalesnės pramonės produkcijos indekso tyrimų analizės, verta pateikti, kokiais metodais mokslininkai vadovaujasi, modeliuodami rodiklio poveikį akcijų rinkoms (žr. 16 lent.).

16 lentelė. Pramonės produkcijos indekso empirinių tyrimų atlikimo metodikos charakteristika

Metai	Autorius (-iai)	Tyrimo imtis (nuo-iki) m.	Duomenų dažnumo tipas	Tyrimo metodai modeliui sudaryti
2019	Erol A.F., Aytekin S.	2009–2018	Ketvirtinis	RA
2018	Chandrasekar R., Sakthivel P., Sampath T., Chittedi K.R.	2000–2016	Mėnesinis	RA
2018	Tiryaki H.N., Tiryaki A.	1991–2017	Mėnesinis	ARDL
2017	Alam N.	2005–2013	Mėnesinis	RA GARCH
2016	Jareno F., Negrut L.	2008–2014	Ketvirtinis	PC
2014	Alam Z., Rashif K.	2001–2011	Mėnesinis	GARCH
2013	Forson J.A., Janrattanagul J.	1990–2009	Mėnesinis	VECM

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktos lentelės matoma, kad vidutinė tyrimų apimtis yra 13 metų, taigi sukurti modeliai apima kelis ekonominius ciklo periodus. Pagal duomenų tipą autoriai renkasi mėnesinius, ketvirtinius akcijų indeksų kainų duomenis, taigi tikėtina, kad objektyviausi modeliai buvo sudaryti pagal mėnesio akcijų indekso kainų duomenis. Skirtingų metodų modeliams sudaryti buvo rasti 6 metodai. Dažniausiai naudojamas yra regresijos analizės metodas.

Kiti rodikliai yra analizuojami ne taip dažnai, kaip anksčiau minėti. Tai gaminamųjų kainų indeksas, aukso kaina, naftos kaina, tiesioginės užsienio investicijos, eksportas, didmeninės prekybos indeksas ir rinkas aplenkiantis rodiklis (žr. 17 lent.).

17 lentelė. Kitų rodiklių poveikio akcijų rinkoms apžvalga

Metai	Autorius (-iai)	Rodiklis	Poveikis rinkai	Šalis
2019	Celebi k., Honig M.	Rinkas aplenkiantis rodiklis	+	Vokietija

Lentelės tęsinys 46 psl.

Lentelė atkelta iš 45 psl.

2019	Tetteh J.E., Adenutsi D.E., Amoah A.	Naftos kaina	-	Gana
2019	Celebi k., Honig M.	Eksportas	-	Vokietija
2018	Garg K., Kalra R.	Aukso kaina	+	Indija
2017	Giri A.K., Pooja J.	Naftos kaina	-	Indija
2017	Jurkšas L., Paškevičius A.	Tiesioginės užsienio investicijos	+	Lietuva
2015	Singh G.	Didmeninės prekybos indeksas	+	Indija
2012	Martin S.	Gamintojų kainų indeksas	+	JAV

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Rinkas aplenkiantys rodiklis skirtas pateikti ankstyvus verslo ciklą posūkio taškų signalus, rodančius ekonominės veiklos svyravimą aplink jo ilgalaikį potencialą.

Naftos kainos rodiklis – naftos, kuri gaunama iš žemės jos dar neapdirbant, kaina, kitaip sakant, žalios naftos (BRENT ar WTI) kaina.

Aukso kaina – tai kaina, kuria auksu prekiaujama pasirinktoje finansų rinkoje.

Tiesioginės užsienio investicijos apima ilgalaikius ekonominius finansinius santykius ir interesus tarp tiesioginio užsienio investuotojo (ne rezidento) ir šalies tiesioginio investavimo subjekto (rezidento).

Didmeninės prekybos indeksas – indeksas, kuris matuoja ir seka prekių kainų pokyčius etapais iki mažmeninės prekybos lygio. Kitaip sakant, tai yra prekės, kurios parduodamos nesupakuotos ir kuriomis prekiaujama tarp verslo subjektų.

Gamintojų kainų indeksas – tai indeksas, apskaičiuojantis ir parodantis vidutinį vidaus produkcijos pardavimo kainų pokytį per tam tikrą laiką.

Naftos kainą, aukso kainą, gamintojų kainų indeksą rodiklius teoriškai galima priskirti prie ūkio šakos arba sektoriaus rodikliais. Tačiau praktikoje jie yra nagrinėjami kartu su makroekonominiais rodikliais.

Kadangi lentelėje pateikti skirtingi rodikliai, tyrinėti tik kelių mokslinių tyrinėtojų, tai įžvelgti kiekvieno rodiklio poveikio tendencijų neįmanoma, todėl šiame darbe jų poveikis nebus aprašomas.

Kaip ir su VKI ir valiutos kurso, palūkanų normos, pinigų pasiūlos rodikliais,

BVP, nedarbo lygio ir pramonės produkcijos indekso tyrimui atlikti mokslininkai dažniausiai pasirenka tirti vienos šalies akcijų indeksą.

Pereinant prie detalesnės tyrimų analizės, verta pateikti, kokiais metodais mokslininkai vadovaujasi, modeliuodami rodiklio poveikį akcijų rinkoms (žr. 18 lent.).

18 lentelė. Kitų rodiklių empirinių tyrimų atlikimo metodikos charakteristika

Metai	Autorius (-iai)	Rodiklis	Tyrimo imtis (nuo-iki) m.	Duomenų dažnumo tipas	Tyrimo metodai
2019	Celebi k., Honig M.	Rinkas aplenkiantys rodikliai	1991–2018	Mėnesinis	RA
2019	Tetteh J.E., Adenutsi D.E., Amoah A.	Naftos kaina	2000–2016	Mėnesinis	RA
2019	Celebi k., Honig M.	Eksportas	1991–2018	Ketvirtinis	RA
2018	Garg K., Kalra R.	Aukso kaina	1991–2017	Mėnesinis	PC
2017	Giri A.K., Pooja J.	Naftos kaina	1979–2014	Metinis	ARDL VECM
2017	Jurkšas L., Paškevičius A.	Tiesioginės užsienio investicijos	2000–2013	Ketvirtinis	ARDL
2015	Singh G.	Didmeninės prekybos indeksas	2007–2014	Mėnesinis	VECM
2012	Martin S.	Gamintojų kainų indeksas	1999–2012	Mėnesinis	RA

Šaltinis: parengta autoriaus pagal lentelėje nurodytus mokslininkus.

Iš pateiktos lentelės matoma, kad vidutinė tyrimų apimtis yra 16 metų. Taigi sukurti modeliai apima kelis ekonominius ciklo periodus. Pagal duomenų tipą autoriai renkasi mėnesinius, ketvirtinius akcijų indeksų kainų duomenis, taigi tikėtina, kad objektyviausi modeliai buvo sudaryti pagal mėnesio akcijų indekso kainų duomenis. Nors rodikliai yra įvairūs, tačiau modeliui sudaryti autoriai dažniausiai pasirenka regresijos analizės metodą.

Siekiant konstruktyviau apibendrinti poskyrio informaciją, buvo sudaryta 19

lentelė, kurioje nurodytos kiekvieno išanalizuoto rodiklio charakteristikos.

19 lentelė. Makroekonominių rodiklių poveikio akcijų rinkoms apibendrinimas

Rodiklis	Poveikis rinkai	Tyrimo imtis (metais)	Duomenų dažnumas	Tyrimo metodai modeliui sudaryti
VKI	-	18	Mėnesinis	RA
Valiutų kursas	+	15	Mėnesinis	RA
Palūkanų norma	-	17	Mėnesinis	RA
P pinigų pasiūla	+	11	Mėnesinis	RA
BVP	+	19	Mėnesinis	VECM
Nedarbo lygis	-	16	Mėnesinis	RA
Pramonės produkcijos indeksas	+	13	Mėnesinis	RA
Kiti	-+	16	Mėnesinis	RA
	Vidurkis	16	Mėnesinis	RA

Šaltinis: parengta autoriaus pagal 3–18 lentelėse nurodytus šaltinius.

Iš pateiktos lentelės matoma, kad vidutinė atskirų rodiklių apimtis yra 16 metų, taigi sukurti modeliai apima kelis ekonominius ciklo periodus. Rodiklio reikšmei didėjant, neigiamą poveikį akcijų indeksams turi VKI, palūkanų norma ir nedarbo lygio rodikliai, o valiutos kurso, pinigų pasiūlos, BVP, pramonės produkcijos indekso didėjimas teigiamai veikia šalių akcijų kainas. Atlikta palyginamoji tyrimų analizė rodo, kad mokslininkai dažniausiai nagrinėja rodiklių poveikį akcijų grąžai mėnesio dažnumu, kas, autoriaus nuomone, yra priskirtina prie šių tyrimų ribotumų, nes tampa neaišku, kaip kinta akcijos kainos per trumpesnę laiko tarpą. Antras minėtų tyrimų ribotumas galėtų būti tas, kad mokslininkai orientuoti tik į faktines makroekonominių rodiklių reikšmes, neįvertinant tuo metu rinkoje vyraujančių lūkesčių, kurie taip pat galėtų paveikti akcijų grąžą.

Tolimesniame poskyryje nagrinėjami akcijų grąžos analizavimo tyrimai efektyvios rinkos hipotezės požiūriu, kur akcijų grąža skaičiuojama per trumpą laiko tarpą, kas iš esmės panaikina vieną iš fundamentaliosios analizės ribotumų.

1.2 Akcijų gražos analizavimo tyrimai efektyvios rinkos hipotezės aspektu

1.2.1 Efektyvios rinkos hipotezės teoriniai aspektai

Kita populiari ir šiam tyrimui aktuali akcijų nagrinėjanti teorija yra efektyvios rinkos hipotezės teorija. Mokslinių tyrimų, siekiančių teoriškai ir empiriškai pagrįsti efektyvios rinkos hipotezę, yra labai daug. Remiantis Macijausku (2015) empirinis šios teorijos pagrindimas iki šiol apima du skirtingus „išgyvenimo“ laikotarpius:

- » iki aštuntojo dešimtmečio pabaigos, kai daugumos mokslinių tyrimo rezultatai patvirtino ERH;
- » nuo devintojo dešimtmečio pradžios, kai pastebimas didėjantis neigiamų tyrimų rezultatų antplūdis.

Visus tyrinėjimus efektyvios rinkos hipotezės tema iki 1965 metų galima pavadinti atsitiktinio klaidžiojimo (arba žingsnio) teorija. Pirmieji empiriniai tyrimai šia kryptimi, anot Macijausko (2015), buvo atlikti Regnault (1863), Rayleigh (1880), Venn (1888), Bachelier (1900), Barriol (1908), Dibblee (1912), Keynes (1923), Cowles (1933), Working (1934), Osborne (1959), Cootner (1964), Fama (1965), kurie tikrino atsitiktinio klaidžiojimo teoriją ir nustatė, kad akcijų kainų pokyčiai yra nepriklausomi. Minėti tyrimai leido suformuluoti efektyvios rinkos hipotezę, ir pirmuoju jos autoriumi tapo Eugene Fama. Remdamasis savo tyrimo „Akcijų rinkų kainų elgsena“ (1965) išvadomis mokslininkas teigė, kad ERH yra rinka, kuri staigiai reaguoja į naujausią informaciją, o tai reiškia, kad VP kainų prognozavimas ilguoju laikotarpiu neatneštų daugiau gražos nei bendra finansų rinkos finansinio priemonių krepšelio kaina.

Pasak mokslininko, ERH egzistavimui keliamos tokios prielaidos (šalia jų šios disertacijos autorius išsako savo požiūrį):

» *Finansų rinkoje egzistuoja daugybė pelno siekiančių dalyvių, kurie analizuoja ir vertina vertybinių popierių kainas nepriklausomai nuo kitų.*

Galima sutikti, kad dauguma individualių ir institucinių investuotojų yra nepriklausomi ir siekia maksimizuoti savo pelną. Tačiau nepriklausomumas tarp finansų rinkos dalyvių mažėja ir didėja jų integracija: dalijimasis sėkmės istorijomis, analizų metodais, sukurtais algoritmais, daugėja norinčių pasidalinti savo patirtimi, kuriamos internetinės svetainės, organizuojami forumai.

» *Nauja informacija ateina į rinką nepriklausomai nuo kitos informacijos ir atsitiktine tvarka.*

Galima sutikti, kad žiniasklaida yra nepriklausoma, ir žurnalistų atlikti tyrimai, surinkti duomenys ir publikuoti straipsniai pasirodo nepriklausomai nuo įtakos sferų poreikių. Tačiau kartu dauguma makroekonominių ir kt. rodiklių skelbiami pagal iš anksto sutartą grafiką, konkrečią dieną ir valandą, o tai nėra atsitiktinumai, ir yra informacijos nutekėjimo tikimybė.

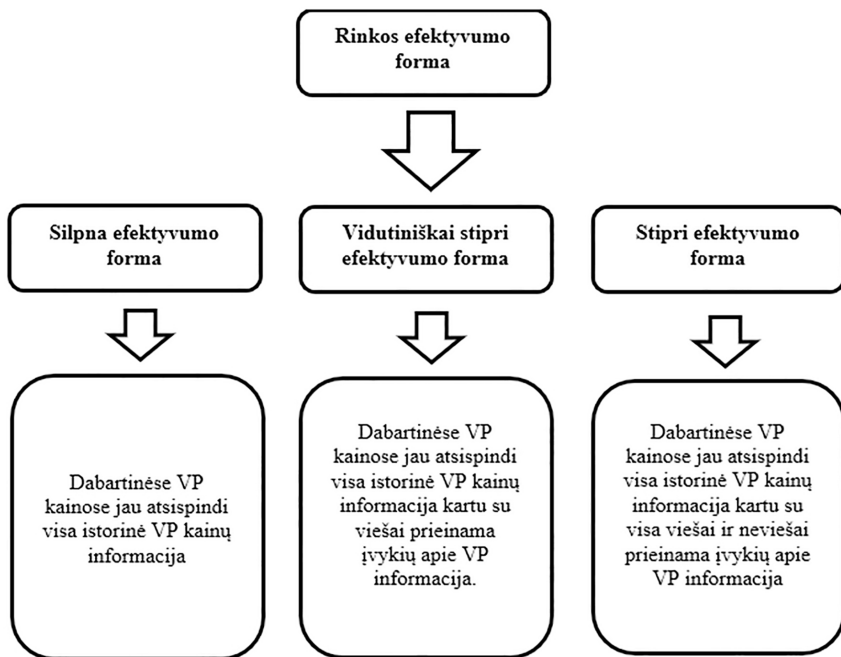
» *Akcijų kainos greitai keičiasi pagal naujausią informaciją.*

Galima sutikti, kad akcijų kainos gana greitai reaguoja į viešojoje erdvėje pasirodžiusią informaciją. Kitaip sakant, finansų rinkos dalyviai greitai priima investicinius sprendimus. Tačiau kai kurios informacijos prieinamumas kainuoja, dėl to ne visi finansų rinkos dalyviai disponuoja vienoda informacija. Ten, kur informacijos gavimas kainuoja, paprastai ji pateikiama operatyviau ir patogesniu formatu nei įprastais kanalais. Dėl šios priežasties ne visi finansų rinkos dalyviai į naujai pasirodžiusią informaciją sureaguoja vienu metu ir teisingai. Todėl galime sakyti, kad ir akcijų kainos keičiasi ne taip staigiai ir taip teisingai, kaip turėtų.

» *Akcijų kainose atsispindi visa tuo metu rinkoje žinoma informacija.*

Galima sutikti, kad didžioji dalis finansų rinkos dalyvių yra suinteresuoti informaciją gauti kaip įmanoma greičiau, dėl to jie seka naujienas, žino jų išėjimo grafiką, o į pasirodžiusią informaciją sureaguoja greitai. Tačiau, kaip jau buvo minėta, tam tikros informacijos prieinamumas kainuoja, dėl to ne visi finansų rinkos dalyviai disponuoja vienoda informacija. Tai reiškia, kad akcijų kainų kitimo priežasčių kai kurie finansų rinkos dalyviai net nežino, dėl to negali priimti investicinių sprendimų. Todėl akcijų kainose atsispindi ne visų rinkos dalyvių investiciniai sprendimai, kas reiškia, kad į akcijų kainas nėra įtraukta visa informacija.

1970 metais Fama savo darbe „Efektyvios kapitalo rinkos: teorinė ir empirinė darbo apžvalga“, atsižvelgdamas į kritikų pastabas, ERH išskaidė į tris efektyvumo formas: silpnąją, vidutiniškai stiprią ir stipriąją (žr. 4 pav.). Pasak Klimašauskienės ir Mošcinskienės (1998), šios formos viena nuo kitos skiriasi informacijos apimtimi bei galimybėmis ją gauti.



Šaltinis: Sudaryta autoriaus, remiantis Fama (1970).

4 pav. Akcijų rinkos efektyvumo formos

Silpnos formos efektyvios rinkos hipotezė teigia, kad VP kainose jau atsispindi visa istorinė VP kainų informacija. Kadangi praeities duomenys jau yra paveikę VP kainas, tai investuotojams neįmanoma nuspėti ateities kainas, naudojant praeities informaciją apie kainų kitimą. Tai reiškia, kad investuotojai negalės gauti didesnio pelno už rinkos vidurkį net ir tuomet, kai naudos techninės analizės rodiklius savo sprendimui priimti. Vidutiniškai stiprios formos efektyvios rinkos hipotezė teigia, kad VP kainose jau atsispindi visa istorinė VP kainų informacija kartu su viešai prieinama įvykių apie VP informacija. Kadangi praeities duomenys ir viešai prieinama informacija jau yra paveikę VP kainas, tai investuotojams neįmanoma nuspėti ateities kainų, naudojant praeities informaciją apie VP kainų kitimą ir viešai prieinamą informaciją apie įvykius. Tai reiškia, kad investuotojai negalės gauti didesnio pelno už rinkos vidurkį net ir tuomet, kai pasirodys nauja informacija apie įmonės rezultatus. Stiprios formos efektyvios rinkos hipotezė teigia, kad VP kainose jau atsispindi visa istorinė VP kainų informacija

kartu su visa viešai ir neviešai prieinama įvykių apie VP informacija. Kadangi praeities duomenys ir viešai bei neviešai prieinama informacija jau yra paveikę VP kainas, tai investuotojams neįmanoma nuspėti ateities kainos, naudojant praeities informaciją apie kainų kitimą ir viešai bei neviešai prieinamą informaciją apie VP įvykius. Tai reiškia, kad investuotojai negalės gauti didesnio pelno už rinkos vidurkį net ir tuomet, jei naudosis viešai neatskleista informacija.

1.2.2 Silpnos formos efektyvios rinkos hipotezės tyrimų analizė

Kaip ir buvo aprašyta anksčiau, silpnos formos ERH sako, kad VP kainose jau atsispindi visi istoriniai rinkos duomenys. Kadangi praeities duomenys jau yra paveikę VP kainas, tai investuotojams neįmanoma nuspėti ateities kainų, naudojant praeities informaciją apie kainų kitimą.

Naujausių tyrimų išvadų apžvalga pateikiama 20 lentelėje.

20 lentelė. Silpnos formos efektyvios rinkos hipotezės naujausių mokslinių tyrimų išvados

Metai	Autoriai	Tyrimų rinka	Tyrimų išvados
2018	Nagpal, Jain	Indija	Atmetama silpnos formos ERH. Patvirtinta, kad kalendorinės anomalijos turi didelį poveikį akcijų grąžoms, ir investuotojai gali tendencingai uždirbti daugiau nei rinkos vidurkis.
2017	Barghouthi, Ehsan	Jordanija	Atmetama silpnos formos ERH.
2017	Jose, Suresh	Indija	Atmetama silpnos formos ERH.
2016	Sofat	Indija IT sektorius	Atmetama silpnos formos ERH.
2016	Singh, Leepsa Kushwaha	JAV, Japonija, Brazilija, Indija	Nagrinėjant dieninius akcijų kainų svyravimus, silpnos formos ERH atmetama. Nagrinėjant mėnesinius akcijų kainų svyravimus, silpno efektyvumo hipotezė atmetama trijose iš keturių nagrinėjamų akcijų rinkose.
2015	Malhotra, Tandon, Tandon	Azijos 10 akcijų biržų	Nagrinėjant dieninius ir savaitinius akcijų kainų svyravimus, silpnos formos ERH atmetama. Nagrinėjant mėnesinius akcijų kainų svyravimus, silpno efektyvumo rinkos hipotezė neatmetama.

Lentelės tęsinys 53 psl.

Lentelė atkelta iš 52 psl.

2013	Luthura, Mahajan	Kinija	Atmetama silpnos formos ERH.
------	------------------	--------	------------------------------

Šaltinis: sudaryta autoriaus, remiantis lentelėje nurodytais mokslininkais.

Daugumoje naujausių mokslinių tyrimų (žr. 20 lent.) išvadų silpnos formos ERH yra atmetama. Tai sako, kad finansų rinkų dalyviai, remdamiesi praeities VP kainų analize, turėtų galimybę ilguoju laikotarpiu uždirbti daugiau, nei rinkos vidurkis.

Siekiant patvirtinti arba paneigti silpnos formos ERH egzistavimą pasirinktoje rinkoje, reikalinga pasirinkti tyrimo metodus, pagal kuriuos vėliau empiriškai įrodoma, ar finansų rinkos dalyviai toje rinkoje gali uždirbti daugiau grąžos nei rinkos vidurkis. Dėl to tikslinga išskirti, kokius metodus mokslininkai naudoja savo tyrimuose (žr. 21 lent.).

21 lentelė. Silpnos formos efektyvios rinkos hipotezės nustatymo metodai naujausiuose moksliniuose tyrimuose

Metai	Autoriai	Tyrimų tikslas	Tyrimuose naudojami metodai
2018	Nagpal, Jain	Patvirtinti arba paneigti, ar Indijoje esančios kalendorinės anomalijos turi didesnę įtaką jos akcijų rinkos grąžai nei jos rinkos vidurkis.	<ul style="list-style-type: none"> – Vienetinės šaknies testas – Serijų testas – Autokoreliacijos testas – Breusch-Godfrey testas – ARCH LM testas – Breusch-Pagan-Godfrey testas – EGARCH
2017	Barghouthi, Ehsan	Patikrinti, ar techninės analizės slankiųjų vidurkių metodu galima gauti didesnes nei vidurkis grąžas Jordanijos akcijų biržoje.	<ul style="list-style-type: none"> – Techninė analizė – slankiųjų vidurkių metodas
2017	Jose, Suresh	Patvirtinti arba paneigti silpnos formos ERH egzistavimą Indijos akcijų biržoje.	<ul style="list-style-type: none"> – Autokoreliacijos testas – Variacijos testas – Serijų testas – Vienetinės šaknies testas

Lentelės tęsinys 54 psl.

2016	Sofat	Patvirtinti arba paneigti silpnos formos ERH egzistavimą Indijos akcijų rinkos IT sektoriuje.	– Serijų testas
2016	Singh, Leep- sa Kushwaha	Patvirtinti arba paneigti silpnos formos ERH egzistavimą JAV, Japonijos, Brazilijos ir Indijos anglies sektoriaus akcijų rinkoje.	– Kolmogorov-Smirnov testas – Shapiro-Wilk testas – Serijų testas – Autokoreliacijos testas
2015	Malhotra, Tandon, Tandon	Patvirtinti arba paneigti silpnos formos ERH egzistavimą dešimtyse Azijos biržų.	– Autokoreliacijos testas – Serijų testas – Vienetinės šaknies testas
2013	Luthura, Mahajan	Patvirtinti arba paneigti silpnos formos ERH egzistavimą Kinijos akcijų biržose.	– Serijų testas – Autokoreliacijos testas

Šaltinis: sudaryta autoriaus, remiantis lentelėje nurodytais mokslininkais.

Taigi iš pateiktų mokslinių tyrimų, siekiant nustatyti, patikrinti arba paneigti silpnos formos ERH, dažniausiai naudojami šie statistiniai metodai:

» Autokoreliacijos testas.

Autokoreliacijos arba serijinės koreliacijos testas matuoja kainos koreliaciją tarp įvairaus dydžio pasirinkto laiko vėlavimų, tokių kaip minutė, valanda, diena, savaitė ir t. t.

» Serijų testas.

Šiuo testu tikrinamas sekos gretimų porų tolygumas ir nepriklausomumas. Akcijų kainų pokyčiai vertinami ženklais „+“, „0“, „-“. Paprastai paskui daromas palyginimas su teorinėmis atsitiktinai išdėstytų duomenų serijomis. Jeigu akcijų kainų pokyčių serijų yra daugiau nei atsitiktinių duomenų serijų, tai reiškia, kad kainų pokyčiai nėra visiškai atsitiktiniai.

» Vienetinės šaknies testas.

Šiuo testu nustatoma, ar VP kainos yra nestacionarios, t. y. neišlaikomas pastovus vidurkis.

Šiame darbe silpnos formos ERH yra neaktuali, nes apima praeities kainų analizę (galima vadinti ir technine analize) ir jos ryšį su būsimomis kainomis, o ne įvairius makroekonominius rodiklius.

1.2.3 Vidutiniškai stiprios formos efektyvios rinkos hipotezės tyrimų analizė

Kaip buvo aprašyta anksčiau, vidutiniškai stiprios formos efektyvios rinkos hipotezė teigia, kad VP kainose jau atsispindi visi istoriniai duomenys kartu su visa viešai prieinama informacija. Pasak Klimašauskienės ir Moščinskienės (1998), jei rinka yra efektyvi vidutiniškai stipria forma, tai jos dalyviai, naudodamiesi visa istorine duomenų informacija ir viešai prieinama informacija (informacija apie dividendus, pajamas, akcijų smulkinimą, balanso straipsnius ir pan.), negalės uždirbti viršpelnio.

Remiantis Fama (1991), vidutiniškai stiprios formos efektyvios rinkos hipotezės tyrimus galima suskirstyti į dvi grupes:

1. Tyrimus, siekiančius nuspėti būsimas akcijų kainas, naudojantis istorine ir viešai prieinama informacija. Dažniausiai sutinkamas tyrimo metodas yra laiko eilučių analizė.

2. Įvykių tyrimus, kurie analizuoja, kaip greitai akcijų kainos prisitaiko prie naujos informacijos apie svarbius makroekonominis įvykius pasirinktoje rinkoje. Cleary, Atkinson ir Drake (2013) teigia, kad įvykių tyrimai atliekami, lyginant laukiamą pelningumą apskaičiuojantį modelį su tikro aktyvo pelningumu, įmonei paskelbus naują informaciją. Jei skirtumas tarp laukiamo ir faktinio pelningumo bus statistiškai reikšmingas, bus laikytina, kad rinka greitai sureaguoja į naujai pasirodžiusią informaciją ir, priimant investicinius sprendimus, remiantis šia informacija jau po to kai ji pateko į rinką, viršpelnio uždirbti nebepavyks.

Naujausių tyrimų išvadų apžvalga pateikiama 22 lentelėje.

22 lentelė. Vidutiniškai stiprios formos efektyvios rinkos hipotezės naujausių mokslinių tyrimų išvados

Metai	Autoriai	Tyrimų rinka	Tyrimų išvados
2017	Andrade, Santos	Brazilija	Patvirtinta vidutiniškai stipri efektyvios rinkos hipotezė. Iš publikuotų finansinių ataskaitų negalima tendencingai uždirbti daugiau nei rinkos vidurkis.
2017	Mackey, Macon	JAV	Patvirtinta vidutiniškai stipri efektyvios rinkos hipotezė. Iš įmonių publikuotų akcijų supirkimo arba akcijų išleidimo naujienų negalima tendencingai uždirbti daugiau nei rinkos vidurkis.

Lentelės tęsinys 56 psl.

2015	Woodard, Bacon	JAV	Atmetama vidutiniškai stipri efektyvios rinkos hipotezė. 1995 ir 2013 m. vyriausybės paskelbta informacija apie nedarbą stipriai paveikė įmonių akcijų kainas.
2014	Mallikarjunappa, Dsouza	Indija	Atmetama vidutiniškai stipri efektyvios rinkos hipotezė. Iš publikuotų ketvirtinių įmonių finansinių naujienų galima tendencingai uždirbti didesnę nei rinkos grąžą.
2014	Ferrara, Bacon	JAV	Patvirtinta vidutiniškai stipri efektyvios rinkos hipotezė. Iš įmonių publikuotų susijungimo ir susiliejimo naujienų negalima tendencingai uždirbti daugiau nei rinkos vidurkis.
2010	Westfall	JAV	Patvirtinta vidutiniškai stipri efektyvios rinkos hipotezė. Iš publikuotų įmonių naujienų apie akcijų smulkinimą negalima tendencingai uždirbti daugiau nei rinkos vidurkis.
2009	Sharma	Indija	Atmetama vidutiniškai stipri efektyvios rinkos hipotezė. Iš publikuotų įmonių naujienų apie įmonių konsolidaciją, vadovų pasikeitimą ir naujų įmonių įsigijimą galima tendencingai uždirbti daugiau nei rinkos vidurkis.
2009	Mallikarjunappa, Manjunatha	Indija	Atmetama vidutiniškai stipri efektyvios rinkos hipotezė. Iš publikuotų dividendinių naujienų galima tendencingai uždirbti didesnę nei rinkos grąžą.

Šaltinis: sudaryta autoriaus, remiantis lentelėje nurodytais mokslininkais.

Nagrinėtuose tyrimuose vidutiniškai stiprios formos efektyvios rinkos hipotezė yra ir patvirtinama, ir atmetama. Vienuose tyrimuose akcijų kainos juda atsitiktinai, dėl to finansų rinkų dalyviams uždirbti viršpelnių nepavyks. Kituose moksliniuose tyrimuose akcijų kainos juda pagal tam tikras tendencijas, kuriomis remiantis ilguoju laikotarpiu galima uždirbti daugiau nei rinkos vidurkis.

Siekiant patvirtinti arba paneigti vidutiniškai stiprios formos efektyvios rinkos hipotezės egzistavimą pasirinktoje rinkoje, reikalinga pasirinkti tyrimo metodus, pagal kuriuos vėliau empiriškai įrodama, ar finansų rinkos dalyviai toje rinkoje gali uždirbti daugiau grąžos nei rinkos vidurkis. Dėl to tikslinga išskirti, kokius metodus mokslininkai naudoja savo naujausiuose tyrimuose (žr. 23 lent.)

23 lentelė. Vidutiniškai stiprios formos efektyvios rinkos hipotezės nustatymo metodai naujausiuose moksliniuose tyrimuose

Metai	Autoriai	Tyrimų tikslas	Tyrimuose naudojami metodai
2017	Andrade, Santos	Patvirtinti arba paneigti vidutiniškai stiprios formos efektyvios rinkos hipotezės egzistavimą Brazilijos akcijų biržoje. Tyrimo objektas – publikuotos finansinės ataskaitos.	<ul style="list-style-type: none"> - IPS testas - Hadri testas - Breusch-Pagan testas - Parametric F testas - Hausman testas - Autokoreliacijos testas - RA - Baltagi ir Li vienos uodegos LM testas - Granger priežastingumo testas
2017	Mackey, Macon	Patvirtinti arba paneigti vidutiniškai stiprios formos efektyvios rinkos hipotezės egzistavimą JAV akcijų biržoje. Tyrimo objektas – įmonių akcijų supirkimo ir išleidimo naujienos.	Įvykių studijų metodologija: <ul style="list-style-type: none"> - RA - T-testas - RAR
2015	Woodard, Bacon	Patvirtinti arba paneigti vidutiniškai stiprios formos efektyvios rinkos hipotezės egzistavimą 50 įmonių, besikotiruojančių S&P 500 akcijų biržoje. Tyrimo objektas – vyriausybės nedarbo 1995 ir 2013 m. paviėšinta informacija.	Įvykių studijų metodologija: <ul style="list-style-type: none"> - RA - RAR
2014	Mallikarjuna-ppa, Dsouza	Patvirtinti arba paneigti vidutiniškai stiprios formos efektyvios rinkos hipotezės egzistavimą Indijos akcijų biržoje. Tyrimo objektas – ketvirtiniai įmonių pranešimai apie pelną.	Įvykių studijų metodologija: <ul style="list-style-type: none"> - MAR - MKAR - T-testas - Serijų testas
2014	Ferrara, Bacon	Patvirtinti arba paneigti vidutiniškai stiprios formos efektyvios rinkos hipotezės egzistavimą JAV akcijų biržoje. Tyrimo objektas – įmonių susijungimo ir susilieimo naujienos.	Įvykių studijų metodologija: <ul style="list-style-type: none"> - RA - RAR

Lentelė atkelta iš 57 psl.

2010	Westfall	Patvirtinti arba paneigti vidutiniškai stiprios formos efektyvios rinkos hipotezės egzistavimą JAV NYSE ir NASDAQ akcijų biržose. Tyrimo objektas – įmonių akcijų smulkinimo informacija.	Įvykių studijų metodologija: – RAR
2009	Sharma	Patvirtinti arba paneigti vidutiniškai stiprios formos efektyvios rinkos hipotezės egzistavimą Indijos akcijų biržoje. Tyrimo objektas – publikuotos įmonių naujienos apie įmonių konsolidaciją, vadovų pasikeitimą ir įmonių įsigijimus.	Įvykių studijų metodologija: – MKAR
2009	Mallikarjuna-ppa, Manjunatha	Patvirtinti arba paneigti vidutiniškai stiprios formos efektyvios rinkos hipotezės egzistavimą Indijos akcijų biržoje. Tyrimo objektas – įmonių informacija apie dividendus.	Įvykių studijų metodologija: – RA

Šaltinis: sudaryta autoriaus, remiantis lentelėje nurodytais mokslininkais.

Remiantis 22 ir 23 lentelėmis pastebima, kad vidutiniškai stiprios formos ERH su nagrinėjama tematika siejasi „įvykių tyrimais“, kurie, kaip matome iš 22 lentelės, dažniausiai gali būti įmonių finansinės naujienos arba šalių makroekonominiai rodikliai. 23 lentelė parodo, kokiais metodais galima nustatyti ar nagrinėjama rinka yra vidutiniškai stiprios formos efektyvi. Šių metodų specifika yra ta, kad jie dažniausiai naudojami tirti akcijų kainos ar grąžos pasikeitimus per trumpą laiko tarpą.

Siekiant konstruktyviau apibendrinti dažniausiai naudojamus metodus, norint nustatyti ir patikrinti vidutiniškai stiprios ERH, buvo sukurta 24 lentelė.

24 lentelė. Dažniausiai naudojami įvykių tyrimų metodai, susiję su vidutiniškai stipria ERH

Modelio trumpinys	Formulė	Modelio tikslas
RA	$Y=f(X_1;X_2,\dots,X_k)+\varepsilon$	Siekiami įvertinti vieno ar daugiau veiksnių įtaką nagrinėjamam reiškiniai.
MKAR	$AR_{it} = R_{it} - R_{mt}$	Siekiami nustatyti, ar VP grąža įvykio dieną yra didesnė/mažesnė už rinkos (indekso) grąžą įvykio dieną.

Lentelės tęsinys 59 psl.

Lentelės atkelta iš 58 psl.

RAR	$AR_{it} = R_{it} - (\alpha_i + \beta_i \times R_{mt})$	Siekiami nustatyti, ar VP grąža įvykio dieną yra didesnė/mažesnė už rinkos (indekso) grąžą įvykio dieną, papildomai įvertinus ir regresinio modelio elementus.
MAR	$AR_{it} = R_{it} - \bar{R}_i$	Siekiami nustatyti, ar VP grąža įvykio dieną yra didesnė/mažesnė už VP grąžos vidurkį.

Y - nagrinėjamas ekonominis reiškinys;

X_1, X_2, X_k - ekonominių reiškinį sąlygojantys veiksniai, kurie yra sunumeruoti nuo 1 iki k; ϵ - modelio paklaida;

AR_{it} - VP viršpelnis;

R_{it} - akcijos grąža įvykio dieną;

R_{mt} - indekso (rinkos) grąža įvykio dieną;

α_i - konstanta, kuri apibrėžiama kaip priklausomojo kintamojo vidurkis, kai nepriklausomi kintamieji prilyginami nuliui;

β_i - pasikeitimo koeficientas priklausomo kintamoje reikšmėje, kai pasikeičia nepriklausomojo kintamojo nuolydis;

\bar{R}_i - Vidutinė akcijos grąža.

Šaltinis: sudaryta autoriaus, remiantis lentelėje nurodytais mokslininkais.

Iš lentelės matoma, kad dažniausiai sutinkami metodai yra regresinės, koreguotos rinkos grąžos, koreguotos rizikos grąžos, koreguotos vidurkio grąžos modeliai, o jų tikslas yra pateiktas lentelėje.

Apibendrinus ERH teorijos visų poskyrių informaciją, galima sakyti, kad nors ERH atsirado daugiau nei prieš 50 metų ir dauguma jos prielaidų šiandien yra abejotino realistiškumo, tačiau ji vis dar populiari tarp mokslininkų, kurie siekia tirti ir vertinti akcijų grąžą. Daugiausiai tyrimų atliekama nustatinėjant silpnos formos ERH. Čia svarbu yra atlikti istorinių duomenų analizę, o norint patvirtinti, ar nagrinėjama rinka yra silpna forma efektyvi, dažniausiai naudojami autokoreliacijos, serijos ir vienetinės šaknies testai. Kiek mažiau tyrimų randama, nustatant vidutiniškai stiprios formos ERH. Čia reikia vertinti ne tik istorinius duomenis, tačiau ir ką tik pasirodžiusią informaciją. Tokie tyrimai dar vadinami „įvykių tyrimais“, o dažniausiai sutinkami metodai yra regresinės, koreguotos rinkos grąžos, koreguotos rizikos grąžos, koreguotos vidurkio grąžos modeliai. Nė vieno empirinio tyrimo nebuvo rasta, nustatinėjant stiprios formos ERH. Anot šios stiprios formos ERH, investuotojai negalėtų gauti viršpelnio net ir pasinaudojus viešai neatskleista informacija, dėl to neretai ši forma kritikuojama dėl ribotų patikrinimo galimybių. Autorius pastebėjo, kad efektyvios rinkos hipotezės

patvirtinimas arba paneigimas labai priklauso nuo tyrimo imčių, duomenų dažnumo (minutės, valandos, dienos, savaitės, mėnesio) veiksmų. Buvo pastebėta, kad analizuojant dienos-savaitės VP grąžą, buvo atmesta silpnos formos ERH, tačiau analizuojant mėnesines VP grąžas silpnos formos ERH būdavo patvirtinama.

Nors efektyvios rinkos hipotezės tyrimai ir nagrinėja akcijų grąžą per trumpesnę laiką tarpą nei fundamentalioji analizė, tačiau šių teorijų mokslininkai daugiausia orientuoti tik į faktines makroekonominių ir finansinių ataskaitų rodiklių reikšmes, neįvertindami tuo metu rinkoje vyraujančių lūkesčių, kurie taip pat galėtų paveikti akcijų grąžą. Dėl to kitame skyriuje yra aktualu nagrinėti finansų elgsenos teorijos ypatumus ir tyrimus, kurie įtraukia psichologinius aspektus investiciniam sprendimui priimti.

1.3 Akcijų grąžos analizavimo aspektai finansų elgsenos teorijos aspektu

Trečioji svarbi šiam tyrimui teorija yra finansų elgsenos teorija. Ji susiformavo praėjus beveik keliems dešimtmečiams po efektyvios rinkos hipotezės teorijos atsiradimo. Mokslininkai Kahneman ir Tversky (1979) straipsnyje „Perspektyvos teorija: sprendimų priėmimo analizė rizikos sąlygomis“ buvo pirmieji, kurie nustatė ir įrodė, kad žmonės dėl klaidingai suprastos informacijos gali pasielgti neracionaliai. Jie ištyrė, kad pralaimėjimų skausmas žmonėms yra didesnis nei pasitenkinimas laimėjimu. Priimdami sprendimus, kurių rezultatai yra nežinomi, žmonės pasirenka tokius sprendimų variantus, kuriuose pralaimėjimo rizika, kaip jiems atrodo, yra mažiausia. Psichologijos moksle tokia žmonių elgsena vadinama „Nuostolių arba praradimų baime“, ir, kaip parodė eksperimentai, tokia elgsena būdinga daugumai finansų rinkų dalyvių. Dėl to vyksta tiksliai žinomų rezultatų naudos pervertinimas, lyginant su nežinomais (tikėtinais) rezultatais. Šis tyrimas buvo pirmasis, kuris įvertino ir apibrėžė subjektyvių tikimybių vertinimo koncepciją ir buvo pamatas tolimesnės finansų elgsenos teorijos tyrimams.

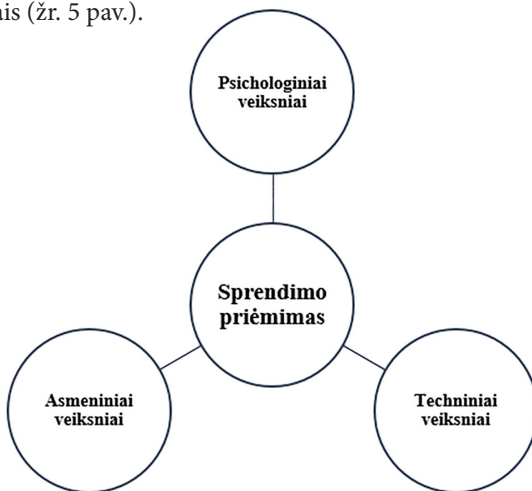
Finansų elgsena yra supratimas, kaip psichologija veikia investavimo sprendimų priėmimą (Shefrin, 2001). Finansų elgsenos veiksniai, turintys įtakos investicijoms, yra baimė, meilė, godumas, optimizmas ir bandos instinktas (Fischer ir Gerhardt, 2007). Anot Das ir Panja (2019), be minėtų veiksnių, tam įtakos turi ir emocijos, pernelyg didelis pasitikėjimas savimi, nepasitikėjimas savimi, akcijų rinkos burbulas ir kt.

Svarbiausias finansų elgsenos teorijos tikslas yra suprasti, kaip žmonės elgiasi priimdami investicinį sprendimą (DeBondt, Forbes ir kt., 2010). Anot mokslininkų, finansų elgsenos teoriją galima suprasti pagal tris psichologinius faktorius: kognityvinė

arba elgesio psichologija, emocinis atsakas ir socialinė psichologija.

Pasak Leipaus ir Norvaišos (2004), finansų elgsenos teorija apibūdinama, kaip teorija, kuri nukrypimą nuo efektyvios rinkos hipotezės teorijos aiškina per iracionalią finansų rinkos dalyvio elgseną. Ši teorija paaiškina, kaip iracionalus finansų rinkos dalyvio elgesys veikia akcijų kainas ir kitus VP aspektus. Chandra (2008) papildo, kad finansų elgsena apibrėžiama, kaip mokslas apie finansų rinkų dalyvio psichologijos įtaką priiminėjant finansinius sprendimus. Mokslininkas teigia, kad finansinė elgsena užima svarbią poziciją finansinių sprendimų priėmimo procese, kadangi ji turi reikšmingą įtaką finansų rinkų dalyvio finansinei gerovei. Panaikinus emocinės būsenos sąlygotus sprendimus, turėtų reikšmingai pagerėti jo finansiniai rezultatai. Pasak mokslininko, būtent emocijos ir sukelia didžiausius ekonominius svyravimus finansų rinkose. Panašiai rašo ir Kartašova (2016), kuri teigia, kad finansų elgsenos mokslas jungia psichologijos, sociologijos ir kitų socialinių mokslų bei finansų teorijų žinias. Anot mokslininkės, ši teorija yra tarsi priešprieša tradicinei efektyvios rinkos hipotezės teorijai, kurios esminis argumentas yra finansų rinkų dalyvių racionalumas.

Anot Chandra (2008), investicinių sprendimų priėmimas finansų rinkoje yra sudėtingas procesas, kuriame analizuojami įvairūs veiksniai. Sprendimo priėmimą gali paveikti asmeniniai ir techniniai veiksniai. Tačiau sprendimai dar turėtų priklausyti ir nuo esamos situacijos. Ir čia paprastai individualus investuotojas susiduria su psichologiniais veiksniais (žr. 5 pav.).



Šaltinis: sudaryta, remiantis Chandra (2008).

5 pav. Sprendimų priėmimas pagal finansų elgsenos teoriją

Individualių investuotojų sprendimų priėmimas dažnai veikiamas asmeninių veiksnių, tokių kaip amžius, išsilavinimas, pajamos, investicijų portfelis ir pan. Kartu sprendimas gali būti nulemtas ir techninių veiksnių – sudėtingų finansinių modelių, pagrįstų rizika ir grąža, tokių kaip CAPM. Psichologiniai veiksniai, anot autoriaus, detalizuojami: godumas ir baimė, mintinė apskaita, kognityvinis disonansas, euristika ir prisirišimas prie reikšmės. Remiantis Das ir Panja (2019), galima papildyti psichologinių veiksnių detalizaciją reprezentatyvumu, nuostolių vengimu, perdėta savikliova, prieinamumu, optimizmu, lošėjo klaida, siauru šablonu, atsisakymo efektu, minios elgsena, *status quo*.

Dauguma išvardintų psichologinių veiksnių turi vieną bendrą bruožą – sentimentus. Anot Kartašovos (2016), Chen, Zhao, Li, Lu (2020), investuotojų sentimentai yra esminė kryptis, analizuojant akcijų grąžą pagal finansų elgsenos teoriją. Tyrėjai Nasiri, Sarraf, Nourollahzadeh, Hamidian, Noorifard (2021), naudodami modelio Fama-Macbeth logiką nustatė, kad vienas pagrindinių veiksnių akcijų grąžoms ir yra investuotojų sentimentai.

Moksliniuose straipsniuose bei daktaro disertacijose neretai galima pamatyti, kad sentimentai prilyginami lūkesčiams. Pavyzdžiui, Kartašova (2012) sentimentus apibūdina, kaip teoriją, kuri aiškina, „*kaip formuojasi investuotojų įsitikinimai ir preferencijos. Kitaip dar vadinama investuotojų lūkesčių / nuotaikų teorija, kuri paaiškina, kaip realiai susiformuoja investuotojų suvokimai ir nustatoma įmonių vertybinių popierių kaina bei formuojama paklausa*“ (p. 49). Navickaitė, Mickutė (2010) sentimentus apibūdina, kaip neracionalią investuotojų elgseną, kuri „*pasireiškia dėl investuotojams būdingų lūkesčių arba taip vadinamo rinkos sentimentu*“ (p. 167). Kaip matome, mokslininkės sentimentų ir lūkesčių ekonominius reiškinius sutapatina ir laiko juos lygiaverčiais. Todėl tikslinga panagrinėti, kaip kiti mokslininkai supranta sentimentus. Mokslininkų požiūriai į sentimentus atskleisti 25 lentelėje.

25 lentelė. Sentimentų sampratos

Šaltinis	Apibrėžimas
Livnat, Petrovits (2009)	Sentimentus apibrėžia, kaip finansų rinkos dalyvių nuotaiką bet kuriuo duotu laiku.
Kaplanski, Levy (2008)	Sentimentai – finansų rinkos dalyvių nuotaikos ir emocijos.
Kartašova (2012)	Sentimentai – finansų rinkos dalyvių elgsenos didesnis priklausomumas nuo psichologijos veiksnių nei nuo makroekonominių motyvų.

Lentelės tęsinys 63 psl.

Baker Wurgler (2007)	Sentimentai – polinkis spekuliuoti arba optimistinis / pesimistinis nusiteikimas finansinės padėties atžvilgiu, nepriklausantis nuo fundamentalių veiksnių.
Mazviona (2015)	Sentimentai – nuomonė (angl. belief) apie būsimus pinigų srautus ir investavimo riziką, kurios negalima paaiškinti dabartine turima informacija.
Uygur, Tas (2012)	Sentimentai – įsitikinimai apie būsimus pinigų srautus, atsižvelgiant į objektyvius veiksnius, kuriais vadovaujantis galima teisingai nustatyti akcijų kainas.
Kartašova (2016)	Sentimentai – rinkos dalyvių įsitikinimai apie ateities pinigų srautus, susiję su tam tikru objektyviu veiksmu – būtent pagrindinės finansinės priemonės tikraja verte.

Šaltinis: Sudaryta autoriaus, remiantis lentelėje nurodytais šaltiniais.

Iš pateiktų sentimentų apibrėžimų matyti, kad skirtingi mokslininkai sentimentų sąvoką traktuoja įvairiai. Dėl plataus nagrinėjamo konteksto sentimentai apibūdinami, kaip finansų rinkos dalyvių nuotaikos, emocijos, polinkiai, nuomonės, nusiteikimas (optimistinis / pesimistinis), įsitikinimai.

Pereinant prie lūkesčių apibūdinimo, mokslinių tyrimų nustatyta, kad lūkesčiai formuoja investavimo finansų rinkos ypatumus. Remiantis lūkesčiais, finansų rinkos dalyviai kuria bendrą šalies investicinių priemonių krepšelį, kurio turto alokacijos strategijos ir plėtros galimybės priklauso nuo finansų rinkos dalyvių lūkesčių ir siekiamo rezultato apskaičiuotų įvykimo galimybių. Anot Forstater (2007), jau XX amžiuje Keinas bandė pagrįsti lūkesčių svarbą per Didžiąją depresiją. Pasak Brannon (2006), Keinas savo darbe laikėsi požiūrio, kad pagrindinė priežastis, dėl kurios Didžioji depresija taip užsitęsė, buvo ta, kad žmonės nebuvo pakankamai protingi suprasti akcijų kainų pokyčių svarbą, todėl jie priėmė įvairius neracionalius sprendimus. Keino idėjomis ne tik buvo aiškinama, kodėl kilo Didžioji depresija, bet ir valdžios veiksmų, siekiant sugrąžinti ekonomiką į buvusį klestėjimo laikotarpį, pagrindas.

Lūkesčių sąvokos supratimas ir jos svarba, siekiant paaiškinant ekonominius reiškinius, yra aktuali ir šiomis dienomis. Siekiant geriau suprasti lūkesčių, kaip ekonominio proceso veiksnio sampratą, tyrimo autorius lūkesčių apibrėžimą pradeda aiškinti, remdamasis terminų žodymais. Tarptautinis ekonomikos terminų žodynas lūkesčius apibūdina kaip individų nuomonės apie būsimų įvykių formavimą pagal visą turimą dabarties informaciją. Prekybos terminų žodyne lūkesčiai traktuojami, kaip veiksnys,

kuriuo remiantis individai numato ateitį ir šiandien apibrėžia tai, ką jie mato ateityje. Investicinių terminų žodyne lūkesčiai laikomi tikimybių įvykimo laipsniu. Mokslininkų lūkesčių apibūdinimas pateikiamas lentelėje (žr. 26 lent.).

26 lentelė. Lūkesčių sampratos

Šaltinis	Apibrėžimas
Ojaslo (2001)	Tai individo tikėjimas, kad veiksmas patenkins iš poreikio kilusį norą.
Stašys, Malikovas (2010)	Tai subjektyvus, įsivaizduojamas ateities rezultatas (prognozė), priklausantis nuo aplinkos veiksnių pokyčių ir vartotojo elgsenos.
Ross ir kt. (1987)	Tai tikėjimai, kurie laikui bėgant gali modifikuotis.
Balaji (2009)	Tai ankstesnė patirtis, bendraujant su organizacija, ir tikėtini veiksmai ateityje.

Šaltinis: Sudaryta autoriaus, remiantis lentelėje nurodytais šaltiniais.

Iš pateiktų lūkesčių apibrėžimų matyti, kad skirtingi terminų žodynai, skirtingi mokslininkai lūkesčių sąvoką traktuoja įvairiai. Dėl plataus nagrinėjamo konteksto vienur lūkesčiai apibūdinami, kaip individų nuomonės, kitur, kaip veiksnys, kuriuo remiantis sudaroma prognozė, dar kitur, kaip tikimybinis laipsnis. Vieni mokslininkai lūkesčius įvardija, kaip individo tikėjimą, kiti, kaip prognozė, tretieji – kaip ankstesnę patirtį. Kadangi šiame darbe lūkesčių sąvokos supratimas yra svarbus bei matoma, kad nėra bendro supratimo ir apibrėžimo, kas yra lūkesčiai, dėl to darbo autorius teigia, kad šiame darbe lūkesčius reikia suprasti kaip prognozes, kurias pasitelkus bus apskaičiuojamos makroekonominių rodiklių netikėtumų reikšmės.

Apibendrinus sentimentų ir lūkesčių sąvokų analizę, sukurta 27 lentelė, kurioje yra pateiktos sentimentų ir lūkesčių sampratos kertinių žodžių sąsajos.

27 lentelė. Sentimentų ir lūkesčių sampratos kertinių žodžių sąsajos

Lūkesčių sampratos kertiniai žodžiai	Sentimentų sampratos kertiniai žodžiai
1. Nuomonė; 2. Prognozė; 3. Tikėjimas; 4. Patirtis; 5. Tikimybinis laipsnis.	1. Nuomonė; 2. Nuotaika; 3. Emocija; 4. Polinkis spekuliuoti; 5. Nusiteikimas; 6. Įsitikinimas.

Šaltinis: sudaryta autoriaus.

Kaip matome iš 27 lentelės, žodis „nuomonė“ naudojamas tiek vienoje, tiek kitoje sampratoje. Lūkesčių sampratos žodį „prognozė“ darbo autorius sugretino su sentimentų sampratos žodžiu „įsitikinimas“, nes iš pateikto konteksto galima rasti panašumų: įšivaizduojamas ateities rezultatas (prognozė) ir įsitikinimai apie būsimus pinigų srautus.

Nors žodinių ir kontekstinių panašumų ir buvo atrasta, tačiau darbo autorius nesutinka dėti lygybės ženklą tarp sentimentų ir lūkesčių sampratų. Išnagrinėjęs pateiktą mokslinę literatūrą, autorius išsako nuomonę, kad sentimentų samprata yra platesnė ir apima bendruosius finansų rinkos dalyvių psichologinius aspektus (nuotaiką, emociją, nusiteikimą) praeities ar ateities laikotarpiu. Tuo tarpu lūkesčiai yra veiksnys, nukreiptas į ateitį, į prognozė, ir kurį jau galima bandyti objektyviai įvertinti, apskaičiuoti (pavyzdžiui, finansų rinkų ekspertai modeliuoja ekonominius lūkesčius – prognozes, pasitelkdami matematinius skaičiavimus).

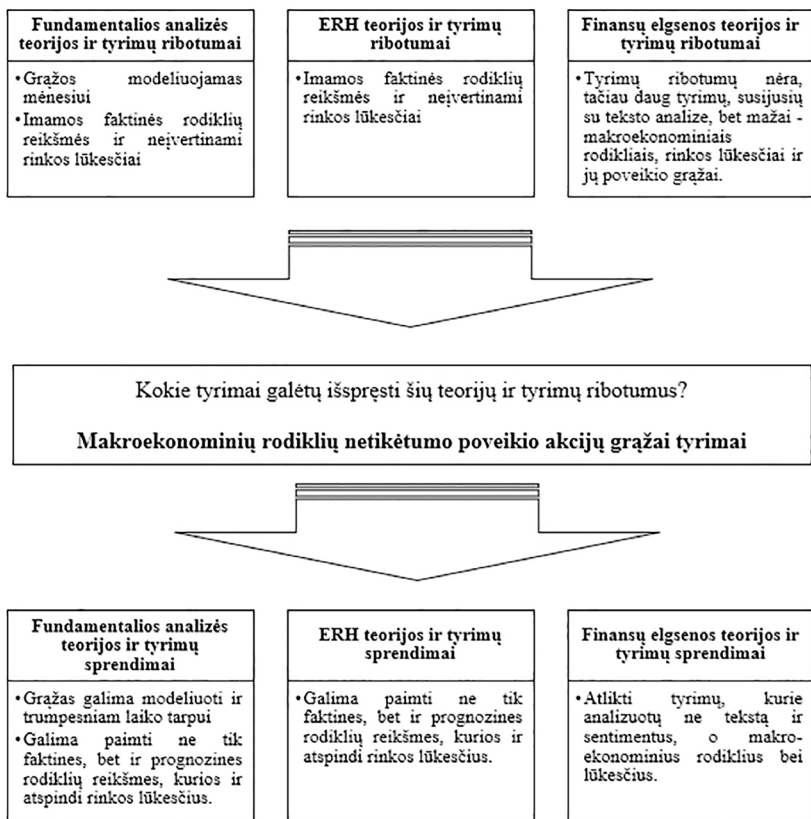
Siekiant atrasti praktiškesnių argumentų, kodėl lūkesčių veiksnio negalima tapatinti su sentimentais, buvo surasti šio tipo tyrimai. Sentimentų tipo tyrimai (Ghahfarrokhi A.H., Shamsfard M. (2020), McGurk Z., Nowak A., Hall Joshua. (2020), Xu Y, Liu Z, Zhao J, Su C. (2017), Deng S., Huang Z., Zhao A. (2018), Heston S.L., Sinha N. R (2017) ir kt.) ir jų poveikis akcijų grąžai labiau susijęs su makroekonominiais ir / arba įmonių / žmonių pranešimais tekstine forma bei įvairiomis apklausomis, kurios vėliau išreiškiamos rodikliais. Jei yra tiriami žodiniai pranešimai tekstine forma, naujausiuose tyrimuose dažniausiai naudojami „Natural language processing“ mašininio mokymosi metodai, kurie analizuoja gautą tekstą ir nustato, kokie kertiniai žodžiai (ir jų svoriai) galėtų turėti įtakos vertybinio popieriaus kainos / grąžos didėjimui ar mažėjimui. Tuo tarpu lūkesčių tyrimai labiau orientuoti į paklaidų skaičiavimus, kur jau 1954 m. buvo

sukurtas adaptyvus lūkesčių formavimo modelis, sakantis, kad ateities lūkesčiai mechaniškai prisitaiko prie ankstesnių lūkesčių klaidų, o po to atsirado implicitinis, racionalus ir kt. metodai (Young ir Darity (2001), Natkevičienė, (2010) ir kt.)

Apibendrinus poskyrį galima sakyti, kad finansinė elgsena užima svarbią poziciją investicinių sprendimų priėmimo procese, kadangi ji turi reikšmingą įtaką finansų rinkų dalyvio finansinei gerovei. Finansų elgseną paprastai formuoja asmeniniai, techniniai ir psichologiniai veiksniai, kur pagrindinė fokusavimo kryptis yra investuotojų sentimentai, kuriuos mokslininkai dažnai painioja su lūkesčiais, bet, kaip parodė sampratų analizė, to daryti nevertėtų. Nors finansų elgsenos teorijos tyrimai ir nagrinėja akcijų grąžą, įvertinus psichologinius aspektus, tačiau absoliuti dauguma tokių tyrimų orientuoti į tekstinių duomenų analizę, kur sukuriama sentimentų rodikliai, su kuriais ir yra modeliuojama akcijų grąža. Su lūkesčiais susijusių tyrimų per finansų elgsenos teoriją, kurie taip pat sietųsi su makroekonominiais rodikliais, autorius nerado, todėl mano, kad šis tyrimas galėtų ženkliai prisidėti prie šios teorijos ir praktikos vystymo.

1.4 Makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tyrimų analizė ir sąsajos su išanalizuotomis teorijomis

Minėtų teorijų ir jų tyrimų ribotumai bei žinojimas, kad laikui bėgant akcijų rinkos tampa vis kompleksiškesnės su vis labiau didėjančiais informacijos srautais, paskatino ieškoti naujų teorijų ir tyrimų. Taip buvo atrasti makroekonominių rodiklių netikėtumo tyrimai, kurie, autoriaus manymu, ne tik jungia šių teorijų principus, bet ir leidžia atsirasti diskusijai dėl naujo įnašo vystant šias teorijas ir praktiką. (žr. 6 pav.).



Šaltinis: sudaryta autoriaus.

6 pav. Makroekonominių rodiklių netikėtumo tyrimų susietumas su fundament aliosios analizės, ERH ir finansų elgsenos teorijomis ir jų tyrimais

Tokie tyrimai, kurie prognozuoja netikėtumo reiškinio poveikį akcijų gražai, mokslinėje ir nemokslinėje literatūroje paprastai vadinami makroekonominių naujie- nų, pranešimų, netikėtumų, lūkesčių tyrimais. Šie tyrimai įvertina ne tik faktines, bet ir prognozes makroekonominių rodiklių reikšmes, taip sukurdami makroekonominį rodiklio netikėtumo matą, kuris ir yra pagrindinis kintamasis modeliuojant akcijų gra- žą per trumpą laiko tarpą.

Kaip matyti iš paveikslo, makroekonominių rodiklių netikėtumų tyrimai galėtų praplėsti fundamentaliosios analizės, ERH ir finansų elgsenos tyrimus, panaikindami

jų ribotumas. Taip pat tokio pobūdžio tyrimai sukurtų pagrindą praplėsti ar modifikuoti fundamentaliosios analizės ar ERH teorijų supratimą, įtraukiant į modelius ne tik faktines, bet ir prognozės rodiklių reikšmes. Šiame kontekste prognoziniai duomenys atspindėtų rinkoje susiformavusius lūkesčius, kurie yra svarbūs nustatant akcijų tikrąją vertę.

Mokslininkai (Kurov, Sancetta ir kt. (2019), Frijns B., Indriawan I., ir kt. (2019), Alexiou, Vogiazas, Taqvi (2018), Cakan, Gupta (2017), Nadleri ir Schmidt (2016), Chen, Liu, Lu., Tang (2015), Miao, Ramchander, Zumwalt (2014), Gurgul, Wójtowicz (2014), Harju, Hussain (2011), Hussain (2010)) savo darbuose paprastai nekelia klausimo, ar makroekonominių rodiklių netikėtumai yra reiškinys ir, kaip buvo minėta, makroekonominių rodiklių (arba kitų rodiklių) netikėtumus dažniausiai apskaičiuoja išvestiniu rodikliu, kuris šiame tyrime vadinamas makroekonominio rodiklio netikėtumo matu (žr. 1 formulę).

$$S_{k,t} = \frac{A_{k,t} - E_{k,t}}{\hat{\sigma}_k}; \quad \hat{\sigma}_k = \sqrt{\text{var}(A_{k,t} - E_{k,t});} \quad (1)$$

$S_{(k,t)}$ – standartizuota makroekonominio rodiklio k netikėtumo mato reikšmė prekybos dieną t .

$A_{(k,t)}$ – faktinė makroekonominio rodiklio k reikšmė prekybos dieną t .

$E_{(k,t)}$ – makroekonominio rodiklio prognozė reikšmė, kuri gaunama apklausiant įmones. Lentelėje išvardinti tyrinėtojai prognozes reikšmes ima iš „Bloomberg“ duomenų bazės.

Skirtumas tarp $A_{k,t}$ ir $E_{k,t}$ – makroekonominio rodiklio netikėtumo reikšmė k prekybos dieną t .

$\hat{\sigma}_k$ – makroekonominių rodiklių k netikėtumų reikšmių standartinis nuokrypis. Šis rodiklio panaudojimas padeda palyginti skirtingus standartizuotus makroekonominis rodiklius.

Nors pati formulė, kuri reprezentuoja makroekonominio rodiklio netikėtumo reiškinį, yra gana paprasta, kyla abejonių dėl reiškinio tokio kaip termino priskyrimo, tačiau labiau pasigilinus, kokie būna makroekonominių rodiklių (pavyzdžiui, BVP, nedarbo lygis ir kt.) veiksniai, kurie turi įtakos rodiklių faktinėms reikšmėms, tampa aišku, kad tokių veiksnių yra labai daug. Todėl, nors makroekonominio rodiklio netikėtumą ir reprezentuoja vienas rodiklis (makroekonominio rodiklio netikėtumo matas), tačiau jį sudarantys kintamieji (makroekonominio rodiklio faktinė ir prognozė reikšmės) yra tokie kompleksiški, kad autorius makroekonominio rodiklio netikėtumą vadina reiškiniu. Verta paminėti, kad nagrinėjamuose darbuose makroekonominių rodiklių netikėtumai nebuvo prilyginami reiškiniui, tad šio darbo autorius negali diskutuoti ir lyginti savo nuomonės su kitais mokslininkais.

Nagrinėjant pačius makroekonominių rodiklių netikėtumų tyrimus ir jų poveikį akcijų kainai ar grąžai, pateikiama 28 lentelė.

28 lentelė. Akcijų kainų ir grąžos analizavimo tyrimai makroekonominių rodiklių netikėtumo aspektu

Metai	Autorius	Nagrinėjama rinka (-os)	Tyrimo problematika
2019	Frijns B., Indiawan I., ir kt.	JAV, Kanada	Kaip modeliuoti makroekonominių rodiklių netikėtumų poveikį akcijų rinkos kokybei?
2019	Kurov K., Sancetta A. ir kt.	JAV	Kaip modeliuoti makroekonominių rodiklių netikėtumų poveikį akcijų indeksų ir išdo ateities sandorių kainoms?
2018	Alexiou C., Vogiazas S., Taqvi A.	JAV	Kaip modeliuoti makroekonominių rodiklių netikėtumų poveikį sudarytų portfelių grąžai?
2017	Cakan E., Gupta R.	Pietų Afrika	Kaip modeliuoti nedarbo ir infliacijos rodiklių netikėtumų poveikį akcijų kainų kintamumui?
2016	Nadleri D., ir Schmidt A.B	JAV	Kaip modeliuoti makroekonominių rodiklių netikėtumų poveikį biržoje prekiaujamų akcijų indekso kainai?
2015	Chen J., Liu Y., Lu. L., Tang Y.	Kinija	Kaip modeliuoti investuotojų dėmesio planuojamiems makroekonominiams pranešimams poveikį ateities akcijų indekso kainai?
2014	Miao H., Ramchander S., Zumwalt J.K.	JAV	Kaip modeliuoti makroekonominių rodiklių netikėtumų poveikį ateities akcijų indekso kainai?
2014	Gurgul H., Wójtowicz T.	Lenkija	Kaip modeliuoti makroekonominių rodiklių netikėtumų poveikį akcijų kainai?
2012	Gupta R., Reid M.	Pietų Afrika	Kaip modeliuoti makroekonominių rodiklių netikėtumų poveikį pramonės šakų akcijų indeksų kainai?
2011	Harju K., Hussain S.M.	Europa	Kaip modeliuoti makroekonominių rodiklių netikėtumų poveikį akcijų indeksų kainai?
2010	Hussain S.M.	JAV	Kaip modeliuoti pinigų politikos rodiklių netikėtumų poveikį akcijų indeksų kainai?

Šaltinis: sudaryta autoriaus, remiantis lentelėje nurodytais mokslininkais.

Mokslininkai Frijns B., Indiawan I. ir kt. (2019) tyrė akcijų rinkos kokybės pokyčius JAV ir Kanadoje per makroekonominius naujienų pranešimus ir netikėtumus. Mokslininkai akcijų rinkos kokybę matavo pagal minėtų kintamųjų priklausomybę nuo grąžos, prekybos kaštų ir akcijų kainų paklaidų. Atlikus empirinį tyrimą paaiškėjo,

kad investuotojai sureaguoja į užsakymų disbalansą 5 minutėmis greičiau JAV, nei kad Kanadoje. Makroekonominių naujienų pranešimų momentu sandorių kaštai Kanadoje didėja labiau nei JAV, o tai rodo, kad JAV rinka siūlo geresnį likvidumą.

Kiti tyrėjai Kurov K., Sancetta A. ir kt. (2019) nagrinėjo JAV akcijų indeksų ateities kainas ir išdoro ateities sandorius, atsižvelgdami į 30 JAV makroekonominių naujienų pranešimus ir jų netikėtumus. Tyrime buvo nustatyta, kad pagal 9 iš 30 pranešimų akcijų kaina pradeda judėti „teisinga“ kryptimi, likus maždaug 30 minučių iki naujienų pasirodymo. Išankstiniai akcijų kainos svyravimai vidutiniškai sudarė apie 40 % viso tos akcijų kainos svyravimo. Todėl autoriai argumentuoja, kad kai kurie prekybininkai turi privačios informacijos apie makroekonominius įvykius.

Mokslininkai Alexiou, Vogiazas ir Taqvi (2018) analizavo 25 akcijų portfelių reakciją į makroekonominių rodiklių netikėtumus, per laikotarpį nuo 1998 m. balandžio iki 2017 m. gegužės. Tyrimų rezultatai rodo, kad ISM ne gamybos indeksas, darbuotojų dirbančių ne žemės sektoriuje skaičius, mažmeninė prekyba, asmeninės vartojimo išlaidos ir bedarbių rodiklių netikėtumai turi didelį poveikį portfelių grąžoms. Taip pat nustatyta, kad ISM ne gamybos indeksas, asmeninio vartojimo išlaidų ir bedarbių paraiškų rodiklių netikėtumai formuoja tam tikras tendencijas įvairiuose portfeliuose. Pastebima, kad sukurdamas portfelius su įmonėmis, kurios turi didesnę veiklos pelningumą ir investavimo lygį, investuotojas gali potencialiai sumažinti nepastovumo riziką, atsirandančią dėl minėtų trijų makroekonominių rodiklių.

Cakan ir Gupta (2017) savo darbe modeliuoja JAV infliacijos ir nedarbo lygio rodiklių netikėtumų poveikį Pietų Afrikos akcijų kainoms. Tyrime nustatyta, kad blogos naujienos apie JAV infliaciją nepaveikia Pietų Afrikos akcijų grąžos kintamumo, kai tuo tarpu geros naujienos didina kintamumą. Taip pat ištirta, kad šalies akcijų rinka svyruoja daugiau, netikėtai didėjant JAV nedarbo lygiui, ir svyruoja mažiau, netikėtai sumažėjus JAV nedarbo lygiui, o pastarasis poveikis yra stipresnis nei pirmasis. Taigi netikėtai infliacijos tempo sumažėjimas ir nedarbo lygio padidėjimas didina akcijų rinkos nestabilumą, o tai savo ruožtu, anot mokslininkų, reikštų, kad finansinės sąlygos šioje šalyje pablogėtų ir neigiamai paveiktų realiąją ekonomiką. Tuo tarpu teigiami JAV infliacijos ir užimtumo pokyčiai prisideda prie stabilesnių, taigi ir mažiau kintančių akcijų rinkų besivystančiose šalyse.

Mokslininkai Nadleri ir Schmidt (2016) analizavo JAV biržoje prekiaujamų akcijų indekso (ETF) kainos reakciją į makroekonominių rodiklių netikėtumus, apimančius laikotarpį nuo 2009 m. sausio iki 2013 m. liepos. Nustatyta, kad vidutinė in-

dekso dienos grąža rodiklių skelbimo dienomis gali būti gerokai didesnė už pirkimo ir laikymo strategiją, nors jų skirtumas gali būti statistiškai nereikšmingas. Pastebėta, kad ISM gamybos indekso, darbuotojų, dirbančių ne žemės sektoriuje, skaičiaus, tarptautinės prekybos balanso, pirmaujančių rodiklių indekso, naujai pradėtų būstų statybos ir bedarbių paraiškos rodikliai turi didžiausią ir statistiškai reikšmingą poveikį indekso grąžai.

Mokslininkai Chen, Liu, Lu ir Tang (2015) nagrinėja investuotojų dėmesio planuojamuose makroekonominiuose pranešimuose vaidmenį, siekdami paaiškinti Kinijos ateities akcijų indekso kainų svyravimus. Pastebėta, kad investuotojų dėmesys, kurį nurodo „Baidu“ paieškos indeksas, yra didžiausias laukiant VKI rodiklių. Nustatyta, kad tik VKI rodiklis turi didelę trumpalaikę įtaką CSI 300 ateities indekso kainai, likvidumui ir nepastovumui. Be to, CSI indekso kainų svyravimai yra didesni, pasirodant blogoms VKI naujienoms ir aukštos infliacijos laikotarpiu.

Mokslininkai Miao, Ramchander ir Zumwalt (2014) analizuoja makroekonominių rodiklių netikėtumų poveikį S&P 500 indekso ateities sandorių kainai. Tyrimai patvirtina stiprų ryšį tarp makroekonominių rodiklių ir indekso kainos svyravimų. Daugiau nei 60 % šuolių tarp 10:00 ir 10:05 ir daugiau kaip 75 % šuolių tarp 8:30 ir 8:35 yra susiję su vienu ar daugiau rodiklių, išleistų atitinkamai 10:00 ir 8:30. Taip pat atkreipiamas dėmesys į teigiamą BVP, gamybos kainų indekso, gamybos užsakymų ir neigiamą VKI, pažangių mažmeninių pardavimų rodiklių netikėtumų poveikį indekso kainai.

Gurgul ir Wójtowicz (2014) analizuoja JAV makroekonominių rodiklių netikėtumų poveikį keturių Lenkijos akcijų indeksų (WSE, WIG20, WIG40, WIG80) kainų kaitai. Akcijų indeksų kainas analizavo praėjus 1 minutei, kai pasirodo rodiklis. Pastebėta, kad vartotojų kainų indekso, produkcijos kainų indekso rodiklių pranešimų reikšmėms esant mažesnėmis už ekspertų prognozes, o ilgalaikių prekių užsakymų, mažmeninių pardavimų, pramoninės gamybos, darbuotojų, dirbančių ne žemės sektoriuje, skaičiaus rodiklių pranešimų reikšmėms esant didesnėmis už ekspertų prognozes yra laikomi geromis naujienomis ir turi teigiamą poveikį WSE akcijų indekso kainai. Taip pat pastebėta, kad WIG20 akcijų indekso kaina po pirmos minutės, pasirodžius naujienai, reaguoja jautriau nei WIG40, WIG80 indeksai.

Gupta ir Reid (2012) savo darbe tyrinėja makroekonominių rodiklių netikėtumų poveikį Pietų Afrikos pramonės šakų akcijų indeksų kainų kaitai. Įvykių analizės metodu atliktas tyrimas rodo, kad ilguoju laikotarpiu tik VKI rodiklių netikėtumai

reikšmingai ir neigiamai veikia akcijų indeksų grąžą. Tuo tarpu Bajeso analizės metodu atliktas tyrimas rodo, kad ir produkcijos kainų indekso rodiklių netikėtumai reikšmingai veikia akcijų indeksų kainas. Tiesa, pastaruoju metodu tiek VKI, tiek produkcijos kainų indekso kainų kintamumas yra trumpalaikis – iš karto pasirodžius rodikliams.

Mokslininkai Harju ir Hussain (2011) savo darbe analizuoja makroekonominių rodiklių netikėtumų poveikį didžiausiems Europos indeksų kainų svyravimams. Autoriai akcijų indeksų kainas analizavo praėjus 5 minutei, kai pasirodo rodiklis. Tyrimo išvados rodo, kad prasidėjus JAV prekybai ženkliai padidėja Europos indeksų kainų kintamumas. Taip pat makroekonominių rodiklių netikėtumai daro tiesioginį ir didelį poveikį Europos akcijų indeksų dienos grąžoms ir kaitai. Anot mokslininkų, tyrimų rezultatai rodo, kad ir toliau reiktų tirti tarpusavio priklausomybes vertybinių popierių rinkoje tarp JAV ir Europos. Taip pat stiprūs akcijų indeksų dienos svyravimai Europos rinkoje turi reikšmingą impulsą mokslininkams ir investuotojams ne tik analizuoti ir modeliuoti trumpalaikę indeksų grąžą, bet ir finansų rinkų dalyvių elgsenos dinamiką.

Hussain (2010) savo darbe nagrinėjo Europos ir JAV pinigų politikos rodiklių netikėtumų įtaką šių minėtų rinkų indeksų kainoms. Akcijų indeksų kainas analizavo praėjus 5 minutėms, kai pasirodo rodiklis. Tyrimas rodo, kad pinigų politikos rodiklių netikėtumai turi reikšmingą poveikį indeksų kainai. Be to autorius pastebėjo, kad ECB spaudos konferencijoje, kuri vyksta praėjus 45 minutėms po tos pačios dienos priimtų pinigų politikos sprendimų, taip pat turi reikšmingą poveikį Europos akcijų indeksų kainai ir kintamumui.

Pereinant prie detalesnės makroekonominių rodiklių netikėtumų tyrimų analizės, verta pateikti, kokiais metodais mokslininkai vadovaujasi, modeliuodami makroekonominio rodiklio poveikį akcijų rinkoms (žr. 29 lent.).

29 lentelė. Akcijų grąžų analizavimo tyrimų metodai makroekonominių rodiklių netikėtumų aspektu

Metai	Autorius	Tyrimo laikotarpis	Duomenų dažnumas	Tyrimo metodai
2019	Frijns B., Indriawan I., ir kt.	2004–2011	Minutiniai	– RA
2019	Kurov K., San-cetta A. ir kt.	2008–2014	Minutiniai	– RA – ES
2018	Alexiou C., Voghiazas S., Taqvi A.	1998–2017	Dieniniai	– RA

Lentelės tęsinys 73 psl.

Lentelė atkelta iš 72 psl.

2017	Cakan E., Gupta R.	1994–2016	Dieniniai	– GJR-GARCH
2016	Nadleri D., ir Schmidt A.B	2009–2013	Dieniniai	– ARMA – GARCH – GJR-GARCH
2015	Chen J., Liu Y., Lu L., Tang Y.	2011–2014	Minutiniai	– SV – RA
2014	Miao H., Ramchander S., Zumwalt J.K.	2003–2010	Minutiniai	– GJD – RA
2014	Gurgul H., Wójtowicz T.	2007–2013	Minutiniai	– ES
2012	Gupta R., Reid M.	2002–2011	Dieniniai	– BVAR – RA – ES
2011	Harju K., Hussain S.M.	2000–2006	Minutiniai	– ARMA – GARCH
2010	Hussain S.M.	2000–2008	Minutiniai	– ARMA – GARCH

Šaltinis: sudaryta autoriaus, remiantis lentelėje nurodytais mokslininkais.

Iš pateiktos lentelės matoma, kad vidutinė tyrimų apimtis yra 9 metai. Taigi sukurti modeliai apima kelis ekonominius ciklo periodus, kas yra gerai, nes įvertinami pakilimai ir nuosmukiai.

Pagal duomenų tipą autoriai renkasi dieninius ir minutinius akcijų kainų duomenis. Duomenų dažnumo tipo pasirinkimas dažniausiai priklauso nuo to, ar pavyksta gauti duomenis. Kuo duomenys dažnesni, tuo patikimesnis modelis. Taigi pagal minėtus tyrimus objektyviausi modeliai yra sudaryti pagal minutės akcijų indekso kainų duomenis.

Nors tyrimai, nagrinėjantis akcijų grąžą makroekonominių rodiklių netikėtumų aspektu ir yra sutinkami, tačiau atlikta tyrimų analizė kelia nemažai klausimų, o išvalgos būtų tokios:

- nėra pakankamai išplėta didelių dažnių duomenų analizė, t. y. mokslininkai tokiuose tyrimuose vis dar pasirenka tirti dienes akcijų grąžas, todėl vis dar tampa neaišku, kaip greitai (minučių tikslumu) nagrinėjama vertybinių popierių rinka pritaiko prie makroekonominių rodiklių netikėtumų;

- trūksta tyrimų, nagrinėjančių euro zonos akcijų rinką, o dažniausiai sutinka-

mi tyrimai buvo atlikti JAV rinkai;

- nė viename darbe nebuvo pastebėta, kad siekiant sukurti tikslesnius prognozavimo modelius, makroekonominių rodiklių netikėtumų reikšmės būtų suskaidytos į įvairius scenarijus.

- vis dar naudojami tradiciniai akcijų grąžų modeliavimo metodai, atsiribojant nuo naujesnių ir inovatyvių mašininio mokymosi metodų;

- mokslininkų darbuose trūko gerųjų modeliavimo praktikų taikymo, kai remiantis skirtingais metodais sukuriama daugiau nei keli modeliai ir vėliau lyginami tarpusavyje, taip siekiant rasti geriausią.

Būtent dėl šių neišplėtotų požiūrių ir anksčiau minėtų teorijų naujumo įnašo į praktikos vystymą manoma, kad šis tyrimas būtų aktualus ir papildantis kitus požiūrius.

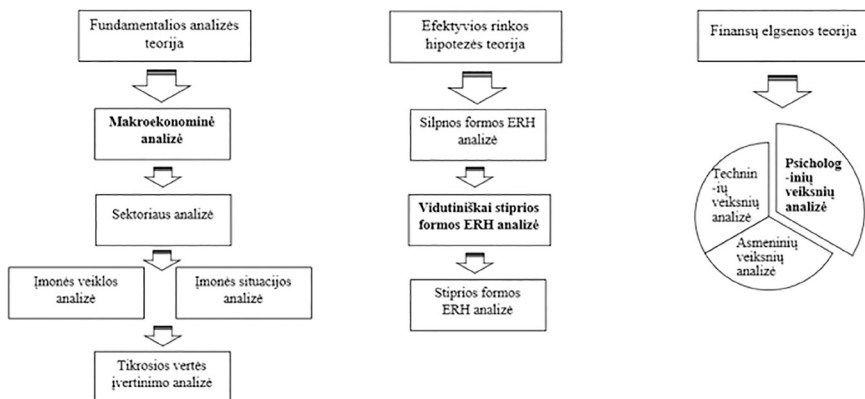
II. MAKROEKONOMINIŲ RODIKLIŲ NETIKĖTUMŲ POVEIKIO AKCIJŲ GRĄŽAI MODELIAVIMO METODIKA

2.1 Makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tirti konceptualaus modelio formavimas

Apibendrinus ekonomikos teorijas ir empirinius tyrimus, susijusius su atskirų veiksmų taikymu akcijų grąžai aiškinti ir prognozuoti, sudarytas konceptualus teorinės dalies makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tirti modelis. Modeliu siekiama nustatyti, kaip akcijų grąža yra analizuojama, remiantis fundamentalia, efektyvios rinkos hipotezės ir finansų elgsenos teorijų požiūriais.

Tam, kad lengviau suprasti, kaip buvo formuotas tyrimo konceptualus modelis, yra sudarytas akcijų grąžą nagrinėjančių teorijų analizės paveikslas (žr. 7 pav.).

Akcijų grąžą analizuojančios teorijos

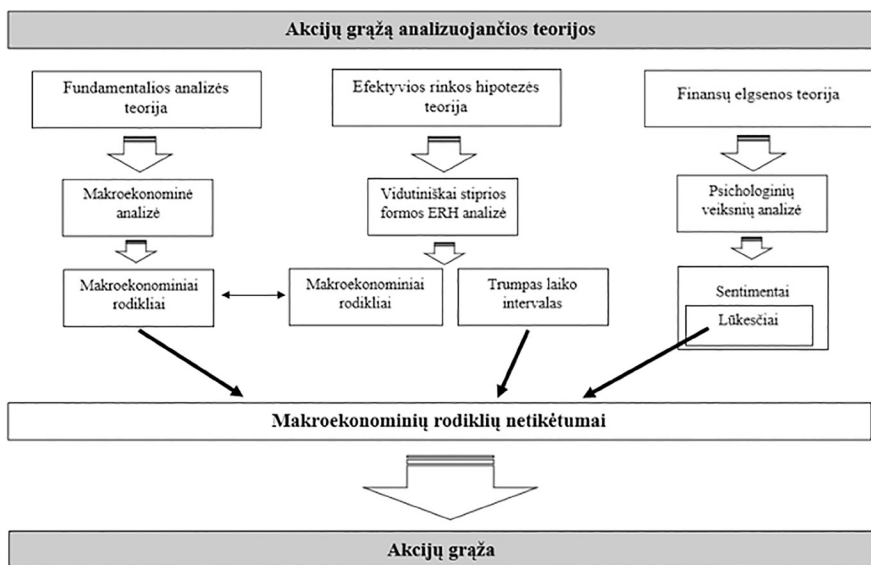


Šaltinis: sudaryta autoriaus.

7 pav. Akcijų grąžą analizuojančių teorijų ir jų veiksnių santrauka

Šiame tyrime buvo apsibrėžta, kad akcijų grąžą veikia trijų teorijų veiksniai ir reiškiniai. Pirmoji yra fundamentaliosios analizės teorija, jos kategorijos pagal analizės kryptį yra pavaizduotos „iš viršaus į apačią“ analizės metodo požiūriu. Antroji yra efektyvios rinkos hipotezės teorija, kurios formos yra pavaizduotos eilės tvarka, kur viršuje lengvai empiriškai patikrinama, o apačioje – sudėtingai. Trečioji yra finansų elgsenos teorija, kurių analizės kryptis pagal sudėtingumą ar analizės eiliškumą yra sunku išskirti, dėl to jos pavaizduotos, kaip vienodai svarbios. Juodai paryškintos tos analizės, kurios pereina į tyrimo konceptualų modelį.

Toliau pateikiamas šio tyrimo sudarytas konceptualus teorinės dalies makroekonominė rodiklių netikėtų poveikio akcijų grąžai tirti modelis (žr. 8 pav.).



Šaltinis: sudaryta autoriaus.

8 pav. Konceptualus teorinės dalies makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tirti modelis

Disertacinio tyrimo autoriaus požiūrį į akcijų grąžos prognozavimą iliustruoja 7 pav., parodantis, kokiomis teorijomis remiamasi, formuojant disertacinio tyrimo modelį. Akcijų grąžos prognozavimas pagrįstas fundamentalios analizės, ERH, finansų elgsenos teorijomis. Iš fundamentalios analizės teorijos išskirta makroekonominė analizė, kuri apima makroekonominius rodiklius. Iš ERH išskirta vidutiniškai stiprios formos ERH, kuri apima makroekonominius rodiklius. Kadangi EHR tyrimais siekiama nustatyti, kaip greitai (minučių, valandos, dienos tikslumu) akcijų kainos ar grąžos prisitaiko prie naujos informacijos apie svarbius ekonominius įvykius pasirinktoje rinkoje, tai kaip atskiras svarbus veiksnys išskirtas trumpas laiko intervalas. Iš finansų elgsenos teorijos pabrėžta psichologinių veiksnių analizė, kuri apima sentimentus, o šie – lūkesčius.

Nagrinėjant fundamentalių veiksnių poveikio akcijų grąžai tyrimus 1.1 skyriuje buvo pastebėta, kad mokslininkai dažniausiai tiria mėnesines akcijų indeksų grąžas. Nors rodiklių poveikis nustatytas kaip statistiškai reikšmingas, tačiau neretai akcijų indeksui per mėnesio laikotarpį turi įtakos ir kiti nenagrinėjami rodikliai. Todėl tampa

aktualu ištirti, koki momentinį poveikį turi rodiklis akcijų grąžai, kai jis paviešinamas, taip išvengiant kitų rodiklių akumuliuoto poveikio. Vienas iš šios teorijos ribotumų yra ir tas, kad ji orientuota į makroekonominių (ir ne tik) rodiklių faktinių reikšmių analizę ir jų poveikį akcijų grąžai, neįvertinant tuo metu rinkoje vyraujančių lūkesčių, kurie taip pat galėtų paveikti akcijų grąžą.

Tokie tyrimai, kurie nagrinėja momentinį, arba dieninį akcijų indeksų grąžų kintamumą, paprastai vadinami įvykių tyrimais (1.2 skyrius). Šiais tyrimais siekiama nustatyti, kaip greitai (minučių, valandos, dienos tikslumu) akcijų kainos prisitaiko prie naujos informacijos apie svarbius makroekonominius įvykius pasirinktoje rinkoje. Nors efektyvios rinkos hipotezės tyrimai ir nagrinėja akcijų grąžą per trumpesnę laiko tarpą, skirtingai nei fundamentalioji analizė, tačiau neįvertina tuo metu rinkoje vyraujančių lūkesčių (1.3 finansų elgsenos skyrius), kurie taip pat galėtų paveikti akcijų grąžą.

Tyrinėjant finansų elgsenos teoriją ir jos tyrimus pamatyta, kad absoliuti dauguma tyrimų orientuoti į tekstinių duomenų analizę, kuriuose sukuriama sentimentų rodikliai, su kuriais ir yra modeliuojama akcijų grąža. Konkrečiai su lūkesčiais susijusių tyrimų, atsižvelgiant į finansų elgsenos teoriją, kurie taip pat sietųsi su makroekonomiais rodikliais, nebuvo rasta.

Taigi makroekonominiai rodikliai, trumpas laiko intervalas ir lūkesčiai formuoja makroekonominių rodiklių netikėtumo reiškinį, kuris daro įtaką akcijų grąžai. Tai yra unikalus šio tyrimo autoriaus požiūris, kuris gali būti diskutuotinas. Verta paminėti, kad nagrinėjamuose darbuose makroekonominių rodiklių netikėtumai nebuvo prilyginami reiškiniui, tad šio darbo autorius negali diskutuoti ir lyginti savo nuomonės su kitais mokslininkais. Makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modelio privalumas tas, kad jį formuojant atsižvelgiama į visus tris akcijų grąžą lemiančius veiksniai. Tokia idėja leidžia išvengti minėtų teorijų tyrimų ribotumų ir leidžia atsirasti diskusijai dėl naujo įnašo vystant šias teorijas ir praktiką.

2.2 Makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tirti tyrimo metodikos pagrindimas

2.2.1 Tyrimo hipotezių formavimas ir pagrindimas

Šiame tyrime yra suformuotos trys hipotezės:

H_1 : Makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiką tarpą, remiantis tradiciniais metodais.

H_2 : Makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiką tarpą, remiantis mašininio mokymosi metodais.

H_3 : Mašininio mokymosi metodai, palyginus su tradiciniais metodais, leidžia sukurti tikslesnius makroekonominių rodiklių netikėtumų poveikio akcijų grąžai prognozavimo modelius.

Pirmosios hipotezės suformavimo pagrindimas kyla iš klausimo, ar apskritai atlikus tyrimą tradiciniais metodais bus gaunami statistiškai patikimi modeliai, kuriais būtų galima prognozuoti pasirinktą akcijų indeksą. Šios hipotezės patvirtinimas neįneštų labai didelio indėlio į ekonomikos mokslą šioje srityje, nes tokių tyrimų jau yra atlikta. Tačiau tai praplėstų panašių tyrimų lauką euro zonos atveju.

Antrosios hipotezės suformavimo pagrindimas kyla iš 1.4 atliktos tyrimų analizės metodų ribotumų. Šioje tematikoje sukurti modeliai dažniausiai sudaromi tradiciniais metodais, tačiau nebuvo pabandyta sukurti modelių, remiantis mašininio ir giliojo mokymosi metodais. Jei ši hipotezė būtų priimta, tai padėtų praplėsti naudojamų metodų lauką analizuojamai tematikai ir įneštų naujovių į šią mokslo sritį.

Trečioji tyrimo hipotezė kilo natūraliai iš pirmųjų dviejų. Yra aišku, kad prognozavimo modelių tikslumą (ypač tradicinių) galima išmatuoti, dėl to kyla klausimas, kurie metodai – tradiciniai ar mašininio mokymosi yra tinkamesni ir geresni šiam darbui. Toks palyginimas leistų objektyviai įvertinti, kiek skiriasi sukurtų modelių tikslumai ir paklaidos. Tai yra originali šio tyrimo idėja ir nebuvo rasta niekur kitur. Jei hipotezė būtų patvirtinta, toks palyginimas paskatintų ir kitus panašios tematikos mokslininkus pabandyti panaudoti mašininio mokymosi metodus, siekiant geresnių ir objektyvesnių rezultatų savo temai atlikti.

2.2.2 Tyrimo logika ir specifika

Tyrimui atlikti buvo pasirinktas EURO STOXX 50 akcijų indeksas. Grąžos analizės ir modeliavimo laikotarpis 2008-01-30–2019-10-03 periodas, o indekso duomenų

dažnumas – minutės. Tokia tyrimo imtis buvo pasirinkta todėl, kad tik nuo 2008-01-30 pradėta minutėmis fiksuoti EURO STOXX 50 indekso kaina.

Duomenys buvo gauti iš „Bloomberg“ terminalo, jie pateikia šią informaciją: indekso minutės atidarymo kaina, aukščiausia kaina, žemiausia kaina ir uždarymo kaina. Turint indekso minutės uždarymo ir atidarymo kainą, galima apskaičiuoti indekso grąžą konkrečią minutę, kuri ir yra modelio priklausomoji reikšmė ir kurią siekiama prognozuoti. Indekso grąža apskaičiuojama taip (žr. 2 formulę).

$$G_m = \frac{U_m - A_m}{A_m} \times 100 \quad (2)$$

Čia:

G_m % – EURO STOXX 50 indekso grąža konkrečią minutę (m).

U_m – EURO STOXX 50 indekso uždarymo kaina konkrečią minutę (m).

A_m – EURO STOXX 50 indekso atidarymo kaina konkrečią minutę (m).

Atkreiptinas dėmesys, kad šiame tyrime skaičiuojama akumuliuota EURO STOXX 50 grąža per 45 minutes po makroekonominio rodiklio realizacijos momento. Pavyzdžiui, norint apskaičiuoti indekso grąžą po 10 minutės po paskelbimo momento, iš 9 minutės uždarymo kainos reikia atimti 1 minutės atidarymo kainą ir dalinti iš 1 minutės atidarymo kainos.

Specifiškai 45 minučių ir ne didesnis intervalas buvo pasirinktas, siekiant išvengti kitų makroekonominių rodiklių poveikio, kurie dar tik atsispindės akcijų grąžoje. Pavyzdžiui, jei žinoma, kad nedarbo lygio rodiklio realizacijos valanda yra 11:00, o RBVP 12:00, tai norint išvengti rinkos „nervingumo“, t. y. akcijų grąžos kintamumo, kuriai įtaką galėtų daryti RBVP rodiklio reikšmės spekuliacijos, tai skaičiuojama grąža po nedarbo lygio rodiklio realizacijos yra iki 45 minučių.

Tyrimui atlikti buvo pasirinkti visi prieinami euro zonos makroekonominiai rodikliai, kuriuos buvo galima rasti „Bloomberg“ terminale. Siekiant atlikti tolimesnius veiksmus, šie rodikliai turėjo turėti faktines ir prognozes reikšmes, tad galiausiai rodiklių skaičius yra 26 (žr. 30 lent.).

Makroekonominių rodiklių faktinės reikšmės šiame tyrime yra realizacijos metu pateiktos / publikuotos reikšmės. Rodiklio paskelbimo momentai žinomi iš anksto, ir yra grafikai, kuriais remiantis galima žinoti tikslią dieną ir valandą, kai rodiklio faktinė reikšmė bus anonsuojama. Faktinės rodiklių reikšmės buvo gautos iš „Bloom-

berg“ terminalo, kurio šaltinis yra „Eurostato“ duomenų bazė.

Makroekonominį rodiklių prognozės reikšmės šiame tyrime yra mediana tarp prognozuojančių bendrovių pateiktų rodiklio reikšmių. Prognozuojančios bendrovės yra bankai, investicinės bendrovės, ribotos rizikos fondai ir kt. Pavyzdžiui, prognozinę rodiklio RBVP ketv. / ketv. reikšmę 2018-12-07 realizacijos dienai prognozavo 41 bendrovė, tarp kurių buvo tokios įmonės, kaip „Nord LB“, „BNP Paribas“, „Barclays“, „Capital Economics“, „Commerzbank“, „Credit Suisse Group“, „Dankse Bank“, „HSBC Bank“ ir dar daug kitų. Tyrimo autorius pastebėjo, kad bendrovės ir jų skaičius yra nuolat kintantys, tačiau dažniausiai rodiklio prognozinę pateikia mažiausiai 5 įmonės, o maksimaliai net 41. Pagal kokius kriterijus yra pasirenkamos bendrovės ir pagal kokią metodiką jos skaičiuoja prognozes reikšmes, autoriui nėra žinoma. Prognozinės rodiklių reikšmės buvo gautos iš „Bloomberg“, kuris, autoriaus manymu, pats ir inicijuoja šias apklausas.

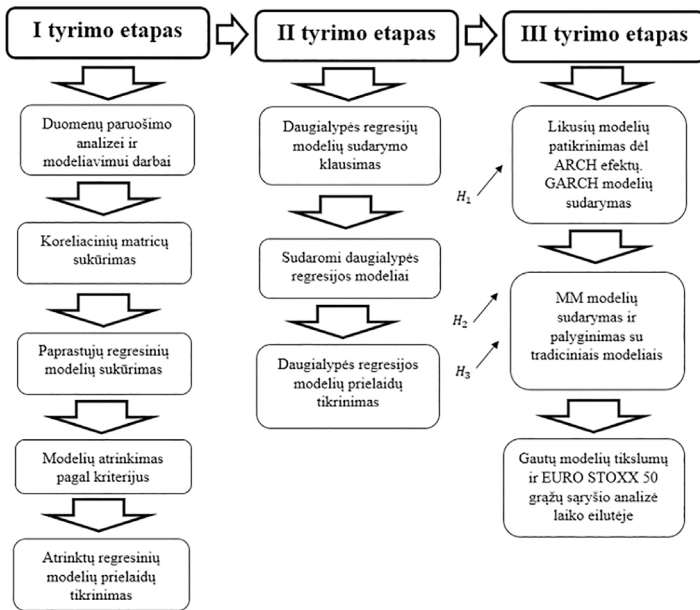
30 lentelė. Makroekonominiai rodikliai ir jų suskirstymas

Rodiklio pavadinimas angliškai	Rodiklio pavadinimas lietuviškai	Reikšmių kiekis
PAGRINDINIAI RODIKLIAI		
Gross Fixed Capital Formation (swda, qoq%)	Bendrojo pagrindinio kapitalo formavimo (ketv./ketv.)	57
Household Consumption (swda, qoq%)	Namų ūkių vartojimo (ketv./ketv.)	58
Real GDP (swda, yoy%)	Realaus bendrojo vidaus produkto (m./m.)	121
Real GDP (swda, qoq%)	Realaus bendrojo vidaus produkto (ketv./ketv.)	121
Unemployment Rate (%)	Nedarbo lygio	141
Trade Balance (€ mn, sa)	Prekybos balanso (m./m.)	126
SEKTORINIAI RODIKLIAI		
PPI Finished Goods (yoy %)	Gamintųjų kainų indekso (m./m.)	141
Producer Price Index (mom %)	Gamintųjų kainų indekso (mėn./mėn.)	141
Retail Sales (yoy %, sa)	Mažmeninių pardavimų indekso (m./m.)	141
Industrial Production (yoy %)	Pramonės produkcijos (m./m.)	140
Industrial Production (mom %)	Pramonės produkcijos (mėn./mėn.)	140
RINKOS NUOTAIKŲ IR LŪKESČIŲ RODIKLIAI		
EC Industrial Confidence Index	Pramonės pasitikėjimo indekso	141
EC Services Confidence Index	Paslaugų pasitikėjimo indekso	141
Markit Euro Area Composite PMI (sa)	Sudėtinis pirkimų vadybininkų indekso	34
Markit Euro Area Manufacturing PMI (sa)	Gamybos pirkimų vadybininkų indekso	34
Markit Euro Area Services PMI (sa)	Paslaugų pirkimų vadybininkų indekso	34
EC Economic Sentiment Index	Ekonominių nuotaikų indekso	249
EC Euro-Area Business Climate Index	Verslo klimato kaitos	141
Consumer Confidence Index	Vartotojų pasitikėjimo indekso	141
Sentix Investor Confidence Index	"Sentix" investuotojų pasitikėjimo indekso	136
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI		
Consumer Price Index (yoy %)	Vartotojų kainų indekso (m./m.)	140
Consumer Price Index (mom %)	Vartotojų kainų indekso (mėn./mėn.)	138
CPI Estimate (yoy %)	Preliminarių duomenų vartotojų kainų indekso (m./m.)	141
CPI ex-Food & Energy (yoy %)	Vartotojų kainų indekso (m./m.) išskyrus energiją, maistą, alkoholią ir tabaką (m./m.)	217
PINIGŲ RINKOS RODIKLIAI		
ECB Main Refinancing Rate (%)	Palūkanų normos	121
M3 Money Supply (yoy %)	Pinigių pasiūlos (m./m.)	140

Šaltinis: sudaryta autoriaus.

Kaip matoma iš lentelės, makroekonominiai rodikliai pagal pobūdį yra suskirstyti į kategorijas. Kiekvienam rodikliui, kiekvieną kartą jam pasirodžius, yra apskaičiuojamas netikėtumo rodiklis (žr. 1 formulę). Šis rodiklis yra naudojamas ryšiui su EURO STOXX 50 gražoms tirti ir modeliams sudaryti.

Kiekvienam makroekonominiam rodikliui, apskaičiuavus netikėtumo rodiklį kiekvienam įvykiui, duomenys buvo perkelti į „Jupyter Notebook“ platformą tolesnei duomenų analizei ir modeliavimui. Pastaroji susideda iš šių etapų (žr. 9 pav.).



Šaltinis: Sudaryta autoriaus.

9 pav. Tyrimo etapai

Pirmojo tyrimo etapo paaiškinimai:

1. Duomenų paruošimo analizei ir modeliavimui darbai.

a) Importuojamos bibliotekos, kurios reikalingos duomenų analizei, vaizdavimui ir modeliavimui. („Numpy“, „Pandas“, „Matplotlib“, „Scikit-learn“ ir pan.)

b) Atliekami duomenų paruošimo analizei darbai: koreguojami duomenų formatai, naikinamos tuščios eilutės, stulpeliai, langeliai ir t. t.

c) Apskaičiuojamos indekso grąžos kiekvienai minutei ir būsimums akumuotoms 45 minutėms (žr. 4 formulę). Tokiu būdu bus galima nustatyti, kokią įvykio minutę makroekonominis netikėtumo rodiklis ir indekso grąža turi didžiausią ryšį, ir su šia minute atlikti tolimesnius modeliavimo veiksmus.

d) Apskaičiuojamos makroekonominių rodiklių netikėtumo reikšmės.

e) Makroekonominių rodiklių netikėtumo reikšmės sujungiamos su indeksų grąžomis pagal datą, taip siekiant gauti vieną duomenų rinkinį.

2. Koreliacinių matricių sukūrimas.

Atlikus aukščiau aprašytus penkis veiksmus, toliau sukuriama koreliacinė matrica tarp kiekvieno makroekonominio rodiklio netikėtumo ir EURO STOXX 50 indekso grąžos nuo 1 iki 45 minutės po makroekonominio rodiklio pasirodymo viešumoje laiko. Koreliacinės matricos sudaromos skirtingais scenarijais:

a) su visomis makroekonominio netikėtumo rodiklio reikšmėmis;

b) kai makroekonominio netikėtumo rodiklio reikšmės > 0 ;

c) kai makroekonominio netikėtumo rodiklis reikšmės ≥ 0 ;

d) kai makroekonominio netikėtumo rodiklis reikšmės < 0 ;

e) kai makroekonominio netikėtumo rodiklis reikšmės ≤ 0 .

Tokiu išskaidymu siekiama gauti kuo labiau išgrynintą ir atfiltruotą koreliacinę matricę, su kuria vėliau bus galima sukurti patikimesnius ir tikslesnius regresinius modelius.

Pirsono koreliacijos koeficiento apskaičiavimo formulė su paaiškinimu pateikiama 3 formulėje:

$$r = \frac{\sum(x-\bar{x})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2 (y-\bar{y})^2}} \quad (3)$$

Kuo didesnė gauta reikšmė, tuo didesnė tarpusavio priklausomybė tarp dviejų kintamųjų. Gautą koreliacijos koeficientą galima vertinti taip:

» $0,00 < |r| < 0,19$ labai silpnas ryšys;

» $0,20 < |r| < 0,39$ silpnas ryšys;

» $0,40 < |r| < 0,69$ vidutinis ryšys;

» $0,70 < |r| < 0,89$ stiprus ryšys;

» $0,90 < |r| < 1,00$ labai stiprus ryšys

Koreliacija gali būti ir neigiama, tokiu atveju sakoma, kad yra neigiama koreliacija, t. y. vienam rodikliui didėjant, kitas mažėja.

3. Paprastųjų regresinių modelių sukūrimas.

Toliau koreliacinėje matricoje yra atrenkama aukščiausią koreliaciją turinti minutė (aukščiausia teigiama arba neigiama) ir su šia minute konkrečiam makroekonominiam rodikliui sudaromas statistinis tiesinis regresijos modelis. Iš viso šiame žingsnyje kiekvienam makroekonominiam rodikliui gaunami 5 skirtingi regresiniai modeliai pagal 2 žingsnyje aprašytus netikėtumo scenarijus.

4. Modelių atrinkimas pagal kriterijus.

2.3 skyriuje bus aprašomi regresijos modelių atrinkimo ir tikrinimo etapai. Remiantis skyriuje išanalizuota informacija, tolesniam etapui atrenkami tik tie sukurti regresiniai modeliai, kurių:

- a) $R^2 > = 20$;
- b) makroekonominio rodiklio p-reikšmė $< 0,05$;
- c) įvykių skaičius > 20 .

Šie minimalūs reikalavimai modeliams atrinkti buvo sudaryti, siekiant paimti tik tuos modelius, kurie būtų statistškai patikimi, kurių įvykių skaičius būtų bent 20 kartų per 12 metų, o tai reiškia, kad jau yra įvykių istorija ir įvykis buvo ne vienkartinis. Determinacijos koeficiento reikšmė buvo pasirinkta tokia todėl, kad bent kažkiek ženkliai sukurtu modeliu būtų galima paaiškinti akcijos grąžą, ir, autoriaus manymu, 20 procentų yra ta minimali riba.

5. Atrinktų regresinių modelių prielaidų tikrinimas.

Toliau tikrinama, ar likę modeliai tenkina regresinės analizės prielaidas. Šios prielaidos bus aprašytos 2.3 skyriuje. Į tolimesnius etapus papuola tik tie modeliai, kurie tenkina visas regresijos analizės prielaidas. Jei modelis netenkina regresijos analizės prielaidų, tada yra bandoma sukurti modelius pagal antrą didžiausią determinacijos reikšmę ir žiūrima, ar modelis atitinka pirmojo etapo prielaidas. Jei atitinka, tada šis modelis toliau testuojamas, ar atitinka regresijos analizės prielaidas.

Antrojo tyrimo etapo paaiškinimai:

Šiame etape keliamas klausimas, ar po pirmojo etapo likusius modelius galima išplėsti, įtraukiant daugiau makroekonominių rodiklių, taip gaunant daugialypius regresijos modelius. Siekiant tai patikrinti, visų pirma reikia, kad makroekonominių rodiklių publikavimo data sutaptų. Tada modeliai tikrinami pagal kriterijus (I etapo, 4 žingsnis) ir ar tenkina regresijos prielaidas (I etapas, 5 žingsnis). Į tolimesnį etapą papuola tik tie modeliai, kurie tenkina minėtus reikalavimus.

Trečiojo tyrimo etapo paaiškinimai:

Į paskutinį tyrimo etapą papuola visi paprastieji regresijos modeliai po pirmojo etapo ir visi daugialypiai regresijos modeliai po antrojo etapo. Trečiojo etapo pirmajame žingsnyje tikrinamos regresijos modelių paklaidos, ar yra ARCH efektų. Jei ARCH efektų yra, tada sudaromi GARCH modeliai. Toliau pagal tokius pačius duomenų scenarijus, kaip kad buvo sudaromi regresijos ir GARCH modeliai, yra sudaromi mašininio mokymosi modeliai. Tada tiek tradicinių, tiek mašininio mokymosi modelių rezultatai lyginami tarpusavyje, ir žiūrima, koks modelis geriausiai paaiškina akcijų grąžą. Taip pat 10 ir 11 priede galima pamatyti vieno rodiklio kodo pavyzdį, kaip buvo atliekami visi duomenų tvarkymo ir modeliavimo darbai iki trečiojo etapo paskutinio žingsnio. Trečiojo etapo pabaigoje atliekama grąžos ir dviejų determinacijos koeficientų (geriausio tradicinio ir geriausio ML) sąryšio analizė, siekiant išvelgti ir išskirti tam tikras tendencijas ir uždarbio galimybes.

Trečiajame etape yra patikrinamos tyrimo hipotezės.

Pirmosios hipotezės patikrinimo kriterijus. Kadangi turime 26 makroekonominis rodiklius, o pirminiai regresijos modeliai sudaromi pagal 5 įvairius scenarijus, tai iš viso regresijos modelių bus sudaryta 130 (neskaitant daugianarės regresijos ir GARCH modelių). Todėl bus laikoma, kad pirmoji hipotezė apie tai, kad makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis tradiciniais metodais, yra priimta, jei daugiau nei pusė tų modelių bus statistiškai patikimi ir reikšmingi. Jei statistiškai patikimų modelių nebus nė vieno, hipotezė atmesime. Jei statistiškai patikimų modelių bus sudaryta mažiau nei pusė nuo bendro skaičiaus, bet daugiau už nulį, – hipotezė bus dalinai priimta.

Antrosios hipotezės patikrinimo kriterijus. Antroji tyrimo hipotezė (makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis mašininio mokymosi metodais) būtų priimta, jei sudarius mašininio mokymosi modelius tiems patiems duomenų rinkiniams, kaip ir gavus statistiškai patikimus modelius, remiantis tradiciniais metodais, jų tikslumą ir paklaidų įverčiai būtų panašūs į tradiciniais metodais sukurtų modelių. Hipotezė būtų atmesta, jei modelių tikslumą ir paklaidų įverčiai būtų blogesni, nei kad tradiciniais metodais sukurtų modelių.

Trečiosios hipotezės patikrinimo kriterijus. Trečioji tyrimo hipotezė (mašininio mokymosi metodai, palyginus su tradiciniais metodais, leidžia sukurti tikslesnius makroekonominių rodiklių netikėtumų poveikio akcijų grąžai prognozavimo modelius) stipriai siejasi su antrąja. Jei nustatoma, kad mašininio mokymosi modelių tikslumą ir paklaidų įverčiai yra ženkliai geresni (n-kartų), tokiu atveju hipotezė bus priimta,

o kitu atveju – atmesta.

Apibendrinant poskyrio informaciją akcentuojama, kad buvo sudaryta modeliavimo metodika, apimanti tris duomenų analizės ir modeliavimo etapus. Pirmajame etape atliekami paruošimo duomenų analizei ir modeliavimo darbai, paprastųjų regresijų modelių sukūrimas ir jų atranka pagal kriterijus ir prielaidas. Antrajame etape keliamas klausimas, ar po pirmojo etapo likusius modelius galima išplėsti, įtraukiant daugiau makroekonominių rodiklių, taip gaunant daugialypius regresijos modelius ir po to juos patikrinant pagal I etapo 4 ir 5 žingsnių kriterijus ir prielaidas. Į trečiąjį tyrimo etapą papuola visi paprastieji regresijos modeliai po pirmojo etapo ir visi daugialypiai regresijos modeliai po antrojo etapo, kurie tenkina visus kriterijus ir prielaidas. Šiame etape tikrinamos regresijos modelių paklaidos, ieškant ARCH efektų, ir, jei jų yra, sudaromi GARCH modeliai. Tada sudaromi mašininio mokymosi modeliai. Po to lyginami visų modelių tikslumo įverčiai ir žiūrima, kuris tiksliausiai paaiškina akcijų grąžą pagal netikėtumo scenarijus. Galiausiai tyrimo pabaigoje atliekama grąžos ir determinacijos koeficientų sąryšio analizė laiko eilutėje, siekiant išvelgti tam tikras tendencijas ir uždario galimybes.

2.3 Tradicinių metodų sudarymo ypatumai

1.4 skyriuje buvo išanalizuoti įvairūs tyrimai, kurie analizuoja makroekonominių rodiklių netikėtumų poveikį akcijų grąžoms ir kainai. Remiantis 29 lentele dažniausiai yra naudojama regresijos analizė ir ARIMA-GARCH metodai akcijų grąžų pokyčiams modeliuoti. Šie tradiciniai metodai bus naudojami ir šio tyrimo mokslinei problemai spręsti.

Regresinė analizė naudojama tirti vieno kintamojo priklausomybę nuo vieno ar kelių kintamųjų ir prognozuoti vėlesnes vidutines kintamųjų reikšmes. Formali regresijos modelio lygtis yra tokia (žr. 4 formulę).

$$Y=b_0+b_1X+b_2Z+b_3W+e; \quad (4)$$

Iš čia:

Y vadinamas priklausomu (arba regresuojamu) kintamuoju;

b_0, b_1, b_2, b_3 – modelio koeficientai;

X, Z, W – aiškinamieji kintamieji;

e – liekamoji paklaida.

Ši lygtis naudojama tiek kiekybiniais, tiek ir kokybiniais tyrimams atlikti. Koefi-

cientų ženklai nurodo, ar regresoriams didėjant priklausomas kintamasis Y didės, ar mažės:

Ką tas didėjimas ar mažėjimas reiškia, priklauso nuo kintamųjų prasmės ir kodavimo. Koeficientas b_0 rodo, kokia yra Y reikšmė, kai kintamieji X, Z, W nėra tiriama. O koeficientai b_{123} rodo, kiek pasikeis Y reikšmė, vienu vienetu padidėjus X, Z, W ir fiksuojant visų kitų kintamųjų reikšmes. Regresijos modelių pavyzdžiai yra pateikiami 31 lentelėje.

31 lentelė. Regresijos modelių pavyzdžiai iš paminėtų tyrimų

Metai	Autoriai	Modelio pavyzdys
2019	Tetteh J.E., Adenutsi D.E., Amoah A.	$SMR_t = \beta_0 + \beta_1 SMR_{t-1} + \beta_2 CPI_t + \beta_3 TBILL_t + \beta_4 EXR_t + \beta_5 RGDB_t + \beta_6 OIL_t + \beta_7 LSE_t + \beta_8 POL_t + \mu_t$
2019	Erol A.F., Aytekin S.	$Y_{INST100} = \beta_0 + \beta_1 X_{OLR} + \beta_2 X_{GDP} + \beta_3 X_{GDP} + \beta_4 X_{IP1} + \beta_5 X_{CPI} + \mu$
2019	Celebi K., Honig M.	$r_t = \beta_0 + \beta_1 MF_{t-1} + \beta_2 MF_{t-2} \dots + \beta_k MF_{t-1} + \varepsilon_t$
2018	Hashim S.L.M., Mohammad H.R., Rosly A.M.	$KLCI = \alpha + \beta_1 IP + \beta_2 ER + \beta_3 MS + \beta_4 IR + \varepsilon$
2018	Alexiou C., Vogiazas S., Taqvi A.	$R_{i,t} = \beta_{0,ik} + \sum \beta_{1,ik} S_{k,t} + \sum \beta_{2,ik} I_{k,t} + \varepsilon_{i,t}$
2015	Chen J., Liu Y., Lu L., Tang Y.	$\frac{P_{15it} - P_{k,it}}{P_{k,it}} = \alpha_i + \beta_i * S_{it} + \sum_{j=i}^n \beta_j * S_{jt} + \varepsilon_{it}$
2014	Miao H., Ramchander S., Zumwalt J.K.	$jp_{t_{j+1}} = c + \sum_{i=1}^n c_i^+ SA_{i,t_j}^+ + \sum_{i=1}^n c_i^- SA_{i,t_j}^- + \varepsilon_{t_{j+1}}$

Šaltinis: sudaryta autoriaus, remiantis lentelėje nurodytais mokslininkais.

Priklausomai nuo tyrimo paskirties, regresijos modelių gali būti įvairių, įtraukiant daugiau kintamųjų. Pavadinimai taip pat skiriasi, nes priklausomai nuo tyrimo autoriaus ir paskirties siekiama kintamuosius pavadinti taip, kad atitiktų tyrimo logiką.

Pirmi keturi pateikti tyrimų modeliai apima 1.1 skyriuje nagrinėtus mokslinius straipsnius. Čia išvardinti tiriama makroekonominiai rodikliai. Pirmame pavyzdyje galima pastebėti, kad mokslininkai į lygtį įtraukė akcijų indekso praeities reikšmės kintamąjį.

Paskutiniai trys tyrimų modelių pavyzdžiai apima 1.3 skyriuje nagrinėtus mokslinius straipsnius. Čia matoma, kad į lygtį įtraukiami kiek kitokie kintamieji, tarp kurių yra išvestinis netikėtumų rodiklis

Siekiant sudaryti regresijos modelius, kurie atvaizduoti 31 lentelėje, reikalinga

atlikti duomenų atitikties analizę regresijos modeliui sudaryti.

1. Priklausomas kintamasis yra normaliai pasiskirstęs.

Kad tai patikrinti, yra naudojamos standartizuotos liekamosios paklaidos. Dažniausiai braižoma histograma, kuri lyginama su normalaus skirstymo kreive, ir skirtumas tarp jų turi būti kuo mažesnis. Papildomai gali būti nubraižomas standartizuotų liekamųjų paklaidų ir normaliojo atsitiktinio skirstinio santykinių procentų dažnių grafikas. Kuo taškai arčiau nubrėžtos tiesės, tuo duomenys normalesni. Trečiasis būdas, kuris parodo, ar Y normaliai pasiskirstęs, yra Šapiro-Vilko testo apskaičiavimas. Testo p reikšmė $\geq 0,05$ rodo, kad standartizuotosios paklaidos yra normalios.

2. Skirtingų stebėjimų liekamosios paklaidos (e) neturi koreliuoti.

Tam, kad tai patikrinti, apskaičiuojama Durbino-Vatsono statistika. Ši statistika parodo, ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (ar yra autokoreliacija). Jeigu Durbino-Vatsono statistinė reikšmė yra tarp 1,5 ir 2,5, tai paprastai reiškia autokoreliacijos nebuvimą.

3. Regresoriai neturi stipriai koreliuoti (nėra multikolinearūs).

Norint patikrinti, ar regresoriai tarpusavyje koreliuoja, apskaičiuojamas dispersijos mažėjimo daugiklis. VIF skaičiuojamas kiekvienam regresoriui. Multikolinearumo problema kyla, kai VIF reikšmė yra daugiau už 4. Jei VIF didesnis už 4, tada kintamąjį galima pašalinti ir atlikti skaičiavimą iš naujo.

4. Duomenyse neturi būti išskirčių.

Išskirtis – tai tokia Y, X, Z arba W reikšmė, kuri stipriai skiriasi nuo kitų stebėjimų. Modelis, sudarytas su išskirtimis, nėra patikimas. Norint patikrinti, ar duomenyse yra išskirčių, skaičiuojamas Kuko matas. Kuko matas skaičiuojamas kiekvienam regresorių rinkiniui. Jeigu imties didumas n , tai ir Kuko matų bus n . Jeigu bent vieno kuko mato n reikšmė viršija 1, tai laikoma, kad duomenyse yra išskirčių.

5. Duomenys turi būti homoskedastiški.

Tikrinama, kad liekamųjų paklaidų dispersija nepriklausytų nuo regresorių X, Z, W reikšmių. Jeigu taip nėra, tai laikoma, kad iškilo heteroskedastiškumo problema. Praktiškai heteroskedastiškumas pasireiškia tuo, kad vienoms regresorių reikšmėms priklausomas kintamasis Y įgyja labai skirtingas reikšmes, o kitoms – ne. Siekiant tai patikrinti, skaičiuojamas Breušo-Pagano (Breusch-Pagan) testas. Jei testo p reikšmė $\geq 0,05$, tai duomenys yra homoskedastiški (nėra heteroskedastiškumo).

Patikrinę, ar duomenys yra tinkami sudaryti regresijos modelį, toliau sudaromas pats modelis. Regresinį modelį paprastai aprašo šie rodikliai:

1. Determinacijos koeficientas (R^2). Tai svarbiausias modelio tikslumą nusakantis rodiklis, kuris privalomas visuose regresijos modelių aprašymuose. R^2 interpretacija gali būti ir tokia – kiek procentų Y elgesio paaiškina kintamųjų X, Z, W elgesys. Determinacijos koeficientas įgyja reikšmes tarp 0 ir 1. Kuo koeficiento reikšmė didesnė, tuo modelis patikimesnis.

2. T – (Stjudento) testai atskiriems regresoriams. Jie padeda nuspręsti, ar kintamasis yra statistiškai reikšmingas, ar ne. Jeigu regresoriaus p reikšmė $< 0,05$, tai laikome, kad kintamasis yra statistiškai reikšmingas ir dažniausiai (jei nėra multikolinearumo) jį modelyje paliekame. Jeigu regresoriaus p reikšmė $\geq 0,05$, tai kintamasis yra statistiškai nereikšmingas ir modelyje jis paliekamas tik ypatingais atvejais.

Vidutinė kvadratinė paklaida. Šis dydis matuoja klaidų kvadratinį vidurkį tarp faktinių ir prognozuojamų reikšmių. Kuo jis mažesnis, tuo gautas modelis yra tikslesnis ir geresnis (žr. 5 formulę).

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (5)$$

Iš čia:

Y_i – priklausomojo kintamojo faktinė reikšmė;

\hat{Y}_i – priklausomojo kintamojo prognozuojama reikšmė;

n – prognozuojamų reikšmių skaičius.

Kitas dažnai sutinkamas netikėtumų poveikio akcijų grąžai modeliuoti metodas yra autoregresinis integruotas slankiojo vidurkio (ARIMA) modelis. Modelio tikslas yra numatyti būsimus vertybinių popierių pokyčius, tiriant serijos verčių skirtumus.

ARIMA modelį galima suprasti ir apibūdinant kiekvieną jo komponentą taip:

- Autoregresija (AR) reiškia modelį, kuris rodo kintantį kintamąjį, kuris regre- suoja pagal savo atsilikusią arba ankstesnę reikšmę.

- Integruota (I) reiškia neapdorotų stebėjimų diferenciaciją.

- Slankusis vidurkis (MA) apima priklausomybę tarp stebėjimo ir likutinės paklaidos iš slankiojo vidurkio modelio, taikomo atsilikusiems stebėjimams.

Kiekvienas komponentas veikia kaip parametras su standartine žyme. ARIMA modeliuose standartinis žymėjimas būtų ARIMA su p, d ir q, kur sveikos skaičiaus reikšmės pakeičia parametrus, kad nurodytų naudojamo ARIMA modelio tipą.

Kaip rodo teorinė analizė, mokslininkai AR(I)MA modelį sujungia su (G)

ARCH modeliu, taip siekdami tiksliau apskaičiuoti akcijų kainų ar gražų pokyčius. Autoregresinis sąlyginis heteroskedastiškumo (ARCH) statistinis metodas naudojamas analizuoti ir prognozuoti laiko eilučių kintamumą. Iš esmės ARCH modeliavimas parodo, kad akcijų rinkų aukštas kintamumas yra pasekmė prieš tai buvusių didelių kintamumų, ir atvirkščiai: mažas kintamumas yra veikiamas ankstesnių prieš tai buvusių kintamumų. Praktiškai tai reiškia, kad kintamumas (arba dispersija) linksta į klasterius: didelio kintamumo, mažo kintamumo. Toks sugrupavimas yra ypač patogus investuotojams įsivertinant riziką, ar įsigyti ir / arba laikyti tam tikras turto klases pasirinktu laikotarpiu.

ARCH koncepciją 1980 m. sukūrė ekonomistas Robert F. Engle, kurio metodas labai greitai išpopuliarėjo. Metodas buvo sukurtas, siekiant pagerinti jau nusistovėjusius ekonometrinius modelius su pastovaus kintamumo konstantos prielaida, pakeičiant ją sąlygine. Mokslininkas pamatė, kad praeities VP kainos (istorija) daro įtaką būsimoms VP kainoms, kas ir paaiškina autoregresyvumo dalį modelyje. O sąlyginę heteroskedastiškumo dalis ARCH modelyje nurodo faktą, kad finansų rinkų kintamumas nėra pastovus – nesvarbu, ar tai VP kainos, ar nafta, valiutų kursai, BVP ir kt., – visi jie susiduria su didesniais ar mažesniais kintamumais per skirtingus laikotarpius.

Taigi ARCH modelis aprūpino ekonomistus nauju požiūriu, išspręsdamas pastovaus kintamumo prielaidą. Be to, šis modelis ne tik atpažįsta kintamumo klasterius, bet ir gali prognozuoti tam tikrus rinkos „šokus“. Pavyzdžiui, 2003–2007 m. „S&P 500“ indekso kainos kintamumas buvo neįprastai mažas, o 2008 prieš pat rinkos korekciją pasiekė rekordinį lygį. Standartiniu nuokrypiu grįštiesiems modeliams šį kintamumą būtų sunku nustatyti, tačiau ARCH modelis tai parodo ir gerai veikia, naudojant aukšto dažnio duomenis.

Šiai dienai ARCH modelių atmainų yra daug, tačiau populiariausi yra GARCH, EGARCH. Šiuose modeliuose svaris ir sąlygiškumas ir modifikuojamas, kad būtų pasiekti tikslesni prognozavimo intervalai. Pavyzdžiui, eksponentinis (E) GARCH metodas suteikia didesnę svorį neigiamai gražai duomenų serijoje, nes įrodyta, kad jos sukuria daugiau nepastovumo. Kitaip tariant, gražos kintamumas padidėja labiau po didelio gražos kritimo nei kad po didelio pakilimo.

Toliau pateikiama ARIMA ir GARCH sąryšio metodologija (žr. 6 formulę).

$$\hat{y}_t = \delta + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (6)$$

Iš čia:

δ – konstanta;

ϕ_j – autoregresijos koeficientas;

θ_j – j(tasis) slankiojo vidurkio koeficientas;

ε_t – paklaida;

t – laiko momentas;

p – autoregresijos eilė;

q – slankiųjų vidurkių eilė.

Žaliai pažymėta vieta yra interpretuojama, kaip ARIMA modelis, o ε_t – GARCH modelis, kuris išreiškiamas taip (žr. 7 formulę).

$$\varepsilon_t = z_t \sqrt{\sigma_t^2} \quad (7)$$

Iš čia:

z_t – baltasis triukšmas. Vidurkis lygus 0, o dispersija lygi 1.

σ_t^2 – standartinis nuokrypis, kuris gaunamas taip (žr. 8 formulę).

$$\sigma_t^2 = s_0 + \sum_{i=1}^q \beta_i \sigma_{t-i}^2 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 \quad (8)$$

Iš čia:

s_0 ir α_i – konstantos;

ε – autoregresinio sąlyginio heteroskedastiškumo procesas su parametrais q ir p.

Norint patikrinti, ar sekos neatitinka baltojo triukšmo, braižomi autokoreliacijos ir dalinės autokoreliacijos grafikai. Baltasis triukšmas yra tada, kai:

- Autokoreliacijos ir dalinės autokoreliacijos funkcijų reikšmės yra artimos nuliui ir nė viena iš linijų neviršija nurodytų intervalo ribų, net jei paklaidos sudvigubinamos.

- Box'o Ljung'o testo kriterijus yra statistiškai nereikšmingas visoms reikšmėms. Šis testas apskaičiuojamas taip (žr. 9 formulę).

$$Q(h) = n(n+2) \sum_{i=1}^h \frac{\hat{\rho}_i^2}{n-i} \quad (9)$$

Iš čia:

n – stebėjimų skaičius;

ρ_i – autokoreliacijos koeficientas i žingsnyje;

h – vėlavimo periodų skaičius.

Jeigu apskaičiuota Q reikšmė kiekviename postūmyje yra mažesnė už kritinę teorinę $\chi^2(chi)$ skirstinio reikšmę, tai laikoma, kad paklaidos nekoreliuoja.

Apibendrinant poskyrį galima akcentuoti, kad regresijos analizė susideda iš kintamųjų preliminaraus tinkamumo tyrimo (duomenų atitikties analizė) ir modelio tinkamumo tyrimo (regresijos modelį aprašantys rodikliai). Patikimam regresijos modeliui R^2 turėtų būti daugiau už 0,2. Studento testas atskiriems regresoriams mažesnis nei 0,05. Jei sudaromas daugialypis regresijos modelis, tai VIF reikšmė turi būti mažesnė nei 4. Kuko mato išskirtis – ne daugiau nei Norint patikrinti liekamųjų paklaidų normalumą, braižoma histograma, P-P grafikas arba apskaičiuojamas Šapiro-Vilko testas, kurio reikšmė turi būti daugiau nei 0,05. Norint patikrinti, ar duomenys yra homoskedastiški, apskaičiuojamas Breušo - Pagano testas. Jo reikšmė turi būti daugiau nei 0,05. Vertinant modelio paklaidas paskutiniame etape, skaičiuojama vidutinė kvadratinė paklaida. Tuo tarpu kitas tradicinis metodas, norint analizuoti akcijų pokyčius per trumpą laiko tarpą, yra kombinuotas ARIMA-GARCH metodas. Norint patikrinti, ar sudarytas ARIMA modelis (šiam tyrimo tiesinė ir daugialypė regresija) turi ARCH efektų, daromi autokoreliacijos, dalinės autokoreliacijos ir Box Ljung testai.

2.4 Dirbtinio intelekto taikymas modeliuojant akcijų grąžą


Ankstesniuose skyriuose buvo išanalizuotos ir pateiktos plačiai mokslinėje literatūroje aprašomos akcijų kainas, grąžą, jos pokyčius aiškinančios teorijos ir tradicinės modeliavimo metodikos. Šiame skyriuje dėmesys sutelkiamas į dirbtinio intelekto teoriją ir metodus, kuriais remiantis galima analizuoti ir modeliuoti akcijų grąžą. Šie dirbtinio intelekto metodai bus naudojami ir šio tyrimo mokslinei problemai spręsti, tuo įnešant naujovę į nagrinėjamos tematikos tyrimus.

Pagal LR ekonomikos ir inovacijų ministerijos dirbtinio intelekto strategijos dokumentą dirbtinis intelektas – tai sistemos, kurios pasižymi protingu ir sumaniu elgesiu, analizuodamos savo aplinką ir darydamos gana savarankiškus sprendimus tikslui pasiekti. Dirbtinio intelekto sistemos gali būti grindžiamos vien tik programine įranga ir veikti virtualiajame pasaulyje (pvz., balso sintezatoriai, vaizdo analizės programinė įranga, paieškos sistemos, kalbos ir veido atpažinimo sistemos) arba gali būti integruotos techninėje įrangoje (pvz., pažangiuose robotuose, savaeigėse transporto priemonėse, bepiločiuose orlaiviuose ar daiktų interneto objektuose).

Anot Crevier (1993) ir Clark (2015), dirbtinis intelektas, kaip atskira discipli-

na, atsirado 1955 m., ir išgyveno keletą optimizmo, nusivylimo ir finansavimo stokos (žinoma kaip „dirbtinio intelekto žiema“) bangų. Tačiau bėgant laikui ir tobulėjant technologijoms (kompiuterių atsiradimas ir jų skaičiavimo galios didėjimas, internetas, debesų technologijos, programinės įrangos, skirtos mašininiam mokymuisi, plėtra, duomenų kiekis ir pan.), susidomėjimas dirbtiniu intelektu ir jo tyrimų finansavimas sugrįžo.

Pagal Nwankpa, Ijomah, Gachagan, Marshall (2018) dirbtinis intelektas gali būti skaidomas į mašininio mokymosi ir giliojo mokymosi šakas (žr. 10 pav.).



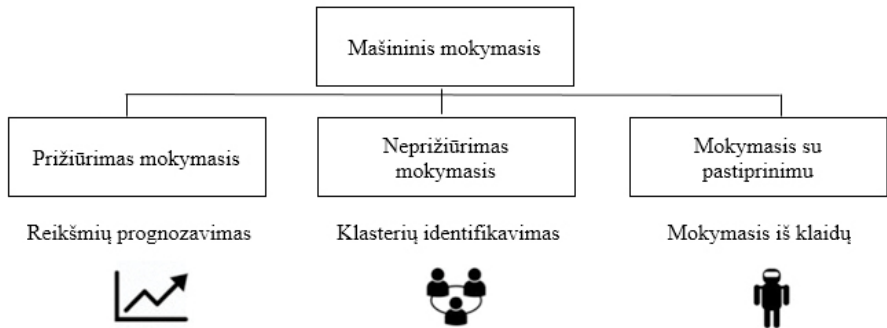
Šaltinis: sudaryta, remiantis Nwankpa, Ijomah, Gachagan, Marshall (2018).

10 pav. Pagrindinės dirbtinio intelekto šakos

Mašininis mokymasis – dirbtinio intelekto šaka, kuri įtraukia kūrimą modelių, mokinančių kompiuterius „mąstyti“. Tai yra modelių kūrimo būdas, kai sukurta sistema mokosi iš duomenų. Sistemos mokymasis yra stipriai susijęs su statistika, nes sistemos mokymasis ir statistika nagrinėja duomenų analizę, bet skirtingai nuo statistikos, mašininis mokymasis yra susijęs su skaičiavimams naudojamų modelių sudėtingumu.

Gilusis mokymasis – mašininio mokymosi šaka, kuri naudoja kelis sluoksnius, kad palaipsniui iš pirminių įvesties duomenų išgautų aukštesnio lygio ypatybes. Pavyzdžiui, apdorojant vaizdą, pirminiai sluoksniai gali identifikuoti kraštus, o vėlesni – žmogui svarbias sąvokas, paveikslus, pvz., raides, veidus.

Mašininio (ir giliojo) mokymosi metodai tradiciškai skirstomi į tris plačias kategorijas (žr. 11 pav.).



Šaltinis: sudaryta, remiantis Hurwitz J., Kirsch D. (2018).

11 pav. Mašininio mokymosi modelių kategorijos

Prižiūrimas mokymasis: metode generuojama funkcija, kuri sieja priklausomus kintamuosius (Y) su nepriklausomais (X) kintamaisiais. Tokių metodų pritaikymas leidžia nustatyti priklausomybės sąryšio funkciją tarp X ir Y kintamųjų. Turint kintamųjų priklausomybės funkciją, tikslas yra metodui pateikti naujus duomenis, kurių jis nebuvo apmokytas, norint gauti prognozuojamas Y reikšmes.

Neprižiūrimas mokymasis: metodui nėra suteikiamos etiketės (Y), todėl jis turi rasti struktūrą tarp įvesties duomenų (X).

Mokymasis su pastiprinimu: metodas sąveikauja su dinamiška aplinka, kurioje jis turi tam tikrą tikslą, pvz., vairuoti transporto priemonę ar žaisti žaidimą su varžovu. Kiekvienas atliktas veiksmas turi įtakos aplinkai, o aplinka grąžina grįžtamąjį ryšį, pagal kurią metodas toliau mokosi ir priiminėja sprendimus.

Kadangi šiame tyrime modeliuojamos akcijų grąžos, tai aktualu pateikti, kokie tyrimai yra atlikti šia tematika, naudojant mašininio mokymosi metodus (žr. 32 lent.).

32 lentelė. Akcijų gražų modeliavimo tyrimų, taikant mašininio mokymosi metodus, kryptys

Metai	Autorius (-iai)	Tyrimų kryptis	Šalis
2020	Nabipour M., Nayyeri P., Jabani H., Mosavi A., Salwana E., Shahab S.	Techninė analizė	Iranas
2020	Song D., Busogi M., Kim N., Baek A.M.C	Techninė analizė	Pietų Korėja
2020	Song H.,Peng D., Huang X.	Sentimentų analizė	Kinija
2019	Lv D., Yuan S., Li M., Xiang Y.	Techninė analizė	JAV, Kinija
2019	Baranes A., Palas R.	Įmonės veiklos ir sektoriaus analizė	JAV
2019	Nikou M., Mansourfar G., Bagherzadeh J.	Techninė analizė	Didžioji Britanija
2019	Botunac I., Panjkota A., Matetic M.	Techninė analizė	JAV
2018	Lopez F.J.G., Batyrshin I., Gelbukh A.	Sentimentų analizė	JAV
2018	Pierdzioch C., Risse M.	Techninė analizė	JAV
2017	Karathanasopoulos A., Mitra S., Skindilias K., Io C.C.	Techninė analizė	Didžioji Britanija, Vokietija
2017	Pyo S., Lee J., Cha M., Jang H.	Techninė analizė	Pietų Korėja
2017	Gunduz H., Cataltepe Z., Yaslan Y.	Techninė analizė	Turkija
2016	Ha'jek P.	Sentimentų analizė, įmonės veiklos analizė	JAV
2016	Li X., Xie H., Wang R., Cai Y., Cao J., Wang F., Min H., Deng X.	Sentimentų analizė, įmonės veiklos analizė	Kinija
2016	Cocianu C.L., Grigoryan H.	Techninė analizė ir makroekonominė analizė	Rumunija
2016	Park S., Lee J., Son Y.	Techninė analizė	JAV
2014	Banik S., Khan A. F. M. K., Anwer M.	Techninė analizė	Bangladešas

Šaltinis: sudaryta autoriaus, remiantis lentelėje nurodytais mokslininkais.

Apibendrinant minėtus tyrimus matoma, kad dažniausiai tyrimai atliekami JAV ir Kinijos akcijų rinkose, o labiausiai naudojami kintamieji yra techninės analizės indikatoriai. Techninė analizė yra visuma finansinės analizės technikų, metodų, kuriomis siekiama nuspėti VP kainas, remiantis praeities VP kainų kitimo tendencijomis. Priešingai nei fundamentalioji, techninė analizė neatsižvelgia į makroekonominius, įmonės veiklos ir kt. duomenis. Daroma prielaida, kad visa sprendimui priimti reikalinga informacija apie reikšmingus įvykius ir rodiklius jau atsispindi VP kainų kitimo kreivėje. Taip pat teigiama, kad įvykiai rinkoje gali analogiškai arba tam tikra forma pasikartoti, todėl jų tendencijas galima nuspėti naudojant įvairius statistinius, kiekybinius metodus vadinamaisiais techninės analizės indikatoriais. Techninė analizė šiame darbe toliau nebus plėtojama, nes ji nėra aktuali nagrinėjamai tematikai.

Pereinant prie detalesnės tyrimų analizės, verta pateikti, kokiais metodais mokslininkai vadovaujasi, modeliuodami akcijų kainas (žr. 33 lent.).

33 lentelė. Dažniausiai naudojami mašininio mokymosi metodai prognozuojant akcijų grąžą

Metai	Autorius (-iai)	Tyrimo laikotarpis	Duomenų dažnumas	Naudojami metodai
2020	Nabipour M., Nayyeri P., Jabani H., Mosavi A., Salwana E., Shahab S.	2009–2019	Dieninis	ML (DT, RF, AB, GBR) DL (RNN, LSTM)
2020	Song D., Busogi M., Kim N., Baek A.M.C	2001–2019	Dieninis	DL (LSTM, RNN)
2020	Song H., Peng D., Huang X.	2014–2017	Dieninis	ML (SVM) DL (LSTM)
2019	Lv D., Yuan S., Li M., Xiang Y.	2010–2017	Dieninis	ML (LRR, SVM, DT, RF, NB GBR), DL (FFNN, DBN, RNN, LSTM, GRU)
2019	Baranes A., Palas R.	2012–2017	Ketvirtinis	ML (SVC)
2019	Nikou M., Mansourfar G., Bagherzadeh J.	2015–2018	Dieninis	ML (SVC, RF) DL (LSTM, RNN, FFNN)
2019	Botunac I., Panjkota A., Matetic M.	2010–2019	Dieninis	DL (FFNN, RNN, LSTM)

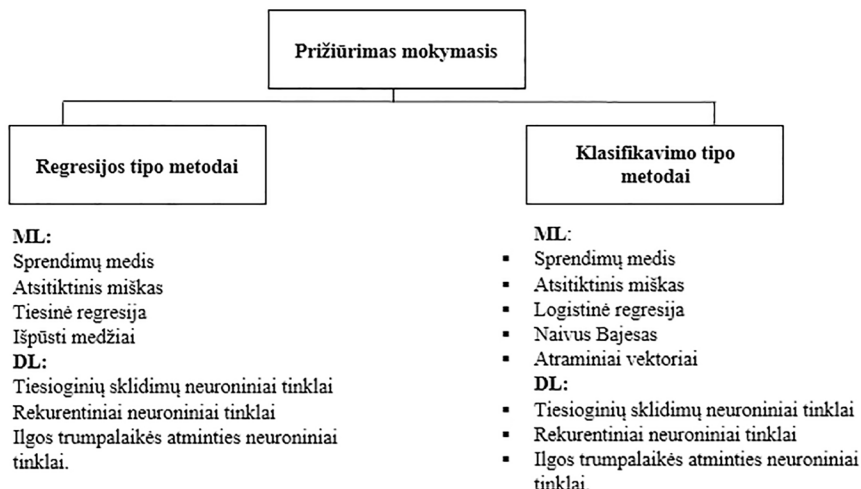
2018	Lopez F.J.G., Batyrshin I., Gelbukh A.	2017–2017	Dieninis	ML (KNN, LR, NB, DT, RF) DL (FFNN)
2018	Pierdzioch C., Risse M.	2015–2015	Pusmetinis	ML (BRT)
2017	Karathanasopoulos A., Mitra S., Skindilias K., lo C.C.	2004–2015	Dieninis	DL (HONN)
2017	Pyo S., Lee J., Cha M., Jang H.	2004–2016	Dieninis	ML (SVC) DL (FFNN)
2017	Gunduz H., Cataltepe Z., Yaslán Y.	2011–2016	Dieninis	ML (LRR, GBR)
2016	Ha'jek P.	2013–2013	Dieninis	ML (DT, LR, NB, PCA, SVM) DL (FFNN)
2016	Li X., Xie H., Wang R., Cai Y., Cao J., Wang F., Min H., Deng X.	2001–2001	Dieninis	ML (SVM) DL (ELM)
2016	Cocianu C.L., Grigoryan H.	2008–2014	Dieninis	ML (SVM) DL (RNN)
2016	Park S., Lee J., Son Y.	2014–2014	Dieninis	ML (NB, SVC) DL (FFNN)
2014	Banik S., Khan A. F. M. K., Anwer M.	2004–2012	Dieninis	DL (FFNN)

Šaltinis: sudaryta autoriaus, remiantis lentelėje nurodytais mokslininkais.

Iš pateiktos lentelės matoma, kad vidutinė tyrimų apimtis yra 6 metai. Taigi sukurti modeliai neapima kelių ekonominių ciklo periodų, kas nėra gerai, nes neįvertinami pakilimai ir nuosmukiai.

Pagal duomenų dažnumą autoriai renkasi dieninius, ketvirtinius, pusmetinius akcijų indeksų kainų duomenis. Duomenų dažnumo tipo pasirinkimas dažniausiai priklauso nuo to, ar pavyksta gauti duomenis. Kuo duomenys dažnesni, tuo patikimesnis modelis. Taigi pagal minėtus tyrimus objektyviausi modeliai yra sudaryti pagal dienišius akcijų indekso kainų duomenis.

Modeliams sudaryti yra naudojami įvairūs metodai. Jie buvo suskaidyti į dvi kategorijas: ML ir DL. Kadangi metodų pasitaikė daug ir įvairių, siekiant tikslingai juos sugrupuoti ir atskirti vienas nuo kito, yra sukurtas 12 paveikslas.



Šaltinis: sudaryta, remiantis 33 lentelėje nurodytais autoriais.

12 pav. Prižiūrimo mokymosi metodų tipai

Paveiksle yra pateikta dažniausiai naudojamų metodų suvestinė iš 33 lentelės. Atkreiptinas dėmesys, kad siekiant modeliuoti akcijų kainas ar grąžas, mokslininkai naudoja regresijos ir klasifikavimo tipo metodus, o kai kurie iš jų yra universalūs.

Regresijos metodais siekiame prognozuoti realią vertę, pavyzdžiui, akcijų grąžą ar kainą. Kintamieji gali būti diskretieji ir tolydieji. Klasifikavimo metodais siekiama prognozuoti kategorinį kintamąjį. Pavyzdžiui, ar akciją reikia parduoti konkrečiu laiko momentu ar pirkti, o gal net laikyti. Klasifikavimo metodai šiame darbe nėra nagrinėjami, todėl antroje tyrimo dalyje buvo detaliau analizuojami regresijos tipo metodai.

Atlikus mašininio mokymosi taikymo modeliuojant akcijų grąžą analizę pastebėta, kad regresijos tipo uždaviniams mokslininkai dažniausiai taiko sprendimų medžio, atsitiktinio miško, tiesinės regresijos, GBR ir giliojo mokymosi metodus. Atkreiptinas dėmesys, kad dauguma tyrimų, kuriuose naudojami mašininio mokymosi metodai akcijų grąžai prognozuoti, susiję techninės ir sentimentų analizės rodikliais, kas parodo, kad trūksta tyrimų, modeliujančių akcijų grąžą makroekonominių rodiklių požiūriu, o būtent tai ir yra vienas iš šio tyrimo naujumo aspektų.

2.5 Statistinio modeliavimo ir mašininio mokymosi skirtumai

Statistinio modeliavimo ir mašininio mokymosi panašumai glumina daugelį žmonių, kurie mano, kad tai yra tas pats dalykas. Vienas iš paprasčiausių to pavyzdžių

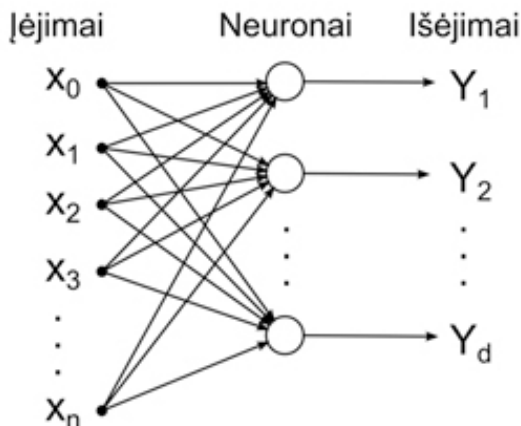
yra tiesinės regresijos modelis, kuris tikriausiai yra pagrindinė šio nesusipratimo priežastis.

Linijinė regresija gali būti tiek statistinis, tiek ir mašininio mokymosi metodas. Atlikus duomenų modeliavimą mašininio mokymosi būdu galima gauti tą patį rezultatą, kaip ir statistinės regresijos modelio atveju. Pastarosios tikslas – kuo labiau sumažinti vidutinę kvadratinę paklaidą. Tuo tarpu mašininio mokymosi atveju daromas vadinamasis modelis „mokymas“, kuris naudoja duomenų pogrupį. Tikrinant, kaip gerai modelis veikia, reikia jį išbandyti su nematytu duomenų rinkiniu, kurio nebuvo treniruotėse. Šiuo atveju mašininio mokymosi tikslas yra pasiekti geriausią testo rinkinio našumą. Tuo tarpu statistiniam modeliui randame liniją, kuri sumažina vidutinę kvadratinę paklaidą visuose duomenyse, darant prielaidą, kad duomenys yra tiesinis regresorius su pridėtu atsitiktiniu triukšmu, kuris paprastai yra Gauso pobūdžio. Taip pat statistinio metodo būdu duomenys paprastai nėra skaidomi į apmokymo ir testavimo duomenis. Daugeliu atvejų modelio esmė yra apibūdinti priklausomojo ir nepriklausomojo kintamojo santykį, o ne numatyti reikšmes. Ši procedūra dažniausiai vadinama statistine išvada, priešingai nei prognozavimas. Tačiau statistinį modelį vis tiek galima naudoti prognozėms atlikti, tačiau modelio vertinimo būdas nereikalauja testų rinkinio, o vertins modelio parametrų reikšmingumą ir tvirtumą.

Taigi mašininio mokymosi tikslas yra gauti kuo tikslesnį / našesnį modelį prognozėms atlikti. Tai įvertinti panaudojami testavimo duomenys, tuo tarpu statistinis modeliavimas yra labiau susijęs su ryšiu tarp kintamųjų ir šių ryšių reikšmingumu, taip numatant prognozes.

Po mašininio mokymosi slypi ir dirbtiniai neuroniniai tinklai, skirtumas nuo statistinio modeliavimo yra pakankamai reikšmingas. Dirbtiniai neuroniniai tinklai buvo sukurti remiantis žmogaus biologiniais neuroniniais tinklais. Smegenys yra sudarytos iš milijardų neuronų, kurie jungdamiesi tarpusavyje sudaro neuronų jungtis. Neuronu vadinama ląstelė, galinti priimti, apdoroti ir perduoti elektrocheminį signalą.

Paprasčiausias neuroninis tinklas vadinamas vienasluoksniu perceptronu (žr. 13 pav.), kuris yra sudarytas iš dviejų sluoksnių – įėjimo ir išėjimo. Tuo tarpu sudėtingesni tinklai turi vieną arba daugiau paslėptų sluoksnių su keletu ar daugiau neuronų. Tokie tinklai vadinami daugiasluoksniais perceptronais.



Šaltinis: parengta Ren, C., Bhoi, S.K., Panda, S.K. et al. (2020).

13 pav. Vienasluoksnių perceptrono pavyzdys

Įėjimo sluoksnyje slypi treniravimui skirtas duomenų rinkinys. Pereinant į neuronus yra priskiriamas perdavimo koeficientas. Kiekvienas neuronas sluoksniuose turi sumavimo ir aktyvavimo funkcijas. Sumavimo funkcija yra tapati tiesinės regresijos funkcijai. Tuo tarpu aktyvavimo funkcija atlieka reguliatoriaus vaidmenį, kuri pagal savo paskirtį praleidžia neuronus su savo svoriais toliau į kitų sluoksnių neuronus arba jų reikšmes transformuoja. Išėjimo sluoksnyje taip pat taikoma funkcija, kuri pateikia rezultatus norima forma.

Daugiasluoksnių perceptronų mokymuisi dažniausiai taikoma stochastinio gradientinio nusileidimo strategija, kurią realizuoja klaidos (tiesinės regresijos atveju MSE) skleidimo atgal algoritmas. Gradientinio nusileidimo strategija yra būdas minimizuoti klaidos funkciją, kurio vienas pagrindinių komponentų yra mokymosi lygis.

Taigi, siekiant išspręsti regresijos problemą dirbtiniais neuroniniais tinklais, skirtingai nei paprastame statistiniame modeliavime, čia jau atsiranda keli papildomai dalykai, tokie kaip aktyvacijos funkcijos, kai išmokti svoriai perduodami arba neperduodami į kitus neuronus, svorių atnaujinami, kt.

Apibendrinus poskyrį dar kartą pabrėžiama, kad pagrindinis skirtumas tarp statistinio ir mašininio mokymosi modeliavimo yra tas, kad statistiniu metodu siekiama kuo labiau sumažinti vidutinę kvadratinę paklaidą ir rasti ryšių tarp kintamųjų

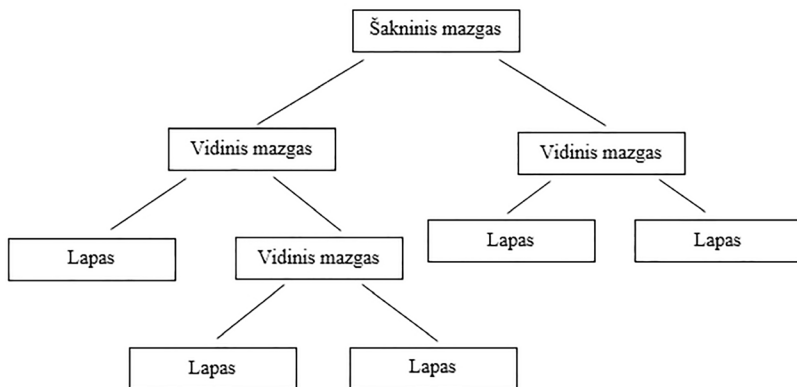
reikšmingumą, tuo tarpu mašininio mokymosi tikslas yra pasiekti didžiausią testo rinkinio tikslumą.

2.6 Mašininio ir giliojo mokymosi metodų ypatumai

Šiame skyriuje bus apibūdinami tyrime panaudoti mašininio mokymosi metodai, jų sudarymo principai, aptariami įvairūs parametrai ir jų paskirtis kiekvieno metodo panaudojime.

Vienas dažniausiai naudojamų ir lengviausiai interpretuojamų mašininio mokymosi metodų, kuris gali būti naudojamas tiek klasifikavimo, tiek ir prognozavimo uždaviniams spręsti, yra sprendimų medis.

Sprendimų medis yra sudarytas iš mazgų, kurie formuoja medį su šaknimis (žr. 14 pav.). Šaknimi yra vadinami medžio mazgai, neturintys įeinančių briaunų. Visi kiti mazgai turi lygiai po vieną įeinančią briauną. Mazgas su išeinančiomis briaunomis yra vadinamas vidiniu mazgu. Visi kiti mazgai yra vadinami lapais (dar vadinami sprendimų mazgais).



Šaltinis: sudaryta, remiantis Fürnkranz J. (2011).

14 pav. Sprendimų medžio metodo loginės schemos pavyzdys

Pagrindiniai šio metodo privalumai yra šie:

- Paprasta suprasti ir interpretuoti. Medžius galima vizualizuoti.
- Nereikalauja didelių pastangų paruošti duomenis. Kiti metodai dažnai reikalauja duomenų normalizavimo, sukurti fiktyvius kintamuosius ar pašalinti tuščias reikšmes. Tačiau atkreiptinas dėmesys, kad metodas reikalauja, kad nebūtų tuščių duo-

menų laukų.

- Geba suprasti tiek skaitinius, tiek kategorinius duomenis.
- Galima patikrinti naudojant statistinius testus.

O pagrindiniai šio metodo trūkumai yra tokie:

- Galimas „persimokymas“, kai modelis taip gerai prisitaiko prie duomenų ir sukuria tiek medžių, kad nebesugeba apibendrinti rezultatų.
- Pridedant naujų, labai skirtingų duomenų, modelis gali tapti nestabilus, nes yra sukuriami nauji medžiai.
- Yra jautrus nesubalansuotam duomenų rinkiniui.

Metodas iškviečiamas iš *sklearn* bibliotekos, o vadinasi jis – *DecisionTreeRegressor*. Modelio klasė ir parametrai užsirašo taip:

```
sklearn.tree.DecisionTreeRegressor(*, criterion=’mse’, splitter=’best’, max_depth=None, min_samples_split=2, min_samples_leaf=1, min_weight_fraction_leaf=0.0, max_features=None, random_state=None, max_leaf_nodes=None, min_impurity_decrease=0.0, min_impurity_split=None, ccp_alpha=0.0)
```

Toliau yra pateikiama 34 lentelė, kurioje nurodyti pagrindiniai parametrai ir jų paskirtys. Parametrų variantai nėra nagrinėjami.

34 lentelė. Pagrindiniai sprendimų medžio parametrai ir jų paskirtis

Parametras angliškai	Parametro paskirtis
Criterion: {“mse”, “friedman_mse”, “mae”, “poisson”}, default=“mse”	Parametras matuojantis medžio išskaidymo kokybę.
Splitter: {“best”, “random”}, default=“best”	Strategija renkantis padalijimą į vidinius mazgus.
max_depth: int, default=None	Apibrėžia vidinių mazgų hierarchijos gylį.
min_samples_split: int or float, default=2	Mažiausias duomenų skaičius, reikalingas vidiniam mazgui padalyti.
min_samples_leaf: int or float, default=1	Mažiausias duomenų skaičius, būtinas lape.
random_state: int, RandomState instance or None, default=None	Nustato metodo panaudojimo atsitiktinumą.

Šaltinis: sudaryta autoriaus, remiantis <https://scikit-learn.org/stable/modules/generated/sklearn.tree.DecisionTreeRegressor.html>.

Sprendimų medžio metodui, autoriaus suvokimu, svarbiausi yra 6 parametrai. Visi jie pagal nutylėjimą jau turi tam tikras reikšmes, todėl galima iškviesti metodą, ir jis veiktų net ir nenurodžius jokių parametrų. Tačiau, siekiant gauti tikslesnius rezultatus, parametrų modifikavimas yra būtinas.

Panašus į sprendimų medį yra atsitiktinio miško metodas. Jis sudarytas iš daugybės paprastų sprendimų medžių. Atsitiktinį mišką sudaro daug medžių, užaugintų iš atsitiktinai parinktų požymių. Taikant tokią metodiką ir naudojant daug užaugintų medžių, vidutinis tikslumas, palyginus su vienu sprendimų medžiu, pagerėja. Metodas iškviečiamas iš *sklearn* bibliotekos, o vadinasi jis – *RandomForestRegressor*. Modelio klasė ir parametrai užsirašo taip:

```
sklearn.ensemble.RandomForestRegressor(n_estimators=100, *, criterion='mse',
max_depth=None, min_samples_split=2, min_samples_leaf=1, min_weight_fraction_leaf=0.0,
max_features='auto', max_leaf_nodes=None, min_impurity_decrease=0.0,
min_impurity_split=None, bootstrap=True, oob_score=False, n_jobs=None, random_state=None,
verbose=0, warm_start=False, ccp_alpha=0.0, max_samples=None)
```

Toliau yra pateikiama 35 lentelė, kurioje nurodyti pagrindiniai parametrai ir jų paskirtys. Parametrų variantai nėra nagrinėjami.

35 lentelė. Pagrindiniai atsitiktinio miško parametrai ir jų paskirtis

Parametras	Parametro paskirtis
n_estimators: int, default=100	Medžių skaičius modelyje.
Criterion: {"mse", "mae"}, default="mse"	Parametras matuoja atsitiktinio miško išskaidymo kokybę.
max_depth: int, default=None	Apibrėžia vidinių mazgų hierarchijos gylį.
min_samples_split: int or float, default=2	Mažiausias duomenų skaičius, reikalingas vidiniam mazgui padalyti.
min_samples_leaf: int or float, default=1	Mažiausias duomenų skaičius, būtinas lape.
random_state: int, RandomState instance or None, default=None	Nustato metodo panaudojimo atsitiktinumą.

Šaltinis: sudaryta autoriaus, remiantis <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html>.

Kaip ir sprendimų medžio metodo atveju, autoriaus įsitikinimu, šiame metodui svarbiausi yra 6 parametrai. Visi jie pagal nutylėjimą jau turi tam tikras reikšmes, todėl

galima iškviesti metodą, ir jis veiktų net ir nenurodžius jokių parametrų. Tačiau, siekiant gauti tikslesnius rezultatus, parametrų modifikavimas yra būtinas.

Naudojant atsitiktinį mišką, pradinis duomenų rinkinys yra atsitiktinai padalijamas į keletą to paties dydžio mažesnių rinkinių. Tada sprendimų medis yra išmokomas veikti kiekvienam padalintam mažesniai rinkiniui. Sudarius keletą sprendimų medžių ir siekiant klasifikuoti ar prognozuoti naujus duomenis, atsitiktinio miško metodas gauna kiekvieno sprendimų medžio „balsą“, kokia turėtų būti priklausomo kintamojo klasė ar reikšmė. Klasifikavimo atveju priskiriama ta klasė, kuri surinko daugiau balsų iš skirtingų sprendimų medžių.

Pagrindiniai privalumai ir trūkumai, kuriuos galima rasti tarp dviejų metodų, yra pateikiami 36 lentelėje.

36 lentelė. Sprendimų medžio ir atsitiktinio miško privalumai ir trūkumai

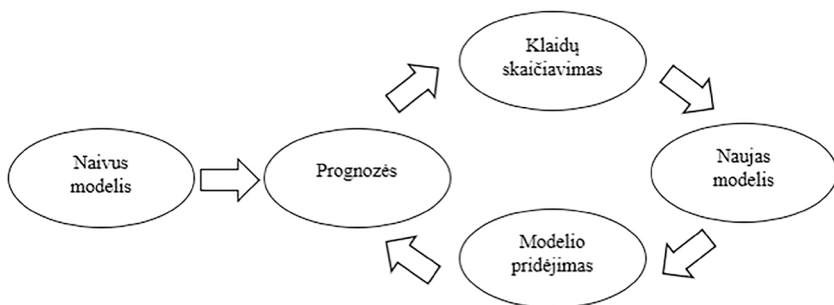
	Sprendimų medis	Atsitiktinis miškas
Privalumai	Skaičiuojamai nebrangus naudoti, nenaudoja daug išteklių, atminties, CPU.	Atsparus persimokymui.
	Metodo išmokti rezultatai yra lengvai suprantami žmonių.	Metodo parametrų nustatymas yra gana paprastas ir intuityvus.
	Gerai atlieka klasifikavimą / prognozavimą su mažu duomenų rinkiniu.	Atlieka gerai klasifikavimą, kai kintamųjų skaičius yra didelis ir didelis kiekis mokymosi duomenų.
		Metodo vidutinis tikslumas yra aukštas.
Trūkumai	Linkęs į persimokymą (kai metodas atlieka darbą su mokymosi duomenimis gerai, tačiau su naujais duomenimis prastai).	Metodo mokymasis gali būti lėtas (priklauso nuo parametrų nustatymo).
	Gali naudoti daug atminties (kuo daugiau kintamųjų, tuo gilesnis ir platesnis sprendimų medis gali būti).	Metodo pagalba sukurti modeliai gali naudoti daug atminties.

Šaltinis: sudaryta autoriaus.

Pagrindinis atsitiktinio miško metodo privalumas prieš sprendimų medį yra tas, kad metodas per daug neprisitaiko prie apmokomųjų duomenų, kadangi medžiai sudaromi naudojant mažesnes imtis: nepriklausomų kintamųjų kiekiu ir / ar medžio

gyliu, t. y. kiekvienas atskiras medis neišmoksta visų duomenų. Tuo tarpu sprendimų medis turi polinkį persimokyti. Problema ta, jei medis turi didelį gylį, labai tiksliai išmokstami apmokymo duomenys, testuojant jie gali būti neteisingai suklasifikuoti / išprognuozuoti.

GBR yra kitas mašininio mokymosi metodas, pagrįstas sprendimų medžio metodo logika, papildomai įtraukus gradientų skaičiavimus (žr. 15 pav.). Šis modelis suka ir gerina save daug kartų. Tai prasideda inicijuojant ansamblį vienu modeliu, kurio prognozės gali būti gana naivios. Net jei jo prognozės yra labai netikslios, vėlesni ansamblio papildymai padės pašalinti šias klaidas.



Šaltinis: sudaryta, remiantis Ji S., Wang X., Zhao W., Guo D. (2019).

15 pav. GBR modelio loginės schemos pavyzdys

Ciklas prasideda nuo paprasto modelio, kuris atlieka prognozavimą. Po prognozavimo apskaičiuojama paklaida, kuri tiesinės regresijos atveju vadintųsi vidutine kvadratine paklaida. Tai atlikus pradedamas kitas modelis, kuris vėl treniruojasi, bet tuo pačiu įvertina ir praeito modelio treniravimosi metu atliktas klaidas. Tada vėl gaunama paklaida, ir viskas tęsiasi tiek, kiek norima, arba kol naujo modelio tikslumas sustoja didėti, o paklaida mažėti, palyginus su ankstesniais modeliais. Šio metodo pranašumas prieš sprendimų medį ir atsitiktinį mišką, tiesinę regresiją yra tas, kad jis turi dar daugiau svarbių koreguotinų parametru, kuriuos žmogus gali keisti, taip leisdamas metodui tobulėti ir gauti geresnius rezultatus. O antras pranašumas – skaičiuojami gradientai, kurie leidžia modeliui surasti mažiausią paklaidą.

Metodas iškviečiamas iš *sklearn* bibliotekos, o vadinasi jis – *GradientBoostin-*

gRegressor. Modelio klasė ir parametrai užsirašo taip:

```
sklearn.ensemble.GradientBoostingRegressor(*, loss='ls', learning_rate=0.1,
n_estimators=100, subsample=1.0, criterion='friedman_mse', min_samples_split=2,
min_samples_leaf=1, min_weight_fraction_leaf=0.0, max_depth=3, min_impurity_de-
crease=0.0, min_impurity_split=None, init=None, random_state=None, max_featu-
res=None, alpha=0.9, verbose=0, max_leaf_nodes=None, warm_start=False, validati-
on_fraction=0.1, n_iter_no_change=None, tol=0.0001, ccp_alpha=0.0)
```

Toliau yra pateikiama 37 lentelė, kurioje nurodyti pagrindiniai parametrai ir jų paskirtys. Parametrų variantai nėra nagrinėjami.

37 lentelė. GBR parametrai ir jų paskirtis

Parametras	Parametro paskirtis
loss{'ls', 'lad', 'huber', 'quantile'}, default='ls'	Parametras, nusakantis, koku būdu bus apskaičiuojamos modelio paklaidos.
learning_rate: float, default=0.1	Parametras, nurodantis, koku greičiu judama prie paklaidos funkcijos minimumo.
n_estimators: int, default=100	Medžių skaičius modelyje.
criterion{'friedman_mse', 'mse', 'mae'}, default='friedman_mse'	Parametras, matuojantis metodo išskaidymo kokybę.
min_samples_split: int or float, default=2	Mažiausias duomenų skaičius, reikalingas vidiniam mazgui padalyti.
min_samples_leaf: int or float, default=1	Mažiausias duomenų skaičius, būtinas lape.
max_depth: int, default=3	Maksimalus atskirų regresijos įverčių gylis.
validation_fraction: float, default=0.1	Parametras, nusakantis, kokią dalį nuo treniravimosi duomenų atidedam validavimui, siekiant išankstinio modelio sustabdymo.
random_state: int, RandomState instance or None, default=None	Nustato metodo panaudojimo atsitiktinumą.

Šaltinis: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingRegressor.html>.

Taikant šį metodą, autoriaus nuomone, svarbiausi yra 9 parametrai. Visi jie pagal nutylėjimą jau turi tam tikras reikšmes, todėl galima iškviesti modelį, ir jis veiktų net ir nenurodžius jokių parametrų. Tačiau, siekiant gauti tikslesnius rezultatus, parametrų modifikavimas yra būtinas.

Regresijos metodas yra kitas tiek statistinis, tiek mašininio mokymosi metodas.

Plačiau apie regresijos analizę ir jos ypatumus jau buvo aprašyta, todėl toliau yra pateikiamas metodo, kaip klasės iškvietimo, būdas.

Metodas iškviečiamas iš *sklearn* bibliotekos, o vadinasi jis – *LinearRegression*. Modelio klasė ir parametrai užsirašo taip:

```
sklearn.linear_model.LinearRegression(*, fit_intercept=True, normalize=False,  
copy_X=True, n_jobs=None, positive=False).
```

Toliau yra pateikiama 38 lentelė, kurioje nurodyti svarbiausi parametrai ir jų paskirtys. Parametrų variantai nėra nagrinėjami.

38 lentelė. Regresijos parametrai ir jų paskirtis

Parametras	Parametro paskirtis
<i>fit_intercept</i> : bool, default=True	Nusako, ar turi būti apskaičiuotas b_0 koeficientas.
<i>Normalize</i> : bool, default=False	Nurodo, ar nepriklausomi kintamieji turi būti normalizuoti.

Šaltinis: https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.LinearRegression.html

Taikant šį metodą svarbiausi yra 2 parametrai. Visi jie pagal nutylėjimą jau turi tam tikras reikšmes, todėl galima iškviešti metodą, ir jis veiktų net ir nenurodžius jokių parametrų.

Neuroninis tinklas yra paskutinis metodas, kuris bus naudojamas šiame tyrime. Plačiau apie šį metodą ir jo ypatumus jau buvo aprašyta, todėl toliau pateikiamas metodo, kaip klasės iškvietimo būdas.

Metodas iškviečiamas iš *keras* bibliotekos, o vadinasi jis – *Sequential*. Metodo tinklas, skirtingai nei kiti minėti metodai, yra konstruojamas pagal poreikį. Pavyzdžiui, vieno sluoksnio pridėjimas yra užrašomas taip:

```
1: model = keras.Sequential();  
2: model.add(layers.Dense(2, activation="relu")).
```

Iš čia 1 eilute mes išsikviečiame ir pavadiname savo neuroninį tinklą, o antroje eilutėje pasakome, kad norime pridėti vieną sluoksnį, kuris turi 2 neuronus su nurodyta aktyvacijos funkcija. Norint pridėti daugiau sluoksnių, galima antrą eilutę dubliuoti ir pakeisti neuronų skaičių į kokį kitą skaičių. Visada rekomenduotina pradėti sukū-

rinėti sluoksnius nuo didesnį skaičių turinčių neuronų, palaipsniui sukuriant kitus sluoksnius su mažiau neuronų.

Baigiant formuoti savo neuroninį tinklą, reikia nurodyti, pagal kokį standartą bus skaičiuojamos paklaidos ir koks optimizatorius bus naudojamas. Pavyzdys pateikiamas taip:

```
1: model.compile(loss='mse', optimizer='adam', metrics=['mse']).
```

Iš čia paklaidos funkcija yra vidutinė kvadratinė paklaida, optimizatoriaus „Adam“, kuris atnaujinama neuroninio tinklo parametrus, sekamas tikslumo matas yra vidutinė kvadratinė paklaida.

Dar keli parametrai, kurie iš tiesų yra svarbūs sudarinėjant neuroninius tinklus, yra *batch size* ir *epochs count*.

```
1: model.fit(x_train, y_train, batch_size=21, epochs=100).
```

Batch size nurodo vienoje iteracijoje panaudotų mokymo pavyzdžių skaičių, o *epochs count* nurodo viso mokymo duomenų rinkinio leidimo skaičių. Šie parametrai nurodomi, kai į neuroninį tinklą paduodame duomenis.

Apibendrinus poskyrį, norima atkreipti dėmesį, kad sprendimų medžio ir atsitiktinio miško metodai tampa vienas su kitu susiję. Pagrindinis skirtumas tarp jų yra tas, kad atsitiktinis miškas talpina daug sprendimų medžių ir yra atsparus persimokymui. Kitas metodas, kuris plačiai naudojamas regresijos tipo uždaviniams spręsti, yra GBR. Jo privalumas tas, kad gali būti sukamas, daug kartų gerindamas savo rezultatus. Sudėtingiausia yra sudaryti neuroninį tinklą, nes reikalingas tinkamas sluoksnių, neuronų, aktyvacijos funkcijų, paklaidos funkcijų, optimizatorių parinkimas, kartu sugreitinant su *batch size* ir *epochs* skaičiumi. Verta pastebėti, kad tyrimui atlikti geriausia pasirinkti ne vieną metodą, o kelis ar net visus prieinamus tam, kad vėliau būtų galima palyginti gautų modelių rezultatus ir išsirinkti geriausią.

2.7 Tyrimo apribojimai

Šio tyrimo apribojimai ir argumentacija aprašoma taip:

1. Akcijų grąžą paprastai veikia daug reiškinų, tačiau šiame tyrime pasirinktas tik makroekonominis rodiklių netikėtumo reiškinys, darant prielaidą, kad niekas kitas, išskyrus minėtą reiškinį neveikia pasirinkto akcijų indekso per trumpą laiko tarpą iki 45 minučių po makroekonominio rodiklio realizacijos momento.

2. Makroekonominis rodiklių netikėtumų reiškinio sandara šiame tyrime argu-

mentuojama iš trijų akcijų grąžą nagrinėjančių teorijų požiūrio taško. Yra sakoma, kad reiškinio charakterizuojantis kintamasis turi fundamentalios analizės, finansų elgsenos ir efektyvios rinkos hipotezės elementų. Tai yra unikalus šio tyrimo autoriaus požiūris, kuris gali būti tiek teisingas, tiek neteisingas.

3. Tyrime darome prielaidą, kad makroekonominių rodiklių netikėtumų poveikis nesitęsia ilgiau nei 45 minutes. Ši prielaida argumentuojama tuo, kad dažniausiai makroekonominių rodiklių realizacija vyksta kas valandą, tokiu būdu siekiama išvengti akcijų indekso grąžos svyravimo įtraukimo į modelį, kuriam įtakos gali turėti dar nerealizuoti, bet labai finansų rinkose laukiami rodikliai.

4. Nors tyrimo laikotarpis ir yra reprezentatyvus – 12 metų, tačiau patys makroekonominiai rodikliai pasirodo vidutiniškai maždaug kas mėnesį. Tokiu būdu prognozavimo modeliai nėra sudaryti iš daug duomenų, kas gali paveikti modelių tikslumo pasikeitimą įtraukiant naujų duomenų. Tyrimo laikotarpio parinkimas susijęs ir su duomenų gavimo galimybėmis. Senesnių nei 2008 m. duomenų gauti nepavyko, kas taip pat yra šio tyrimo ribotumas, nes:

a) Neleidžia įvertinti, kaip kito akcijų grąža prieš Finansų krizę.

b) Mažiau duomenų, o tai daro prognozavimo modelius nestabilius ir mažiau patikimus.

c) Mažiau galimybių sudaryti daugiau modeliavimo scenarijų. Pavyzdžiui, kokį poveikį makroekonominių rodiklių netikėtumai turėjo prieš finansų krizę ir po jos.

5. Prognozavimo modeliai sukurti ne akcijai ar indeksui, prekiaujamam biržoje, o etalonui (akcijų indeksui EURO STOXX 50). Etalonais paprastai nėra prekiaujama akcijų biržose, bet būna sukurti juos „sekantys“ fondai. Tačiau fondų ir etalonų kainų įverčiai ar jų procentiniai pokyčiai ne visada sutampa ar turi sutapti, todėl tai šiek tiek trukdo gautus tyrimų rezultatus paimti ir iškart pritaikyti investicinėje veikloje, nebent naudojamas ETF, kuris 100 % sinchronizuojasi su EURO STOXX 50 etalonu.

III. MAKROEKONOMINIŲ RODIKLIŲ NETIKĖTUMŲ POVEIKIO EURO STOXX 50 AKCIJŲ GRĄŽAI MODELIAVIMAS

Šiame tyrime nėra aprašoma, kaip yra atliekami ir gaunami tyrimų rezultatai kodavimo lygmeniu, t. y. nepateikiamas ir nekomentuojamas užrašomas „Python“ programavimo kalbos kodas „Jupyter Notebook“ platformoje. Darbe yra pateikiama jau apdorota (be kodo) ir galutinė (be tarpinių skaičiavimų) informacija, todėl yra išlaikyta

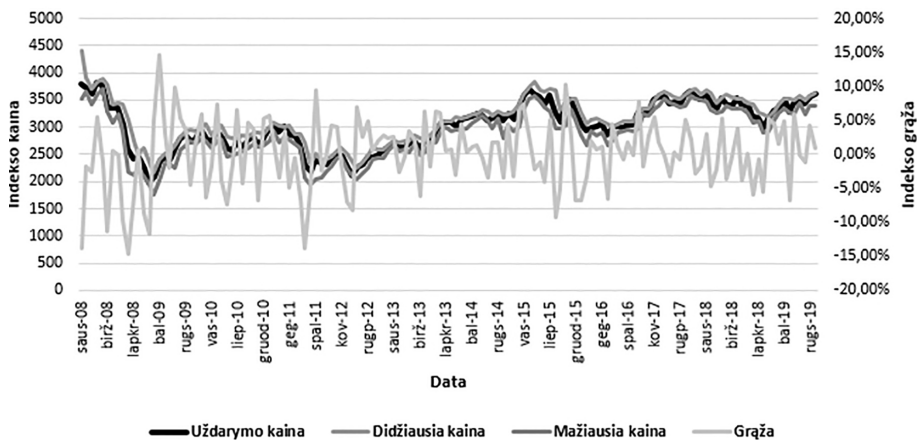
aiški ir suprantama struktūra ekonomikos krypties tyrėjams.

3.1 EURO STOXX 50 akcijų indekso aprašomoji analizė

Teorinėje dalyje buvo pastebėta, kad makroekonominių rodiklių netikėtumų tyrimai apima Indijos, Brazilijos, atskiras Europos šalis, JAV, Kinijos ir kitas akcijų rinkas, tačiau buvo pasigesta tyrimų, apimančių euro zonos akcijų rinką. Dėl šios priežasties buvo pasirinktas EURO STOXX 50 indeksas, kuris reprezentuoja bendrą euro zonos akcijų rinkos būklę. Taip pat indeksas naudojamas, kaip investicinis produktas, sudarant su juo susijusias naujas investicines priemones, tokias kaip biržoje prekiaujamus fondus, ateities, pasirinkimo sandorius ir struktūrizuotus produktus. Šiais produktais plačiai prekiaujama visame pasaulyje. EURO STOXX 50 yra pagrindas sudaryti atskirus subindeksus, tokius kaip EURO STOXX 50 „Ex-Financials“, kurio likvidumas taip pat yra aukštas.

EURO STOXX 50 yra euro zonos akcijų indeksas, kurį sukūrė „Deutsche Börse Group“ priklausantis indekso teikėjas „STOXX“. Euro STOXX 50 indeksas buvo vienas iš pirmųjų „STOXX“ indeksų, pradėtų naudoti 1998 m. Jį sudaro 50 didžiausių ir likvidžiausių euro zonos kompanijų iš 11 euro zonos šalių: Austrijos, Belgijos, Suomijos, Prancūzijos, Vokietijos, Airijos, Italijos, Liuksemburgo, Nyderlandų, Portugalijos ir Ispanijos. Jo sudėtis peržiūrima kiekvieną rugsėjį. Indeksą galima įsigyti keliomis valiutomis (EUR, USD, CAD, GBP, JPY). Indekso kaina skaičiuojama kas 15 sekundžių, nuo 8:00 iki 17:00 Lietuvos laiku.

EURO STOXX 50 kainos ir grąžos judėjimas per 2008 – 2019 metų laikotarpį pateikiamas 16 paveiksle.



Šaltinis: Sudaryta autoriaus.

16 pav. EURO STOXX 50 kainos ir grąžos judėjimas nuo 2008 iki 2019 metų

Kaip matyti iš grafiko, nuo 2008-01 iki 2019-10 indekso grąža svyruoja nuo 1976 iki 4411 punktų. Didžiausias nuosmukis matomas finansų krizės 2007–2009 periodu. Šiuo laikotarpiu kaina krito nuo 3825 iki 1976, kas yra 48,3 % nuo pirminės kainos. Grąža per 12 metų svyravo nuo -14,69 iki 14,69 %.

Verta paminėti, kad EURO STOXX 50 indeksas yra išvestinis iš 19 bendro EURO STOXX regioninių kategorinių sektorių indeksų ir yra didžiausias kategorinis sektoriaus lyderis euro zonoje laisvosios rinkos kapitalizacijos prasme. Indeksas užfiksuoja apie 60 % visos EURO STOXX bendrosios rinkos indekso kapitalizacijos, kuris savo ruožtu apima apie 95 % atstovaujамų šalių laisvosios rinkos kapitalizacijos.

Taigi dėl indekso likvidumo, skaidrumo, susietumo su kitomis finansinėmis priemonėmis, pakankamai didelio kapitalizacijos dydžio, duomenų gavimo klausimo ir buvo nuspręsta pasirinkti būtent šį indeksą.

3.2 Makroekonominių rodiklių duomenų analizė

Šiame skyriuje bus atlikta makroekonominių rodiklių duomenų analizė, kuri leis detaliau susipažinti su šiais rodikliais ir atrasti naujų įžvalgų. Makroekonominiai rodikliai buvo pasirinkti visi, kurie buvo prieinami „Bloomberg“ terminale, kurie turėjo istoriškumą, faktines ir prognozes reikšmes.

Pirmoji makroekonominių rodiklių grupė yra pinigų rinkos rodikliai, į kurių bazę įeina tokie rodikliai, kaip palūkanų normos rodiklis ir pinigų pasiūlos rodiklis (žr. 39 lent.).

39 lentelė. Pinigų rinkos rodiklių duomenų charakteristikos (I dalis)

Rodiklio pavadinimas	Palyginamasis periodas	Laikotarpis (nuo)	Laikotarpis (iki)	Laikotarpis (metais)	Duomenų dažnumas	Duomenų tipas	Reikšmių kiekis	Teorinis poveikis	Rodiklio reikšmė
Palūkanų normos rodiklis	Nėra	2008-02-07	2019-09-12	11	Mėnesis	%	121	+	Aukštas
Pinigų pasiūlos rodiklis	Metai // Metai	2008-02-27	2019-09-26	11	Mėnesis	%	140	+	Mažas

Šaltinis: sudaryta autoriaus.

Iš lentelės matoma, kad pinigų pasiūlos rodiklio palyginamasis periodas yra „Metai // Metai“. Tai reiškia, kad lyginama mėnesio faktinė reikšmė su praėjusių metų to paties mėnesio faktine reikšme. Tuo tarpu palūkanų normos rodiklis palyginamojo periodo neturi.

Vidutinis laikotarpis metais yra 11 metų, kas reiškia, kad rodikliai skaičiuojami ne naujai ir apima kelis ekonominius ciklus, kas yra gerai, nes įvertinami pakilimai ir nuosmukiai.

Pagal duomenų dažnumą matoma, kad rodikliai pasirodo kas mėnesį. Tai yra gerai, nes kuo dažniau jie pasirodo, tuo daugiau duomenų turima ir tuo su jais sudaromi modeliai yra patikimesni.

Rodiklio teorinis poveikis indeksui žymimas (+) ir (-). Plusas reiškia, kad rodikliui didėjant teoriškai akcijų indekso kaina ar grąža turėtų didėti. Minusai – atvirkščiai. Toks pat principas galioja ir netikėtumo mato kiekvienam rodiklio atveju. Pavyzdžiui, jei palūkanų normos reikšmė yra didesnė nei buvo prognozuota, tai turėtų teigiamai paveikti akcijų indeksą.

Rodiklio reikšmingumo lygis pasako, kokio teorinio indekso kainos kintamumo galima tikėtis. Mažas reiškia, kad indekso kaina rodiklio pasirodymo metu svyruos nedaug, vidutinis – vidutiniškai, aukštas – daug.

Apibendrinant pinigų rinkos rodiklių duomenų charakteristikas buvo sukurta 40 lentelė, kurioje yra nurodytos faktinės rodiklių reikšmės nuo ir iki, blogiausias rodiklio periodas, netikėtumo nuo ir iki reikšmės, rodiklio netikėtumo vidutinė reikšmė ir prognozavimo tikslumas procentais.

40 lentelė. Pinigų rinkos rodiklių duomenų charakteristikos (II dalis)

Rodiklio pavadinimas	Palyginamasis periodas	Faktinė reikšmė (nuo)	Faktinė reikšmė (iki)	Blogiausias periodas	Netikėtumo reikšmė (nuo)	Netikėtumo reikšmė (iki)	Netikėtumo vid. reikšmė	Prognozavimo tikslumo rodiklis
Palūkanų normos rodiklis	Nėra	0,00%	4,25%	Nėra	-3,34	3,31	-0,04	93,39%
Pinigų pasiūlos rodiklis	Metai // Metai	-0,40%	11,50%	2008 - 2010 m. Finansų krizė	-2,40	2,47	-0,05	11,43%

Šaltinis: sudaryta autoriaus.

Taigi didžiausius faktinių reikšmių svyravimų ribas turi pinigų pasiūlos rodiklis, kur blogiausias periodas šiam rodikliui buvo 2008–2010 finansų krizė, kurios metu ir buvo pasiektos mažiausios faktinės reikšmės. Didžiausias netikėtumų reikšmių svyravimų ribas turi palūkanų normos rodiklis. Tačiau šio rodiklio vidutinė netikėtumo reikšmė nėra didžiausia, kas rodo mažesnę prognozavimo neatitikimų sklaidą, palyginus su pinigų pasiūlos rodikliu. Didžiausią prognozavimo tikslumo rodiklį turi taip pat palūkanų normos rodiklis, kurio reikšmė siekia 93,39 %, kas indikuoja galimai didesnes grąžas netikėtumo atveju, bet ne taip dažnas investavimo galimybes.

Antroji makroekonominių rodiklių grupė yra pagrindiniai makroekonominiai rodikliai, į kurių bazę įeina bendrojo pagrindinio kapitalo formavimo rodiklis, namų ūkių vartojimo rodiklis, realaus bendrojo vidaus produkto, nedarbo lygio rodiklis ir prekybos balanso rodiklis (žr. 41 lent.).

41 lentelė. Pagrindinių ekonomikos rodiklių duomenų charakteristikos (I dalis)

Rodiklio pavadinimas	Palyginamasis periodas	Laikotarpis (nuo)	Laikotarpis (iki)	Laikotarpis (metais)	Duomenų dažnumas	Duomenų tipas	Reikšmių kiekis	Teorinis poveikis	Rodiklio reikšmė
Bendrojo pagrindinio kapitalo formavimo rodiklis	Ketvirtis // Ketvirtis	2008-03-04	2019-09-06	11	Ketvirtis	%	57	+	Vidutinis
Namų ūkių vartojimo rodiklis	Ketvirtis // Ketvirtis	2008-03-04	2019-09-06	11	Ketvirtis	%	58	+	Mažas
Realaus bendrojo vidaus produkto rodiklis	Metai // Metai	2008-02-14	2019-09-06	11	Ketvirtis	%	121	+	Vidutinis
Realaus bendrojo vidaus produkto rodiklis	Ketvirtis // Ketvirtis	2008-02-14	2019-09-06	11	Ketvirtis	%	121	+	Vidutinis
Nedarbo lygio rodiklis	Nėra	2008-01-31	2019-09-30	11	Mėnesis	%	141	-	Vidutinis
Prekybos balanso rodiklis	Metai // Metai	2008-02-15	2019-09-13	11	Mėnesis	Bil. EUR	126	+	Vidutinis

Šaltinis: sudaryta autoriaus.

Iš lentelės matoma, kad rodikliai turi skirtingą palyginamąjį periodą. „Ketvirtis // Ketvirtis“ reiškia, kad duomenys skaičiuojami už ketvirtį ir lyginami su praėjusiu ketvirčiu. „Metai // Metai“ – lyginama mėnesio reikšmė su praėjusių metų to paties mėnesio reikšme. RBVP atveju yra lyginamas ne mėnesis, o ketvirtis. Svarbu paminėti, kad RBVP rodiklio reikšmių kiekis yra 121, nors duomenys ir yra skaičiuojami už ketvirtį. Taip yra todėl, kad RBVP apskaičiavimas užtrunka apie tris mėnesius, todėl ekonomistai ir analitikai dažnai bando nuspėti, koks turėtų būti ketvirtinis RBVP kas mėnesį.

Vidutinis laikotarpis metais yra 11 metų, kas reiškia, kad rodikliai skaičiuojami ne naujai ir apima kelis ekonominius ciklus.

Pagal duomenų dažnumą matoma, kad vieni rodikliai pasirodo kartą kas ketvirtį, kiti kas mėnesį ir tas turi įtakos reikšmių kiekiui.

Rodiklio teorinis poveikis indeksui žymimas (+) ir (-). Plusas reiškia, kad rodikliui didėjant, teoriškai akcijų indekso kaina ar grąža turėtų didėti. Minus – atvirkščiai. Toks pat principas galioja ir netikėtumo mato kiekvienam rodikliui atveju. Pavyzdžiui, jei RBVP reikšmė yra didesnė nei buvo prognozuota, tai turėtų teigiamai paveikti akcijų indeksą. Nedarbo lygio atveju – atvirkščiai.

Apibendrinant pagrindinių makroekonominių rodiklių duomenų charakteristikas buvo sukurta 42 lentelė, kurioje yra nurodytos faktinės rodiklių reikšmės nuo ir iki, blogiausias rodiklio periodas, netikėtumo nuo ir iki reikšmės, rodiklio netikėtumo vidutinė reikšmė, prognozavimo tikslumo procentas.

42 lentelė. Pagrindinių makroekonominių rodiklių duomenų charakteristikos
(II dalis)

Rodiklio pavadinimas	Palyginamasis periodas	Faktinė reikšmė (nuo)	Faktinė reikšmė (iki)	Blogiausias periodas	Netikėtumo reikšmė (nuo)	Netikėtumo reikšmė (iki)	Netikėtumo vid. reikšmė	Prognozavimo tikslumo rodiklis
Bendrojo pagrindinio kapitalo formavimo rodiklis	Ketvirtis // Ketvirtis	-4,20%	2,10%	2008 - 2010 m. Finansų krizė	-3,15	2,63	-0,01	12,28%
Namų ūkių vartojimo rodiklis	Ketvirtis // Ketvirtis	-0,90%	0,60%	2008 - 2010 m. Finansų krizė	-5,14	1,99	-0,17	36,21%
Realaus bendrojo vidaus produkto rodiklis	Metai // Metai	-4,90%	2,70%	2008 - 2010 m. Finansų krizė	-4,89	3,46	0,02	47,93%
Realaus bendrojo vidaus produkto rodiklis	Ketvirtis // Ketvirtis	-2,50%	1,00%	2008 - 2010 m. Finansų krizė	-6,64	4,40	-0,03	65,29%
Nedarbo lygio rodiklis	Nėra	7,10%	12,20%	2013-2014 m.	-3,32	3,31	-0,10	48,94%
Prekybos balanso rodiklis	Metai // Metai	-6,4	28	2008 - 2010 m. Finansų krizė	-2,57	2,99	0,08	4,76%

Šaltinis: sudaryta autoriaus.

Taigi didžiausias faktinių reikšmių svyravimų ribas turi prekybos balanso ir realaus bendrojo vidaus produkto (ketvirtis / ketvirtis) rodikliai. Blogiausias periodas beveik visiems rodikliams buvo 2008–2010 m. finansų krizė, kurios metu ir buvo pasiektos mažiausios faktinės reikšmės. Didžiausias netikėtumų reikšmių svyravimų ribas turi RBVP rodikliai. Tačiau šių rodiklių netikėtumo vidutinės svyravimų reikšmės nėra didžiausios, kas rodo mažesnę prognozavimo neatitikimų sklaidą, palyginus su kitais rodikliais. Didžiausią prognozavimo tikslumo rodiklį turi RBVP (ketvirtis / ketvirtis) rodiklis, mažiausią – prekybos balanso rodiklis. Vadinasi, RBVP (ketvirtis / ketvirtis) rodiklio netikėtumo atveju yra galimybė uždirbti daugiau, nei kad prekybos balanso rodiklio netikėtumo atveju, tačiau pastarojo investavimo galimybės yra dažnesnės.

Trečioji makroekonominių rodiklių grupė yra sektoriai makroekonominiai rodikliai, į kurių bazę įeina gamintojo kainų indeksai, mažmeninių pardavimų indeksas ir produkcijos pramonės indeksai (žr. 43 lent.).

43 lentelė. Sektorinių makroekonominių rodiklių duomenų charakteristikos (I dalis)

Rodiklio pavadinimas	Palyginamasis periodas	Laikotarpis (nuo)	Laikotarpis (iki)	Laikotarpis (metais)	Duomenų dažnumas	Duomenų tipas	Reikšmių kiekis	Teorinis poveikis	Rodiklio reikšmė
Gamintojų kainų indekso rodiklis	Metai // Metai	2008-02-04	2019-10-03	11	Mėnesis	%	141	+	Mažas
Gamintojų kainų indekso rodiklis	Mėnesis // Mėnesis	2008-02-04	2019-10-03	11	Mėnesis	%	141	+	Mažas
Mažmeninių pardavimų indekso rodiklis	Metai // Metai	2008-02-05	2019-10-03	11	Mėnesis	%	141	+	Mažas
Pramonės produkcijos rodiklis	Metai // Metai	2008-02-13	2019-09-12	11	Mėnesis	%	140	+	Mažas
Pramonės produkcijos rodiklis	Mėnesis // Mėnesis	2008-02-13	2019-09-12	11	Mėnesis	%	140	+	Vidutinis

Šaltinis: sudaryta autoriaus.

Iš lentelės matoma, kad rodikliai turi skirtingą palyginamąjį periodą. „Mėnesis // Mėnesis“ reiškia, kad duomenys skaičiuojami mėnesiui ir lyginami su praėjusiu mėnesiu. „Metai // Metai“ – lyginama mėnesio reikšmė su praėjusių metų to paties mėnesio reikšme.

Vidutinis laikotarpis metais yra 11 metų, kas reiškia, kad rodikliai skaičiuojami ne naujai ir apima kelis ekonominio ciklo periodus.

Pagal duomenų dažnumą matoma, kad rodikliai pasirodo kartą kas mėnesį. Šiuo atveju tai yra gerai, nes, kuo duomenys dažnesni, tuo didesnis reikšmių kiekis, o didesnis duomenų kiekis turui įtakos modelio patikimumui.

Apibendrinant sektorialių makroekonominių rodiklių duomenų charakteristikas buvo sukurta 44 lentelė, kurioje yra nurodytos faktinės rodiklių reikšmės nuo ir iki, blogiausias rodiklio periodas, netikėtumo nuo ir iki reikšmės, rodiklio netikėtumo vidutinė reikšmė, ir prognozavimo tikslumo procentas.

44 lentelė. Sektorialių makroekonominių rodiklių duomenų charakteristikos (II dalis)

Rodiklio pavadinimas	Palyginamasis periodas	Faktinė reikšmė (nuo)	Faktinė reikšmė (iki)	Blogiausias periodas	Netikėtumo reikšmė (nuo)	Netikėtumo reikšmė (iki)	Netikėtumo vid. reikšmė	Prognozavimo tikslumo rodiklis
Gamintojų kainų indekso rodiklis	Metai // Metai	-8,50%	9,00%	2009 - 2010 m. Finansų krizė	-7,45	3,26	-0,11	22,70%
Gamintojų kainų indekso rodiklis	Mėnesis // Mėnesis	-1,90%	1,50%	2009 - 2010 m. Finansų krizė	-8,42	3,38	-0,20	26,95%
Mažmeninių pardavimų indekso rodiklis	Metai // Metai	-4,20%	3,70%	2009 - 2010 m. Finansų krizė, 2013 - 2014 m.	-2,98	1,86	-0,11	4,26%
Pramonės produkcijos rodiklis	Metai // Metai	-21,60%	9,50%	2009 - 2010 m. Finansų krizė	-3,63	3,20	-0,14	6,43%
Pramonės produkcijos rodiklis	Mėnesis // Mėnesis	-3,50%	2,10%	2009 - 2010 m. Finansų krizė	-3,68	3,83	-0,12	7,14%

Šaltinis: sudaryta autoriaus.

Taigi didžiausias faktinių reikšmių svyravimų ribas turi pramonės produkcijos rodiklis (metai // metai). Blogiausias laikotarpis visiems rodikliams buvo 2009–2010 m. per finansų krizę, kurios metu ir buvo pasiektos mažiausios faktinės reikšmės. Nors didžiausias netikėtumų reikšmių svyravimų ribas turi abu gamintojų kainų indekso rodikliai, tačiau matoma, kad pirmojo (metai // metai) svyravimo vidurkis yra mažesnis nei antrojo. Tai rodo, kad jo sklaida visu laikotarpiu yra mažesnė, o tai reiškia, kad prognozinės reikšmės nuo faktinių skyrėsi ne tiek daug, kaip kito rodiklio. Kita vertus, antrasis gamintojų kainų indekso rodiklis turi aukštesnį prognozavimo tikslumą, kas reiškia galimai didesnes grąžas netikėtumo atveju, bet mažiau dažnas investavimo galimybes.

Ketvirtoji makroekonominių rodiklių grupė yra vartotojų kainų indeksų makroekonominiai rodikliai, į kurių bazę įeina preliminarinių duomenų vartotojų kainų indeksas, vartotojų kainų indeksas, išskyrus energiją, maistą, alkoholį ir tabaką (žr. 45 lent.).

45 lentelė. Vartotojų kainų indeksų rodiklių duomenų charakteristikos (I dalis)

Rodiklio pavadinimas	Palyginamasis periodas	Laikotarpis (nuo)	Laikotarpis (iki)	Laikotarpis (metais)	Duomenų dažnumas	Duomenų tipas	Reikšmių kiekis	Teorinis poveikis	Rodiklio reikšmė
Vartotojų kainų indekso rodiklis	Metai // Metai	2008-02-29	2019-09-18	11	Mėnesis	%	140	+	Aukštas
Vartotojų kainų indekso rodiklis	Mėnesis // Mėnesis	2008-02-29	2019-09-18	11	Mėnesis	%	138	+	Vidutinis
Preliminarių duomenų vartotojų kainų indekso rodiklis	Metai // Metai	2008-01-31	2019-10-01	11	Mėnesis	%	141	+	Aukštas
Vartotojų kainų indekso (metai / metai) išskyrus energiją, maistą, alkoholį ir tabaką rodiklis	Metai // Metai	2008-02-29	2019-10-01	11	Dvi savaitės	%	217	+	Vidutinis

Šaltinis: sudaryta autoriaus.

Iš lentelės matoma, kad rodikliai turi skirtingą palyginamąjį periodą. „Mėnesis // Mėnesis“ reiškia, kad duomenys skaičiuojami mėnesiui ir lyginami su praėjusiu mėnesiu. „Metai // Metai“ – lyginama mėnesio reikšmė su praėjusių metų to paties mėnesio reikšme.

Vidutinis laikotarpis metais yra 11 metų, kas reiškia, kad rodikliai skaičiuojami ne naujai ir apima kelis ekonominius ciklus.

Pagal duomenų dažnumą matoma, kad rodikliai pasirodo kartą kas mėnesį, VKI išskyrus energiją, maistą, alkoholį ir tabaką – kas dvi savaites. Šiuo atveju tai yra gerai, nes, kuo duomenys dažnesni, tuo didesnis reikšmių kiekis, o didesnis duomenų kiekis turui įtakos modelio patikimumui.

Apibendrinant vartotojų kainų indeksų rodiklių duomenų charakteristikas buvo sukurta 46 lentelė, kurioje yra nurodytos faktinės rodiklių reikšmės nuo ir iki, blogiausias rodiklio periodas, netikėtumo nuo ir iki reikšmės, rodiklio netikėtumo vidutinė reikšmė, ir prognozavimo tikslumo procentas.

46 lentelė. Vartotojų kainų indeksų rodiklių duomenų charakteristikos (II dalis)

Rodiklio pavadinimas	Palyginamasis periodas	Laikotarpis (nuo)	Laikotarpis (iki)	Laikotarpis (metais)	Duomenų dažnumas	Duomenų tipas	Reikšmių kiekis	Teorinis poveikis	Rodiklio reikšmė
Pramonės pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	2008-01-31	2019-09-27	11	Mėnesis	Punktai	141	+	Mažas
Paslaugų pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	2008-01-31	2019-09-27	11	Mėnesis	Punktai	141	+	Mažas

Lentelė nukelta į 117 psl.

Lentelė atkelta iš 116 psl.

Sudėtinių pirkimų vadybininkų indekso rodiklis	Nėra. Vykdoma apklausa	2017-01-04	2019-10-03	2	Mėnesis	Punktai	34	>50 +	Vidutinis
Gamybos pirkimų vadybininkų indekso rodiklis	Nėra. Vykdoma apklausa	2017-01-02	2019-10-01	2	Mėnesis	Punktai	34	>50 +	Vidutinis
Paslaugų pirkimų vadybininkų indekso rodiklis	Nėra. Vykdoma apklausa	2017-01-04	2019-10-03	2	Mėnesis	Punktai	34	>50 +	Vidutinis
Vartotojų pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	2008-01-31	2019-09-27	11	Dvi savaitės	Punktai	249	+	Mažas
Ekonominių nuotaikų indekso rodiklis	Nėra. Vykdoma apklausa	2008-01-31	2019-09-27	11	Mėnesis	Punktai	141	>100 +	Mažas
Verslo klimato kaitos rodiklis	Nėra. Vykdoma apklausa	2008-01-31	2019-09-27	11	Mėnesis	Punktai	141	+	Mažas
"Sentix" investuotojų pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	2008-02-04	2019-09-09	11	Mėnesis	Punktai	136	+	Mažas

Šaltinis: sudaryta autoriaus.

Taigi didžiausias faktinių reikšmių svyravimų ribas turi VKI (metai // metai). Blogiausi laikotarpiai rodikliams buvo 2009–2010 m. finansų krizės ir 2015–2017 periodai, kada ir buvo pasiektos mažiausios faktinės reikšmės. Didžiausias netikėtumų reikšmių svyravimų ribas turi VKI su preliminariais duomenimis rodiklis. Taip pat šio rodiklio netikėtumo vidutinės svyravimų reikšmės yra vienos didžiausių, kas rodo didesnę prognozavimo neatitikimų sklaidą, palyginus su kitais rodikliais. Didžiausią prognozavimo tikslumą turi VKI (Metai / Metai) rodiklis, kas indikuoja galimai didesnes grąžas netikėtumo atveju, bet mažiau dažnas investavimo galimybės.

Penktoji makroekonominių rodiklių grupė yra rinkos nuotaikų ir lūkesčių rodikliai, į kurių bazę įeina pramonės pasitikėjimo indeksas, paslaugų pasitikėjimo indeksas, sudėtinio pirkimo vadybininko indeksas, gamybos pirkimų vadybininkų indeksas, paslaugų pirkimų vadybininkų indeksas, vartotojų pasitikėjimo indeksas, makroekonominių nuotaikų indeksas, verslo klimato kaitos indeksas ir „Sentix“ investuotojų pasitikėjimo indeksas (žr. 47 lent.).

47 lentelė. Rinkos nuotaikų ir lūkesčių rodiklių duomenų charakteristikos (I dalis)

Rodiklio pavadinimas	Palyginamasis periodas	Laikotarpis (nuo)	Laikotarpis (iki)	Laikotarpis (metais)	Duomenų dažnumas	Duomenų tipas	Reikšmių kiekis	Teorinis poveikis	Rodiklio reikšmė
Pramonės pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	2008-01-31	2019-09-27	11	Mėnesis	Punktai	141	+	Mažas
Paslaugų pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	2008-01-31	2019-09-27	11	Mėnesis	Punktai	141	+	Mažas

Lentelė nukelta į 118 psl.

Lentelė atkelta iš 117 psl.

Sudėtinis pirkimų vadybininkų indekso rodiklis	Nėra. Vykdoma apklausa	2017-01-04	2019-10-03	2	Mėnesis	Punktai	34	>50 +	Vidutinis
Gamybos pirkimų vadybininkų indekso rodiklis	Nėra. Vykdoma apklausa	2017-01-02	2019-10-01	2	Mėnesis	Punktai	34	>50 +	Vidutinis
Paslaugų pirkimų vadybininkų indekso rodiklis	Nėra. Vykdoma apklausa	2017-01-04	2019-10-03	2	Mėnesis	Punktai	34	>50 +	Vidutinis
Vartotojų pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	2008-01-31	2019-09-27	11	Dvi savaitės	Punktai	249	+	Mažas
Ekonominių nuotaičių indekso rodiklis	Nėra. Vykdoma apklausa	2008-01-31	2019-09-27	11	Mėnesis	Punktai	141	>100 +	Mažas
Verslo klimato kaitos rodiklis	Nėra. Vykdoma apklausa	2008-01-31	2019-09-27	11	Mėnesis	Punktai	141	+	Mažas
"Sentix" investuotojų pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	2008-02-04	2019-09-09	11	Mėnesis	Punktai	136	+	Mažas

Šaltinis: sudaryta autoriaus.

Iš lentelės matoma, kad rodikliai neturi palyginamojo periodo. „Nėra. Vykdoma apklausa“ reiškia, kad rodiklis skaičiuojamas apklausos būdu ir galutinis rezultatas nėra lyginamas su praėjusiu periodu.

Vidutinis laikotarpis metais yra 8,3 metų, kas reiškia, kad rodikliai skaičiuojami ne naujai ir apima kelis ekonominius ciklus. Vis dėlto sudėtinio pirkimo vadybininko indekso, gamybos pirkimų vadybininkų indekso ir paslaugų pirkimų vadybininkų indekso rodiklių duomenys buvo gauti tik už tris metus, kas nereprezentuoja ilgo laikotarpio ir didelio duomenų skaičiaus (po 36 stebėjimų), ir tai gali turėti įtakos modelio patikimumui.

Pagal duomenų dažnumą matoma, kad dauguma rodiklių pasirodo kartą kas mėnesį. Tačiau vartotojų pasitikėjimo indeksas pasirodo kas dvi savaites. Šiuo atveju tai yra gerai, nes, kuo duomenys dažnesni, tuo didesnis reikšmių kiekis, o didesnis duomenų kiekis turi įtakos modelio patikimumui.

Rodiklio teorinis poveikis indeksui žymimas (+) ir (-). Plusas reiškia, kad rodikliui didėjant, teoriškai akcijų indekso kaina ar grąža turėtų didėti. Minus – atvirkščiai. „>50+“ arba „>100+“ reiškia, kad teigiamas poveikis indeksui yra tik tada, kai reikšmė yra daugiau nei 50 arba 100 punktų. Toks pat principas galioja ir netikėtumo mato kiekvienam rodikliui atveju.

Apibendrinant rinkos nuotaičių ir lūkesčių rodiklių duomenų charakteristikas buvo sukurta 48 lentelė, kurioje yra nurodytos faktinės rodiklių reikšmės nuo ir iki,

blogiausias rodiklio periodas, netikėtumo nuo ir iki reikšmės, rodiklio netikėtumo vidutinė reikšmė, ir prognozavimo tikslumo procentas.

48 lentelė. Rinkos nuotaikų ir lūkesčių rodiklių duomenų charakteristikos
(II dalis)

Rodiklio pavadinimas	Palyginamasis periodas	Faktinė reikšmė (nuo)	Faktinė reikšmė (iki)	Blogiausias periodas	Netikėtumo reikšmė (nuo)	Netikėtumo reikšmė (iki)	Netikėtumo vid. reikšmė	Prognozavimo tikslumo rodiklis
Pramonės pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	-38,00	9,10	2009 - 2010 m. Finansų krizė	-2,99	2,10	-0,06	12,06%
Paslaugų pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	-25,00	18,40	2009 - 2010 m. Finansų krizė	-4,26	2,86	0,00	6,38%
Sudėtinis pirkimų vadybininkų indekso rodiklis	Nėra. Vykdoma apklausa	50,10	58,80	Nėra	-1,57	3,54	0,36	20,59%
Gamybos pirkimų vadybininkų indekso rodiklis	Nėra. Vykdoma apklausa	45,70	60,60	Nuo 2019-03 m.	-2,06	3,07	0,03	41,18%
Paslaugų pirkimų vadybininkų indekso rodiklis	Nėra. Vykdoma apklausa	51,20	58,00	Nėra	-1,38	2,12	0,29	11,76%
Vartotojų pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	-34,00	1,30	2009 - 2010 m. Finansų krizė	-3,63	4,19	-0,02	41,37%
Ekonominių nuotaikų indekso rodiklis	Nėra. Vykdoma apklausa	64,60	116,00	2009 - 2010 m. Finansų krizė	-4,78	2,37	-0,01	3,55%
Verslo klimato kaitos rodiklis	Nėra. Vykdoma apklausa	-3,58	1,66	2009 - 2010 m. Finansų krizė	-3,13	2,58	-0,03	0,71%
"Sentix" investuotojų pasitikėjimo indekso rodiklis	Nėra. Vykdoma apklausa	-42,70	34,00	2009 - 2010 m. Finansų krizė	-5,81	2,47	-0,12	0,00%

Šaltinis: sudaryta autoriaus.

Taigi didžiausias faktinių reikšmių svyravimų ribas turi makroekonominių nuotaikų indeksas. Blogiausi laikotarpiai daugumai rodiklių buvo 2009–2010 finansų krizės metai, kada ir buvo pasiektos mažiausios faktinės reikšmės. Didžiausias netikėtumų reikšmių svyravimų ribas turi „Sentix“ investuotojų pasitikėjimo indekso rodiklis. Šis rodiklis turi ir mažiausią prognozavimo tikslumą, kuris yra lygus 0,00 %. Tokiu atveju sunku nustatyti, kokie galimi akcijų indekso kainų svyravimai, kai faktinės reikšmės išprognozuojamos teisingai. Didžiausią netikėtumo vidutinę reikšmę turi sudėtinis pirkimų vadybininkų indeksas, kas rodo didesnę prognozavimo neatitikimų sklaidą, palyginus su kitais rodikliais.

3.3 I tyrimo etapas

3.3.1 Regresijos modelių sudarymas ir atranka pagal kriterijus

Pirmasis tyrimo etapas susideda iš penkių dalių. Tai duomenų paruošimo analizei ir modeliavimui darbai, koreliacinių matricų sukūrimas, statistinių regresinių mo-

delių sukūrimas, modelių atrinkimas pagal tris kriterijus, kurie yra: $R^2 \geq 20$ p-reikšmė $< 0,05$, įvykių skaičius > 20 . Galiausiai atliekamas ir regresijos modelių prielaidų tikrinimas. Siekiant gauti tikslesnius rezultatus, gražos modeliavimas atliekamas su penkiais netikėtumo reikšmių scenarijais ir 49 lentelėje pateikiama pirmojo scenarijaus modelių suvestinė.

49 lentelė. EURO STOXX 50 gražų modeliai pagal makroekonominių rodiklių netikėtumus su visomis netikėtumo rodiklio reikšmėmis

Rodiklio pavadinimas	Regresijos modelis	R ²	R ² minutėje	P-reikšmė	Įvykių skaičius
PAGRINDINIAI RODIKLIAI					
Bendrojo pasirinkimo kapitalo formavimo (katv./katv.)	Gražos polovnis % = -0.0109 - 0.0889 * netikėtumas	9,50%	42	0,020	57
Namu ūkių vartojimo (katv./katv.)	Gražos polovnis % = 0.0023 - 0.0172 * netikėtumas	9,00%	1	0,022	58
Realaus bendrojo vidaus produkto (m./m.)	Gražos polovnis % = 0.0077 + 0.0159 * netikėtumas	7,70%	1	0,002	121
Realaus bendrojo vidaus produkto (katv./katv.)	Gražos polovnis % = 0.0086 + 0.0152 * netikėtumas	8,10%	1	0,002	121
Nedarbo lygis	Gražos polovnis % = -0.0014 - 0.0100 * netikėtumas	5,90%	1	0,004	141
Prekybos balanso (m./m.)	Gražos polovnis % = -0.0063 - 0.0246 * netikėtumas	2,80%	10	0,061	126
SEKTORINIAI RODIKLIAI					
Gamintojų kainų indekso (m./m.)	Gražos polovnis % = 0.0106 - 0.0234 * netikėtumas	1,70%	29	0,123	141
Gamintojų kainų indekso (mėn./mėn.)	Gražos polovnis % = 0.0090 - 0.0207 * netikėtumas	1,60%	29	0,141	141
Mažmeninių pardavimų indekso (m./m.)	Gražos polovnis % = 0.0108 - 0.0107 * netikėtumas	0,60%	11	0,347	141
Pramonės produkcijos (m./m.)	Gražos polovnis % = -0.0069 + 0.0218 * netikėtumas	6,00%	3	0,004	140
Pramonės produkcijos (mėn./mėn.)	Gražos polovnis % = -0.0071 - 0.0238 * netikėtumas	2,50%	13	0,063	140
RINKOS NUOTAIKŲ IR LŪKESČIŲ RODIKLIAI					
Pramonės pasitikėjimo indekso	Gražos polovnis % = 0.0067 - 0.0112 * netikėtumas	4,80%	1	0,009	141
Paslaugų pasitikėjimo indekso	Gražos polovnis % = 0.0060 - 0.0130 * netikėtumas	6,10%	1	0,003	141
Sudėtinių priėmimų vadovėlių indekso	Gražos polovnis % = 0.0143 - 0.0438 * netikėtumas	7,60%	45	0,121	34
Gamybos priėmimų vadovėlių indekso	Gražos polovnis % = -0.0048 - 0.0091 * netikėtumas	7,30%	1	0,122	34
Paslaugų priėmimų vadovėlių indekso	Gražos polovnis % = -0.0058 + 0.0118 * netikėtumas	5,90%	2	0,175	34
Ekonominių nuotaičių indekso	Gražos polovnis % = 0.0302 + 0.0378 * netikėtumas	6,10%	12	0,003	249
Verslo klimato laikus	Gražos polovnis % = 0.0064 + 0.0108 * netikėtumas	5,40%	1	0,005	141
Vartotojų pasitikėjimo indekso	Gražos polovnis % = 0.0081 - 0.0160 * netikėtumas	2,10%	3	0,023	141
"Sentix" investuotojų pasitikėjimo indekso	Gražos polovnis % = -0.0022 + 0.0042 * netikėtumas	1,80%	1	0,124	136
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI					
Vartotojų kainų indekso (m./m.)	Gražos polovnis % = -0.0057 - 0.0166 * netikėtumas	2,80%	3	0,049	140
Vartotojų kainų indekso (mėn./mėn.)	Gražos polovnis % = -0.0033 - 0.0072 * netikėtumas	0,90%	1	0,261	138
Preliminarūs duomenys vartotojų kainų indekso (m./m.)	Gražos polovnis % = -0.0075 - 0.0387 * netikėtumas	5,10%	21	0,007	141
Vartotojų kainų indekso išlaidų energija, maistas, alkoholis ir tabakas (m./m.)	Gražos polovnis % = -0.0055 - 0.0269 * netikėtumas	9,20%	2	0,000	217
PENGIŲ RINKOS RODIKLIAI					
Palūkanų normos	Gražos polovnis % = -0.0170 - 0.1383 * netikėtumas	20,70%	1	0,000	121
Pirnių pasiūlos (m./m.)	Gražos polovnis % = 0.0003 - 0.0127 * netikėtumas	0,90%	5	0,275	140

Šaltinis: sudaryta autoriaus.

Šie tradiciniai regresijos modeliai ekonominiu požiūriu gali būti aiškinami taip:

Kokios EURO STOXX 50 indekso gražos nurodytą minutę galima tikėtis atlikus pardavimo sandorį, kai ekonomistai teisingai arba neteisingai išprognozavo faktines makroekonominio rodiklio reikšmes.

R^2 (determinacijos koeficientas) reikšmė rodo, kiek procentų makroekonominio rodiklio netikėtumo rodiklis paaiškina EURO STOXX 50 gražą nurodytą minutę.

Lentelėje pateikta ta minutė, kurią buvo užfiksuota didžiausia R^2 reikšmė per 45 minutes. Atkreiptinas dėmesys, kad dauguma atvejų didžiausias R^2 buvo nustatytas pirmomis rodiklių realizacijos minutėmis, t. y. 65 % atvejų didžiausias R^2 buvo užfiksuotas per pirmas penkias minutes. Tai rodo, kad netikėtumo rodikliai akumuliuotas indekso grąžas pirmas minutes galima paaiškinti labiau, negu kad vėlesnes minutes, tad ir uždarbio galimybės yra didžiausios šiame laiko tarpe.

P-reikšmė rodo, ar nurodytas regresijos modelis yra statistiškai patikimas. Jei p-reikšmės įvertis yra mažesnis nei 0,05, tada laikoma, kad modelis yra statistiškai patikimas.

Iš pateiktos lentelės matoma, kad tik palūkanų normos rodiklis atitinka išsikelto kriterijus, t. y. > 20 %, p-reikšmė mažiau nei 0,05, o įvykius skaičius daugiau nei 20. Taigi į kitą tyrimo etapą papuola tik šis rodiklis.

50 lentelėje yra pateikti antrojo scenarijaus rezultatai:

Rodiklio pavadinimas	Regresijos modelis	R^2	R^2 minutėje	P-reikšmė	Įvykių kiekis
PAGRINDINIAI RODIKLIAI					
Bendrojo pasirinktinio kapitalo formavimo (kctv./kctv.)	Gražos pokytis % = 0.0272 - 0.0309 * netikėtumas	6.70%	3	0.191	17
Namu ūkiu vartojimo (kctv./kctv.)	Gražos pokytis % = 0.1594 - 0.0850 * netikėtumas	9.00%	8	0.321	23
Realaus bendrojo vidaus produkto (m./m.)	Gražos pokytis % = -0.0358 + 0.0451 * netikėtumas	39.00%	3	0.000	30
Realaus bendrojo vidaus produkto (kctv./kctv.)	Gražos pokytis % = 0.0051 + 0.0181 * netikėtumas	6.60%	3	0.275	20
Nedarbo lygis	Gražos pokytis % = 0.0226 - 0.0228 * netikėtumas	4.90%	1	0.229	31
Prekybos balanso (m./m.)	Gražos pokytis % = -0.0245 + 0.0415 * netikėtumas	6.00%	10	0.060	60
SEKTORINIAI RODIKLIAI					
Gamtintųjų kainų indekso (m./m.)	Gražos pokytis % = -0.0872 + 0.1111 * netikėtumas	8.00%	45	0.036	55
Gamtintųjų kainų indekso (mėn./mėn.)	Gražos pokytis % = -0.0290 + 0.0235 * netikėtumas	3.80%	3	0.205	44
Mažmeninių pardavimų indekso (m./m.)	Gražos pokytis % = 0.0482 - 0.0723 * netikėtumas	2.50%	45	0.215	63
Pramonės produkcijos (m./m.)	Gražos pokytis % = -0.1040 + 0.1745 * netikėtumas	24.70%	40	0.000	61
Pramonės produkcijos (mėn./mėn.)	Gražos pokytis % = -0.0949 - 0.1401 * netikėtumas	13.90%	43	0.004	59
RINKOS NUOŲ KAINŲ IR LŪKĖSČIŲ RODIKLIAI					
Pramonės pasitikejimo indekso	Gražos pokytis % = 0.1149 - 0.1104 * netikėtumas	4.20%	31	0.115	60
Paslaugų pasitikejimo indekso	Gražos pokytis % = -0.0208 - 0.0755 * netikėtumas	4.40%	12	0.080	70
Sudėtinių prekių vadovbininkų indekso	Gražos pokytis % = 0.0082 - 0.0427 * netikėtumas	6.30%	44	0.316	18
Gamtos prekių vadovbininkų indekso	Gražos pokytis % = -0.0552 - 0.0242 * netikėtumas	13.80%	5	0.291	10
Paslaugų prekių vadovbininkų indekso	Gražos pokytis % = -0.0170 + 0.0231 * netikėtumas	9.80%	2	0.193	19
Ekonominių nuotakių indekso	Gražos pokytis % = -0.0177 + 0.0592 * netikėtumas	8.70%	4	0.009	77
Verslo klimato laisvės	Gražos pokytis % = 0.0236 - 0.0103 * netikėtumas	2.20%	1	0.231	66
Vartotojų pasitikejimo indekso	Gražos pokytis % = -0.0474 + 0.0356 * netikėtumas	8.30%	3	0.014	72
"Sentis" imensuotojų pasitikejimo indekso	Gražos pokytis % = 0.0433 - 0.0484 * netikėtumas	3.50%	22	0.139	63
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI					
Vartotojų kainų indekso (m./m.)	Gražos pokytis % = -0.4713 + 0.2457 * netikėtumas	24.70%	1	0.120	11
Vartotojų kainų indekso (mėn./mėn.)	Gražos pokytis % = 0.6458 - 0.4491 * netikėtumas	26.90%	4	0.040	16
Preliminaru duomenų vartotojų kainų indekso (m./m.)	Gražos pokytis % = 0.2337 - 0.1779 * netikėtumas	41.30%	38	0.000	39
Vartotojų kainų indekso išlysus energija, maistą, alkoholi ir tabaką (m./m.)	Gražos pokytis % = -0.1383 + 0.0952 * netikėtumas	4,60%	10	0,147	47
PINIGŲ RINKOS RODIKLIAI					
Palūkanų normos	Gražos pokytis % = 0.1238 - 0.0959 * netikėtumas	96.60%	34	0.118	3
Pinigų pasiūlos (m./m.)	Gražos pokytis % = -0.0355 + 0.0543 * netikėtumas	1.90%	16	0.294	61

Lentelė tęsiasi 121 psl.

Lentelė atkelta iš 121 psl.

PINIGŲ RINKOS RODIKLIAI					
Pašikamų normos	Gražos polvisis % = 0.1238 - 0.0959 * netikėtumas	96,60%	34	0,118	3
Pirau pasitūios (m./m.)	Gražos polvisis % = -0.0355 - 0.0543 * netikėtumas	1,90%	16	0,294	61

Šaltinis: sudaryta autoriaus.

Šie regresijos modeliai ekonominiu požiūriu gali būti aiškinami taip:

Kokios EURO STOXX 50 indekso gražos nurodytą minutę galima tikėtis, atlikus pardavimo sandorį, kai realizacijos metu pateikti rodiklių įverčiai viršijo (gesrni nei tikėtasi) ekonomistų prognozes (negalioja nedarbo lygio rodiklio atveju).

Atkreiptinas dėmesys, kad beveik puse atvejų didžiausias R^2 buvo nustatytas pirmomis realizacijos minutėmis, t. y. 46 % atvejų didžiausias R^2 buvo užfiksuotas per pirmas penkias minutes. Tai rodo, kad netikėtumo rodikliais akumuliuotas indekso gražas pirmomis minutėmis galima paaiškinti labiau, negu kad vėlesnėmis minutėmis, tad ir uždarblio galimybės yra didžiausios šiuo laiko tarpu.

Didžiausią R^2 , kuris tenkina išsikeltą kriterijų, turi VKI (m./m.), VKI (mėn./ mėn.), preliminarų duomenų VKI (m/m), palūkanų normos, pramonės produkcijos (m./m.), RBVP (m./m.) rodikliai. Tačiau jei žiūrėsime į kitus išsikeltus kriterijus, tai VKI (m./m.), VKI (mėn./mėn.) ir palūkanų normos rodikliai netenkinta p-reikšmės ir įvykių kiekio reikalavimų. Taigi į kitą tyrimo etapą papuola preliminarų duomenų VKI (m./m.), pramonės produkcijos (m./m.) ir RBVP (m./m.) rodikliai.

51 lentelėje yra pateikti trečiojo scenarijaus rezultatai:

51 lentelė. EURO STOXX 50 gražų modeliai pagal makroekonominių netikėtumų rodiklių netikėtumus, kai netikėtumo rodiklio reikšmės ≥ 0

Rodiklio pavadinimas	Regresijos modelis	R^2	R^2 minutėje	P-reikšmė	Įvykių kiekis
PAGRINDINIAI RODIKLIAI					
Bendrojo pagrindinio kapitalo formavimo (katv./katv.)	Gražos polvisis % = 0.0275 - 0.0312 * netikėtumas	8,30%	3	0,097	34
Namų ūkių vartojimo (katv./katv.)	Gražos polvisis % = -0.0005 - 0.1028 * netikėtumas	5,40%	21	0,186	34
Realaus bendrojo vidaus produkto (m./m.)	Gražos polvisis % = 0.0004 - 0.0245 * netikėtumas	6,50%	3	0,017	88
Realaus bendrojo vidaus produkto (katv./katv.)	Gražos polvisis % = 0.0078 - 0.0172 * netikėtumas	5,10%	1	0,024	99
Nedarbo lygis	Gražos polvisis % = -0.0020 - 0.0413 * netikėtumas	3,10%	9	0,081	100
Prekybos balanso (m./m.)	Gražos polvisis % = -0.0216 - 0.0194 * netikėtumas	7,00%	1	0,031	66
SEKTORINIAI RODIKLIAI					
Gamtinių išimčių indeksas (m./m.)	Gražos polvisis % = -0.0805 - 0.1063 * netikėtumas	8,50%	45	0,006	87
Gamtinių išimčių indeksas (mėn./mėn.)	Gražos polvisis % = -0.0594 - 0.0749 * netikėtumas	6,50%	34	0,021	82
Mažmeninių pardavimo indeksas (m./m.)	Gražos polvisis % = 0.0799 - 0.1051 * netikėtumas	5,20%	45	0,059	69
Pramonės produkcijos (m./m.)	Gražos polvisis % = -0.0876 - 0.1705 * netikėtumas	21,80%	42	0,000	70
Pramonės produkcijos (mėn./mėn.)	Gražos polvisis % = -0.0641 - 0.1159 * netikėtumas	10,10%	43	0,008	69
RINKOS NUOTAIKŲ IR LŪKESČIŲ RODIKLIAI					
Pramonės pasitūioimo indeksas	Gražos polvisis % = 0.0657 - 0.0632 * netikėtumas	2,50%	28	0,170	77
Paslaugų pasitūioimo indeksas	Gražos polvisis % = -0.0010 - 0.0544 * netikėtumas	2,80%	12	0,144	79
Sudėtinis pirikamų vadybinikų indeksas	Gražos polvisis % = -0.0168 - 0.0283 * netikėtumas	3,50%	44	0,369	25

Lentelės tęsinys 123 psl.

Lentelė atkelta iš 122 psl.

Gamybos pirkimų vadovėtininko indeksas	Gražos pokytis % = 0.0377 - 0.0562 * netikėtumas	7,70%	25	0,189	24
Paslaugų pirkimų vadovėtininko indeksas	Gražos pokytis % = -0.0102 + 0.0177 * netikėtumas	7,30%	2	0,012	23
Ekonominių moutaičių indeksas	Gražos pokytis % = -0.0230 + 0.0648 * netikėtumas	11,00%	4	0,002	83
Verslo klimato laikas	Gražos pokytis % = 0.0412 - 0.0199 * netikėtumas	3,90%	2	0,109	67
Vartotojų pasitikėjimo indeksas	Gražos pokytis % = 0.0190 - 0.0172 * netikėtumas	0,60%	9	0,291	175
"Sentis" investuotojų pasitikėjimo indeksas	Gražos pokytis % = 0.0433 - 0.0484 * netikėtumas	3,50%	22	0,139	63
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI					
Vartotojų kainų indeksas (m./m.)	Gražos pokytis % = -0.0008 - 0.0196 * netikėtumas	3,60%	1	0,034	125
Vartotojų kainų indeksas (mėn./mėn.)	Gražos pokytis % = -0.0144 + 0.0361 * netikėtumas	2,10%	7	0,109	121
Preliminarų duomenų vartotojų kainų indeksas (m./m.)	Gražos pokytis % = 0.0128 - 0.0637 * netikėtumas	9,00%	17	0,003	93
Vartotojų kainų indeksas išskyrus energiją, maistą, alkoholi ir tabaką (m./m.)	Gražos pokytis % = -0.0023 - 0.0106 * netikėtumas	1,30%	1	0,152	162
PINIGŲ RINKOS RODIKLIAI					
Palikimų normos	Gražos pokytis % = -0.0359 - 0.1394 * netikėtumas	4,50%	16	0,022	116
Pirinių pasiūlos (m./m.)	Gražos pokytis % = -0.0376 + 0.0562 * netikėtumas	2,30%	16	0,190	77

Šaltinis: sudaryta autoriaus.

Šie regresijos modeliai ekonominiu požiūriu gali būti aiškinami taip:

Kokios EURO STOXX 50 indekso gražos nurodytą minutę galima tikėtis, atlikus pardavimo sandorį, kai realizacijos metu pateikti makroekonominių rodiklių įverčiai viršijo (geresni nei tikėtasi) ir atitiko ekonomistų prognozes (negalioja nedarbo lygio rodiklio atveju).

Atkreiptina, jog 46 % sudarytų modelių didžiausias R^2 buvo nustatytas pirmomis 10 realizacijos minučių, tai rodo, kad netikėtumo rodikliais akumuliuotas indekso gražas pirmomis minutėmis galima paaiškinti labiau, negu kad vėlesnėmis minutėmis, tad ir uždarbui galimybės yra didžiausios šiuo laiko tarpu.

Iš pateiktos lentelės matoma, kad tik pramonės produkcijos (m./m.) rodiklis atitinka išsiskirtus tyrimo kriterijus, taigi į kitą tyrimo etapą papuola tik šis rodiklis.

52 lentelėje yra pateikti ketvirtojo scenarijaus rezultatai:

52 lentelė. EURO STOXX 50 gražų modeliai pagal makroekonominių netikėtumų rodiklių netikėtumus kai netikėtumo rodiklio reikšmės < 0

Rodiklio pavadinimas	Regresijos modelis	R^2	R^2 minutėje	P-reikšmė	Įvykių kiekis
PAGRINDINIAI RODIKLIAI					
Bendrojo pagrindinio kapitalo formavimo (ketv./ketv.)	Gražos pokytis % = -0.0426 - 0.0779 * netikėtumas	11,50%	11	0,114	23
Narų vėjų vartojimo (ketv./ketv.)	Gražos pokytis % = -0.0655 - 0.0637 * netikėtumas	11,00%	12	0,113	24
Realaus bendrojo vidaus produkto (m./m.)	Gražos pokytis % = -0.0381 - 0.0577 * netikėtumas	9,60%	7	0,080	33
Realaus bendrojo vidaus produkto (ketv./ketv.)	Gražos pokytis % = -0.0089 - 0.0270 * netikėtumas	5,50%	7	0,292	22
Nedarbo lygis	Gražos pokytis % = -0.0172 - 0.0216 * netikėtumas	9,70%	1	0,047	41
Prelimbos balanso (m./m.)	Gražos pokytis % = 0.0259 - 0.0383 * netikėtumas	4,80%	4	0,093	60
SEKTORINIAI RODIKLIAI					
Gamtinių jėgų indeksas (m./m.)	Gražos pokytis % = -0.0119 - 0.0098 * netikėtumas	4,80%	2	0,116	53
Gamtinių jėgų indeksas (mėn./mėn.)	Gražos pokytis % = -0.0290 - 0.0580 * netikėtumas	8,50%	43	0,026	58
Mažmeninių pardavimo indeksas (m./m.)	Gražos pokytis % = -0.0067 - 0.0086 * netikėtumas	0,30%	6	0,634	71
Pramonės produkcijos (m./m.)	Gražos pokytis % = 0.0395 - 0.0658 * netikėtumas	7,00%	20	0,026	70

Lentelės tęsinys 124 psl.

Lentelė atkelta iš 123 psl.

Pramonės produkcijos (m./m.)	Gražos pokytis % = 0.0395 - 0.0658 * netikėtumas	7.00%	20	0.026	70
Pramonės produkcijos (mėn./mėn.)	Gražos pokytis % = 0.0514 - 0.0454 * netikėtumas	1.60%	31	0.288	71
RINKOS NUOT AIKU IR LŪKESČŲ RODIKLIAI					
Pramonės pasitikejimo indeksas	Gražos pokytis % = 0.0051 + 0.0113 * netikėtumas	2.20%	1	0.243	64
Paslaugų pasitikejimo indeksas	Gražos pokytis % = 0.0123 + 0.0207 * netikėtumas	8.40%	1	0.022	62
Sudėtinis priėmimų vadovėtininkų indeksas	Gražos pokytis % = 0.0422 - 0.0754 * netikėtumas	66.20%	5	0.014	8
Gamybos priėmimų vadovėtininkų indeksas	Gražos pokytis % = -0.0477 - 0.0613 * netikėtumas	14.90%	19	0.271	10
Paslaugų priėmimų vadovėtininkų indeksas	Gražos pokytis % = -0.0830 - 0.1097 * netikėtumas	9.40%	15	0.390	10
Ekonominių nuotikių indeksas	Gražos pokytis % = 0.0323 - 0.0380 * netikėtumas	8.60%	7	0.024	59
Verslo klimato kaitos	Gražos pokytis % = 0.0117 + 0.0211 * netikėtumas	8.60%	1	0.011	74
Vartotojų pasitikejimo indeksas	Gražos pokytis % = -0.0091 - 0.0389 * netikėtumas	6.20%	3	0.033	74
"Sentis" investuotojų pasitikejimo indeksas	Gražos pokytis % = -0.0083 - 0.0068 * netikėtumas	1.20%	2	0.356	73
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI					
Vartotojų kainų indeksas (m./m.)	Gražos pokytis % = 0.1979 + 0.1072 * netikėtumas	5.80%	1	0.386	15
Vartotojų kainų indeksas (mėn./mėn.)	Gražos pokytis % = 0.2308 + 0.1598 * netikėtumas	11.10%	1	0.191	17
Preliminarūs duomenys vartotojų kainų indeksas (m./m.)	Gražos pokytis % = -0.0357 - 0.0308 * netikėtumas	4.50%	3	0.148	48
Vartotojų kainų indeksas išskyrus energiją, maistą, alkoholį ir tabaką (m./m.)	Gražos pokytis % = -0.1592 - 0.1532 * netikėtumas	27.60%	14	0.000	55
PINIGŲ RINKOS RODIKLIAI					
Palikarų normos	Gražos pokytis % = 1.9586 + 0.5022 * netikėtumas	24.00%	18	0.402	5
Pirčių pasiūlos (m./m.)	Gražos pokytis % = 0.0969 - 0.0968 * netikėtumas	7.40%	13	0.032	62

Šaltinis: sudaryta autoriaus.

Šie regresijos modeliai ekonominiu požiūriu gali būti aiškinami taip:

Kokios EURO STOXX 50 indekso gražos nurodytą minutę galima tikėtis, atlikus pardavimo sandorį, kai realizacijos metu pateikti rodiklių įverčiai nepateisino (blogesni nei tikėtasi) ekonomistų prognozių (negalioja nedarbo lygio rodiklio atveju).

Atkreiptinas dėmesys, kad 62 % sudarytų modelių didžiausias R^2 buvo nustatytas per pirmas 10 realizacijos minučių, tai rodo, kad netikėtumo rodikliais akumuliuotas indekso gražas pirmomis minutėmis galima paaiškinti labiau, negu kad vėlesnėmis minutėmis, tad ir uždarbui galimybės yra didžiausios šiuo laiko tarpu.

Iš pateiktos lentelės matoma, kad tik VKI, išskyrus energiją, maistą, alkoholį ir tabaką, rodiklis atitinka išsiktus tyrimo kriterijus, taigi į kitą tyrimo etapą papuola tik šis rodiklis.

53 lentelėje yra pateikti penktojo scenarijaus rezultatai:

53 lentelė. EURO STOXX 50 gražų modeliai pagal makroekonominių netikėtumų

Rodiklio pavadinimas	Regresijos modelis	R^2	R^2 nūnūteje	P-reikšmė	Įvykių kiekis
PAGRINDINIAI RODIKLIAI					
Bendrojo pagrindinio kapitalo formavimo (ketv./ketv.)	Gražos pokytis % = -0.0365 - 0.1020 * netikėtumas	11.20%	23	0.071	30
Namų ūkių vartavimo (ketv./ketv.)	Gražos pokytis % = 0.0015 - 0.0173 * netikėtumas	6.10%	1	0.101	45
Realus bendrojo vidaus produkto (m./m.)	Gražos pokytis % = -0.0185 - 0.0457 * netikėtumas	6.90%	7	0.012	91
Realus bendrojo vidaus produkto (ketv./ketv.)	Gražos pokytis % = 0.0071 + 0.0134 * netikėtumas	3.80%	1	0.050	101
Nedarbo lygis	Gražos pokytis % = -0.0054 - 0.0142 * netikėtumas	7.50%	1	0.004	110
Prekybos balanso (m./m.)	Gražos pokytis % = 0.0094 + 0.0253 * netikėtumas	2.20%	4	0.237	66
SEKTORINIAI RODIKLIAI					
Gamintojų kainų indeksas (m./m.)	Gražos pokytis % = -0.0334 - 0.0619 * netikėtumas	8.20%	43	0.008	85
Gamintojų kainų indeksas (mėn./mėn.)	Gražos pokytis % = -0.0489 - 0.0657 * netikėtumas	10.00%	43	0.002	96
Mažmeninių pardavimų indeksas (m./m.)	Gražos pokytis % = -0.0004 + 0.0060 * netikėtumas	1.40%	1	0.311	77
Pramonės produkcijos (m./m.)	Gražos pokytis % = 0.0204 - 0.0531 * netikėtumas	4.60%	20	0.059	79
Pramonės produkcijos (mėn./mėn.)	Gražos pokytis % = 0.0363 - 0.0357 * netikėtumas	1.10%	31	0.354	81

Lentelės tęsinys 125 psl.

Lentelė atkelta iš 124 psl.

RINKOS NUOTAIKŲ IR LŪKESČIŲ RODIKLIAI						
Pramonės pasitikoimo indeksas	Gražios pokytis % = 0.0129 - 0.0174 * netikėtumas	5,80%	1	0,031	81	
Paslaugų pasitikoimo indeksas	Gražios pokytis % = 0.0126 - 0.0209 * netikėtumas	9,20%	1	0,010	71	
Sudėtinis pramonės vadovbininku indeksas	Gražios pokytis % = -0.0495 - 0.1772 * netikėtumas	21,60%	43	0,081	15	
Gamybos priemonių vadovbininku indeksas	Gražios pokytis % = 0.0341 - 0.0390 * netikėtumas	11,40%	5	0,107	24	
Paslaugų priemonių vadovbininku indeksas	Gražios pokytis % = 0.0018 + 0.0962 * netikėtumas	16,10%	10	0,156	14	
Ekonominių nuotaičių indeksas	Gražios pokytis % = 0.0252 - 0.0339 * netikėtumas	7,20%	7	0,033	64	
Verslo klimato kainos	Gražios pokytis % = 0.0147 - 0.0235 * netikėtumas	10,10%	1	0,006	75	
Vartotojų pasitikoimo indeksas	Gražios pokytis % = 0.008 - 0.0282 * netikėtumas	3,80%	3	0,010	177	
"Sentix" investuotojų pasitikoimo indeksas	Gražios pokytis % = -0.0083 - 0.0068 * netikėtumas	1,20%	2	0,356	73	
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI						
Vartotojų kainų indeksas (m./m.)	Gražios pokytis % = -0.0241 - 0.0388 * netikėtumas	2,00%	11	0,107	129	
Vartotojų kainų indeksas (mėn./mėn.)	Gražios pokytis % = -0.0179 - 0.0208 * netikėtumas	1,50%	4	0,181	122	
Preliminari duomenų vartotojų kainų indeksas (m./m.)	Gražios pokytis % = -0.0272 - 0.0257 * netikėtumas	4,30%	3	0,037	102	
Vartotojų kainų indeksas išskyrus energiją, maistą, alkoholi ir tabaką (m./m.)	Gražios pokytis % = -0.0148 - 0.0404 * netikėtumas	13,60%	2	0,000	170	

Šaltinis: sudaryta autoriaus.

Šie regresijos modeliai ekonominiu požiūriu gali būti aiškinami taip:

Kokios EURO STOXX 50 indekso gražios nurodytą minutę galima tikėtis atlikus pardavimo sandorį, kai realizacijos metu pateikti rodiklių įverčiai nepateisino (blogesni nei tikėtasi) ir atitiko ekonomistų prognozes (negalioja nedarbo lygio rodiklio atveju).

Atkreiptinas dėmesys, kad 35 % visų modelių didžiausias R^2 buvo užfiksuotas praktiškai nedelsiant po rodiklio realizavimo, t. y. pirmąją minutę, tad ir uždarbio galimybės čia yra didžiausios.

Iš pateiktos lentelės matoma, kad tik palūkanų normos rodiklis atitinka išsikelto tyrimo kriterijus, taigi į kitą tyrimo etapą papuola tik šis rodiklis.

Apibendrinant pirmojo etapo pirmųjų keturių žingsnių rezultatus, buvo sukurta 54 lentelė, kurioje nurodyti visi rodikliai ir jų scenarijai, kurie tenkina pirmojo etapo ketvirtojo žingsnio kriterijus ir su kuriais bus tęsiamas tyrimas. Su šiais rodikliais pirmajame etape, penktajame žingsnyje, bus tikrinamos regresijos analizės prielaidos.

54 lentelė. Atrinkti modeliai I tyrimo etapo penktajam žingsniui

Ekonominis rodiklis	Regresijos modelis	R^2	R^2 minutėje	Pretikimė	Įvykių kiekis	Scenarijai
PAGRINDINIAI RODIKLIAI						
RBVP (m./m.)	Gražios pokytis % = -0.0358 - 0.0451 * netikėtumas	39,00%	3	0,00	30	>0
SEKTORINIAI RODIKLIAI						
Pramonės produkcijos (m./m.)	Gražios pokytis % = -0.1040 + 0.1745 * netikėtumas	24,70%	40	0,00	61	>0
Pramonės produkcijos (m./m.)	Gražios pokytis % = -0.0876 - 0.1705 * netikėtumas	21,80%	42	0,00	70	>=0
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI						
Preliminari duomenų vartotojų kainų indeksas (m./m.)	Gražios pokytis % = 0.2337 - 0.1779 * netikėtumas	41,30%	38	0,00	39	>0
Vartotojų kainų indeksas išskyrus energiją, maistą, alkoholi ir tabaką (m./m.)	Gražios pokytis % = -0.1592 - 0.1532 * netikėtumas	27,60%	14	0,00	55	<0
PINIGŲ RINKOS RODIKLIAI						
Palūkanų normos	Gražios pokytis % = -0.0170 - 0.1383 * netikėtumas	20,70%	1	0,00	121	visi
Palūkanų normos	Gražios pokytis % = -0.0271 - 0.1935 * netikėtumas	26,30%	1	0,00	118	<=0

Šaltinis: sudaryta autoriaus.

Atkreiptinas dėmesys, kad iš penkių makroekonominių rodiklių kategorijų į tolimesnio tyrimo I etapo žingsnį papuola keturių kategorijų rodikliai. Rinkos nuotaikų ir lūkesčių kategorijos rodiklių tarp jų nėra.

3.3.2 Sukurtų regresijos modelių prielaidų tikrinimas

Šiame skyriuje yra tikrinamos sukurtų regresijos modelių prielaidos. Pirmasis modelis, kurio regresijos analizės prielaidos bus tiriamos, yra RBVP (m./m.) rodiklis (žr. 55 lent.).

55 lentelė. RBVP (m./m.) rodiklio regresijos modelio prielaidų tikrinimas, esant > 0 scenarijui

Regresijos modelio prielaidos	Prielaidų rezultatai
Ar priklausomas kintamasis yra normaliai pasiskirstęs?	Taip Šapiro-Vilko p-reikšmė yra 0,12
Ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (autokoreliacijos problema)?	Ne Durbino-Watsono reikšmė yra 2,377
Ar tarp regresorių nėra multikolinearumo?	Neaktuali
Ar duomenyse yra išskirčių?	Ne Visos Kuko mato reikšmės neviršija 1
Ar duomenys yra homoskedastiški?	Ne Breušo-Pagano p-reikšmė yra 0,01

Šaltinis: sudaryta autoriaus.

Pirmajai prielaidai patikrinti buvo pasirinktas Šapiro-Vilko testo skaičiavimas. Jei testo p-reikšmė \geq už 0,05, tai sakoma, kad standartizuotos paklaidos yra normalios ir priklausomas kintamasis yra normaliai pasiskirstęs. Antrajai prielaidai patikrinti buvo pasirinkta Durbino-Vatsono statistika. Jeigu Durbino-Vatsono statistikos reikšmė yra tarp 1,5 ir 2,5, tai paprastai reiškia autokoreliacijos nebuvimą. Trečioji prielaida šiame tyrimo etape yra neaktuali, kadangi yra tik vienas regresorius. Ketvirtajai prielaidai patikrinti yra naudojamas Kuko matas. Jeigu bent vieno Kuko mato n reikšmė viršija 1, tai sakoma, kad duomenyse yra išskirčių. Penktajai prielaidai patikrinti yra skaičiuojamas Breušo-Pagano testas. Jei testo p-reikšmė \geq 0,05, tai duomenys yra homoskedastiški (nėra heteroskedastiškumo).

Taigi minėtas modelis neatitinka pirmosios prielaidos – EURO STOXX 50 in-

dekso grąų reikšmės nėra normaliai pasiskirsčiusios. Tokiu atveju galima teigti, kad sudarytas modelis nėra statistiškai patikimas prognozuoti EURO STOXX 50 indekso grąų.

Antrasis modelis, kurio regresijos analizės prielaidos yra tiriamos, yra pramonės produkcijos (m./m.) rodiklis (žr. 56 lent.).

56 lentelė. Pramonės produkcijos (m./m.) rodiklio regresijos modelio prielaidų tikrinimas, esant > 0 scenarijui

Regresijos modelio prielaidos	Prielaidų rezultatai
Ar priklausomas kintamasis yra normaliai pasiskirstęs?	Taip Šapiro-Vilko p-reikšmė yra 0,63
Ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (autokoreliacijos problema)?	Ne Durbino-Watsono reikšmė yra 1,979
Ar tarp regresorių nėra multikolinearumo?	Neaktuali
Ar duomenyse yra išskirčių?	Ne Visos Kuko mato reikšmės neviršija 1
Ar duomenys yra homoskedastiški?	Taip Breušo – Pagano p-reikšmė yra 0,30

Šaltinis: sudaryta autoriaus.

Minėtas modelis atitinka visas regresijos analizei keliamas prielaidas, todėl galima teigti, kad sudarytas modelis yra statistiškai patikimas prognozuoti EURO STOXX 50 indekso grąų.

Trečiasis modelis, kurio regresijos analizės prielaidos yra tiriamos, tas pats pramonės produkcijos (m./m.) rodiklis, tačiau su kitu netikėtumo rodiklio scenarijumi (žr. 57 lent.).

57 lentelė. Pramonės produkcijos (m./m.) rodiklio regresijos modelio prielaidų tikrinimas, esant ≥ 0 scenarijui

Regresijos modelio prielaidos	Prielaidų rezultatai
Ar priklausomas kintamasis yra normaliai pasiskirstęs?	Taip Šapiro-Vilko p-reikšmė yra 0,64
Ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (autokoreliacijos problema)?	Ne Durbino-Watsono reikšmė yra 1,866

Lentelės tęsinys 128 psl.

Lentelė atkelta iš 127 psl.

Ar tarp regresorių nėra multikolinearumo?	Neaktualu
Ar duomenyse yra išskirčių?	Ne Visos Kuko mato reikšmės neviršija 1
Ar duomenys yra homoskedastiški?	Taip Breušo-Pagano p-reikšmė yra 0,14

Šaltinis: sudaryta autoriaus.

Taigi minėtas modelis atitinka visas regresijos analizei keliamas prielaidas, todėl galima teigti, kad sudarytas modelis yra statistiškai patikimas prognozuoti EURO STOXX 50 indekso grąžą.

Ketvirtasis modelis, kurio regresijos analizės prielaidos yra tiriamos, yra preliminarių duomenų vartotojų kainų indekso (m./m.) rodiklis (žr. 58 lent.).

58 lentelė. Preliminarių duomenų vartotojų kainų indekso (m./m.) rodiklio regresijos modelio prielaidų tikrinimas, esant ≥ 0 scenarijui

Regresijos modelio prielaidos	Prielaidų rezultatai
Ar priklausomas kintamasis yra normaliai pasiskirstęs?	Taip Šapiro-Vilko p-reikšmė yra 0,67
Ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (autokoreliacijos problema)?	Ne Durbino-Watsono reikšmė yra 1,837
Ar tarp regresorių nėra multikolinearumo?	Neaktualu
Ar duomenyse yra išskirčių?	Taip Viena kuko reikšmė viršija 1
Ar duomenys yra homoskedastiški?	Ne Breušo-Pagano p-reikšmė yra 0,02

Šaltinis: sudaryta autoriaus.

Kaip matoma iš lentelės, modelis neatitinka ketvirtosios prielaidos – duomenyse yra išskirčių, ir penktosios prielaidos – duomenys nėra homoskedastiški. Tokiu atveju galima teigti, kad sudarytas modelis nėra statistiškai patikimas prognozuoti EURO STOXX 50 indekso grąžą.

Penktasis modelis, kurio regresijos analizės prielaidos yra tiriamos, yra vartotojų kainų indekso (m./m.), išskyrus energiją, maistą, alkoholį ir tabaką, rodiklis (žr. 59 lent.).

59 lentelė. Vartotojų kainų indekso (m./m.), išskyrus energiją, maistą, alkoholį ir tabaką, rodiklio regresijos modelio prielaidų tikrinimas, esant >0 scenarijui

Regresijos modelio prielaidos	Prielaidų rezultatai
Ar priklausomas kintamasis yra normaliai pasiskirstęs?	Ne Šapiro-Vilko p-reikšmė yra 0,01
Ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (autokoreliacijos problema)?	Ne Durbino-Watsono reikšmė yra 1,639
Ar tarp regresorių nėra multikolinearumo?	Neaktualu
Ar duomenyse yra išskirčių?	Ne Visos Kuko mato reikšmės neviršija 1
Ar duomenys yra homoskedastiški?	Taip Breušo-Pagano p-reikšmė yra 0,77

Šaltinis: sudaryta autoriaus.

Lentelė rodo, kad minėtas modelis neatitinka pirmosios prielaidos – EURO STOXX 50 indekso grąžų reikšmės nėra normaliai pasiskirsčiusios. Tokiu atveju galima teigti, kad sudarytas modelis nėra statistiškai patikimas prognozuoti EURO STOXX 50 indekso grąžą.

Šeštasis modelis, kurio regresijos analizės prielaidos yra tiriamos, yra palūkanų normos rodiklis (žr. 60 lent.).

60 lentelė. Palūkanų normos rodiklio regresijos modelio prielaidų tikrinimas, esant visiems netikėtumo rodiklio scenarijams

Regresijos modelio prielaidos	Prielaidų rezultatai
Ar priklausomas kintamasis yra normaliai pasiskirstęs?	Ne Šapiro-Vilko p-reikšmė yra 0,00
Ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (autokoreliacijos problema)?	Ne Durbino-Watsono reikšmė yra 1,716
Ar tarp regresorių nėra multikolinearumo?	Neaktualu
Ar duomenyse yra išskirčių?	Taip Kelios Kuko mato reikšmės viršija 1
Ar duomenys yra homoskedastiški?	Taip Breušo-Pagano p-reikšmė yra 0,86

Šaltinis: sudaryta autoriaus.

Taigi minėtas modelis neatitinka pirmosios prielaidos – EURO STOXX 50 indekso gražų reikšmės nėra normaliai pasiskirsčiusios, ir ketvirtosios prielaidos – duomenyse yra išskirčių. Tokiu atveju galima teigti, kad sudarytas modelis nėra statistiškai patikimas prognozuoti EURO STOXX 50 indekso gražą.

Septintasis modelis, kurio regresijos analizės prielaidos yra tiriamos, yra tas pats palūkanų normos rodiklis, tačiau esant kitam scenarijui (žr. 61 lent.).

61 lentelė. Palūkanų normos rodiklio regresijos modelio prielaidų tikrinimas, esant ≤ 0 scenarijui

Regresijos modelio prielaidos	Prielaidų rezultatai
Ar priklausomas kintamasis yra normaliai pasiskirstęs?	Ne Šapiro-Vilko p-reikšmė yra 0,00
Ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (autokoreliacijos problema)?	Ne Durbino-Watsono reikšmė yra 1,610
Ar tarp regresorių nėra multikolinearumo?	Neaktualu
Ar duomenyse yra išskirčių?	Taip Kelios Kuko mato reikšmės viršija 1
Ar duomenys yra homoskedastiški?	Taip Breušo-Pagano p-reikšmė yra 0,054

Šaltinis: sudaryta autoriaus.

Minėtas modelis neatitinka pirmosios prielaidos – EURO STOXX 50 indekso gražų reikšmės nėra normaliai pasiskirsčiusios, ir ketvirtosios prielaidos – duomenyse yra išskirčių. Tokiu atveju galima teigti, kad sudarytas modelis nėra statistiškai patikimas prognozuoti EURO STOXX 50 indekso gražą.

Apibendrinant modelių rezultatus buvo sukurta 62 lentelė, kurioje nurodyti, kokie rodikliai kokias prielaidas tenkina ir kokių netenkina.

62 lentelė. Regresijos modelių prielaidų tenkinimo apžvalga

Ekonominis rodiklis	R ²	R ² minutėje	P- reikšmė	Įvykių kiekis	Scenarijai	Regresijos analizės prielaidos				
						1	2	3	4	5
PAGRINDINIAI RODIKLIAI										
RBVP (m.m.)	39,00%	3	0,00	30	>0					
SEKTORINIAI RODIKLIAI										
Pramonės produkcijos (m./m.)	24,70%	40	0,00	61	>0					
Pramonės produkcijos (m./m.)	21,80%	42	0,00	70	>=0					
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI										
Preliminarų duomenų vartotojų kainų indekso (m./m.)	41,30%	38	0,00	39	>0					
Vartotojų kainų indekso išskyrus energiją, maistą, alkoholią ir tabaką (m./m.)	27,60%	14	0,00	55	<0					
PINIGŲ RINKOS RODIKLIAI										
Palikamų normos	20,70%	1	0,00	121	vši					
Palikamų normos	26,30%	1	0,00	118	<=0					

Balta spalva – modelis atitiko prielaidą.

Pilka spalva – modelis netenkinio prielaidos.

1-oji prielaida – Ar priklausomas kintamasis yra normaliai pasiskirstęs?

2-oji prielaida – Ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (autokoreliacijos problema)?

3-oji prielaida – Ar tarp regresorių nėra multikolinearumo?

4-oji prielaida – Ar duomenyse yra išskirčių?

5-oji prielaida – Ar duomenys yra homoskedastiški?

Šaltinis: sudaryta autoriaus.

Taigi, iš likusių 7 regresijos modelių po pirmojo etapo 4 žingsnio, kurie penktajame žingsnyje buvo tikrinami, ar yra statistiškai patikimi ir tinkami regresijos analizei, pasiteisino tik 2 modeliai. Tokiu atveju su tais modeliais, kurie netenkinio regresijos analizės prielaidų, yra kuriami nauji modeliai pagal antrą, trečią, ketvirtą, penktą ir t. t. aukščiausiąją determinacijos reikšmę, tikrinama, ar jie atitinka pirmojo etapo prielaidas (žr. 63 lent.).

63 lentelė. Modelių su mažesnėmis determinacijos reikšmėmis sudarymo apžvalga

Ekonominis rodiklis	Regresijos modelis	R ²	R ² minutėje	P-reikšmė	Įvykių kiekis	Scenarijai
PAGRINDINIAI RODIKLIAI						
RBVP (m.m.)	Gražos pokytis % = - 0.0358 + 0.0451 * netikėtumas	39,00%	3	0,00	30	>0
RBVP (m.m.)	Gražos pokytis % = - 0.0403 + 0.0412 * netikėtumas	23,70%	4	0,01	30	>0
SEKTORINIAI RODIKLIAI						
Pramonės produkcijos (m./m.)	Gražos pokytis % = - 0.1040 + 0.1745 * netikėtumas	24,70%	40	0,00	61	>0
Pramonės produkcijos (m./m.)	Gražos pokytis % = - 0.0876 + 0.1705 * netikėtumas	21,80%	42	0,00	70	>=0
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI						
Preliminarų duomenų vartotojų kainų indekso (m./m.)	Gražos pokytis % = 0.2337 - 0.1779 * netikėtumas	41,30%	38	0,00	39	>0

Lentelės tęsinys 132 psl.

Lentelė atkelta iš 131 psl.

Preliminarių duomenų vartotojų kainų indekso (m./m.)	Gražos pokytis % = 0.1869 - 0.1408 * netikėtumas	32,20%	36	0,00	39 >0
Vartotojų kainų indekso išskyrus energiją, maistą, alkoholį ir tabaką (m./m.)	Gražos pokytis % = - 0.1592 - 0.1532 * netikėtumas	27,60%	14	0,00	55 <0
Vartotojų kainų indekso išskyrus energiją, maistą, alkoholį ir tabaką (m./m.)	Gražos pokytis % = - 0.1009 - 0.1165 * netikėtumas	26,90%	10	0,00	55 <0
PINIGŲ RINKOS RODIKLIAI					
Palūkanų normos	Gražos pokytis % = - 0.0170 - 0.1383 * netikėtumas	20,70%	1	0,00	121 visi
Palūkanų normos	Gražos pokytis % = - 0.0060 - 0.1210 * netikėtumas	11,80%	2	0,00	121 visi
Palūkanų normos	Gražos pokytis % = - 0.0271 - 0.1935 * netikėtumas	26,30%	1	0,00	118 <=0
Palūkanų normos	Gražos pokytis % = - 0.0149 - 0.1725 * netikėtumas	14,90%	2	0,00	118 <=0

Šaltinis: sudaryta autoriaus.

Makroekonominiai rodikliai, kurių šriftas nuspalvintas pilkai, reiškia, kad sudaryti modeliai netenkino regresijos analizės prielaidų. Po jų yra pateikti kiti modeliai su mažesnėmis determinacijos reikšmėmis.

RBVP rodiklio atveju matoma, kad sudarius modelį su mažesne determinacijos reikšme kitą minutę, jis tenkina pirmojo etapo prielaidas. Preliminarių duomenų vartotojų kainų indekso (m./m.) rodiklio atveju modelis buvo sudarytas 36 minutę. Šio modelio rezultatai taip pat tenkino I etapo prielaidas. Tas pats rezultatas gaunamas ir su vartotojų kainų indeksu (m./m.), išskyrus energiją, maistą, alkoholį ir tabaką.

Sudarant naujus palūkanų normos modelius matoma, kad jie netenkina pirmojo etapo prielaidų – jų determinacijos reikšmės yra mažesnės nei 20. Tokiu atveju su palūkanų normos modeliais tyrimas nebus tęsiamas.

Gavus naujus I etapo kriterijus, tenkinančius RBVP, preliminarių duomenų VKI (m/m), VKI (m/m), išskyrus energiją, maistą, alkoholį ir tabaką, rodiklių regresijos modelius, toliau apskaičiuojama, ar šie modeliai tenkina I etapo regresijos analizės prielaidas.

64 lentelėje yra pateiktas naujasis RBVP rodiklio modelis, kurio regresijos analizės prielaidos bus tiriamos.

64 lentelė. RBVP (m./m.) rodiklio regresijos modelio prielaidų tikrinimas, esant > 0 scenarijui

Regresijos modelio prielaidos	Prielaidų rezultatai
Ar priklausomas kintamasis yra normaliai pasiskirstęs?	Taip Šapiro-Vilko p-reikšmė yra 0,11
Ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (autokoreliacijos problema)?	Ne Durbino-Watsono reikšmė yra 2,107

Lentelės tęsinys 133 psl.

Lentelė atkelta iš 131 psl.

Ar tarp regresorių nėra multikolinearumo?	Neaktualu
Ar duomenyse yra išskirčių?	Ne Visos Kuko mato reikšmės neviršija 1
Ar duomenys yra homoskedastiški?	Taip Breušo-Pagano p-reikšmė yra 0,20

Šaltinis: sudaryta autoriaus.

Kaip matoma iš lentelės, modelis atitinka visas regresijos analizei keliamas prielaidas, todėl galima teigti, kad sudarytas modelis yra statistiškai patikimas prognozuoti EURO STOXX 50 indekso grąžą.

65 lentelėje yra pateiktas naujasis preliminarių duomenų VKI (m./m.) rodiklio modelis, kurio regresijos analizės prielaidos yra tiriamos.

65 lentelė. Preliminarių duomenų vartotojų kainų indekso (m/m) rodiklio regresijos modelio prielaidų tikrinimas, esant > 0 scenarijui

Regresijos modelio prielaidos	Prielaidų rezultatai
Ar priklausomas kintamasis yra normaliai pasiskirstęs?	Taip Šapiro-Vilko p-reikšmė yra 0,31
Ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (autokoreliacijos problema)?	Ne Durbino-Watsono reikšmė yra 1,639
Ar tarp regresorių nėra multikolinearumo?	Neaktualu
Ar duomenyse yra išskirčių?	Ne Visos Kuko mato reikšmės neviršija 1
Ar duomenys yra homoskedastiški?	Taip Breušo-Pagano p-reikšmė yra 0,77

Šaltinis: sudaryta autoriaus.

Iš lentelės matoma, kad modelis atitinka visas regresijos analizei keliamas prielaidas, todėl galima teigti, kad sudarytas modelis yra statistiškai patikimas prognozuoti EURO STOXX 50 indekso grąžą.

66 lentelėje yra pateiktas naujasis VKI (m./m.), išskyrus energiją, maistą, alko-

holį ir tabaką, rodiklio modelis, kurio regresijos analizės prielaidos yra tiriamos.

66 lentelė. Vartotojų kainų indekso (m./m.), išskyrus energiją, maistą, alkoholį ir tabaką, rodiklio regresijos modelio prielaidų tikrinimas, esant <0 scenarijui

Regresijos modelio prielaidos	Prielaidų rezultatai
Ar priklausomas kintamasis yra normaliai pasiskirstęs?	Taip Šapiro-Vilko p-reikšmė yra 0,23
Ar skirtingų stebėjimų liekamosios paklaidos koreliuoja (autokoreliacijos problema)?	Ne Durbino-Watsono reikšmė yra 2,012
Ar tarp regresorių nėra multikolinearumo?	Neaktualu
Ar duomenyse yra išskirčių?	Ne Visos Kuko mato reikšmės neviršija 1
Ar duomenys yra homoskedastiški?	Taip Breušo-Pagano p-reikšmė yra 0,27

Šaltinis: sudaryta autoriaus.

Taigi minėtas modelis atitinka visas regresijos analizei keliamas prielaidas, todėl galima teigti, kad sudarytas modelis yra statistiškai patikimas prognozuoti EURO STOXX 50 indekso grąžą.

Apibendrinant poskyrį yra sukurta 67 lentelė, kurioje pateikti galutiniai modeliai, kurie atitinka I etapo kriterijus ir prielaidas.

67 lentelė. Galutiniai modeliai, kurie tenkina I tyrimo etapo kriterijus ir prielaidas

Ekonominis rodiklis	Regresijos modelis	R ²	R ² minutėje	P-reikšmė	Įvykių kiekis	Scenarijai	Ar tenkina visas regresijos analizės prielaidas
PAGRINDINIAI RODIKLIAI							
RBVP (m./m.)	Gražos pokytis % = - 0.0403 + 0.0412 * netikėtumas	23,70%	3 → 4	0,01	30	>0	Taip
SEKTORINIAI RODIKLIAI							
Pramonės produkcijos (m./m.)	Gražos pokytis % = - 0.1040 + 0.1745 * netikėtumas	24,70%	40	0,00	61	>0	Taip
Pramonės produkcijos (m./m.)	Gražos pokytis % = - 0.0876 + 0.1705 * netikėtumas	21,80%	42	0,00	70	=0	Taip
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI							
Preliminarų duomenų vartotojų kainų indekso (m./m.)	Gražos pokytis % = 0.1869 - 0.1408 * netikėtumas	32,20%	38 → 36	0,00	39	>0	Taip
Vartotojų kainų indekso išskyrus energiją, maistą, alkoholį ir tabaką (m./m.)	Gražos pokytis % = - 0.1009 - 0.1165 * netikėtumas	26,90%	14 → 10	0,00	55	<0	Taip

Šaltinis: sudaryta autoriaus.

Prie determinacijos koeficiento nurodytos rodyklės reiškia, kad modelis buvo pakeistas nurodytą minutę. Taigi, po I etapo liko 5 modeliai, kurie tenkino determinacijos koeficiento p-reikšmės, įvykių kiekio kriterijus ir regresijos analizės prielaidas. Šių modelių koreliacines matricas galima rasti 1–5 priede.

3.4 II tyrimo etapas: daugianarės regresijos modelių sudarymas

Šiame tyrimo etape yra sudaromi ir tikrinami daugianariai regresijos modeliai. Keliamas klausimas ar galima praplėsti I etapą praėjusius tiesinės regresijos modelius, papildant juos naujais makroekonominiais rodikliais. Norint sudaryti daugianarius regresijos modelius, tikrinama, ar likusių makroekonominių rodiklių realizavimo data sutampa su esamais makroekonominiais rodikliais. Jei sutampa – sudaromi daugianariai regresijos modeliai ir tikrinami pagal I etapo kriterijus ir prielaidas (žr. 68 lent.).

68 lentelė. Daugianariai regresijos modeliai ir jų tikrinimas

Modelių skaičius	Rodiklių pavadinimai	Daugialypis regresijos modelis	R ²	R ² minutėje	P-reikšmė	Ivykių kiekių	Scenarijai
1	RBVP (m./m.)	Grąžos pokytis % = - 0.0523 + 0.0639 * RBVP (m./m.) - 0.0198 * RBVP (ketv./ketv.)	28,20%	4	0,010	30	> 0
	RBVP (ketv./ketv.)				0,210		
2	Pramonės produkcijos (m./m.)	Grąžos pokytis % = - 0.1207 + 0.2374 * PP (m./m.) - 0.0680 PP (mėn./mėn.)	28,90%	40	0,000	61	> 0
	Pramonės produkcijos (mėn./mėn.)				0,072		
3	Pramonės produkcijos (m./m.)	Grąžos pokytis % = - 0.0981 + 0.2309 * PP (m./m.) - 0.0712 PP (mėn./mėn.)	25,70%	42	0,000	70	≥ 0
	Pramonės produkcijos (mėn./mėn.)				0,068		
4	Preliminarių duomenų vartotojų kainų indekso (m./m.)	Grąžos pokytis % = 0.1366 - 0.1243 * PVKI (m./m.) + 0.0282 NL	50,60%	36	0,000	18	> 0
	Nedarbo lygio				0,340		
5	Vartotojų kainų indekso šskyrus energiją, maistą, alkoholi ir tabaką (m./m.)	Grąžos pokytis % = - 0.0602 - 0.0793 * VKI-EX (m./m.) - 0.0458 VKI (m./m.) + 0.0235 VKI (mėn./mėn.)	27,40%	10	0,020	24	< 0
	Vartotojų kainų indekso (m./m.)				0,200		
	Vartotojų kainų indekso (mėn./mėn.)				0,640		

Šaltinis: sudaryta autoriaus.

Pirmasis sudarytas daugialypis regresijos modelis yra tarp RBVP rodiklių. Šie makroekonominiai rodikliai viešumoje pasirodo vienu metu, todėl ir yra tikslinga sudaryti bendrą regresijos lygtį. Iš šios lygties matoma, kad didesnę koeficiento reikšmę turi pirmasis RBVP rodiklis, vadinasi, jo poveikis EURO STOXX 50 grąžai yra taip pat didesnis. Determinacijos koeficientas yra 28,20 %. Tai rodo, kad 4 minutę, esant netikėtumo rodiklio scenarijui > 0, šiais dviem makroekonominiais rodikliais akumuliuotas EURO STOXX 50 indekso grąžos susidarymas paaiškinamas 28,20 %. Perėjus prie regresorių statistinio patikimo matoma, kad antrojo rodiklio p-reikšmė yra didesnė nei pasirinktas pasiklovimo lygmuo (0,05), tokiu atveju modelis netenka prasmės, nes nėra statistiškai patikimas.

Antrasis sudarytas daugialypis modelis yra tarp pramonės produkcijos rodiklių, esant netikėtumo rodiklio reikšmei didesnei už 0. Iš šios lygties matoma, kad didesnę koeficiento reikšmę turi pirmasis pramonės produkcijos rodiklis, vadinasi, jo poveikis EURO STOXX 50 grąžai yra taip didesnis. Determinacijos koeficientas yra 28,90 %.

Tai rodo, kad 40 minutę, esant netikėtumo rodiklio scenarijui > 0 , šiais dviem makroekonominiais rodikliais akumuliuotas EURO STOXX 50 indekso grąžos susidarymas paaiškinamas 28,90 %. Perėjus prie regresorių statistinio patikimumo matoma, kad antrojo rodiklio p-reikšmė yra didesnė nei pasirinktas pasiklovimo lygmuo (0,05), vadinasi, modelis nėra statistiškai patikimas.

Trečiasis sudarytas daugialypis modelis yra tarp pramonės produkcijos rodiklių, esant netikėtumo rodiklio reikšmei didesnei už ar lygiai 0. Iš šios lygties matoma, kad didesnę koeficiento reikšmę turi pirmasis PP rodiklis, vadinasi jo poveikis EURO STOXX 50 grąžai yra taip pat didesnis. Determinacijos koeficientas yra 25,70 %. Tai rodo, kad 42 minutę, esant netikėtumo rodiklio scenarijui ≥ 0 , šiais dviem makroekonominiais rodikliais akumuliuotas EURO STOXX 50 indekso grąžos susidarymas paaiškinamas 25,70 %. Perėjus prie regresorių statistinio patikimumo matoma, kad antrojo rodiklio p-reikšmė yra didesnė nei pasirinktas pasiklovimo lygmuo (0,05), tokiu atveju modelis netenka prasmės, nes nėra statistiškai patikimas.

Ketvirtasis sudarytas daugialypis modelis yra tarp preliminarių duomenų VKI ir nedarbo lygio rodiklių, esant netikėtumo rodiklio reikšmei didesnei už 0. Iš šios lygties matoma, kad didesnę koeficiento reikšmę turi pirmasis rodiklis, vadinasi jo poveikis EURO STOXX 50 grąžai yra taip pat didesnis. Determinacijos koeficientas yra 50,60 %. Tai rodo, kad 18 minutę, esant netikėtumo rodiklio scenarijui > 0 , šiais dviem makroekonominiais rodikliais akumuliuotas EURO STOXX 50 indekso grąžos susidarymas paaiškinamas 50,60 %. Perėjus prie regresorių statistinio patikimumo matoma, kad antrojo rodiklio p-reikšmė yra didesnė nei pasirinktas pasiklovimo lygmuo (0,05), tokiu atveju modelis netenka prasmės, nes nėra statistiškai patikimas. Taip pat šis modelis neatitinka ir įvykių kiekio kriterijaus.


Penktasis sudarytas daugialypis modelis yra tarp VKI, išskyrus energiją, maistą, alkoholį ir tabaką, VKI (m./m.) ir VKI (mėn./mėn.) rodiklių, esant netikėtumo rodiklio reikšmei mažesnei už 0. Iš šios lygties matoma, kad didesnę koeficiento reikšmę turi pirmasis rodiklis, vadinasi, jo poveikis EURO STOXX 50 grąžai yra taip pat didesnis. Determinacijos koeficientas yra 27,40 %. Tai rodo, kad 10 minutę, esant netikėtumo rodiklio scenarijui < 0 , šiais trimis makroekonominiais rodikliais akumuliuotas EURO STOXX 50 indekso grąžos susidarymas paaiškinamas 27,40 %. Perėjus prie regresorių statistinio patikimumo matoma, kad antrojo ir trečiojo rodiklių p-reikšmės yra didesnės nei pasirinktas pasiklovimo lygmuo (0,05), vadinasi, modelis nėra statistiškai patikimas.

Verta pastebėti, kad visų daugianarių regresijos modelių determinacijos koeficiento reikšmės buvo didesnės nei paprastųjų regresijos modelių. Tai paaiškinama tuo, kad prisidėjo papildomi regresoriai. Tačiau įtraukus papildomus regresorius paaiškėjo, kad kai kurių regresorių koeficientų reikšmės yra statistiškai nereikšmingos, dėl to sudaryti modeliai nėra patikimi. Tokiu atveju šiame tyrime daugialypiai regresijos modeliai toliau nagrinėjami nebus.

3.5 III tyrimo etapas

3.5.1 Regresijos modelių patikrinimas, ieškant ARCH efektų, ir GARCH modelių sudarymas


Šiame tyrimo etape yra patikrinama, ar sukurti ir 67 lentelėje pateikti regresijos modeliai turi ARCH efektų. Žemiau nurodyti grafikai yra sudaryti naudojant regresijos modelių paklaidas. Pirmasis modelis, kurio paklaidoms tikrinami ARCH efektai, yra RBVP modelis, esant scenarijui > 0 (žr. 17 pav.).



Šaltinis: sudaryta autoriaus.

17 pav. Autokoreliacijos ir dalinės autokoreliacijos testai RBVP modeliui, esant scenarijui > 0

Iš paveikslėlio matoma, kad autokoreliacijos dydžiai neviršija kritinės intervalo ribos. Dalinės autokoreliacijos grafike 3 ir 12 lagai viršija kritinę ribą, tačiau 12 yra labai tolimas, o 3 viršija labai mažai. Siekiant įsitikinti, kad autokoreliacijos nėra, buvo sudarytas Ljung-Box testas (žr. 18 pav.).




Šaltinis: Sudaryta autoriaus.

18 pav. Ljung-Box testo p-reikšmės RBVP modeliui, esant scenarijui > 0

Iš grafiko įsitikinama, kad autokoreliacijos tarp paklaidų tikrai nėra, nes visuose postūmiuose p-reikšmė yra didesnė nei pasirinktas reikšmingumo lygmuo 0,05. Tokiu atveju GARCH modelis RBVP rodiklio atvejui, esant scenarijui > 0, nėra sudaromas.


Antrasis modelis, kurio paklaidoms tikrinami ARCH efektai, yra pramonės produkcijos indekso modelis, esant scenarijui > 0 (žr. 19 pav.).



Šaltinis: sudaryta autoriaus.

19 pav. Autokoreliacijos ir dalinės autokoreliacijos testai PP indekso modeliui, esant scenarijui > 0

Iš paveikslu matoma, kad tiek autokoreliacijos, tiek dalinės autokoreliacijos dydžiai neviršija kritinės intervalo ribos. Siekiant įsitikinti, kad autokoreliacijos nėra, buvo sudarytas Ljung-Box testas (žr. 20 pav.).




Šaltinis: sudaryta autoriaus.

20 pav. Ljung-Box testo p-reikšmės PP indekso modeliui, esant scenarijui > 0

Iš grafiko įsitikinama, kad autokoreliacijos tarp paklaidų tikrai nėra, nes visuose postūmiuose p-reikšmė yra didesnė nei pasirinktas reikšmingumo lygmuo 0,05. Tokiu atveju GARCH modelis pramonės produkcijos rodiklio atvejui, esant scenarijui > 0, nėra sudaromas.


Trečiasis modelis, kurio paklaidoms tikrinami ARCH efektai, yra pramonės produkcijos indekso modelis, esant scenarijui ≥ 0 (žr. 21 pav.).



Šaltinis: sudaryta autoriaus.

21 pav. Autokoreliacijos ir dalinės autokoreliacijos testai PP indekso modeliui, esant scenarijui ≥ 0

Iš paveiklo matoma, kad tiek autokoreliacijos, tiek dalinės autokoreliacijos dydžiai neviršija kritinės intervalo ribos. Siekiant įsitikinti, kad autokoreliacijos nėra, buvo sudarytas Ljung-Box testas (žr. 22 pav.).




Šaltinis: sudaryta autoriaus.

22 pav. Ljung-Box testo p-reikšmės PP indekso modeliui, esant scenarijui ≥ 0

Iš grafiko įsitikinama, kad autokoreliacijos tarp paklaidų tikrai nėra, nes visuose postūmiuose p-reikšmė yra didesnė nei pasirinktas reikšmingumo lygmuo 0,05. Tokiu atveju GARCH modelis pramonės produkcijos rodiklio atvejui, esant scenarijui ≥ 0 , nėra sudaromas.


Ketvirtasis modelis, kurio paklaidoms tikrinami ARCH efektai, yra preliminarių duomenų VKI modelis, esant scenarijui > 0 (žr. 23 pav.).



Šaltinis: sudaryta autoriaus.

23 pav. Autokoreliacijos ir dalinės autokoreliacijos testai preliminarių duomenų VKI modeliui, esant scenarijui > 0

Iš paveiklo matoma, kad tiek autokoreliacijos, tiek dalinės autokoreliacijos dydžiai neviršija kritinės intervalo ribos. Siekiant įsitikinti, kad autokoreliacijos nėra, buvo sudarytas Ljung-Box testas (žr. 24 pav.).




Šaltinis: sudaryta autoriaus.

24 pav. Ljung-Box testo p-reikšmės preliminarių duomenų VKI modeliui, esant scenarijui > 0

Iš grafiko įsitikinama, kad autokoreliacijos tarp paklaidų tikrai nėra, nes visuose postūmiuose p-reikšmė yra didesnė nei pasirinktas reikšmingumo lygmuo 0,05. Tokiu atveju GARCH modelis preliminarių duomenų VKI atvejui, esant scenarijui > 0 , nėra sudaromas.


Penktasis ir paskutinis modelis, kurio paklaidoms tikrinami ARCH efektai, yra VKI, išskyrus energiją, maistą, alkoholį ir tabaką, modelis, esant scenarijui < 0 (žr. 25 pav.).



Šaltinis: sudaryta autoriaus.

25 pav. Autokoreliacijos ir dalinės autokoreliacijos testai VKI, išskyrus energiją, maistą, alkoholį ir tabaką modeliui, esant scenarijui < 0

Iš paveiklo matoma, kad tiek autokoreliacijos, tiek dalinės autokoreliacijos dydžiai neviršija kritinės intervalo ribos. Siekiant įsitikinti, kad autokoreliacijos nėra, buvo sudarytas Ljung-Box testas (žr. 26 pav.).



Šaltinis: sudaryta autoriaus.

26 pav. Ljung-Box testo p-reikšmės VKI, išskyrus energiją, maistą, alkoholį ir tabaką modeliui, esant scenarijui < 0

Iš grafiko įsitikinama, kad autokoreliacijos tarp paklaidų tikrai nėra, nes visuose postūmiuose p-reikšmė yra didesnė nei pasirinktas reikšmingumo lygmuo 0,05. Tokiu atveju GARCH modelis VKI, išskyrus energiją, maistą, alkoholį ir tabaką, atvejui, esant scenarijui < 0 , nėra sudaromas.

Taigi atlikus ARCH efektų testus paaiškėjo, kad sudaryti GARCH modelius nėra tikslinga, todėl vienintelis tradicinis modelis šiame tyrime, kaip atrama ML modeliams, bus tiesinė regresija. Remiantis gautais skaičiavimais, galima dalinai priimti pirmąją tyrimo hipotezę, teigiančią, kad makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis tradiciniais metodais. Iki šio momento buvo sudaryta 133 tiesinės, 5 daugianarės regresijos modeliai. Iš jų tik 5 tiesinės regresijos modeliai atitiko visus tyrime išsikeltus kriterijus ir prielaidas. Verta paminėti,

kad regresijos modelių galiausiai galėjo būti ir daugiau, tačiau tyrime buvo išskirti papildomi kriterijai, kuriais remiantis buvo atfiltruoti tik geriausiai EURO STOXX 50 grąžą nusakantys regresijos modeliai. Šiame skyriuje likusiems 5 regresijos modeliams buvo norima sukurti ir GARCH modelius, tačiau nebuvo aptikti ARCH efektai. Kas galėjo lemti mažą statistiškai validžių modelių skaičių, nėra iki galo aišku, ir galima tik spėlioti: netinkamai pasirinktas akcijų indeksas; per mažas analizavimo laiko intervalas minutėmis; neteisingai apskaičiuotas netikėtumo rodiklis; netinkamai pasirinkti metodai; arba tiesiog makroekonominiai rodiklių netikėtumai nedaro tokios didelės įtakos akcijų grąžai.

3.5.2. Mašininio mokymosi modelių sudarymas ir palyginimas su sudarytais tradiciniais modeliais

Šiame skyriuje yra analizuojamos apibendrintos sudarytų regresijos ir mašininio modelių kiekvienam rodiklio scenarijui charakteristikos, t. y. komentuojamos determinacijos koeficientų reikšmės, paklaidos, pateikiami modelių grafikai. GBR, DT, RF tikslius modelių parametrus galima rasti 7–9 priede, o DL modelio vizualizaciją – 6 priede.

69 lentelėje priminimui nurodyti 2 tyrimo etapą perėję modeliai.

69 lentelė. Sukurtų regresijos modelių charakteristikos

Makroekonominis rodiklis	Regresijos modelis	R ²	R ² nuizėje	P reikšmė	Įvykių kiekis	Scenarijai	Poveikis indeksui
PAGRINDINIAI RODIKLIAI							
RBVP (m.m.)	Gražos pokytis % = - 0.0403 - 0.0412 * netikėtumas	23.70%	4	0,01	30	>0	Teigiamas
SEKTORINIAI RODIKLIAI							
Pramonės produkcijos (m.m.)	Gražos pokytis % = - 0.1040 - 0.1745 * netikėtumas	24.70%	40	0,00	61	>0	Teigiamas
Pramonės produkcijos (m.m.)	Gražos pokytis % = - 0.0876 - 0.1705 * netikėtumas	21.80%	42	0,00	70	>=0	Teigiamas
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI							
Preliminarčių duomenų vartotojų kainų indekso (m.m.)	Gražos pokytis % = 0.1869 - 0.1408 * netikėtumas	32,20%	36	0,00	39	>0	Neigiamas
Vartotojų kainų indekso išlaidų energijai, maistui, alkoholiui ir tabakui (m.m.)	Gražos pokytis % = - 0.1009 - 0.1165 * netikėtumas	26,90%	10	0,00	55	<0	Teigiamas

Šaltinis: sudaryta autoriaus.

Ši lentelė nuo paskutinės versijos (67 lentelės) skiriasi tuo, kad papildomai buvo pridėtas stulpelis „Poveikis indeksui“. Jame parašyta, kokį poveikį makroekonominiai netikėtumo rodikliai turi akcijų indeksui. Jei prie antro koeficiento matomas pliuso ženklas ir scenarijus yra > arba >= 0, tai poveikis akcijų indeksui yra teigiamas (grąža didėja). Jei prie antro koeficiento matomas minuso ženklas ir scenarijus > 0, tai poveikis akcijų indekso grąžai yra mažėjantis (neigiamas). Didžiausią antrojo koeficiento reikšmę turi pramonės produkcijos rodikliai pagal skirtingus scenarijus. Tai reiškia, kad netikėtumo rodiklio poveikis akcijų indekso grąžai yra didžiausias, lyginant su kitais rodikliais.

Toliau iš kiekvienam likusių rodiklių yra sudaromi mašininio mokymosi modeliai, ir jų bei tradicinio LR modelio rezultatai lyginami tarpusavyje (žr. 70 lent.).



70 lentelė. RBVP (m./m.) rodiklio modeliai 4 minutę, kai netikėtumo reikšmės daugiau už 0

Modelis	Įvykių skaičius	Įvykių skaičius treniravimuisi	Įvykių skaičius testavimui	R ²	MSE	RMSE
Tradicinis LR	30	-	-	23,70%	0,0030	0,0550
ML LR	30	20	10	76,55%	0,0005	0,0221
ML RF	30	20	10	86,75%	0,0003	0,0167
ML DT	30	20	10	77,18%	0,0006	0,0250
ML GBR	30	20	10	75,51%	0,0007	0,0259
DL FFNN	30	20	10	45,81%	0,0014	0,0371

Šaltinis: sudaryta autoriaus.

Iš lentelės matoma, kad prasčiausias modelis yra tradicinis tiesinės regresijos modelis, kurio tikslumas 23,70 %, o vidutinė kvadratinė paklaida 0,0030. Tačiau panaudojus mašininio mokymosi metodus gaunami kiti modeliai su didesniu tikslumu ir mažesne paklaida. Didžiausias tikslumas (86,75 %) ir mažiausia paklaida (0,0003, 0,0167) buvo pasiekta, sudarius atsitiktinio miško modelį.

Toliau pateiktas 27 paveikslas, kuris vizualizuoja blogiausią ir geriausią modelius.



Šaltinis: sudaryta autoriaus.

27 pav. Tradicinio tiesinės regresijos (kairėje) ir atsitiktinio miško (dešinėje) modeliai

Juoda linija vaizduoja modelį, o mėlyni taškai akumuliuotą EURO STOXX 50 indekso grąžą iki 4 minutes. Statmenas skirtumas tarp juodos linijos ir taškų indikuoja paklaidas. Taigi vizualiai taip pat galima pamatyti, kad atsitiktinio miško paklaidos yra kur kas mažesnės nei paprastojo tiesinės regresijos modelio, kas turi įtakos modelio tikslumui. Kadangi duomenų apsimokinti ir patikrinti atsitiktinio miško modelį

yra mažai, šiuo atveju kyla modelio patikimumo problema. Yra nemaža tikimybė, kad įtraukus daugiau stebėjimų atsitiktinio miško modelis gali prognozuoti blogiau.

Toliau pateikiamos kito rodiklio modelių rezultatai (žr. 71 lent.).


71 lentelė. Pramonės produkcijos (m./m.) rodiklio modeliai 40 minutę, kai netikėtumo reikšmės daugiau už 0

Modelis	Įvykių skaičius	Įvykių skaičius treneravimuisi	Įvykių skaičius testavimui	R ²	MSE	RMSE
Tradicinis LR	61	-	-	24,70%	0,0351	0,1873
ML LR	61	41	20	58,47%	0,0163	0,1276
ML RF	61	41	20	32,24%	0,0411	0,2027
ML DT	61	41	20	48,78%	0,0376	0,1940
ML GBR	61	41	20	51,09%	0,0359	0,1896
DL FFNN	61	41	20	31,05%	0,0537	0,2317

Šaltinis: sudaryta autoriaus.

Iš lentelės matoma, kad prasčiausias modelis yra tradicinis tiesinės regresijos modelis, kurio tikslumas 24,70 %, o vidutinė kvadratinė paklaida 0,0351. Tačiau panaudojus mašininio mokymosi metodus gaunami kiti modeliai su didesniu tikslumu ir mažesne paklaida. Didžiausias tikslumas (58,47 %) ir mažiausia paklaida (0,0163, 0,1276) buvo pasiekta, sudarius mašininio mokymosi tiesinės regresijos modelį.

Toliau pateiktas 28 paveikslas, kuris vizualizuoja blogiausią ir geriausią modelius.



Šaltinis: sudaryta autoriaus.

28 pav. Tradicinio tiesinės regresijos (kairėje) ir ML tiesinės regresijos (dešinėje) modeliai

Iš paveikslų galima pamatyti, kad ML regresijos modelio paklaidos yra mažesnės nei paprastojo tiesinės regresijos modelio, kas turi įtakos modelio tikslumui. Kadangi duomenų apsimokinti ir patikrinti ML tiesinės regresijos modelį nebuvo daug, šiuo atveju kyla modelio patikimumo problema. Yra tikimybė, kad įtraukus daugiau

stebėjimų modelis gali prognozuoti blogiau.

Toliau pateikiamas kito rodiklio modelių rezultatai (žr. 72 lent.).


72 lentelė. Pramonės produkcijos (m./m.) rodiklio modeliai 42 minutę, kai netikėtumo reikšmės daugiau arba lygios už 0

Modelis	Įvykių skaičius	Įvykių skaičius treniravimuisi	Įvykių skaičius testavimui	R ²	MSE	RMSE
Tradicinis LR	70	-	-	21,80%	0,0416	0,2040
ML LR	70	50	20	55,97%	0,0212	0,1455
ML RF	70	50	20	29,59%	0,0652	0,2554
ML DT	70	50	20	40,96%	0,0536	0,2315
ML GBR	70	50	20	41,75%	0,0390	0,1974
DL FFNN	70	50	20	33,07%	0,0402	0,2006

Šaltinis: sudaryta autoriaus.

Iš lentelės matoma, kad prasčiausias modelis yra tradicinis tiesinės regresijos modelis, kurio tikslumas 21,80 %, o vidutinė kvadratinė paklaida 0,0416. Sukūrus ML modelius, didžiausias tikslumas (55,97 %) ir mažiausia paklaida (0,0212, 0,1455) buvo pasiekta, sudarius tiesinės regresijos modelį.

Toliau pateiktas 29 paveikslas, kuris vizualizuoja blogiausią ir geriausią modelius.



Šaltinis: sudaryta autoriaus.

29 pav. Tradicinio tiesinės regresijos (kairėje) ir ML tiesinės regresijos (dešinėje) modeliai

Taigi vizualiai galima pamatyti, kad ML regresijos modelio paklaidos yra mažesnės nei paprastojo tiesinės regresijos modelio, kas turi įtakos modelio tikslumui. Kadangi duomenų apsimokinti ir patikrinti ML tiesinės regresijos modelį nebuvo daug, šiuo atveju kyla modelio patikimumo problema. Yra tikimybė, kad įtraukus daugiau stebėjimų modelis gali prognozuoti blogiau.

Toliau pateikiamos kito rodiklio modelių rezultatų metrikos (žr. 73 lent.).


73 lentelė. Preliminarių duomenų vartotojų kainų indekso (m/m) rodiklio modeliai 36 minutę, kai netikėtumo reikšmės daugiau už 0

Modelis	Įvykių skaičius	Įvykių skaičius treniravimuisi	Įvykių skaičius testavimui	R ²	MSE	RMSE
Tradicinis LR	39	-	-	32,20%	0,0288	0,1698
ML LR	39	21	18	63,39%	0,0128	0,1130
ML RF	39	21	18	39,47%	0,0280	0,1673
ML DT	39	21	18	52,49%	0,0191	0,1381
ML GBR	39	21	18	51,63%	0,1393	0,0194
DL FFNN	39	21	18	40,38%	0,0222	0,1490

Šaltinis: sudaryta autoriaus.

Iš lentelės matoma, kad prasčiausias modelis yra paprastasis tiesinės regresijos modelis, kurio tikslumas 32,20 %, o vidutinė kvadratinė paklaida 0,0288. Tačiau panaudojus mašininio mokymosi metodus gaunami kiti modeliai, kur didžiausias tikslumas (63,39 %) ir mažiausia paklaida (0,0128, 0,1130) buvo pasiekta, sudarius ML tiesinės regresijos modelį.

Toliau pateiktas 30 paveikslas, kuris vizualizuoja blogiausią ir geriausią modelius.



Šaltinis: sudaryta autoriaus.

30 pav. Tradicinio tiesinės regresijos (kairėje) ir ML tiesinės regresijos (dešinėje) modeliai

Iš paveikslų taip aiškiai nesimato, kad ML regresijos modelio paklaidos yra mažesnės nei paprastojo tiesinės regresijos modelio. Kadangi duomenų apsimokinti ir patikrinti ML tiesinės regresijos modelį nebuvo daug, šiuo atveju kyla modelio patikimumo problema. Yra tikimybė, kad įtraukus daugiau stebėjimų modelis gali prognozuoti blogiau.

Toliau pateikiamos kito rodiklio modelių rezultatų metrikos (žr. 74 lent.).


74 lentelė. Vartotojų kainų indekso (m./m.), išskyrus energiją, maistą, alkoholį ir tabaką, rodiklio modeliai 10 minutę, kai netikėtumo reikšmės mažiau už 0

Modelis	Ivykių skaičius	Ivykių skaičius treniravimuisi	Ivykių skaičius testavimui	R ²	MSE	RMSE
Tradicinis LR	55	-	-	26,90%	0,0145	0,1204
ML LR	55	35	20	63,06%	0,0040	0,0635
ML RF	55	35	20	68,42%	0,0054	0,0738
ML DT	55	35	20	75,27%	0,0055	0,0744
ML GBR	55	35	20	73,79%	0,0059	0,0767
DL FFNN	55	35	20	55,79%	0,0059	0,0771

Šaltinis: sudaryta autoriaus.

Iš lentelės matoma, kad prasčiausias modelis yra tradicinis tiesinės regresijos modelis, kurio tikslumas 26,90 %, o vidutinė kvadratinė paklaida 0,0145. Tačiau panaudojus mašininio mokymosi metodus gaunami kiti modeliai su didesniu tikslumu ir mažesne paklaida. Didžiausias tikslumas (68,42 %) ir mažiausia paklaida (0,0054, 0,0738) buvo pasiekta, sudarius sprendimų medžio modelį.

Toliau pateiktas 31 paveikslas, kuris vizualizuoja blogiausią ir geriausią modelius.



Šaltinis: sudaryta autoriaus.

31 pav. Tradicinio tiesinės regresijos (kairėje) ir Sprendimų medžio (dešinėje) modeliai

Iš paveikslų matyti, kad ML Sprendimų medžio modelio paklaidos yra mažesnės nei tiesinės regresijos, kas turi įtakos modelio tikslumui. Kadangi duomenų apsimokinti ir patikrinti atsitiktinio sprendimų medžio modelį nebuvo daug, šiuo atveju kyla modelio patikimumo problema. Yra tikimybė, kad įtraukus daugiau stebėjimų modelis gali prognozuoti blogiau.

Toliau pateikiama apibendrinanti 75 lentelė, talpinti prasčiausius ir geriausius modelius kartu su lygtimis.

75 lentelė. Tiesinės regresijos ir pagrindinių ML modelių charakteristikos

Makroekonominiai rodikliai ir modelio tipas	Lygtis	R ²	MSE	R ² minimėje	Įvykių kiekis	Scenarijai	Poveikis indeksui
PAGRINDINIAI RODIKLIAI							
RBVP (m.m.) tradicinis LR	Grąžos polytis % = - 0.0403 + 0.0412 * netikėtumas	23,70%	0,0030	4	30	>0	Taigiarnas
RBVP (m.m.) ML RF	Lygties užrašyti negalima	86,73%	0,0003	4	10	>0	Taigiarnas
RBVP (m.m.) ML LR	Grąžos polytis % = - 0.0393 + 0.0405 * netikėtumas	76,55%	0,0005	4	10	>0	Taigiarnas
SEKTORINIAI RODIKLIAI							
Pramonės produkcijos (m.m.) tradicinis LR	Grąžos polytis % = - 0.1040 + 0.1745 * netikėtumas	24,70%	0,0351	40	61	>0	Taigiarnas
Pramonės produkcijos (m.m.) ML LR	Grąžos polytis % = - 0.0839 + 0.1473 * netikėtumas	58,47%	0,0163	40	20	>0	Taigiarnas
Pramonės produkcijos (m.m.) tradicinis LR	Grąžos polytis % = - 0.0876 + 0.1705 * netikėtumas	21,80%	0,0416	42	70	≥0	Taigiarnas
Pramonės produkcijos (m.m.) ML LR	Grąžos polytis % = - 0.0703 + 0.1404 * netikėtumas	55,97%	0,0212	42	20	≥0	Taigiarnas
VARTOTOJŲ KAINŲ INDEKSO RODIKLIAI							
Preliminarų duomenų VKI (m.m.) tradicinis LR	Grąžos polytis % = 0.1869 - 0.1408 * netikėtumas	32,20%	0,0288	36	39	>0	Neigiarnas
Preliminarų duomenų VKI (m.m.) ML LR	Grąžos polytis % = 0.1930 - 0.1437 * netikėtumas	63,39%	0,0128	36	18	>0	Neigiarnas
VKI išskyrus energiją, maistą, alkoholi ir tabaką (m.m.) tradicinis LR	Grąžos polytis % = - 0.1009 - 0.1165 * netikėtumas	26,90%	0,0145	10	55	<0	Taigiarnas
VKI išskyrus energiją, maistą, alkoholi ir tabaką (m.m.) ML DT	Lygties užrašyti negalima	75,27%	0,0055	10	20	<0	Taigiarnas
VKI išskyrus energiją, maistą, alkoholi ir tabaką (m.m.) ML LR	Grąžos polytis % = - 0.0724 - 0.0974 * netikėtumas	63,06%	0,0040	10	20	<0	Taigiarnas

Šaltinis: sudaryta autoriaus.

Atsitiktinio miško ir Sprendimų medžio modelių lygties užrašyti negalima, nes jie neturi lengvai interpretuojamų koeficientų, kaip kad turi tiesinė regresija. Tokiu atveju po jų buvo įdėti ML LR modeliai, kad būtų galima pažiūrėti ir palyginti lygties koeficientus su tradiciniais LR modeliais.

Iš lentelės matoma, kad ML modelių koeficientų reikšmės skiriasi nuo tradicinių modelių. Poveikis indeksui išlieka vienodas. ML regresijos modelių testavimo atveju įvykių kiekis yra daug mažesnis nei tradicinių modelių. Taip yra todėl, kad teko duomenis suskaidyti į apmokymo ir testavimo. Pastebima, kad mašininio mokymosi metodais sukurti modelių rezultatai buvo žymiai geresni net ir su mažiau stebėjimų. Tačiau verta paminėti, kad dėl mažo duomenų kiekio mašininio mokymosi modeliai negali būti traktuojami kaip labai patikimi.

Šiame tyrimo etape galima grįžti prie antrosios ir trečiosios tyrimo hipotezių. Šiuo tikslu yra sukurta hipotezių tikrinimo rezultatus apibendrinanti 76 lentelė, į kurią yra įtraukti ir pirmosios hipotezės rezultatai.

76 lentelė. Hipotezių tikrinimo apibendrinti rezultatai

Hipotezė	Statusas	Esminiai argumentacijos akcentai
H1: Makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis tradiciniais metodais.	Dalinai priimta	Iš sukurtų 133 tiesinės regresijos ir 5 daugiavarės regresijos modelių, tik 5 tiesinės regresijos modeliai statistiškai reikšmingi ir patikimi. ARCH efektų nebuvo.
H2: Makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą remiantis mašininio mokymosi metodais.	Priimta	Gauti logiški rezultatai: modelių koeficientų reikšmės stipriai nesiskiria nuo tradicinių modelių koeficientų reikšmių; koeficientų ženklai sutampa su tradiciniais modeliais; grafikai atrodo logiški.
H3: Mašininio mokymosi metodai, palyginus su tradiciniais metodais, leidžia sukurti tikslesnius makroekonominių rodiklių netikėtų poveikio akcijų grąžai prognozavimo modelius.	Priimta	ML prognozavimo modelių tikslumas yra 2–3 kartus didesnis, o paklaidos 10 kartų mažesnės nei tradicinių prognozavimo modelių.

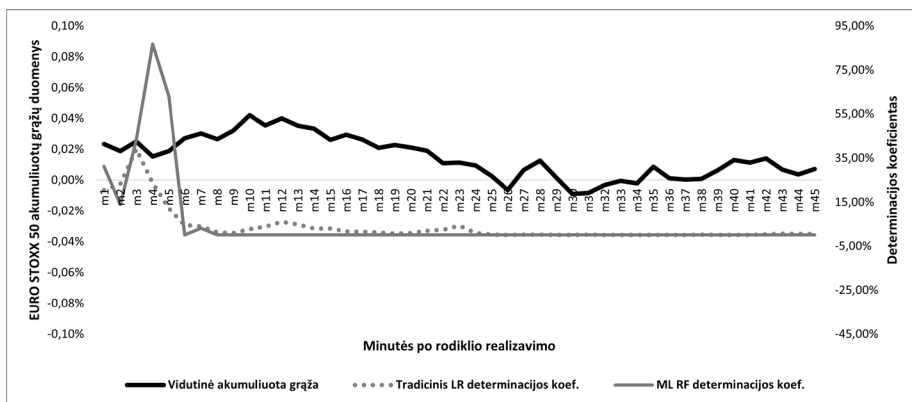
Šaltinis: sudaryta autoriaus.

Antrąją tyrimo hipotezę, teigiančią, kad makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis mašininio mokymosi metodais, galima priimti. Su tais pačiais 5 likusių regresijos modelių rinkiniais, sudarius mašininio mokymosi modelius, buvo gauti logiški rezultatai: koeficientų reikšmės nėra nepaaiškinamos, jų ženklai sutampa su tradiciniais tiesinės regresijos modeliais ir kt. Trečiąją tyrimo hipotezę, aiškinančią, kad mašininio mokymosi metodai, palyginus su tradiciniais metodais, leidžia sukurti tikslesnius makroekonominių rodiklių netikėtų poveikio akcijų grąžai prognozavimo modelius, galima priimti. Gauti empirinio tyrimo rezultatai rodo, kad mašininio mokymosi modelių tikslumas yra 2–3 kartus didesnis, o paklaidos 10 kartų mažesnės nei tradicinių modelių. Čia galima prisiminti, kad dalinai priimant pirmąją tyrimo hipotezę buvo neaišku, kas galėjo paveikti tokį mažą tradicinių modelių skaičių. Ir viena to priežasčių autorių buvo įsivardinęs netinkamus metodus. Taigi, panaudojus mašininio mokymosi metodus, matomi daug geresni rezultatai. Tokiu atveju vertėtų tęsti tyrimus ta pačia tema, bet kaip bazinius modelius paimti ne tradicinius modelius, o mašininio mokymosi modelius, ir gal tada modelių būtų kur kas daugiau.

3.5.3 Modelių tikslumo ir EURO STOXX 50 grąžos sąryšio laiko eilutėje analizė

Atlikus modeliavimo dalį konkrečiose minutėse, būtų įdomu ir tikslinga pana- grinėti, kokių tikslumu kistų EURO STOXX 50 grąža visame 45 minučių intervale, jei būtų sudaromi tie patys ML ir tradiciniai regresijos modeliai, kurie buvo aptariami anksčiau, tačiau ne konkrečiomis minutėmis, o ties kiekviena akumuluota minute vi- same 45 minučių intervale. Šios potėmės akcentas – palyginti grąžos ir dviejų determi- nacijos koeficientų (tradicinio ir ML) sąryšį ir bandyti išvelgti tam tikras tendencijas, kurios papildytų mokslinių tyrimų požiūrius į tai, kaip kinta akcijų grąža, ir koks būtų modelių tikslumas per trumpą laiko tarpą, o investuotojams tai padėtų priimti investi- cinius sprendimus.

Pateikiamas RBVP vidutinių akumuluotų grąžų ir determinacijos koeficientų paveikslas (žr. 32 pav.).




Šaltinis: sudaryta autoriaus.

32 pav. EURO STOXX 50 grąžos ir determinacijos koeficientų analizė RBVP rodiklio atveju, esant netikėtumo scenarijui > 0

Šiuo grafiku siekiama parodyti, kokios vidutinės EURO STOXX 50 indekso grąžos galima tikėti po rodiklio paskelbimo. Iš paveikslo matosi, kad didžiausia grąža pasiekama 11 minutę, tačiau daugiausia grąžos svyravimus modeliai paašikintų pirmomis 5 minutėmis. Ties 9 minute ML LR ir tradicinio LR modelių sudarymo atveju determinacijos koeficientai svyruotų apie 0, kas liudytų, kad jokio ryšio tarp rodiklio ir grąžos nebūtų, vadinasi, grąžos svyravimai vyktų dėl kitų veiksnių.

Toliau pateikiamas pramonės produkcijos vidutinių akumuliuotų grąžų ir determinacijos koeficientų paveikslas (žr. 33 pav.), esant netikėtumo scenarijui > 0 .




Šaltinis: sudaryta autoriaus.

33 pav. EURO STOXX 50 grąžos ir determinacijos koeficientų analizė pramonės produkcijos rodiklio atveju, esant netikėtumo scenarijui > 0

Iš paveikslu matosi, kad didžiausia grąža pasiekama 37 minutę, o daugiausia grąžos svyravimus modeliai paaiškintų paskutinėmis minutėmis, ypač ML atveju. Priešingai nei RBVP rodiklio atveju, čia grąža ir determinacijos koeficientai didžiausi yra pabaigoje, kas rodo, kad priimti sprendimus dėl pardavimo reiktų ne iš karto, kaip kad buvo RBVP atveju, o po 37 minučių.

Toliau pateikiamas pramonės produkcijos vidutinių akumuliuotų grąžų ir determinacijos koeficientų paveikslas (žr. 34 pav.), esant netikėtumo scenarijui ≥ 0 .




Šaltinis: sudaryta autoriaus.

34 pav. EURO STOXX 50 grąžos ir determinacijos koeficientų analizė pramonės produkcijos rodiklio atveju, esant netikėtumo scenarijui ≥ 0

Šis grafiko parametrai labai panašūs į ankstesnio, išskyrus tai, kad ML modelio determinacijos koeficientai svyruoja laiko periode labiau. Tai rodo, kad vieną ar kitą minutę rodikliu galima daugiau ar mažiau paaiškinti EURO STOXX grąžą.

Toliau pateikiamas preliminarių duomenų VKI vidutinių akumuliuotų grąžų ir determinacijos koeficientų paveikslas (žr. 35 pav.), esant netikėtumo scenarijui ≥ 0 .

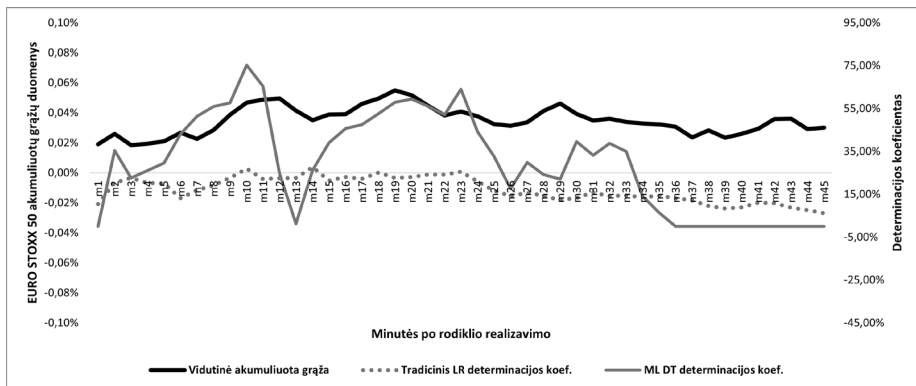


Šaltinis: sudaryta autoriaus.

35 pav. EURO STOXX 50 grąžos ir determinacijos koeficientų analizė preliminarių duomenų VKI rodiklio atveju, esant netikėtumo scenarijui > 0

Šiame grafike matoma, kad grąžos iš indekso pardavimo 45 minučių laiko intervale nederėtų tikėtis. Didžiausios determinacijos koeficientų reikšmės pasiekiamos periodo pabaigoje, kas rodo, kad rodiklio realizavimo ir indekso grąžos sąryšis atsiranda ne iš karto, o stebėjimo pabaigoje.

Toliau pateikiamas VKI, išskyrus energiją, maistą, alkoholį ir tabaką, vidutinių akumuliuotų grąžų ir determinacijos koeficientų paveikslas (žr. 36 pav.), esant netikėtumo scenarijui < 0 .



Šaltinis: sudaryta autoriaus.

36 pav. EURO STOXX 50 grąžos ir determinacijos koeficientų analizė preliminarių duomenų VKI išskyrus energiją, maistą, alkoholį ir tabaką (m./m.) rodiklio atveju, esant netikėtumo scenarijui < 0

Iš šio grafiko matosi, kad grąža svyruoja nuo 0,02 iki 0,05 % pastoviu intervalu. Tai suteikia galimybę uždirbti, net jei būtų praleistas didžiausios tikėtinos grąžos pardavimo momentas. Didžiausia determinacijos koeficiento reikšmė matoma tarp 9 ir 23 minučių, kas rodo, jog su pardavimu reikia palaukti.

Siekiant patogiau apibendrinti grafikų rezultatus, buvo sukurta 77 lentelė, kurioje pateikiami pirkimo ir pardavimo EURO STOXX 50 indekso momentai kartu su tikėtina grąža bei tikslumu.

77 lentelė. EURO STOXX 50 pardavimo momento nustatymas

Makroekonominis rodiklis, scenarijus ir modelio tipas	Pirkimo momentas	Pardavimo momentas	Grąža	R ²
RBVP > 0, ML RF	M0	M4	0,015%	86,75%
Pramonės produkcijos > 0, ML LR	M0	M40	0,034%	58,47%
Pramonės produkcijos ≥ 0 , ML LR	M0	M42	0,030%	55,97%
Preliminarių duomenų VKI > 0, ML LR	M0	M36	0,800%	63,39%
VKI išskyrus energiją, maistą, alkoholį ir tabaką < 0, ML DT	M0	M10	0,047%	75,27%

Šaltinis: sudaryta autoriaus.

Iš lentelės pastebima, kad uždirbamos grąžos nurodytomis pardavimo minutėmis, kurioms ir buvo sukurti modeliai ir paskaičiuoti tikslumai, nėra didelės paprastam investuotojui. Tačiau, jei tai yra rizikos kapitalo fondai, pensijų fondai ir pan., kurie disponuoja dideliais pinigų ištekliais, tuomet situacija keičiasi iš esmės, nes yra investuo-

jami milijonai / milijardai. Apskaičiuotas tikslumas leidžia su patikimumu / tikimybe uždirbti lentelėje nurodytą grąžą.

Apibendrinant sudarytų grafikų tendencijas, su sąlyga, kad būtų sudaryti tie patys ML ir tradiciniai LR modeliai kitomis minutėmis, buvo pastebėta, kad RBVP atveju didžiausia grąža ir modelių tikslumai būtų fiksuojami per pirmąsias 10 minučių. Pramonės produkcijos atveju – skirtingiems scenarijams nuo 33 iki 45 min. Preliminarių duomenų VKI atveju – nuo 33 iki 45 min., o VKI, išskyrus energiją, maistą, alkoholį ir tabaką – tarp 9 ir 23 min. Tokio tipo analizės leidžia investuotojams rasti geriausią pardavimo momentą pagal grąžą atsižvelgiant į numatomų modelių tikslumą.

Apibendrinant tyrimų sąsajas su susijusiomis teorijomis, t. y. fundamentalios analizės ir finansų elgsenos teorijomis, galima sakyti, kad ne tik pavyko sukurti sėkmingus prognozavimo modelius, kuriais siekiama išprognuoti EURO STOXX 50 akcijų grąžą, bet ir praplėsti šių teorijų tyrimų lauką būtent per makroekonominių rodiklių netikėtumo reiškinių.

MOKSLINĖ DISKUSIJA

Šiuo disertaciniu tyrimu siekiama išspręsti dvi problemas. Pirma, užpildyti spragą, aiškinant makroekonominių rodiklių netikėtumo reiškinių esmę. Antra, papildyti kitų tyrimų bandymus išprognuoti akcijų grąžą euro zonos rinkoje, atsižvelgiant į makroekonominių rodiklių netikėtumus, įtraukiant ne tik tradicinius, tačiau ir mašininio mokymosi metodus.

Išanalizavus makroekonominių rodiklių netikėtumų poveikio akcijų grąžoms tyrimus pastebėta, kad mokslininkai labai nedaug nagrinėja makroekonominio rodiklio netikėtumo, tokio kaip reiškinių, kilmės teorijas. Daugiausiai mokslininkai (Gurgul H., Wójtowicz T. (2014), Gupta R., Reid M. (2012), Harju K., Hussain S.M. (2011), Hussain S.M. (2010)) savo tyrimuose užsimena apie efektyvios rinkos hipotezės teoriją ir modeliavimą atlieka, naudodami įvykių studijų metodologiją, papildomai atlikdami ir ARMA – GARCH modelius. Kiti tyrėjai (Alexiou C., Vogiazas S., Taqvi A. (2018), Cakan E., Gupta R. (2017), Nadleri D., Schmidt A.B. (2016)) užsimena apie turto kainos arbitražo teoriją ir turto kainos modelio teoriją bei modeliams atlikti naudoja regresijos lygtį, ARMA-GARCH ir GJR-GARCH metodus. Treti autoriai užsimena apie fundamentalios analizės teoriją (Gurgul H., Wójtowicz T. (2014)) ir modeliams atlikti naudoja įvykių studijų metodologiją. Ketvirtieji tyrėjai savo darbuose išvis neužsimina

apie jokiais teorijas, o modeliams atlikti naudoja jau paminėtus metodus.

Šiame tyrime makroekonominių rodiklių netikėtumo reiškinys ir su juo susiję tyrimai yra suprantami ir aiškinami, atsižvelgiant į tris žymias teorijas: tai yra fundamentalios analizės teorija, efektyvios rinkos hipotezės teorija ir finansų elgsenos teorija. Išanalizavus šių teorijų principus paaiškėjo, kad jie glaudžiai siejasi su makroekonominių rodiklių netikėtumo reiškiniumi, jo apskaičiavimo principu. Atlikus šių teorijų tyrimų ribotumų analizę ir nustatčius sąsajas su makroekonominių rodiklių netikėtumo tyrimais įžvelgiama, kad fundamentalios analizės teorijos tyrimai gali būti praplečiami, analizuojant VP grąžą ne mėnesio, bet dienos, minučių ir kitu dažnumu. Taip pat galima praplėsti fundamentalios analizės ir ERH teorijų suvokimą ir į tyrimus įtraukti ne tik faktines rodiklių reikšmes, bet ir prognozes reikšmes, kurios bent iš dalies atspindėtų rinkos lūkesčius, kurie yra svarbi dedamoji, parodanti finansų rinkos dalyvių psichologinę būklę. Pastebima, kad finansų elgsenos tyrimai gali būti praplečiami, analizuojant ne tik tekstinę informaciją, kuria remiantis kuriami sentimentų rodikliai ir modeliuojamas jų poveikis akcijų grąžai, bet ir paimant makroekonominius rodiklius.

Atlikus empirinį tyrimą paaiškėjo, kad geresnės nei tikėtasi naujienos apie RBVP teigiamai veikia EURO STOXX 50 grąžą. Panašius rezultatus skirtingose rinkose (JAV, ES, Pietų Afrikos respublika), gavo mokslininkai: Kurov K., Sancetta A. ir kt. (2019), Alexiou, Vogiazas ir Taqvi (2018), Nadleri, ir Schmidt (2016), Miao, Ramchander ir Zumwalt (2014), Gupta ir Reid (2012) Harju ir Hussain (2011), tačiau determinacijos koeficientų palyginti negalima, nes tyrėjai vienu metu tyrė ne vieną, o kelis rodiklius arba iš viso neskaičiavo šių determinacijos koeficientų.

Gauti pramonės produkcijos modelių parametrai rodo, kad geresnės nei tikėtasi naujienos apie pramonės gamybą teigiamai veikia akcijų grąžą. Panašius rezultatus skirtingose rinkose (JAV ir Lenkija) gavo mokslininkai: Kurov K., Sancetta A. ir kt. (2019), Gurgulas ir Wójtowicz (2014) bei Harju ir Hussainas (2011), tačiau priešingus rezultatus gavo mokslininkai Nadleri ir Schmidt (2016). Determinacijos koeficientų palyginti negalima, nes tyrėjai vienu metu tyrė ne vieną, o kelis rodiklius arba išvis neskaičiavo šių determinacijos koeficientų.

Gauti preliminarinių duomenų VKI modelių koeficientai rodo, kad geresnės nei tikėtasi naujienos apie preliminarinius VKI duomenis neigiamai veikia akcijų grąžą. Skirtinga situacija matoma su rodikliu VKI, išskyrus energiją, maistą, alkoholį ir tabaką. Čia mažesnė nei tikėtasi netikėtumo reikšmė daro teigiamą poveikį EURO STOXX 50 akcijų grąžai. Lyginti šių rodiklių modelių rezultatus su kitais tyrėjais negalima, nes

atlikta teorinė analizė neparodė nė vieno tyrėjo, modeliuojančio akcijų grąžą pagal šių rodiklių netikėtumus.

Minėtuose tyrimuose mokslininkai naudojo tradicinius metodus akcijų grąžai modeliuoti. Tuo tarpu šiame tyrime buvo panaudoti ir mašininio mokymosi metodai, kurie, kaip parodė modelių palyginimų lentelės, 2–3 kartus viršija tradicinio regresijos metodo tikslumą.

Pereinant prie išsikeltų tyrimo hipotezių rezultatų diskusijos, galima dalinai priimti pirmąją hipotezę, sakančią, kad makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis tradiciniais metodais. Šiame tyrime buvo sudaryta 133 tiesinės regresijos, 5 daugianarės, kurios reprezentavo tradicinių metodų modelius. Iš jų tik 5 tiesinės regresijos modeliai atitiko visus tyrime išsikeltus kriterijus ir prielaidas. Verta paminėti, kad regresijos modelių galiausiai galėjo būti ir daugiau, tačiau tyrime buvo išsikelti papildomi kriterijai, kuriais remiantis buvo atfiltruoti tik geriausiai EURO STOXX 50 grąžą nusakantys regresijos modeliai. Šiame tyrime likusiems 5 regresijos modeliams buvo norima sukurti ir GARCH modelius, tačiau nebuvo aptikta ARCH efektų.

Antrąją tyrimo hipotezę, sakančią, kad makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis mašininio mokymosi metodais, galima priimti. Su tais pačiais 5 likusių regresijos modelių duomenų rinkiniais, sudarius mašininio mokymosi modelius, buvo gauti logiški ir validūs rezultatai.

Trečiąją tyrimo hipotezę, teigiančią, kad mašininio mokymosi metodai, palyginus su tradiciniais metodais, leidžia sukurti tikslesnius makroekonominių rodiklių netikėtumų poveikio akcijų grąžai prognozavimo modelius, galima priimti. Gauti empirinio tyrimo rezultatai rodo, kad mašininio mokymosi modelių tikslumas yra 2–3 kartus didesnis, o paklaidos 10 kartų mažesnės nei tradicinių modelių.

Šis tyrimas taip pat turėjo ribotumą, kuriuos autorius nori paminėti. Paprastai akcijų grąžą veikia daug reiškinių, tačiau šiame tyrime pasirinktas tik makroekonominių rodiklių netikėtumo reiškinys su tais rodikliais, kurie yra lengvai išmatuojami. Tokiu atveju neįvertinami daugelis kitų: politiniai, socialiniai, technologiniai ir t. t., kurie, autoriaus supratimu, galėtų iš esmės pakeisti tyrimo rezultatus, t. y. gautus modelius.

45 minučių intervalas šiame tyrime buvo pasirinktas, siekiant išvengti kitų makroekonominių rodiklių realizacijos poveikio, tačiau neretai kiti mokslininkai to nepaiso. Todėl būtų galima atlikti tyrimą ir žiūrėti, kokie rezultatai gaunami, analizuojant ne 45 minutes, o valandą ar daugiau.

Tyrimo laikotarpis taip pat turi įtakos gautiems rezultatams. Nors tyrimo apimtis ir yra 12 metų, tačiau pačių rodiklių realizacija vyksta ne taip ir dažnai – kartą per mėnesį. Senesnių nei 2008 m. duomenų gauti nepavyko, kas taip pat yra šio tyrimo ribotumas, nes:

- » neleidžia įvertinti, kaip kito akcijų grąža prieš finansų krizę;
- » mažiau duomenų, kas daro prognozavimo modelius nestabilius ir mažiau patikimus;
- » mažiau galimybių sudaryti daugiau modeliavimo scenarijų, pavyzdžiui, kokią poveikį makroekonominių rodiklių netikėtumai turėjo prieš finansų krizę ir po jos.

IŠVADOS

1. Šiame tyrime makroekonominių rodiklių netikėtumo reiškinys ir su juo susiję tyrimai yra suprantami ir aiškinami trijų didelių teorijų požiūriu aspektu: fundamentalios analizės teorijos, efektyvios rinkos hipotezės teorijos ir finansų elgsenos teorijos. Atlikus šių teorijų tyrimų ribotumą analizę ir nustačius sąsajas su makroekonominių rodiklių netikėtumo tyrimais išvelgiama, kad fundamentalios analizės teorijos tyrimai gali būti praplečiami, prognozuojant VP grąžą ne mėnesio, bet dienos, minučių ir kitu dažnumu. VP grąžų prognozavimas per trumpą laiko tarpą padėtų investuotojams ir mokslininkams tiksliau suprasti, kaip kinta akcijų grąža ir kaip greitai ji prisitaiko prie makroekonominių rodiklių netikėtumų, o tai padidintų uždarbio galimybes. Taip pat galima praplėsti ar modifikuoti fundamentalios analizės ir ERH teorijų suvokimą ir į tyrimus įtraukti ne tik faktines, bet ir prognozinės rodiklių reikšmes, kurios bent iš dalies atspindėtų rinkos lūkesčius, kurie yra svarbi dedamoji, parodanti finansų rinkos dalyvių psichologinę būklę. Prognozinės rodiklių reikšmės kaip kintamojo panaudojimas praplėstų esamus tyrimus ir leistų tyrėjams aiškiau suprasti, kaip VP grąža priklauso nuo psichologinių aspektų, o tai didina uždarbio galimybes. Galiausiai pastebima, kad finansų elgsenos tyrimai gali būti praplečiami, analizuojant ne tik tekstinę informaciją, kuria remiantis kuriami sentimentų rodikliai ir modeliuojamas jų poveikis akcijų grąžai, bet įtraukiant ir makroekonominius rodiklius. Tai praplėstų finansų elgsenos teorijos tyrimų lauką ir atneštų naujų kryptių, impulsų praktikai vystyti.

2. Makroekonominių rodiklių netikėtumų poveikiui akcijų grąžoms modeliuoti dažniausiai naudojami regresijos analizės (mažiausių kvadratų), GJR-GARCH, ARMA-GARCH, SV, GJD, ES, BVAR metodai. Iš jų dažniausiai sutinkami yra regresijos analizės mažiausių kvadratų metodas ir ARMA-GARCH metodai. Pastebima, kad mašininio mokymosi metodai panašios tematikos tyrimuose nebuvo naudojami, bet užtat yra naudojami šiame tyrime, todėl yra naujovė tokio tipo tyrimuose. Tradicinių ir kartu mašininio mokymosi metodų panaudojimas leidžia objektyviau įvertinti gautus tyrimų rezultatus, palyginti gautų prognozavimo modelių rezultatus tarpusavyje ir pasirinkti geriausią prognozavimo modelį.

3. Sudaryta makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliavimo metodika, apimanti tris duomenų analizės ir modeliavimo etapus. Pirmajame etape atliekami duomenų paruošimo analizei ir modeliavimo darbai, koreliacinių matricų sukūrimas pagal penkis scenarijus, paprastųjų regresijų modelių sukūrimas

ir jų atranka pagal kriterijus ir prielaidas. Antrajame etape keliamas klausimas, ar po pirmojo etapo likusius regresijos modelius galima išplėsti, įtraukiant daugiau makroekonominių rodiklių, taip gaunant daugianarius regresijos modelius ir po to juos patikrinant pagal I etapo išsikeltus kriterijus ir prielaidas. Į trečią tyrimo etapą papuola visi tiesiniai regresijos modeliai po pirmojo etapo ir visi daugianariai regresijos modeliai po antrojo etapo, kurie tenkina visus kriterijus ir prielaidas. Trečiojo etapo pirmajame žingsnyje esami regresijos modeliai tikrinami, ieškant ARCH efektų, ir jei jų regresijos modeliai turi, sudaromi GARCH modeliai. Sukūrus tradicinius modelius, tiems patiems duomenų rinkiniams yra kuriami mašininio mokymosi modeliai, kurių tikslumas ir paklaidos palyginamos su tradiciniais modeliais. Trečiojo etapo pabaigoje atliekama modelių tikslumo ir EURO STOXX 50 indekso grąžos sąryšio analizė 45 minučių laiko eilutėje.

4. Atlikus mašininio mokymosi metodų taikymo, modeliuojant akcijų kainą ir grąžą, analizę pastebėta, kad regresijoms tipo uždaviniams mokslininkai dažniausiai taiko sprendimų medžio, atsitiktinio miško, tiesinės regresijos, GBR ir giliojo mokymosi metodus. Pagrindinis skirtumas tarp tradicinių ir mašininio mokymosi metodų yra tas, kad tradiciniu metodu siekiama kuo labiau sumažinti vidutinę kvadratinę paklaidą ir rasti ryšių tarp kintamųjų reikšmingumą, tuo tarpu mašininio mokymosi metodo tikslas yra pasiekti didžiausią testo rinkinio tikslumą. Šis atskleidimas leidžia mokslininkams ir investuotojams geriau suvokti, kada geriau naudoti tradicinius, o kada mašininio mokymosi metodus.

5. Atlikus parengtos makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliavimo metodikos, taikant tradicinius metodus, patikrinimą, dalinai priimta hipotezė, kad makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis tradiciniais metodais. Dalinai todėl, kad iš visų tyrime pasirinktų makroekonominių rodiklių (26) pagal įvairius faktinius duomenų scenarijus tik kelių rodiklių poveikis EURO STOXX 50 grąžai buvo nustatytas, kaip statistiškai reikšmingas. Patikrinimo metu iš viso buvo sudaryti 133 tiesiniai ir 5 daugianariai regresijos modeliai. Iš jų tik 5 tiesiniai regresijos modeliai atitiko visus išsikeltus kriterijus ir regresijos analizės prielaidas. Šie modeliai buvo tikrinami, ieškant ARCH efektų, tačiau jie nebuvo aptikti. Remiantis gautais rezultatais ir analizuojant, kas galėjo lemti mažą statistiškai patikimų prognozavimo modelių skaičių, buvo prieita prie tokių nuomonių: per mažas analizavimo laiko intervalas minutėmis; netinkama makroekonominio rodiklio netikėtumo formulė; netinkami metodai; makroekonomi-

nių rodiklių netikėtumai nedaro tokios didelės įtakos akcijų grąžai, kaip tikėtasi ir kt. Gauta išvada įspėja investuotojus ir mokslininkus atsargiai tikėtis gerų prognozavimo modelių rezultatų panašios tematikos tyrimuose euro zonos akcijų rinkoje, naudojant panašią tyrimo metodiką ir taikant tradicinius metodus.

6. Atlikus parengtos makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliavimo metodikos, taikant mašininio mokymosi metodus, patikrinimą, hipotezę, kad makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis mašininio mokymosi metodais, buvo priimta. Su tais pačiais tradicinių modelių duomenų rinkiniais sudarius mašininio mokymosi modelius, buvo gauti validūs rezultatai. Idėja panaudoti mašininio mokymosi metodus šiame tyrime pasiteisino. Tokiu atveju rekomenduojama tęsti tyrimą ta pačia tematika, bet kaip atskaitos tašką (bazinius) prognozavimo modelius sukurti remiantis ne tradiciniais metodais, bet mašininio mokymosi metodais. Mokslininkams ir investuotojams tai gali būti papildomas postūmis domėtis kitokiais, inovatyvesniais metodais prognozuojant akcijų grąžą.

7. Trečioji tyrimo hipotezė, teigianti, kad mašininio mokymosi metodai, palyginus su tradiciniais metodais, leidžia sukurti tikslesnius makroekonominių rodiklių netikėtumų poveikio akcijų grąžai prognozavimo modelius, yra priimta. Mašininio mokymosi modelių tikslumas yra 2–3 kartus didesnis, o paklaidos 10 kartų mažesnės nei tradicinės tiesinės regresijos modelių. Remiantis gautais tyrimo rezultatais, rekomenduojama modeliuoti akcijų grąžą, remiantis ne tik tradiciniais, bet ir mašininio mokymosi metodais. Atlikus modelių tikslumo ir EURO STOXX 50 grąžos sąryšio analizę laiko eilutėje, rekomenduojama pardavimo sandorius atlikti taip: RBVP atveju – per pirmas 10 minučių, kur 4 minutę galima gauti patikimiausią grąžą; pramonės produkcijos atveju pagal du scenarijus – nuo 33 iki 45 minučių, kur patikimiausia grąža gaunama atitinkamai 40 ir 42 minutę; preliminarių duomenų VKI atveju – nuo 33 iki 45 minučių, kur patikimiausia grąža gaunama 36 minutę; VKI, išskyrus energiją, maistą, alkoholį ir tabaką, – tarp 9 ir 23 minučių, kur patikimiausia grąža užfiksuota 10 minutę.

Tolesni tyrimai galėtų būti vykdomi šiomis kryptimis:

1. Siekiant panaikinti šio tyrimo ribotumus:

a) Akcijų grąžą paprastai veikia daug reiškinų, tačiau šiame tyrime pasirinktas tik makroekonominių rodiklių netikėtumo reiškinys, darant prielaidą, kad niekas

kitas, išskyrus minėtą reiškinį, neveikia pasirinkto akcijų indekso. Siekiant panaikinti šį ribotumą, galima būtų pasirinkti ne vieną, o kelis reiškinius, kaip nepriklausomus kintamuosius.

b) Tyrime daroma prielaida, kad makroekonominių rodiklių netikėtumų poveikis nesitęsia ilgiau nei 45 minutes. Siekiant papildyti esamus rezultatus, galima būtų prailginti šį laiką ir pažiūrėti, kokie rezultatai gaunami.

c) Nors tyrimo laikotarpis ir yra reprezentatyvus – 12 metų, tačiau patys makroekonominiai rodikliai pasirodo vidutiniškai maždaug kas mėnesį. Todėl prognozavimo modeliai nėra sudaryti iš daug duomenų, kas gali paveikti modelių tikslumo pasikeitimą, įtraukiant naujų duomenų. Taigi, siekiant tęsti tyrimus panašia tematika, būtinai rekomenduojama pridėti naujausius duomenis. Galbūt naudotis kitomis (ne „Bloomberg“) duomenų bazėmis, kur duomenys būtų ilgesnio termino, nes šiame tyrime senesnių, nei 2008 metų duomenų gauti nepavyko.

d) Prognozavimo modeliai sukurti ne akcijai ar indeksui, kuriais yra prekiaujama akcijų biržoje, o etalonui (akcijų indeksui EURO STOXX 50). Etalonais paprastai nėra prekiaujama akcijų biržose, todėl priklausomąjį kintamąjį būtų galima pasirinkti ne akcijų rinkos etaloną, o biržoje prekiaujančius fondus, akcijas ar kt. Taip gautus tyrimo rezultatus galima būtų iš karto panaudoti investicinėje veikloje.

2. Šeštoji šio tyrimo išvada parodė, kad idėja panaudoti mašininio mokymosi metodus pasiteisino. Todėl rekomenduojama tęsti tyrimą ta pačia tematika, bet kaip atskaitos tašką bazinius prognozavimo modelius sukurti remiantis ne tradiciniais metodais, bet mašininio mokymosi metodais. Tokiu atveju tikėtina, kad bazinių modelių, kurie tenkintų visus išsikeltus kriterijus ir prielaidas, būtų daugiau, nei šiame tyrime (penkta šio tyrimo išvada parodė, kad taikant tradicinius metodus, bazinių modelių galiausiai liko penki).

3. Paskutinė autoriaus idėja, kaip būtų galima tęsti tyrimą, tai – keisti modeliaavimo logiką ir duomenų struktūrą. Rekomenduojama sudaryti nepertraukiamas laiko eilutes (kas minutę, visus 12 ar daugiau metų), pasirinkti ne vieną, o du priklausomus kintamuosius, kur vienas galėtų būti kaip atskaitos taškas, matuojant kito reakciją į makroekonominių rodiklių netikėtumus. Nepertraukiamos laiko eilutės leistų nagrinėti akcijų grąžą ir prieš makroekonominių rodiklių netikėtumus. Patys tyrimo metodai taip pat keistųsi, ir, ko gero, būtų rasti ARCH efektai, tad būtų galimybė sudaryti GARCH modelius bei panaudoti kitus ML modelius, tokius kaip RNN ir LSTM, ir galiausiai praplėsti vidutiniškai stiprios ERH teorijos tyrimus.

LITERATŪROS SĄRAŠAS

1. Abed R.E., Zardoub A. (2019). Exploring the nexus between macroeconomic variables and stock market returns in Germany: An ARDL Co-integration approach. *Theoretical and Applied Economics* Volume XXVI, No. 2(619), Summer, pp. 139–148.
2. Akcijų rinkų kapitalizacija pagal šalis. GlobalEconomy. Prieiga per internetą: https://www.theglobaleconomy.com/rankings/stock_market_capitalization_dollars/MSCI-Frontier-Markets/ ; <https://data.worldbank.org/>.
3. Alam A., Rashid k. (2014). Time Series Analysis of the Relationship between Macroeconomic Factors and the Stock Market Returns in Pakistan. *Journal of Yasar University*, 9(36) 6261 – 6380.
4. Alam N. (2017). Analysis of the impact of select macroeconomic variables on the Indian stock market: A heteroscedastic cointegration approach. *BEH – Business and Economic Horizons*. Volume 13 | Issue 1 |pp.119–127. DOI: <http://dx.doi.org/10.15208/beh.2017.09>
5. Alexiou C., Vogiazas S., Taqvi A. (2018). Macroeconomic announcements and stock returns in US portfolios formed on operating profitability and investment. *Investment Management and Financial Innovations*, Volume 15, Issue 1. DOI: 10.21511/imfi.15(1).2018.08
6. Altinkilic O., Hansen R.S., Ye L. (2015). Can analysts pick stocks for the long-run?, *Journal of Financial Economics*. Prieiga per internetą: <http://ssrn.com/abstract=1787707>
7. Andrade L.L., Santos N.S.S. (2017). Accounting information and stock returns: evidences from Brazil. *International journal of management, accounting and economics*. Vol. 4, No. 5.
8. Atsitiktinio miško modelio klasė, jos parametrai ir atributai. Prieiga per internetą: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html>
9. Baker M., Wurgler J. (2007). Investors Sentiment in the Stock Market // *Journal of Finance*, Vol. 21, No. 2, p. 1645–1680. – ISSN 1540–6261.
10. Balaji, M. (2009) Customer satisfaction with Indian mobile services. *The IUP Journal of Management Research*. Vol. 8, no. 10.
11. Banik S., Khan A. F. M. K., Anwer M. (2014). Hybrid Machine Learning Technique for Forecasting Dhaka Stock Market Timing Decisions. *Hindawi Publishing Corporation Computational Intelligence and Neuroscience* Volume 2014, Article

ID 318524, 6 pages <http://dx.doi.org/10.1155/2014/318524>.

12. Baranes A., Palas R. (2019). Earning movement prediction using machine learning-support vector machines (SVM). *Journal of Management Information and Decision Sciences*. Volume 22, Issue 2, 2019, p. 36–53.
13. Barghouthi S.A., Ehsan A. (2017). Market efficiency analysis of Amnan stock exchange through moving average method. *International journal of business and society*, Vol. 18 S3, 531–544.
14. Botunac I., Panjkota A., Matetic M. (2019). The Importance of Time Series Data Filtering for Predicting the Direction of Stock Market Movement Using Neural Networks, *Proceedings of the 30th DAAAM International Symposium*, pp.0886-0891, B. Katalinic (Ed.), Published by DAAAM International, DOI: 10.2507/30th.daaam.proceedings.123.
15. Brannon I. (2006). Remembering the Man Behind Rational Expectations. *Regulation*, Vol. 29, No. 1, pp. 18–22, Spring, Available at SSRN: <https://ssrn.com/abstract=898197>
16. Cakan E., Gupta R. (2017). Does the US macroeconomic news make the South African stock market riskier? *The Journal of Developing Areas* Volume 51 No. 4.
17. Celebi K., Honig M. (2018). Dynamic macroeconomic effects on the German stock market before and after the financial crisis. *Working Paper Series: Business and Law*, No. 13. Prieiga per internetą: <http://hdl.handle.net/10419/179124>.
18. Celebi K., Honig M. (2019). The Impact of Macroeconomic Factors on the German Stock Market: Evidence for the Crisis, Pre- and Post-Crisis Periods. *Int. J. Financial Stud.* 7, 18; doi:10.3390/ijfs7020018
19. Chamdrashekar R., Sakthivel P., Sampath T., Chittedi K.R. (2018). Macroeconomic variables and stock prices in emerging economies: A panel analysis. *Theoretical and Applied Economics* Volume XXV, No. 3(616), Autumn, pp. 91–100.
20. Chandra A. (2008). Decision-making in the stock market: incorporating psychology with finance. Paper No. 21288. Prieiga per internetą: <https://mpira.ub.uni-muenchen.de/21288/>.
21. Chen Y, Zhao H, Li Z, Lu J (2020) A dynamic analysis of the relationship between investor sentiment and stock market realized volatility: Evidence from China. *PLoS ONE* 15(12): e0243080. <https://doi.org/10.1371/journal.pone.0243080>.
22. Chen J., Liu Y., Lu L., Tang Y. (2015). Investor attention and macroeconomic news announcements: evidence from stock index futures. *The Journal of Futures Markets*, Vol. 36, No. 3, 240–266. DOI: 10.1002/fut.21727.
23. Clark A. (2015). Embodied Prediction. In T. Metzinger & J. M. Windt (Eds). *Open*

- MIND: 7(T). Frankfurt am Main: MIND Group. doi: 10.15502/9783958570115.
24. Cleary W. S., Atkinson H. J., Drake P. P. (2013). Market Efficiency. Equity and Fixed Income. p. 119-151.
 25. Cocianu C.L., Grigoryan H. (2016). Machine learning techniques for stock market prediction. A case study of OMV Petrom. Economic Computation and Economic Cybernetics Studies and Research, Issue 3, Vol. 50, p. 63–82.
 26. Crevier D. (1993). The Tumultuous History of the Search for Artificial Intelligence. 1993. Basic Books, New York, NY. 432 pages. ISBN: 0-465-02997-3.
 27. Damodaran A., 2012, Investment Valuation: Tools and Techniques for Determining the Value of Any Asset, John Wiley & Sons, Inc., New York.
 28. Das A.R., Panja A.R.. (2019). Understanding Behavioral Finance. Conference: 5th Management Doctoral Colloquium. Department of Management Studies, National Institute of Technology Silchar.
 29. DeBondt, W., Forbes, W., Hamalainen, P. and Gulnur Muradoglu, Y. (2010), “What can behavioural finance teach us about finance?”, *Qualitative Research in Financial Markets*, Vol. 2 No. 1, pp. 29–36. <https://doi.org/10.1108/17554171011042371>.
 30. Deng S., Huang Z., Zhao A. (2018). The interaction between microblog sentiment and stock returns: an empirical examination. *MIS Quarterly* Vol. 42 No. 3, pp. 895-918/September. DOI: 10.25300/MISQ/2018/14268.
 31. Erol A.F., Aytikin S. (2019). The role of macroeconomic indicators on BIST 100 stock price index: evidence from Turkey. *Global Journal of Economics and Business*. Volume: 8 Issue: 15 (61–68).
 32. Fama E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*. *Jungtinės Amerikos Valstijos*, 25 (2), p. 383–418. Prieiga per internetą: <https://www.jstor.org/stable/2325486?origin=JSTOR-pdf>
 33. Fama E. F. (1991). Efficient Capital Markets. *Journal of Finance*, nr. 46 (5), p. 1575–1617.
 34. Fama E. F., French K. R. (2015). A five-factor asset pricing model. *Journal of Financial Economics* 116 (1): 1–22.
 35. Fama, E.F., (1965). The behavior of stock market prices. *Journal of Business*, Vol.38, No. 1, 34-105.
 36. Ferrara D. Bacon F. (2014). Merger and acquisition announcements effect on acquiring company's stock price: a test of market efficiency. *Proceedings of the Academy of Accounting and Financial Studies*, Volume 19, Number 1.
 37. Filip B.F (2016). Determinants of economic growth in EU 28 countries before, during and after the recent crisis. *Annals of the University of Oradea, Economic*

Science Series . Vol. 25 Issue 2, p76-86. 11p.

38. Fischer, R. and Gerhardt, R. (2007) Investment Mistakes of Individual Investors and the Impact of Financial Advice. Working Paper, European Business School, London.
39. Forson J.A., Janrattanagul A. (2013). Selected Macroeconomic Variables and Stock Market Movements: Empirical evidence from Thailand. Vol. 8 Issue 2, 154-174. DOI: 10.5709/ce.1897-9254.138
40. Forstater, M. (2007) Technology as transsubjective structural context: the uncertainty of investor expectations. *Review of Political Economy*. Vol. 19, no. 3.
41. Frijns B., Indriawan I., Tourani-Rad A., Tse Y. (2019). Market Quality around Macroeconomic News Announcements: Evidence from the US and Canadian Markets. *International Review of Finance*, 19:3, pp. 575–612, DOI: 10.1111/irfi.12190.
42. Fürnkranz J. (2011) Decision Tree. In: Sammut C., Webb G.I. (eds) *Encyclopedia of Machine Learning*. Springer, Boston, MA. https://doi.org/10.1007/978-0-387-30164-8_204.
43. Garg K., Kalra R. (2018). Impact of macroeconomic factors on indian stock market. *Parikalpana - KIIT Journal of Management*, Vol.14(I). DOI: 10.23862/kiit-parikalpana/2018/v14/i1/173248.
44. Ghahfarrokhi A.H., Shamsfard M. (2020). Tehran stock exchange prediction using sentiment analysis of online textual opinions. *Intell. Sys. Acc. Fin. Mgmt*; 27:23–38.
45. Giri A.K., Pooja J. (2017). The impact of macroeconomic indicators on indian stock prices: an empirical analysis. *Studies in Business and Economics* no. 12(1). DOI 10.1515/sbe-2017-0005.
46. Gradiento modelio klasė, jos parametrai ir atributai. Prieiga per internetą: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingRegressor.html>.
47. Graham B., and D. L. Dodd. (1934). *Security Analysis*. New York, NY: McGraw-Hill.
48. Grimm, R. C. (2012). Fundamental Analysis as a Traditional Austrian Approach to Common Stock Selection. *The Quarterly Journal of Austrian Economics* 2, 221-236.
49. Gunduz H., Cataltepe Z., Yaslan Y. (2017). Stock daily return prediction using expanded features and feature selection. *Turkish Journal of Electrical Engineering & Computer Sciences*. *Turk J Elec Eng & Comp Sci* 25: 4829- 4840. doi:10.3906/elk-1704-256.

50. Gupta R., Reid M. (2012). Macroeconomic Surprises and Stock Returns in South Africa. Stellenbosch Economic Working Papers: 05/12. Prieiga per internetą: <https://ideas.repec.org/p/sza/wpaper/wpapers157.html>.
51. Gurgul H., Wójtowicz T. (2014). The Response of Intraday ATX Returns to U.S. Macroeconomic News. *Finance a úvěr-Czech Journal of Economics and Finance*, 65, 2015, no. 3.
52. Ha'jek P. (2016). Combining bag-of-words and sentiment features of annual reports to predict abnormal stock returns. *Neural Comput & Applic* 29:343–358 <https://doi.org/10.1007/s00521-017-3194-2>.
53. Harju K., Hussain S.M. (2011). Intraday Seasonalities and Macroeconomic News Announcements. *European Financial Management*, Vol. 17, No. 2, 2011, 367–390 doi: 10.1111/j.1468-036X.2009.00512.x
54. Hashim S.L.M., Mohammad H.R., Rosly A.M. (2018). The Impact of Macroeconomic Variables towards Malaysian Stock Market. *Global Business and Management Research: An International Journal* Vol. 10, No. 3 (Special Issue).
55. Heston S.L., Sinha N. R (2017). News vs. Sentiment: Predicting Stock Returns from News Stories. *Financial Analysts Journal | A Publication of CFA Institute*, Volume 73 Number 3.
56. Ho S.Y. (2018). Macroeconomic determinants of stock market development in South Africa. *International Journal of Emerging Markets*. Doi: <https://doi.org/10.1108/IJoEM-09-2017-0341>.
57. Hurwitz J., Kirsch D. (2018). *Machine Learning For Dummies®*, IBM Limited Edition. Published by John Wiley & Sons, Inc. ISBN: 978-1-119-45494-6 (ebk).
58. Hussain S.M. (2010). Simultaneous monetary policy announcements and international stock markets response: an intraday analysis. *Bank of Finland Research Discussion Papers* 8.
59. Yen G., Lee C. F. (2008). Efficient market hypothesis (EMH): Past, present and future, *Review of Pacific Basin Financial Markets and Policies* 11(2): 305–329.
60. Jareno F., Negrut L. (2016). US Stock Market And Macroeconomic Factors. *The Journal of Applied Business Research*. Volume 32, Number 1.
61. Ji S., Wang X., Zhao W., Guo D. (2019). An Application of a Three-Stage XGBoost-Based Model to Sales Forecasting of a Cross-Border E-Commerce Enterprise. *Mathematical Problems in Engineering*, p.1-15, Article ID 8503252, DOI: <https://doi.org/10.1155/2019/8503252>.
62. Jose. B., Suresh T.S. (2017). Weak form efficiency of indian stock market: an empirical analysis. *International journal of research in commerce & management*.

63. Jurkšas L., Paškevičius A. (2017). The relationship between macroeconomy and asset prices: long run causality evidence from Lithuania. organizations and markets in emerging economies, VOL. 8, No. 1(15).
64. Kahneman D., Tversky A. (1979). Prospect Theory: An Analysis of Decision Under Risk // *Econometrica*. Vol. 47. p. 263-291.
65. Kaplanski, G., Levy, H. (2008). Sentiment and Stock Prices: The Case of Aviation Disasters (July 1, 2008). *Journal of Financial Economics (JFE)*, Vol. 95, No. 2, pp. 174-201, February 2010, Available at SSRN: <https://ssrn.com/abstract=1084533>.
66. Karathanasopoulos A., Mitra S., Skindilias K., lo C.C. (2017). Modelling and Trading the English and German Stock Markets with Novelty Optimization Techniques. *Journal of Forecasting, J. Forecast.* 36, 974–988 DOI: 10.1002/for.2445.
67. Kartašova J. (2012). Iracionalią investuotojų elgseną formuojantys veiksniai ir jų poveikis priimamiems sprendimams Lietuvos akcijų rinkoje (Daktaro disertacija). Kaunas. Vytauto Didžiojo universitetas.
68. Kartašova J. (2016). Racionalumo transformacijos: finansų elgsenos teorija ir praktika (Monografija). Vilnius. Mykolo Romerio universitetas.
69. Kartašova, J., Venclauskienė, D. (2014). Valuation of fundamental analysis reliability in stock pricing: theoretical approach. *Business and Management*, Vilnius, 225-262.
70. Klačok J., Kvietkauskienė A. (2018). Fundamentinės ir techninės analizės taikymas formuojant investicinį portfelį. *Verslas XXI amžiuje*, vvf.2017.020, 1-12.
71. Klimašauskienė, D., Moščinskienė V. (1998). Lietuvos kapitalo rinkos efektyvumo problema. *Pinigų studijos*, nr. 2, p. 25-34.
72. Kozel V. (2015). Finansinės elgsenos principų taikymo investiciniams sprendimams priimti teoriniai aspektai. 18-osios Lietuvos jaunųjų mokslininkų konferencijos „Mokslas – Lietuvos ateitis“ teminė konferencija, 248.
73. Kurov A., Sancetta A., Strasser G., Wolfe N. H. (2019). Price Drift Before U.S. Macroeconomic News: Private Information about Public Announcements? *Journal of financial and quantitative analysis*. Vol. 54, No. 1, Feb., pp. 449 – 479. doi:10.1017/S0022109018000625
74. Lekavičienė D., Stašys R. (2005) Vertybinių popierių rinkos funkcionavimo prielaidų vertinimas. *Tiltai*, 3, 1-9.
75. Li X., Xie H., Wang R., Cai Y., Cao J., Wang F., Min H., Deng X. (2016). Empirical analysis: stock market prediction via extreme learning machine. *Neural Comput & Applic*, 27:67–78 DOI 10.1007/s00521-014-1550-z.

76. Tiesioginės užsienio investicijos. Lietuvos bankas. Prieiga per internetą: <https://www.lb.lt/lt/tiesiogines-uzsienio-investicijos-lietuvoje-pagal-sali-1>.
77. Lietuvos dirbtinio intelekto strategija. Prieiga per internetą: [https://eimin.lrv.lt/uploads/eimin/documents/files/DI_strategija_LT\(1\).pdf](https://eimin.lrv.lt/uploads/eimin/documents/files/DI_strategija_LT(1).pdf).
78. Livnat, J., Petrovits, Ch. (2009). Investor Sentiment, Post-Earnings Announcement Drift, and Accruals AAA 2009 Financial Accounting and Reporting Section (FARS) Paper, Available at SSRN: <https://ssrn.com/abstract=1262757> or <http://dx.doi.org/10.2139/ssrn.1262757>.
79. Lopez F.J.G., Batyrshin I., Gelbukh A. (2018). Analysis of relationships between tweets and stock market trends. *Journal of Intelligent & Fuzzy Systems* 34. 3337–3347 DOI:10.3233/JIFS-169515.
80. Lv D., Yuan S., Li M., Xiang Y. (2019). An Empirical Study of Machine Learning Algorithms for Stock Daily Trading Strategy. *Hindawi Mathematical Problems in Engineering* Volume, Article ID 7816154, 30 pages <https://doi.org/10.1155/2019/7816154>.
81. Macijauskas L. (2015). Finansų rinkų dalyvių iracionalumu paremta taktinė turto alokacija. VGTU leidyklos Technika. Daktaro disertacija.
82. Mackey A.M., Bacon F.W. (2017). Signaling with issues and repurchases: a test of semistrong form market efficiency. *Journal of Business and Behavioral Sciences*. Vol 29, No 1.
83. Mahajan S., Luthra M. (2013). Efficient market hypothesis in China stock markets. *International journal of research in commerce & manage*. Volume No. 4, issue no. 9.
84. Makroekonominių rodiklių duomenų bazė ir jų aprašymai. Prieiga per internetą <https://www.investing.com/economic-calendar/>
85. Makroekonominių rodiklių duomenų bazė ir jų aprašymai. Prieiga per internetą <https://tradingeconomics.com/calendar#>
86. Malhotra N., Tandon K., Tandon D. (2015). Testing the empirics of weak form of efficient market hypothesis: evidence from Asia-Pacific markets. *The IUP journal of applied finance*, Vol. 21, No. 4.
87. Mallick, C., Bhoi, S.K., Panda, S.K. et al. (2020) An efficient learning algorithm for periodic perceptron to test XOR function and parity problem. *SN Appl. Sci.* 2, 160. <https://doi.org/10.1007/s42452-020-1952-8>.
88. Mallikarjunappa T., Dsouza J.J. (2014) A Study of Quarterly Earnings Announcement and Stock Price Reactions. *IUP Journal of Applied Finance*, (95-106).
89. Mallikarjunappa T., Manjunatha T. (2009). Stock price reactions to dividend announcements. *Journal of management & public policy*. Vol. 1 No. 1 pp 43- 56.

90. Martin S. (2012). Macroeconomic variables and stock market: US review. *IJCSMS International Journal of Computer Science and Management Studies*, Vol / Issue 2231-5268.
91. Mazviona B.W. (2015). Measuring investor sentiment on the Zimbabwe stock exchange. *Asian Journal of Economic Modelling*, 3(2): 21-32.
92. McGurk Z., Nowak A., Hall Joshua. (2020). Stock returns and investor sentiment: textual analysis and social media. *Journal of Economics and Finance*, 44:458–485, <https://doi.org/10.1007/s12197-019-09494-4>.
93. Miao H., Ramchander S., Zumwalt J.K. (2014). S&P 500 index-futures price jumps and macroeconomic news. *The Journal of Futures Markets*, Vol. 34, No. 10, 980–1001. DOI: 10.1002/fut.21627.
94. Mickutė L., Navickaitė D. (2010) Pabaltijo šalių akcijų pelningumus lemiantys fundamentiniai ir psichologiniai veiksniai. *Ekonomikos ir vadybos aktualijos*, p. 166–177.
95. Modelio vizualizavimo įrankis: Prieiga per internetą: <https://netron.app>.
96. Nabipour M., Nayyeri P., Jabani H., Mosavi A., Salwana E., Shahab S. (2020). Deep Learning for Stock Market Prediction. *Entropy*, 22, 840; doi:10.3390/e22080840.
97. Nadleri D., ir Schmidt A.B. (2016). Impact of Macroeconomic Announcements on US Equity Prices: 2009–2013. *Journal of Forecasting*, J. Forecast. 35, 34–42. DOI: 10.1002/for.2359.
98. Nagpal A., Jain M. (2018). Efficient market hypothesis in Indian stock market: a re-examination of calendar anomalies. *Amity Global Business Review Faculty of Management Studies, University of Delhi, Delhi*.
99. Naseem S., Rizwan F., Abbas Z., Rehman M.Z. (2019). Impact of Macroeconomic Variables on Pakistan Stock Market. *The Dialogue*, Volume XIV Number 2.
100. Nasiri M., Nourollahzadeh F.S.N, Hamidian M., Noorifard Y. (2021) Modeling Asset Pricing Using Behavioral Variables: FamaMacbeth Approach. *Iranian Journal of Management Studies (IJMS) 2021*, 14(3): 547-564.
101. Natkevičienė R. Namų ūkių ekonominių lūkesčių ir makroekonominių procesų sąsajų vertinimas Baltijos šalyse: magistro darbas: 62404S112 – *Ekonomika*. – Kaunas: Vytauto Didžiojo 74 universitetas, 2010. – p. 8-10. – URL: http://vddb.laba.lt/fedora/get/LT-eLABa-0001:E.0_2~2010~D_20_100621_115412-09767/DS.005.0.02.ETD.
102. Nawrocki D., Violen F. (2014). Behavioral finance in financial market theory, utility theory, portfolio theory and the necessary statistics: A review, *Journal of Behavioral and Experimental Finance* 2: 10–17.


103. Neuroninio tinklo modelio klasė, jos parametrai ir atributai. Prieiga per internetą: https://keras.io/guides/sequential_model.
104. Nikou M., Mansourfar G., Bagherzadeh J. (2019). Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms. *Intell Sys Acc Fin Mgmt*.26:164–174, DOI: 10.1002/isaf.1459.
105. Norvaiša R., Leipus R. (2004). Finansų rinkos teorijų taikymas. Pinigų studijos. *Ekonomikos teorija ir praktika*, p. 31-54.
106. Nwankpa C.E., Ijomah W., Gachagan A., Marshall S. (2018). Activation Functions: Comparison of Trends in Practice and Research for Deep Learning. arXiv:1811.03378v1 [cs.LG] 8.
107. Ojasalo, J. (2001) Managing Customer Expectations in Professional Services. *Managing Service Quality*, 11, 200-212. <http://dx.doi.org/10.1108/09604520110391379>.
108. Ojasalo, J., (2001). Managing customer expectations in professional services. *Managing service quality*. Vol. 11.
109. Panfil M., Szablewski A., 2013, Dylematy wyceny przedsiębiorstwa (Dilemmas of Company Valuation), Wydawnictwo Poltext, Warszawa.
110. Park S., Lee J., Son Y. (2016). Predicting Market Impact Costs Using Nonparametric Machine Learning Models, p. 1-13, *PLOS ONE* | DOI:10.1371/journal.pone.0150243
111. Pasquariello P. (2014). Prospect Theory and market quality, *Journal of Economic Theory* 149: 276–310.
112. Pierdzioch C., Risse M. (2018). A machine-learning analysis of the rationality of aggregate stock market forecasts. *Int J Fin Econ.*;23: 642–654. DOI: 10.1002/ijfe.1641.
113. Pyo S., Lee J., Cha M., Jang H. (2017). Predictability of machine learning techniques to forecast the trends of market index prices: Hypothesis testing for the Korean stock markets, p.1-17, DOI <https://doi.org/10.1371/journal.pone.0188107>.
114. Pražak T., Stavrek D. (2017). The Relationship Between Stock Market Development and Macroeconomic Fundamentals in the Visegrad Group. *Comparative Economic Research*, Volume 20, Number 3, 10.1515/cer-2017-0017.
115. Regresijos modelio klasė, jos parametrai ir atributai. Prieiga per internetą: https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.LinearRegression.html.
116. Ross, C.K, Frommelt, G, Hazelwood, L. (1987) The role of expectations in patient satisfaction with medical care. *Journal of Health Care Marketing*. Vol. 7, no. 4.
117. Sharma A. (2009). Impact of public announcement of open offer on sharehol-

- ders return: an empirical test for efficient market hypothesis. *The IUP Journal of applied finance*, Vol. 15, No. 11.
118. Shefrin H. (2001) Behavioral Corporate Finance. *Journal of Applied Corporate Finance*, Vol. 14, No. 3, Fall 2001, Available at SSRN: <https://ssrn.com/abstract=288257> or <http://dx.doi.org/10.2139/ssrn.288257>.
 119. Singh G. (2015). The Impact of Macroeconomic Fundamentals on Stock Prices Revised: A Study of Indian Stock Market. *Journal of International Economics*, Volume 6, Issue 2, July-December, pp.78-93.
 120. Singh R., Leepsa N.M., Kushwaha N.N. (2016). Testing the weak form of efficient market hypothesis in carbon efficient stock indices along with their benchmark indices in select countries. *Iranian journal of management studies (IJMS)*. Vol. 9, No. 3. pp. 627-650.
 121. Sloan R.G. (2019). Fundamental Analysis Redux. *American Accounting Association. The accountant review*, 94(2), 363–377. Doi: 10.2308/accr-10652.
 122. Sofat R. (2016). Analyzing the weak form market efficiency and performance of selected indian IT stocks. *Chinniah lakshmiammal educational academy & research. Volume No. 7, issue No.06 (June)* .
 123. Song D., Busogi M., Kim N., Baek A.M.C (2020). Forecasting stock market index based on pattern driven long short-term memory. *Economic Computation and Economic Cybernetics Studies and Research*, Issue 3. P.25-41, DOI: 10.24818/18423264/54.3.20.02.
 124. Song H., Peng D., Huang X. (2020). Incorporating Research Reports and Market Sentiment for Stock Excess Return Prediction: A Case of Mainland China. *Hindawi Scientific Programming Volume*, Article ID 8894757, 7 pages <https://doi.org/10.1155/2020/8894757>.
 125. Sousa A.M., Noriller A.M., Huppes C.M., Lopes A.C.V., Meurer R.M. (2018). Relation between the macroeconomic variables and the stock return in companies of the finance and insurance sector from Latin American stock market. *GCG Georgetown University – Universia*, Vol. 12 Num. 3. DOI 10.3232/GCG.2018.V12.N3.01.
 126. Spahija D., Xhaferi Seadin. (2019). Fundamental and technical analysis of the stock price. *International Scientific Journal “Monte”* DOI : 10.33807/monte.1.201904160.
 127. Sprendimų medžio modelio klasė, jos parametrai ir atributai. Prieiga per internetą: <https://scikit-learn.org/stable/modules/generated/sklearn.tree.DecisionTreeRegressor.html>.

128. Sprendimų medžio modelio privalumai ir trūkumai. Prieiga per internetą: <https://scikit-learn.org/stable/modules/tree.html>.
129. Stašys, R., Malikovas, A. (2010) Antrojo lygio pensijų fondų dalyvių lūkesčiai. Vadybos mokslas ir studijos – kaimo verslų ir jų infrastruktūros plėtrai. Nr. 5(24).
130. Tetteh J.E., Adenutsi D.E., Amoah A. (2019). The Determinants of Stock Market Return in Ghana: FMOLS and DOLS Approaches. *The IUP Journal of Applied Finance*, Vol. 25, No. 4.
131. Tiryaki H.N., Tiryaki A. (2018). Determinants of turkish stock returns under the impact of economic policy uncertainty. *International Journal of Economic and Administrative Studies*. (22):147-162. DOI: 10.18092/ulikidince.424369.
132. Uygur, U. and O. Tas, 2012. Modeling the effects of investor sentiment and conditional volatility in international stock markets. *Journal of Applied Finance & Banking*, Sciencepress Ltd, 2(5): 239- 260.
133. Umar B., Nayan S. (2018). Unemployment and Stock Market Development: Empirical Evidence from Africa. *Management and Economic Journal*. Page no. 351-360.
134. Warren Y., Darity W.A (2001). The Early History of Rational and Implicit Expectations." *History of Political Economy*, vol. 33 no. 4, p. 773-813. Project MUSE muse.jhu.edu/article/13325.
135. Westfall T. (2010). Stock split announcements: a test of market efficiency. *Allied academies international conference. Proceedings of the Academy of Accounting and Financial Studies*, Volume 15, Number 1.
136. Woodard J.H., Bacon F.W. (2015). Government shutdown: a test of market efficiency. *Journal of business and behavioral sciences*. Vol 27, No 2.
137. Xu Y, Liu Z, Zhao J, Su C (2017) Weibo sentiments and stock return: A time-frequency view. *PLoS ONE* 12(7): e0180723. <https://doi.org/10.1371/journal.pone.0180723>


PRIEDAI

1 Priedas. RBVP koreliacinė matrica scenarijui >0 ir EURO STOXX 50 grąžos




Šaltinis: sudaryta autoriaus, remiantis „Bloomberg“ duomenų baze, „Jupyter Notebook“ aplinka ir „Python“ kalba.

2 Priedas. Pramonės produkcijos koreliacinė matrica scenarijui >0 ir EURO STOXX 50 gražos




Šaltinis: sudaryta autoriaus, remiantis „Bloomberg“ duomenų baze, „Jupyter Notebook“ aplinka ir „Python“ kalba.

3 Priedas. Pramonės produkcijos koreliacinė matrica scenarijui >=0 ir EURO STOXX 50 gražos





Šaltinis: sudaryta autoriaus, remiantis „Bloomberg“ duomenų baze, „Jupyter Notebook“ aplinka ir „Python“ kalba.

4 Priedas. Preliminarių duomenų VKI koreliacinė matrica scenarijui >0 ir EURO STOXX 50 gražos



Šaltinis: sudaryta autoriaus, remiantis „Bloomberg“ duomenų baze, „Jupyter Notebook“ aplinka ir „Python“ kalba.

5 Priedas. VKI, išskyrus energiją, maistą, alkoholį ir tabaką, koreliacinė matrica scenarijui <0 ir EURO STOXX 50 gražos



Šaltinis: sudaryta autoriaus, remiantis „Bloomberg“ duomenų baze, „Jupyter Notebook“ aplinka ir „Python“ kalba.

6 Priedas. Neuronų tinklo modelio architektūra


RBVP modelis scenarijui >0 ir EURO STOXX 50 grąžos 4 minutę

Pramonės produkcijos modelis scenarijui >0 ir EURO STOXX 50 grąžos 40 minutę

Pramonės produkcijos modelis scenarijui ≥ 0 ir EURO STOXX 50 grąžos 42 minutę

Preliminarių duomenų VKI modelis scenarijui >0 ir EURO STOXX 50 grąžos 36 minutę

VKI, išskyrus energiją, maistą, alkoholį ir tabaką, modelis scenarijui <0 ir EURO STOXX 50 grąžos 10 minutę



Šaltinis: sudaryta autoriaus, remiantis „Bloomberg“ duomenų baze, „Jupyter Notebook“ aplinka ir „Python“ kalba.

7 Priedas. Atsitiktinio miško modelio architektūra

RBVP modelis scenarijui >0 ir EURO STOXX 50 gražos 4 minutę

Pramonės produkcijos modelis scenarijui >0 ir EURO STOXX 50 gražos 40 minutę

Pramonės produkcijos modelis scenarijui >=0 ir EURO STOXX 50 gražos 42 minutę

Preliminarių duomenų VKI modelis scenarijui >0 ir EURO STOXX 50 gražos 36 minutę

VKI, išskyrus energiją, maistą, alkoholį ir tabaką, modelis scenarijui <0 ir EURO STOXX 50 gražos 10 minutę

```
RandomForestRegressor
base_estimator = criterion: "mse", splitte...
base_estimator_ = criterion: "mse", splitte...
bootstrap = true
ccp_alpha = 0
class_weight =
criterion = mse
estimators_ = ( criterion: "mse", split...
estimator_params = "criterion", "max_depth",...
max_depth =
max_features = auto
max_leaf_nodes =
max_samples =
min_impurity_decrease = 0
min_impurity_split =
min_samples_leaf = 1
min_samples_split = 2
min_weight_fraction_leaf = 0
n_estimators = 100
n_features_ = 1
n_jobs =
n_outputs_ = 1
oob_score = false
random_state = 1
verbose = 0
warm_start = false
```

Šaltinis: sudaryta autoriaus, remiantis „Bloomberg“ duomenų bazės informacija, „Jupyter Notebook“ aplinka, „Python“ kalba, „Netron“ modelio vizualizacijos įrankiu.

8 Priedas. Sprendimų medžio modelio architektūra

RBVP modelis scenarijui >0 ir EURO STOXX 50 grąžos 4 minutę

Pramonės produkcijos modelis scenarijui >0 ir EURO STOXX 50 grąžos 40 minutę

Pramonės produkcijos modelis scenarijui >=0 ir EURO STOXX 50 grąžos 42 minutę

Preliminarių duomenų VKI modelis scenarijui >0 ir EURO STOXX 50 grąžos 36 minutę

VKI išskyrus energiją, maistą, alkoholi ir tabaką modelis scenarijui <0 ir EURO STOXX 50 grąžos 10 minutę

```
DecisionTreeRegressor
ccp_alpha = 0
class_weight =
criterion = mse
max_depth =
max_features =
max_features_ = 1
max_leaf_nodes =
min_impurity_decrease = 0
min_impurity_split =
min_samples_leaf = 1
min_samples_split = 2
min_weight_fraction_leaf = 0
n_features_ = 1
n_outputs_ = 1
presort = deprecated
random_state = 207
splitter = best
tree_ = n_features: 1, n_classes:...
```

Šaltinis: sudaryta autoriaus, remiantis „Bloomberg“ duomenų bazės informacija, „Jupyter Notebook“ aplinka, „Python“ kalba, „Netron“ modelio vizualizacijos įrankiu.

9 Priedas. GBR modelio architektūra

RBVP modelis scenarijui >0 ir EURO STOXX 50 grąžos 4 minutę

Pramonės produkcijos modelis scenarijui >0 ir EURO STOXX 50 grąžos 40 minutę

Pramonės produkcijos modelis scenarijui >=0 ir EURO STOXX 50 grąžos 42 minutę

Preliminarių duomenų VKI modelis scenarijui >0 ir EURO STOXX 50 grąžos 36
minutę

VKI, išskyrus energiją, maistą, alkoholį ir tabaką, modelis scenarijui <0 ir EURO
STOXX 50 grąžos 10 minutę

```
GradientBoostingRegressor
estimators_ (100x1)
train_score_ (100)
alpha = -6.065988000114918e+66
ccp_alpha = 0
criterion = friedman_mse
init =
init_ = strategy: "mean", constan...
learning_rate = -1.5423487136675799e-180
loss = ls
loss_ = 1
max_depth = 3
max_features =
max_features_ = 1
max_leaf_nodes =
min_impurity_decrease = 0
min_impurity_split =
min_samples_leaf = 1
min_samples_split = 2
min_weight_fraction_leaf = 0
n_classes_ = 1
n_estimators = 100
n_estimators_ = 100
n_features_ = 1
n_iter_no_change =
presort = deprecated
random_state = 207
subsample = 3.03865e-319
tol = 1.17284221540043e-90
validation_fraction = -1.5423487136675799e-180
verbose = 0
warm_start = false
```

Šaltinis: sudaryta autoriaus, remiantis „Bloomberg“ uomenų bazės informacija, „Jupyter Notebook“ aplinka, „Python“ kalba, „Netron“ modelio vizualizacijos įrankiu.

10 Priedas. RBVP ir EURO STOXX 50 duomenų analizė, tvarkymas, koreliacinių matricių sudarymas, modeliavimas, tikrinimas, lyginimas – kodas

```
# -*- coding: utf-8 -*-  
"""Real GDP (swda, yoy %).ipynb
```

Automatically generated by Colaboratory.

Original file is located at

<https://colab.research.google.com/drive/10MuWqrHolqViL2ml1wZ5Jic-kEbKz6UUt>

```
# Importuojami bibliotekas  
"""
```

```
# Commented out IPython magic to ensure Python compatibility.
```

```
import pandas as pd  
import numpy as np  
import matplotlib.pyplot as plt  
from mpl_toolkits.mplot3d import axes3d  
import seaborn as sns  
import math  
from functools import reduce
```

```
from sklearn.preprocessing import scale  
import sklearn.linear_model as skl_lm  
from sklearn.metrics import mean_squared_error, r2_score  
import statsmodels.api as sm  
import statsmodels.formula.api as smf
```

```
from sklearn.model_selection import train_test_split  
from sklearn.linear_model import LinearRegression  
from sklearn.metrics import r2_score  
import statsmodels.formula.api as smf  
import scipy.stats as stats  
import pylab  
import statsmodels.stats.api as sms
```

```
# %matplotlib inline
```

```
"""## Importuoju Euro Stoxx 50 nuo 2008 iki 2019 metų"""
```

```
df = pd.read_csv('df.csv')  
df.head(10)
```

```
df.info()
```

```
"""Keičiu Date formatą iš object"""
```

```
df['Date'] = pd.to_datetime(df['Date'], format='%Y-%m-%d %H:%M:%S.%f')
```

```
df.info()
```

```
"""## Sukuriu indekso %Change"""
```

```
df['m1'] = (df['Close'] - df['Open']) / df['Open']*100  
df['m2'] = (df['Close'].shift(1) - df['Open']) / df['Open']*100  
df['m3'] = (df['Close'].shift(2) - df['Open']) / df['Open']*100  
df['m4'] = (df['Close'].shift(3) - df['Open']) / df['Open']*100  
df['m5'] = (df['Close'].shift(4) - df['Open']) / df['Open']*100  
df['m6'] = (df['Close'].shift(5) - df['Open']) / df['Open']*100  
df['m7'] = (df['Close'].shift(6) - df['Open']) / df['Open']*100  
df['m8'] = (df['Close'].shift(7) - df['Open']) / df['Open']*100  
df['m9'] = (df['Close'].shift(8) - df['Open']) / df['Open']*100  
df['m10'] = (df['Close'].shift(9) - df['Open']) / df['Open']*100  
df['m11'] = (df['Close'].shift(10) - df['Open']) / df['Open']*100  
df['m12'] = (df['Close'].shift(11) - df['Open']) / df['Open']*100  
df['m13'] = (df['Close'].shift(12) - df['Open']) / df['Open']*100  
df['m14'] = (df['Close'].shift(13) - df['Open']) / df['Open']*100  
df['m15'] = (df['Close'].shift(14) - df['Open']) / df['Open']*100  
df['m16'] = (df['Close'].shift(15) - df['Open']) / df['Open']*100  
df['m17'] = (df['Close'].shift(16) - df['Open']) / df['Open']*100  
df['m18'] = (df['Close'].shift(17) - df['Open']) / df['Open']*100  
df['m19'] = (df['Close'].shift(18) - df['Open']) / df['Open']*100  
df['m20'] = (df['Close'].shift(19) - df['Open']) / df['Open']*100  
df['m21'] = (df['Close'].shift(20) - df['Open']) / df['Open']*100  
df['m22'] = (df['Close'].shift(21) - df['Open']) / df['Open']*100  
df['m23'] = (df['Close'].shift(22) - df['Open']) / df['Open']*100  
df['m24'] = (df['Close'].shift(23) - df['Open']) / df['Open']*100  
df['m25'] = (df['Close'].shift(24) - df['Open']) / df['Open']*100
```

```

df['m26'] = (df['Close'].shift(25) - df['Open']) / df['Open']*100
df['m27'] = (df['Close'].shift(26) - df['Open']) / df['Open']*100
df['m28'] = (df['Close'].shift(27) - df['Open']) / df['Open']*100
df['m29'] = (df['Close'].shift(28) - df['Open']) / df['Open']*100
df['m30'] = (df['Close'].shift(29) - df['Open']) / df['Open']*100
df['m31'] = (df['Close'].shift(30) - df['Open']) / df['Open']*100
df['m32'] = (df['Close'].shift(31) - df['Open']) / df['Open']*100
df['m33'] = (df['Close'].shift(32) - df['Open']) / df['Open']*100
df['m34'] = (df['Close'].shift(33) - df['Open']) / df['Open']*100
df['m35'] = (df['Close'].shift(34) - df['Open']) / df['Open']*100
df['m36'] = (df['Close'].shift(35) - df['Open']) / df['Open']*100
df['m37'] = (df['Close'].shift(36) - df['Open']) / df['Open']*100
df['m38'] = (df['Close'].shift(37) - df['Open']) / df['Open']*100
df['m39'] = (df['Close'].shift(38) - df['Open']) / df['Open']*100
df['m40'] = (df['Close'].shift(39) - df['Open']) / df['Open']*100
df['m41'] = (df['Close'].shift(40) - df['Open']) / df['Open']*100
df['m42'] = (df['Close'].shift(41) - df['Open']) / df['Open']*100
df['m43'] = (df['Close'].shift(42) - df['Open']) / df['Open']*100
df['m44'] = (df['Close'].shift(43) - df['Open']) / df['Open']*100
df['m45'] = (df['Close'].shift(44) - df['Open']) / df['Open']*100

```

```
df.head()
```

```
"""## Importuojų makroekonominę naujieną"""
```

```
Indicator = pd.read_excel(r'C:\Users\Asosi\OneDrive\VCS\DR\Economic news\Real GDP (swda, yoy%).xlsx')
```

```
Indicator.head()
```

```
Indicator.info()
```

```
Indicator=Indicator.replace("-",0)
```

```
Indicator.info()
```

```
Indicator['Date'] = pd.to_datetime(Indicator['Date'].apply(str)+' '+Indicator['Time'].apply(str))
```

```
Indicator.head(5)
```

```
# Indicator['Actual'] = pd.to_numeric(Indicator.Actual)
```

```

# Indicator.info()

"""# Sujungiu dvi lenteles"""

df_Indicator = pd.merge(df, Indicator, left_on='Date', right_on='Date')
df_Indicator.head(5)

# df_Indicator.to_excel("test.xlsx", sheet_name = 'Test1')

"""## Susikuriu lentelę su naudojamai stulpeliais"""

df_Indicator=df_Indicator[['Date',m1",m2",m3",m4",m5",m6",m7",m8",m9",m10',
                           'm11",m12",m13",m14",m15",m16",m17",m18",m19",m20',
                           'm21",m22",m23",m24",m25",m26",m27",m28",m29",m30',
                           'm31",m32",m33",m34",m35",m36",m37",m38",m39",m40',
                           'm41",m42",m43",m44",m45',
                           'Surprise']]

df_Indicator.head()

df_Indicator.info()

# df_Indicator.to_excel("test1.xlsx", sheet_name = 'Test1')

"""# Koreliacija ir modelis su pilnais duomenimis"""

f, ax = plt.subplots(figsize=(35, 30))
corr = df_Indicator.corr()
hm = sns.heatmap(round(corr,2), annot=True, ax=ax, cmap="coolwarm",fmt='%.2f',
                  linewidths=.08)
ax.set_ylim(sorted(ax.get_xlim(), reverse=True))
f.subplots_adjust(top=0.93)

est = smf.ols('m1 ~ Surprise', df_Indicator).fit()
est.summary()

"""# Koreliacija ir modelis, kai surprises > 0"""

df_Indicator1 = df_Indicator[df_Indicator['Surprise'] > 0]

```

```

# df_Indicator1.to_excel("test.xlsx", sheet_name = 'Test1')
df_Indicator1.info()

f, ax = plt.subplots(figsize=(32, 28))
corr = df_Indicator1.corr()
hm = sns.heatmap(round(corr,2), annot=True, ax=ax, cmap="coolwarm",fmt=
t='2f',
                    linewidths=.05)
ax.set_ylim(sorted(ax.get_xlim(), reverse=True))
f.subplots_adjust(top=0.93)

est1 = smf.ols('m4 ~ Surprise', df_Indicator1).fit()
est1.summary()

"""# Modelio prielaidų tikrinimas

# 1. Ar yra tiesinė priklausomybė tarp Y ir X
"""

sns.lmplot(x='Surprise', y='m4', data=df_Indicator1)

"""# 2. Ar liekamųjų paklaidų vidurkis lygus 0"""

est1.resid.mean()

"""# 3. Ar liekamosios paklaidos yra homoskedastiškos

"""

# Commented out IPython magic to ensure Python compatibility.
# %matplotlib inline
# %config InlineBackend.figure_format = 'retina'
import seaborn as sns
import matplotlib.pyplot as plt
import statsmodels.stats.api as sms
sns.set_style('darkgrid')
sns.mpl.rcParams['figure.figsize'] = (15.0, 9.0)

def homoscedasticity_test(model):
    """

```

```

Args:
* model - fitted OLS model from statsmodels
"""

fitted_vals = model.predict()
resids = model.resid
resids_standardized = model.get_influence().resid_studentized_internal

fig, ax = plt.subplots(1,2)

sns.regplot(x=fitted_vals, y=resids, lowess=True, ax=ax[0], line_kws={'color': 'red'})
ax[0].set_title('Residuals vs Fitted', fontsize=16)
ax[0].set(xlabel='Fitted Values', ylabel='Residuals')

sns.regplot(x=fitted_vals, y=np.sqrt(np.abs(resids_standardized)), lowess=True, ax=ax[1], line_kws={'color': 'red'})
ax[1].set_title('Scale-Location', fontsize=16)
ax[1].set(xlabel='Fitted Values', ylabel='sqrt(abs(Residuals))')

bp_test = pd.DataFrame(sms.het_breuschpagan(resids, model.model.exog),
                      columns=['value'],
                      index=['Lagrange multiplier statistic', 'p-value', 'f-value', 'f p-value'])

gq_test = pd.DataFrame(sms.het_goldfeldquandt(resids, model.model.exog)
                      [:-1],
                      columns=['value'],
                      index=['F statistic', 'p-value'])

print('\n Breusch-Pagan test ----')
print(bp_test)
print('\n Goldfeld-Quandt test ----')
print(gq_test)
print('\n Residuals plots ----')

homoscedasticity_test(est1)

sns.distplot(est1.resid)

```



```
stats.probplot(df_Indicator1['m4'], dist="norm", plot=plt)
plt.show()
```

“”Matome, kad ir histograma, ir kvantilių grafikas rodo liekamųjų paklaidų normalumą. Dabar

patikrinsime paklaidų normalumą Šapiro-Vilko kriterijumi. Nulinė hipotezė teigia, kad paklaidos normalios. Normalumo prielaida netenkinama, jeigu $p < 0,05$ ””

```
sw = stats.shapiro(est1.resid)
print(f'Shapiro-Wilk test ---- statistic: {sw[0]:.4f}, p-value: {sw[1]:.4f}')
```

“””Įsitikiname, kad $p = \dots > 0,05$. Todėl galima teigti, kad sprendžiant iš Shapiro-Wilk kriterijaus, liekamosios paklaidos turi normalųjį skirstinį.

5. Ar duomenyse neturi būti išskirčių

```
sns.boxplot(x=df_Indicator1['m4'])
```

```
sns.boxplot(x=df_Indicator1['Surprise'])
```

```
influence = est1.get_influence()
#c is the distance and p is p-value
(c, p) = influence.cooks_distance
plt.stem(np.arange(len(c)), c, markerfmt="")
```

```
from statsmodels.graphics.regressionplots import *
plot_leverage_resid2(est1)
influence_plot(est1)
```

6. Ar nėra autokoreliacijos

7. Ar nėra multikolinearumo

```
#from statsmodels.stats.outliers_influence import variance_inflation_factor
```

```
#vif = [variance_inflation_factor(df_Indicator1['Surprise'], i) for i in range(-
df_Indicator1['Surprise'].shape[1])]
```

```

#pd.DataFrame({'vif': vif[1:]}, index=X.columns).T

### Aprašome duomenis
"""

x = df_Indicator1[['Surprise']].values
y = df_Indicator1['m4'].values

"""### Padalijame duomenis į training ir test"""

x_train, x_test, y_train, y_test = train_test_split(x, y, test_size = 0.50, random_
state = 141)

### Aprašomi training ir test rodikliai, kur 20% skiriame test analizei.

"""### Brėžiame training duomenų grafiką"""

plt.scatter(x_train, y_train, color = 'blue')
plt.title('Surprise & m4 dependency')
plt.xlabel('Surprise')
plt.ylabel('m4')
plt.show()

"""### Sukuriame ir aprašome modelį"""

lm = LinearRegression()

### Toliau sukursime tiesinės regresijos modelį naudodami train ir test duo-
menų rinkinius

"""### Įvertiname modelį"""

lm.fit(x_train,y_train)

"""### Prognozuojame y reikšmes pagal testines x reikšmes"""

yPrediction = lm.predict(x_test)

"""### Vizualizuojame train duomenimis įvertintą modelį"""

```

```
plt.scatter(x_train, y_train, color = 'green')
plt.plot(x_train, lm.predict(x_train), color = 'blue')
plt.title('Surprise & m4 (Training set)')
plt.xlabel('Surprise')
plt.ylabel('m4')
plt.show()
```

```
"""### Tikriname modelio tikslumą"""
```

```
lm.score(x,y)
```

Modelio pavyzdys rodo, kad prognozė yra pakankamai tiksli ir prognozės duomenys bus kokybiški

```
"""### Vizualizuojame, kaip modelis tinka test duomenims"""
```

```
plt.scatter(x_test, y_test, color = 'green')
plt.plot(x_train, lm.predict(x_train), color = 'blue')
plt.plot(x_test, lm.predict(x_test), color = 'blue')
plt.title('Surprise & m4 (Test set)')
plt.xlabel('Surprise')
plt.ylabel('m4')
plt.show()
```

```
lm.coef_
```

```
lm.intercept_
```

```
from sklearn.metrics import mean_squared_error
```

```
print("R^2: {}".format(lm.score(x_test, y_test)))
rmse = np.sqrt(mean_squared_error(y_test, lm.predict(x_test)))
print("Root Mean Squared Error: {}".format(rmse))
```

```
X = df_Indicator1[['Surprise']]
```

```
Y = df_Indicator1['m4']
```

```
from sklearn.model_selection import train_test_split
```

```
X_train, X_test, Y_train, Y_test = train_test_split(X, Y, test_size = 0.50, ran-
```

```

dom_state=141)
    print(X_train.shape)
    print(X_test.shape)
    print(Y_train.shape)
    print(Y_test.shape)

from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error, r2_score

lin_model = LinearRegression()
lin_model.fit(X_train, Y_train)

y_train_predict = lin_model.predict(X_train)
rmse = (np.sqrt(mean_squared_error(Y_train, y_train_predict)))
r2 = r2_score(Y_train, y_train_predict)

print("Modelio rezultatai su apmokymo duomenimis")
print("-----")
print('RMSE: {}'.format(rmse))
print('R2: {}'.format(r2))
print("\n")

# model evaluation for testing set
y_test_predict = lin_model.predict(X_test)
rmse = (np.sqrt(mean_squared_error(Y_test, y_test_predict)))
r2 = r2_score(Y_test, y_test_predict)

print("Modelio rezultatai su testavimo duomenimis")
print("-----")
print('RMSE: {}'.format(rmse))
print('R2: {}'.format(r2))

lin_model.score(X,Y)

lin_model.coef_

lin_model.intercept_

"""# Koreliacija ir modelis, kai surprises >= 0"""

```

```

df_Indicator2 = df_Indicator[df_Indicator['Surprise'] >= 0]
df_Indicator2.info()

f, ax = plt.subplots(figsize=(32, 28))
corr = df_Indicator2.corr()
hm = sns.heatmap(round(corr,2), annot=True, ax=ax, cmap="coolwarm",fmt=
t='.2f',
                    linewidths=.05)
f.subplots_adjust(top=0.93)

est = smf.ols('m3 ~ Surprise', df_Indicator2).fit()
est.summary()

""""# Koreliacija ir modelis, kai surprises < 0""""

df_Indicator3 = df_Indicator[df_Indicator['Surprise'] < 0]
df_Indicator3.info()

f, ax = plt.subplots(figsize=(32, 28))
corr = df_Indicator3.corr()
hm = sns.heatmap(round(corr,2), annot=True, ax=ax, cmap="coolwarm",fmt=
t='.2f',
                    linewidths=.05)
f.subplots_adjust(top=0.93)

est = smf.ols('m7 ~ Surprise', df_Indicator3).fit()
est.summary()

""""# Koreliacija ir modelis, kai surprises <= 0""""

df_Indicator4 = df_Indicator[df_Indicator['Surprise'] <= 0]
df_Indicator4.info()

f, ax = plt.subplots(figsize=(32, 28))
corr = df_Indicator4.corr()
hm = sns.heatmap(round(corr,2), annot=True, ax=ax, cmap="coolwarm",fmt=
t='.2f',
                    linewidths=.05)
f.subplots_adjust(top=0.93)

est = smf.ols('m7 ~ Surprise', df_Indicator4).fit()
est.summary()

```

11 Priedas. RBVP ir EURO STOXX 50 modeliavimo dalis – kodas

```
# -*- coding: utf-8 -*-  
"""Real GDP (swda, yoy%) all models.ipynb
```

Automatically generated by Colaboratory.

Original file is located at

```
https://colab.research.google.com/drive/14fON35IVzYT78Uia56XF9zpgLJL-  
vAcE_  
"""
```

```
from google.colab import drive  
drive.mount("/content/drive")
```

```
# Commented out IPython magic to ensure Python compatibility.
```

```
import pandas as pd  
import numpy as np  
import matplotlib.pyplot as plt  
from mpl_toolkits.mplot3d import axes3d  
import seaborn as sns  
import math  
from functools import reduce
```

```
from sklearn.preprocessing import scale  
import sklearn.linear_model as skl_lm  
from sklearn.metrics import mean_squared_error, r2_score  
from math import sqrt  
import statsmodels.api as sm  
import statsmodels.formula.api as smf
```

```
from sklearn.model_selection import train_test_split  
from sklearn.linear_model import LinearRegression  
from sklearn.metrics import r2_score  
import statsmodels.formula.api as smf  
import scipy.stats as stats  
import pylab  
import statsmodels.stats.api as sms  
from sklearn.ensemble import RandomForestRegressor  
from sklearn.tree import DecisionTreeRegressor  
from sklearn import datasets, ensemble
```

```

import tensorflow.keras as keras
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.callbacks import ModelCheckpoint
from tensorflow.keras import backend as K

# %matplotlib inline

df = pd.read_csv('/content/drive/MyDrive/DR/Ketvirtas_etapas/df.csv')
df.head()

df.describe()

df.isnull().sum()

df['Date'] = pd.to_datetime(df['Date'], format='%Y-%m-%d %H:%M:%S.%f')

df

for i in range(1,46):
    df['m'+str(i)] = (df['Close'].shift(i-1) - df['Open']) / df['Open'] * 100

df.head()

Indicator = pd.read_excel("/content/drive/MyDrive/DR/Economic_news/
Real GDP (swda, yoy%).xlsx")
Indicator.head()

Indicator.isnull().sum()

Indicator['Date'] = pd.to_datetime(Indicator['Date'].apply(str)+' '+Indicator['Time'].apply(str))
Indicator.head(5)

df_Indicator = pd.merge(df, Indicator, left_on='Date', right_on='Date')
df_Indicator.head(5)

df_Indicator=df_Indicator[['Date',m1,m2,m3,m4,m5,m6,m7,m8,m9,m10,
m11,m12,m13,m14,m15,m16,m17,m18,m19,m20,
m21,m22,m23,m24,m25,m26,m27,m28,m29,m30,

```

```
    'm31",m32",m33",m34",m35",m36",m37",m38",m39",m40',  
    'm41",m42",m43",m44",m45',  
    'Surprise']]
```

```
df_Indicator.head()
```

```
df_Indicator.isnull().sum()
```

```
df_Indicator.describe()
```

```
def surprise_heatmap(df):  
    f, ax = plt.subplots(figsize=(35, 0.5))  
    corr = df.corr()[-1:]  
    hm = sns.heatmap(round(corr,2), annot=True, ax=ax, cmap="coolwarm",fm-  
t='.2f',linewidths=.05)  
    f.subplots_adjust(top=0.93)
```

```
def OLS_results(formula1, df):  
    model = smf.ols(formula = formula1, data = df).fit()  
    return model.summary()
```

```
def max_corr_minute(df):  
    return df.corr()[-1:].round(2).drop(columns = ["Surprise"]).abs().idx-  
max(axis = 1)[0]
```

```
df0 = df_Indicator  
surprise_heatmap(df0)  
minute0 = max_corr_minute(df0)  
print(OLS_results(minute0 + '~ Surprise', df0))
```

```
fig, ax1 = plt.subplots(ncols=1, sharey=True)  
sns.lmplot(y=minute0, x='Surprise', data=df0)  
sns.distplot(df0[minute0],kde=True, rug=True, color='green', ax = ax1)
```

```
df1 = df_Indicator[df_Indicator.Surprise > 0]  
surprise_heatmap(df1)  
minute1 = max_corr_minute(df1)  
print(OLS_results(minute1 + '~ Surprise', df1))
```

```
fig, ax1 = plt.subplots(ncols=1, sharey=True)  
sns.lmplot(y=minute1, x='Surprise', data=df1)
```



```
sns.distplot(df1[minute1],kde=True, rug=True, color='green', ax = ax1)
```

```
df2 = df_Indicator[df_Indicator.Surprise >= 0]
surprise_heatmap(df2)
minute2 = max_corr_minute(df2)
print(OLS_results(minute2 + '~ Surprise', df2))
```

```
fig, ax1 = plt.subplots(ncols=1, sharey=True)
sns.lmplot(y=minute2, x='Surprise', data=df2)
sns.distplot(df2[minute2],kde=True, rug=True, color='green', ax = ax1)
```

```
df3 = df_Indicator[df_Indicator.Surprise < 0]
surprise_heatmap(df3)
minute3 = max_corr_minute(df3)
print(OLS_results(minute3 + '~ Surprise', df3))
```

```
fig, ax1 = plt.subplots(ncols=1, sharey=True)
sns.lmplot(y=minute3, x='Surprise', data=df3)
sns.distplot(df3[minute3],kde=True, rug=True, color='green', ax = ax1)
```

```
df4 = df_Indicator[df_Indicator.Surprise <= 0]
surprise_heatmap(df4)
minute4 = max_corr_minute(df4)
print(OLS_results(minute4 + '~ Surprise', df4))
```

```
fig, ax1 = plt.subplots(ncols=1, sharey=True)
sns.lmplot(y=minute4, x='Surprise', data=df4)
sns.distplot(df4[minute4],kde=True, rug=True, color='green', ax = ax1)
```

```
residuals = []
```

```
def linear_regression(df, x, y):
    from sklearn.metrics import mean_squared_error, r2_score

    model = smf.ols(y + '~' + x, data = df).fit()
    print(model.summary())
    residuals.append(model.resid)

    y_pred = model.predict()

    print(f" x shape {df[x].shape}")
```

```
print(f" y_test shape {df[y].shape}")
```

```
r2_score = r2_score(df[y], y_pred)
rmse = (np.sqrt(mean_squared_error(df[y], y_pred)))
mse = mean_squared_error(df[y], y_pred)
```

```
print(f" R2 Score is {round(r2_score * 100,4)} %")
print(f" Root mean square error is {round(rmse,4)}")
print(f" Mean square error is {round(mse,4)}")
```

```
fig, ax = plt.subplots(figsize=(8, 4))
ax.scatter(df[y], y_pred)
ax.plot([df[y].min(), df[y].max()], [df[y].min(), df[y].max()], 'k--', lw=4)
ax.set_xlabel('Faktinės reikšmės')
ax.set_ylabel('Prognozuojamos reikšmės')
plt.show()
```

```
sns.distplot(model.resid, bins=20, kde=True, rug=True, color='green')
```

```
linear_regression(df1, 'Surprise', 'm4')
```

```
"""# Patikrinimas del GARCH"""
```

```
residuals
```

```
residuals = pd.DataFrame(residuals).T
```

```
residuals[0]
```

```
def tsdisplay(y, figsize = (14, 8), title = "", lags = 14):
    tmp_data = pd.Series(y)
    fig = plt.figure(figsize = figsize)
    #Plot the time series
    tmp_data.plot(ax = fig.add_subplot(311), title = "$Time\ Series\ " + title + "$", legend = False)
    #Plot the ACF:
    sm.graphics.tsa.plot_acf(tmp_data, lags = lags, zero = False, ax = fig.add_subplot(323), title="Autokoreliacija")
    plt.xlabel("Ekonominio rodiklio pranešimų lagai")
    plt.ylabel("Autokoreliacijos dydis")
```

```

plt.xticks(np.arange(1, lags + 1, 1.0))
#Plot the PACF:
sm.graphics.tsa.plot_pacf(tmp_data, lags = lags, zero = False, ax = fig.add_subplot(324), title="Dalinė autokoreliacija")
plt.xlabel("Ekonominio rodiklio pranešimų lagai")
plt.ylabel("Dalinės autokoreliacijos dydis")
plt.xticks(np.arange(1, lags + 1, 1.0))
#Plot the QQ plot of the data:
sm.qqplot(tmp_data, line='s', ax = fig.add_subplot(325))
plt.title("QQ Plot")
#Plot the residual histogram:
fig.add_subplot(326).hist(tmp_data, bins = 40)
plt.title("Histogram")
#Fix the layout of the plots:
plt.tight_layout()
plt.show()

def tsdiag(y, figsize = (14,8), title = "", lags = 14):
    #The data:
    tmp_data = pd.Series(y)
    #The Ljung-Box test results for the first k lags:
    tmp_acor = list(sm.stats.diagnostic.acorr_ljungbox(tmp_data, lags = lags, boxpierce = True))
    # get the p-values
    p_vals = pd.Series(tmp_acor[1])
    #Start the index from 1 instead of 0 (because Ljung-Box test is for lag values from 1 to k)
    p_vals.index += 1
    fig = plt.figure(figsize = figsize)
    #Plot the p-values:
    p_vals.plot(ax = fig.add_subplot(313), linestyle="", marker='o', title = "P-reikšmės Ljung-Box testo", legend = False)
    #Add the horizontal 0.05 critical value line
    plt.axhline(y = 0.05, color = 'blue', linestyle='--')
    plt.xlabel("Ekonominio rodiklio pranešimų lagai")
    plt.ylabel("P-reikšmė")
    # Annotate the p-value points above and to the left of the vertex
    x = np.arange(p_vals.size) + 1
    for X, Y, Z in zip(x, p_vals, p_vals):
        plt.annotate(round(Z, 4), xy=(X,Y), xytext=(-5, 5), ha = 'left', textcoords='offset points')

```

```

plt.show()
# Return the statistics:
col_index = ["Ljung-Box: X-squared", "Ljung-Box: p-value", "Box-Pierce: X-squared", "Box-Pierce: p-value"]
return pd.DataFrame(tmp_acor, index = col_index, columns = range(1, len(tmp_acor[0]) + 1))

# Suppress matplotlib's annoying deprecation warning
import warnings
import matplotlib.cbook
warnings.filterwarnings("ignore", category = matplotlib.cbook.mplDeprecation)

tsdisplay(residuals[0])

tsdiag(residuals[0])

tsdisplay(residuals[0]**2)

tsdiag(residuals[0]**2)

def linear_regression_ml(df, x, y):
    from sklearn.metrics import mean_squared_error, r2_score

    x_train, x_test, y_train, y_test = train_test_split(df[[x]], df[[y]], test_size = 0.32, random_state = 1864)
    model = LinearRegression().fit(x_train, y_train)
    y_pred = model.predict(x_test)

    print(f" x_train shape {x_train.shape}")
    print(f" x_test shape {x_test.shape}")
    print(f" y_train shape {y_train.shape}")
    print(f" y_test shape {y_test.shape}")

    print(f" Model intercept is {model.intercept_}")
    print(f" Model coef is {model.coef_}")

    r2_score = r2_score(y_test, y_pred)
    rmse = (np.sqrt(mean_squared_error(y_test, y_pred)))
    mse = mean_squared_error(y_test, y_pred)

```

```

print(f" R2 Score is {round(r2_score * 100,4)} %")
print(f" Root mean square error is {round(rmse,4)}")
print(f" Mean square error is {round(mse,4)}")

fig, ax = plt.subplots(figsize=(8, 4))
ax.scatter(y_test, y_pred)
ax.plot([-0.10, -0.05,0.00,0.05,0.10,0.15,0.20], [-0.10, -0.05,0.00,0.05,0.10,0.1
5,0.20], 'k--', lw=4)
ax.set_xlabel('Faktinēs reikšmės')
ax.set_ylabel('Prognozuojamos reikšmės')
plt.show()

sns.distplot(y_test - y_pred, kde=True, rug=True, color='green')

linear_regression_ml(df1, 'Surprise', 'm4')

def random_forest(df, x, y):
    from sklearn.metrics import mean_squared_error, r2_score

    x_train, x_test, y_train, y_test = train_test_split(df[[x]], df[y], test_
size = 0.32, random_state = 735)
    model = RandomForestRegressor(random_state=1).fit(x_train, y_train)
    y_pred = model.predict(x_test)

    print(f" x_train shape {x_train.shape}")
    print(f" x_test shape {x_test.shape}")
    print(f" y_train shape {y_train.shape}")
    print(f" y_test shape {y_test.shape}")

    # print(f" Model intercept is {model.intercept_}")
    # print(f" Model coef is {model.coef_}")

    r2_score = r2_score(y_test, y_pred)
    rmse = (np.sqrt(mean_squared_error(y_test, y_pred)))
    mse = mean_squared_error(y_test, y_pred)

    print(f" R2 Score is {round(r2_score * 100,4)} %")
    print(f" Root mean square error is {round(rmse,4)}")
    print(f" Mean square error is {round(mse,4)}")

```

```

fig, ax = plt.subplots(figsize=(8, 4))
ax.scatter(y_test, y_pred)
ax.plot([-0.10, -0.05, 0.00, 0.05, 0.10, 0.15, 0.20], [-0.10, -0.05, 0.00, 0.05, 0.10, 0.15, 0.20], 'k--', lw=4)
ax.set_xlabel('Faktinès reikšmės')
ax.set_ylabel('Prognozuojamos reikšmės')
plt.show()

```

```
sns.distplot(y_test - y_pred, kde=True, rug=True, color='green')
```

```
random_forest(df1, 'Surprise', 'm4')
```

```

def decision_tree(df, x, y):
    from sklearn.metrics import mean_squared_error, r2_score

    x_train, x_test, y_train, y_test = train_test_split(df[[x]], df[y], test_size = 0.32, random_state = 5540)
    model = DecisionTreeRegressor(random_state=207).fit(x_train, y_train)
    y_pred = model.predict(x_test)

    print(f" x_train shape {x_train.shape}")
    print(f" x_test shape {x_test.shape}")
    print(f" y_train shape {y_train.shape}")
    print(f" y_test shape {y_test.shape}")

    # print(f" Model intercept is {model.intercept_}")
    # print(f" Model coef is {model.coef_}")

    r2_score = r2_score(y_test, y_pred)
    rmse = (np.sqrt(mean_squared_error(y_test, y_pred)))
    mse = mean_squared_error(y_test, y_pred)

    print(f" R2 Score is {round(r2_score * 100,4)} %")
    print(f" Root mean square error is {round(rmse,4)}")
    print(f" Mean square error is {round(mse,4)}")

```

```

fig, ax = plt.subplots(figsize=(8, 4))
ax.scatter(y_test, y_pred)
ax.plot([y_test.min(), y_test.max()], [y_test.min(), y_test.max()], 'k--', lw=4)

```

```
ax.set_xlabel('Faktinēs reikšmēs')
ax.set_ylabel('Prognozuojamos reikšmēs')
plt.show()
```

```
sns.distplot(y_test - y_pred, kde=True, rug=True, color='green')
```

```
decision_tree(df1, 'Surprise', 'm4')
```

```
def gradient_boosting(df, x, y):
```

```
    from sklearn.metrics import mean_squared_error, r2_score
```

```
        x_train, x_test, y_train, y_test = train_test_split(df[[x]], df[y], test_
size = 0.32, random_state = 5540)
```

```
        model = ensemble.GradientBoostingRegressor(random_state=207).fit(x_
train, y_train)
```

```
        y_pred = model.predict(x_test)
```

```
    print(f" x_train shape {x_train.shape}")
```

```
    print(f" x_test shape {x_test.shape}")
```

```
    print(f" y_train shape {y_train.shape}")
```

```
    print(f" y_test shape {y_test.shape}")
```

```
#    print(f" Model intercept is {model.intercept_}")
```

```
#    print(f" Model coef is {model.coef_}")
```

```
r2_score = r2_score(y_test, y_pred)
```

```
rmse = (np.sqrt(mean_squared_error(y_test, y_pred)))
```

```
mse = mean_squared_error(y_test, y_pred)
```

```
print(f" R2 Score is {round(r2_score * 100,4)} %")
```

```
print(f" Root mean square error is {round(rmse,4)}")
```

```
print(f" Mean square error is {round(mse,4)}")
```

```
fig, ax = plt.subplots(figsize=(8, 4))
```

```
ax.scatter(y_test, y_pred)
```

```
ax.plot([y_test.min(), y_test.max()], [y_test.min(), y_test.max()], 'k--', lw=4)
```

```
ax.set_xlabel('Faktinēs reikšmēs')
```

```
ax.set_ylabel('Prognozuojamos reikšmēs')
```

```
plt.show()
```

```

sns.distplot(y_test - y_pred, kde=True, rug=True, color='green')

gradient_boosting(df1, 'Surprise', 'm4')

def deep_learning(df, x, y):
    from sklearn.metrics import mean_squared_error, r2_score
    from numpy.random import seed
    seed(1)

    x_train, x_test, y_train, y_test = train_test_split(df[[x]], df[y], test_
size = 0.32, random_state = 95)

    print(f" x_train shape {x_train.shape}")
    print(f" x_test shape {x_test.shape}")
    print(f" y_train shape {y_train.shape}")
    print(f" y_test shape {y_test.shape}")

    model = Sequential(name='model')
    model.add(keras.Input(shape=1, name='input_layer'))
    model.add(keras.layers.Dense(512, activation='relu', name='inner_layer_1'))
    model.add(keras.layers.Dense(256, activation='relu'))
    model.add(keras.layers.Dense(128, activation='relu'))
    model.add(Dense(1, name='output_layer'))

# print(model.summary())

model.compile(loss='mse',
              optimizer='adam',
              metrics=['mse'])

history = model.fit(x_train, y_train,
                   batch_size=5,
                   epochs=100,
                   verbose=1)

model.evaluate(x_test, y_test)
y_pred = model.predict(x_test)
y_pred = y_pred.reshape(-1)

r2_score = r2_score(y_test, y_pred)

```



```

rmse = (np.sqrt(mean_squared_error(y_test, y_pred)))
mse = mean_squared_error(y_test, y_pred)

print(f" R2 Score is {round(r2_score * 100,4)} %")
print(f" Root mean square error is {round(rmse,4)}")
print(f" Mean square error is {round(mse,4)}")

fig, ax = plt.subplots(figsize=(8, 4))
ax.scatter(y_test, y_pred)
ax.plot([y_test.min(), y_test.max()], [y_test.min(), y_test.max()], 'k--', lw=4)
ax.set_xlabel('Faktinēs reikšmės')
ax.set_ylabel('Prognozuojamos reikšmės')
plt.show()

# sns.distplot(y_test - y_pred, bins = 20, kde=True, rug=True, color='green')

print(history.history.keys())

# summarize history for accuracy
plt.plot(history.history["mse"])
# plt.plot(history.history['val_mean_squared_error'])
plt.ylabel('Vidutinė kvadratinė paklaida')
plt.xlabel('Epocha')
plt.legend(['train'], loc='upper left')
plt.show()

deep_learning(df1, 'Surprise', 'm4')

```

MYKOLO ROMERIO UNIVERSITETAS

Aleksejus Sosidko

MAKROEKONOMINIŲ RODIKLIŲ
NETIKĖTUMŲ POVEIKIO AKCIJŲ GRĄŽAI
MODELIAVIMAS

Daktaro disertacijos santrauka
Socialiniai mokslai, ekonomika (S 004)

Vilnius, 2022

Mokslo daktaro disertacija rengta 2017–2021 metais Mykolo Romerio universitete pagal Vytauto Didžiojo universitetui su ISM Vadybos ir ekonomikos universitetu, Mykolo Romerio universitetu ir Vilniaus universitetu Lietuvos Respublikos švietimo, mokslo ir sporto ministro 2019 m. vasario 22 d. įsakymu Nr. V-160 suteiktą doktorantūros teisę.

Mokslinė vadovė:

prof. dr. Ligita Gasparėnienė (Mykolo Romerio universitetas, socialiniai mokslai, ekonomika S 004).

Mokslo daktaro disertacija ginama Vytauto Didžiojo universiteto, ISM Vadybos ir ekonomikos universiteto, Mykolo Romerio universiteto ir Vilniaus universiteto Šiaulių akademijos ekonomikos mokslo krypties taryboje:

Pirmininkė:

prof. dr. Asta Vasiliauskaitė (Mykolo Romerio universitetas, socialiniai mokslai, ekonomika S 004).

Nariai:

prof. dr. Gintaras Černius (Mykolo Romerio universitetas, socialiniai mokslai, ekonomika S 004);

prof. dr. Valdonė Darškuvienė (ISM Vadybos ir ekonomikos universitetas, socialiniai mokslai, ekonomika S 004);

doc. dr. Aleksandra Fedajev (Belgrado universitetas, Serbijos Respublika, socialiniai mokslai, ekonomika S 004);

prof. dr. Kristina Levišauskaitė (Vytauto Didžiojo universitetas socialiniai mokslai, ekonomika S 004);

Daktaro disertacija bus ginama viešame Ekonomikos mokslo krypties tarybos posėdyje 2022 m. balandžio 8 d. 11 val. Mykolo Romerio universitete, I-414 auditorijoje.

Adresas: Ateities g. 20, 08303 Vilnius.

Su disertacija galima susipažinti Lietuvos nacionalinėje Martyno Mažvydo bibliotekoje, ISM Vadybos ir ekonomikos universiteto, Mykolo Romerio universiteto, Vilniaus universiteto Šiaulių akademijos ir Vytauto Didžiojo universiteto bibliotekose.

MAKROEKONOMINIŲ RODIKLIŲ NETIKĖTUMŲ POVEIKIO AKCIJŲ GRĄŽAI MODELIAVIMAS

SANTRAUKA

Temos aktualumas. Spartus finansų rinkų vystymasis ir lengvai prieinami finansiniai produktai formuoja vis didesnę mokslininkų, profesionalių ir neprofesionalių investuotojų susidomėjimą vertybinių popierių grąža ir ją lemiančiais veiksniais. Vienos populiariausių – įmonių akcijos (remiantis Pasaulio banko statistika, akcijų kapitalizacija, apimant visą pasaulį, nuo 2010 m. išaugo ~1,72 karto, ir 2020 m. sudarė ~92 trilijonų JAV dolerių), o jų kainų, grąžos pokyčių priežasčių identifikavimas, analizė, prognozavimas ir vertinimas laikomi atskira mokslinių tyrinėjimų sritimi.

Vieni moksliniai tyrinėjimai, kuriais siekiama prognozuoti akcijų grąžą, pagrįsti fundamentaliosios analizės koncepcija. Svarbiausia šios analizės prielaida, kad rinkoje akcijų grąžos pasikeitimus sąlygoja makroekonominiai, ūkio šakos arba sektoriaus, įmonės veiklos ir kt. veiksniai, o šių veiksnių rodiklių kaitos reikšmių analizė yra svarbi dedamoji, prognozuojant akcijų grąžą. Tuo tarpu kituose moksliniuose tyrinėjimuose teigiama, kad akcijų grąžos dinamikai įtakos turi finansų rinkos dalyvių racionali arba (ir) iracionali elgsena. Racionalios elgsenos tyrinėtojų atstovai yra efektyvios rinkos hipotezės teorijos šalininkai, o iracionalios elgsenos – priklauso finansų elgsenos mokslo sričiai.

Dažniausiai finansų rinkos dalyviai labiau linkę patikėti savo investicijas efektyvioms akcijų rinkoms, kurios yra stabilios, patikimos ir kuriomis sunku manipuliuoti spekuliaciniais tikslais (darant prielaidą, kad efektyvios rinkos yra išsivysčiusiose šalyse ir atvirkščiai, remiantis Pasaulio banko 2020 m. statistika, išsivysčiusių šalių akcijų rinkų bendra kapitalizacija yra ~2,5 karto didesnė nei besivystančių šalių: atitinkamai ~66 ir ~26 trilijonų JAV dolerių). Nors kiekviena arbitražo galimybė ir gali išbalansuoti net ir vidutiniškai stiprios formos efektyvią akcijų rinką, tačiau tokie veiksniai, kaip informacijos prieinamumas internete, inovatyvūs informaciniai technologiniai sprendimai bei egzistuojantis aukštas elektroninių pinigų mobilumas, tokią tikimybę akivaizdžiai

sumažina. Antra vertus, finansų rinkų dalyviai siekia uždirbti kuo didesnę grąžą savo rizikos tolerancijos ribose, dėl to skirtingas informacijos apdorojimo lygis, skirtingas turimų galingų analitinių programų skaičius, skirtingas grąžos ir rizikos suvokimo laipsnis, emocijos ir kt. mažina akcijų rinkų efektyvumą. Esant skirtingam akcijų rinkų efektyvumo lygiui, skirtingam finansų rinkos dalyvių elgsenos tipui, skirtingam finansų rinkos dalyvių grąžos poreikiui ir rizikos tolerancijos lygiui, neužtenka taikyti tik fundamentalios arba tik finansų elgsenos, arba tik efektyvios rinkos hipotezės teorijų analizių ir modeliavimo metodikas.

Šis supratimas paskatino ieškoti ekonominio reiškinių, kuris apimtų ne tik šių teorijų požiūrius teoriniu aspektu, bet ir jas papildytų, sumažintų ar panaikintų jų ribotumus. Taip buvo pastebėtas makroekonominių rodiklių netikėtumų reiškinys, kurio poveikio modeliavimas akcijų grąžai yra mažai plėtojama sritis. Visų pirma, tai lemia duomenų gavimo ribotumas, kai tokio pobūdžio tyrimuose dažniausiai renkami aukšto dažnio akcijų kainų duomenys, o tokių duomenų gavimas tampa sudėtingas, nes reikia mokėti programavimo kalbą ar žinoti, kaip naudotis didelėmis duomenų šaltinių bazėmis. Antra, dėl paprastumo vis dar atliekama daug tyrimų, kurie remiasi vienos akcijų grąžą nagrinėjančios teorijos gairėmis ir specifika, bet pamirštama, kad akcijų rinkos dėl vis didėjančių informacijos srautų tampa vis kompleksiškesnės ir vis sunkiau nuspėjamos. Trečia, kyla dvejonė, ar tradiciniai metodai, kurie dažniausiai taikytini vienai teorijai, vis dar yra tinkami tokio tipo tyrimams, o naujų metodų paieška ir atranka neretai būna sunkus uždavinys. Taigi duomenų gavimo ribotumas, neaiškus teorijų susietumo, kompleksškumo ir metodų parinkimo klausimas daro makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tematiką itin sudėtingą ir kompleksiską, bet kartu aktualią ir įdomią.

Problemos ištyrimo lygis. Akcijų grąžą aiškinti ir prognozuoti bandoma jau kelis dešimtmečius, ir yra daug tyrimų, kuriuose ieškoma pagrindinių akcijų grąžos pokyčius lemiančių veiksnių.

Vieni moksliniai tyrimai, besigilinantys į akcijų grąžą, grįsti fundamentaliaisiais veiksniais – makroekonominiais ((Graham ir Dodd 1934), Panfil ir Szablewski 2013), (Gurgul ir Wójtcowicz 2014), (Sinha ir Kohli 2015), Figurska ir Wisniewski 2016) (Pražak ir Stavarek, 2017), (Pooja ir Giri, 2017), (Chamdrashekar, Sakthivel, Sampath ir Chittedi, 2018), (Ho, 2018), (Abed, Zardoub 2019), (Tetteh, Adenutsi, Amoah 2019), (Erol ir Aytakin 2019) ir kt.), ūkio šakos arba sektoriaus ((Panfil ir Szablewski 2013, (Borowski 2014) ir kt.), įmonės veiklos analizės ((Graham ir Dodd 1934), Figurska

ir Wisniewski 2016) ir kt.). Analizuojant makroekonominių rodiklių poveikio akcijų grąžai tyrimus buvo pastebėta, kad mokslininkai dažniausiai tiria mėnesines akcijų indeksų grąžą. Nors rodiklių poveikis nustatytas kaip statistiškai reikšmingas, tačiau neretai akcijų indeksui mėnesio laikotarpiu turi įtakos ir kiti nenagrinėjami rodikliai, kas būtent ir nėra įvertinama. Antra, mokslininkai dažniausiai orientuojasi į makroekonominių rodiklių faktines reikšmes, neįvertindami tuo metu rinkoje vyraujančių lūkesčių, kurie taip pat galėtų paveikti akcijų grąžą.

Kiti moksliniai tyrinėjimai, analizuojantys akcijų grąžą, pagrįsti racionalia arba iracionalia finansų rinkos dalyvių elgsena. Racionalios elgsenos atstovai yra efektyvios rinkos hipotezės šalininkai ((Fama, 1965, 1970), (Malkiel, 1992), (Yen ir Lee, 2008), (Fama ir French, 2015), (Altinkilic, Hansen ir Ye, 2015), (Singh, Leepsa ir Kushwaha 2016), (Sofat, 2016), (Mackey ir Macon, 2017), (Andrade ir Santos, 2017), (Jose ir Suresh, 2017), (Barghouthi ir Ehsan, 2017), (Nagpal ir Jain, 2018) ir kt.). Šios teorijos tyrimai paprastai vadinami įvykių tyrimais. Jais siekiama nustatyti, kaip greitai (minučių, valandos, dienos tikslumu) akcijų kainos prisitaiko prie naujos informacijos apie svarbius makroekonominius įvykius pasirinktoje rinkoje. Tačiau neretai tokio pobūdžio tyrimų modeliuose pasigendama finansų elgsenos elementų, kai modelis apima ne tik faktines, bet ir prognozes makroekonominių rodiklių reikšmes.

Iracionalios elgsenos tyrinėtojai ((Kahneman ir Tversky 1979), (Shefrin, 2001), (Leipus ir Norvaiša, 2004), Fischer ir Gerhardt, 2007), (Chandra 2008), (DeBondt, Forbes ir kt., 2010) (Kartašova, 2016, 2012) (Das ir Panja 2019), (Nasiri, Sarraf, Nourollahzadeh, Hamidian, Noorifard 2021) ir kt.) analizuoja psichologinę aspektų įtaką akcijų grąžai ir yra priskiriami finansų elgsenos teorijai. Šiuose tyrimuose pabrėžiama, kad sprendimo priėmimas vertybinių popierių aplinkoje yra sudėtingas procesas, kuriam įtakos turi šie veiksniai: asmeniniai, techniniai ir psichologiniai, iš jų į psichologinius veiksnius įeina sentimentai, o į šiuos – ir lūkesčiai. Nors tyrimų kryptį įvairovė, pritaikomumas ir metodų panaudojimų naujumas – didelis, tačiau šiuose tyrimuose trūksta to, kas yra EHR tyrimų lauko privalumas – didelių dažnių duomenų analizės ir akcijų grąžos modeliavimo per trumpą laiko tarpą.

Minėtų teorijų ir tyrimų ribotumas, taip pat žinojimas, kad laikui bėgant akcijų rinkos tampa vis kompleksiškesnės, informacijos šrautai vis didėja, paskatino ieškoti naujo požiūrio ir tyrimų. Taip buvo atrasti makroekonominių rodiklių netikėtumo tyrimai, kurie, autoriaus manymu, ne tik jungia šių teorijų principus, bet ir leidžia atsirasti diskusijai dėl naujo įnašo vystant šias teorijas ir praktiką.

Tokie tyrimai, kurie analizuoja netikėtumo reiškinio poveikį akcijų grąžai,

mokslinėje ir nemokslinėje literatūroje paprastai vadinami makroekonominių naujienų, pranešimų, netikėtumų, lūkesčių tyrimais ((Hussain 2010), (Gupta, Reid 2012), (Harju, Hussain 2011), (Gurgul, Wójtowicz 2014), (Miao, Ramchander, Zumwalt 2014), (Chen, Liu, Lu, Tang 2015), (Nadleri, ir Schmidt 2016), (Cakan, Gupta 2017), (Alexiou, Vogiazas ir Taqvi 2018) ir kt). Šie tyrimai įvertina ne tik faktines, bet ir prognozes makroekonominių rodiklių reikšmes, taip sukurdami netikėtumo rodiklį, kuris ir yra svarbiausias kintamasis, modeliuojant akcijų grąžą per trumpą laiko tarpą.

Tačiau atlikta šių tyrimų analizė parodė:

- nėra pakankamai išplėta didelių dažnių duomenų analizė, t. y. mokslininkai tokiuose tyrimuose vis dar pasirenka tirti dienes akcijų grąžas, todėl lieka neišskaidyti, kaip greitai (minučių tikslumu) nagrinėjama vertybinių popierių rinka prisitaiko prie makroekonominių rodiklių netikėtumų;

- trūksta tyrimų, nagrinėjančių euro zonos akcijų rinką, o dažniausiai sutinkami tyrimai buvo atlikti JAV rinkai;

- nė viename darbe nebuvo pastebėta, kad siekiant sukurti tikslesnius prognozavimo modelius, makroekonominių rodiklių netikėtumų reikšmės būtų suskaidytos į įvairius scenarijus.

- vis dar naudojami tradiciniai akcijų grąžos modeliavimo metodai ir atsiribojama nuo naujesnių bei inovatyvių mašininio mokymosi metodų;

- mokslininkų darbuose trūksta gerųjų modeliavimo praktikų taikymo, kai remiantis skirtingais metodais sukuriama daugiau nei keli modeliai, kurie lyginami tarpusavyje, siekiant rasti geriausią.

Būtent dėl šių neišplėtotų požiūrių ir anksčiau minėtų teorijų bei jiems būdingų darbų ribotumų yra atliekamas šis tyrimas ir formuluojama mokslinė problema.

Mokslinė problema: kokia yra makroekonominių rodiklių netikėtumų reikšmės esmė, kaip ją įvertinti ir modeliuoti makroekonominių rodiklių netikėtumų poveikį akcijų grąžai tradiciniais ir mašininio mokymosi metodais.

Mokslinio tyrimo objektas – makroekonominių rodiklių netikėtumų poveikis akcijų grąžai.

Tyrimo tikslas – ištirti makroekonominių rodiklių netikėtumų reikšmę ir jo sąsajas su akcijų grąža bei sudaryti ir empiriškai patikrinti makroekonominių rodiklių netikėtumų poveikio akcijų grąžai prognozavimo modelius, panaudojant tradicinius ir mašininio mokymosi metodus.

Tyrimo uždaviniai:

1. Išanalizuoti akcijų grąžą nagrinėjančias teorijas, susijusias su makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliavimo tyrimais.
2. Atskleisti makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliavimo tyrimų metodus.
3. Parengti metodiką makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliuoti.
4. Atskleisti mašininio mokymosi naudojamus metodus modeliuojant akcijų grąžą ir jų skirtumą nuo tradicinių metodų.
5. Patikrinti metodiką makroekonominių rodiklių netikėtumų poveikio EURO STOXX 50 grąžai prognozuoti, taikant tradicinius metodus.
6. Patikrinti metodiką makroekonominių rodiklių netikėtumų poveikio EURO STOXX 50 grąžai prognozuoti, taikant mašininio mokymosi metodus.
7. Palyginti gautus empirinius rezultatus, taikant tradicinius ir mašininio mokymosi metodus makroekonominių rodiklių netikėtumų poveikio EURO STOXX 50 grąžai prognozuoti, tarpusavyje bei atlikti modelių tikslumo ir EURO STOXX 50 grąžos sąryšio analizę laiko eilutėje.

Tyrimo hipotezės:

H_1 : Makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis tradiciniais metodais.

H_2 : Makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis mašininio mokymosi metodais.

H_3 : Mašininio mokymosi metodai, palyginus su tradiciniais metodais, leidžia sukurti tikslesnius makroekonominių rodiklių netikėtumų poveikio akcijų grąžai prognozavimo modelius.

Mokslinio tyrimo metodai. Mokslinės literatūros analizės ir sintezės, apibendrinimo, lyginimo ir grafiniai metodai buvo taikomi, siekiant nustatyti dažniausiai sutinkamus požiūrius ir tyrimus, analizuojant akcijų grąžą, prognozavimo modelių analizei pateikti ir ribotumams išskirti, netikėtumo rodikliui apibrėžti.

Rengiant metodologinę-empirinę tyrimo dalį, taikyta skaitinė ir grafinė makroekonominių rodiklių duomenų analizė. Indekso grąžos minutei nustatyti naudotos koreliacinės matricos. Tradiciniams modeliams sudaryti naudota regresijos analizė, ARCH efektų patikrinimai. Inovatyviems modeliams sudaryti naudoti mašininio mokymosi metodai: regresijos, atsitiktinio miško, sprendimų medžio, GBR ir neuroninių

tinklų. Modeliams palyginti tarpusavyje naudoti determinacijos koeficientai, mažiausių kvadratų paklaidų metodai. Modelių tikslumo ir EURO STOXX 50 gražos sąryšio analizė atlikta, naudojant lyginamuosius, skaitinius ir grafinius metodus.

Duomenims analizuoti naudojamas programinis paketas „Microsoft Excel“, kuris taikytas makroekonominių rodiklių grafikams sudaryti bei modelio tikslumo EURO STOXX 50 gražos sąryšio grafikams sukurti. Modeliams atlikti buvo naudojamas paketas „Jupyter Notebook“. Užklausoms, analizei ir modeliams sukurti naudojama programavimo kalba „Python“. Pagrindinis makroekonominių rodiklių duomenų šaltinis – duomenų bazė „Bloomberg“.

Tyrimo apribojimai. Akcijų gražą paprastai veikia daug reiškinių, bet šiam tyrimui pasirinktas tik makroekonominių rodiklių netikėtumo reiškinys, darant prielaidą, kad niekas kitas neveikia pasirinkto akcijų indekso per trumpą laiko tarpą iki 45 minučių po makroekonominio rodiklio realizacijos momento.

Makroekonominių rodiklių netikėtumų reiškinio sandara šiame tyrime argumentuojama, atsižvelgiant į tris akcijų gražą nagrinėjančias teorijas. Imama, kad reiškinio charakterizuojantis kintamasis turi fundamentalios analizės, finansų elgsenos ir efektyvios rinkos hipotezės elementų – tai yra unikalus šio tyrimo autoriaus požiūris, kuris gali būti tiek teisingas, tiek neteisingas.

Tyrimo daroma prielaida, kad makroekonominių rodiklių netikėtumų poveikis nesitęsia ilgiau nei 45 min. Ši prielaida argumentuojama tuo, kad dažniausiai makroekonominių rodiklių realizacija vyksta kas valandą, tuo siekiama išvengti akcijų indekso gražos svyravimo įtraukimo į modelį, kuriam įtaką gali turėti dar nerealizuoti, bet labai finansų rinkose laukiami rodikliai.

Nors tyrimo laikotarpis ir reprezentatyvus – 12 metų, tačiau patys makroekonominiai rodikliai pasirodo vidutiniškai maždaug kas mėnesį. Todėl prognozavimo modeliai nėra sudaryti iš daug duomenų, kas gali paveikti modelių tikslumo pokytį, įtraukus naujų duomenų. Tyrimo laikotarpio parinkimas susijęs ir su duomenų gavimo galimybėmis. Senesnių 2008 m. duomenų gauti nepavyko, kas taip pat yra šio tyrimo ribotumas, nes:

- a) neleidžia įvertinti, kaip kito akcijų gražą prieš finansų krizę;
- b) mažiau duomenų, kas daro prognozavimo modelius nestabilius ir mažiau patikimus;
- c) mažiau galimybių sudaryti daugiau modeliavimo scenarijų, pavyzdžiui, kokį poveikį makroekonominių rodiklių netikėtumai turėjo prieš finansų krizę ir po jos.

Prognozavimo modeliai sukurti ne akcijai ar indeksui, kuriuo yra prekiaujama biržoje, o etalonui (akcijų indeksui EURO STOXX 50). Etalonais paprastai nėra prekiaujama akcijų biržose, bet būna sukurti juos „sekantys“ fondai. Tačiau fondų ir etalonų kainų įverčiai ar jų procentiniai pokyčiai ne visada sutampa ar turi sutapti, todėl tai šiek tiek apriboja gautus tyrimų rezultatus: neleidžia jų iš karto pritaikyti investicinėje veikloje, nebent naudojamas ETF, kuris 100 % sinchronizuojasi su EURO STOXX 50 etalonu. Verta paminėti, kad EURO STOXX 50 indeksas yra išvestinis iš 19 bendrų EURO STOXX regioninių kategorinių sektorių indeksų ir yra kategorinis sektoriaus lyderis euro zonoje laisvosios rinkos kapitalizacijos prasme. Indeksas užfiksuoja apie 60 % visos EURO STOXX bendrosios rinkos indekso kapitalizacijos, kas savo ruožtu apima apie 95 % atstovaujamų šalių laisvosios rinkos kapitalizacijos.

Mokslinė disertacijos vertė ir taikomoji darbo reikšmė.

1. Išanalizavus pagrindines akcijų grąžą aiškinančias teorijas, pateikti šių teorijų tyrimų ribotumai, taip pereinant prie makroekonominių rodiklių netikėtumo reiškinio tyrimų ir jų įnašo vystant šias teorijas ir praktiką. Pastebėta, kad fundamentalios analizės teorijos tyrimai gali būti praplečiami, analizuojant VP grąžą ne mėnesio, bet dienos, minučių ir kitu dažnumu. Galima praplėsti ar modifikuoti fundamentaliosios analizės ir ERH teorijų suvokimą ir į tyrimus įtraukti ne tik faktines rodiklių reikšmes, bet ir prognozes reikšmes, kurios bent iš dalies atspindėtų rinkos lūkesčius, kas yra svarbi dedamoji, parodanti finansų rinkos dalyvių psichologinę būklę. Finansų elgsenos tyrimai gali būti praplečiami, analizuojant ne tik tekstinę informaciją, kuria remiantis kuriami sentimentų rodikliai ir modeliuojamas jų poveikis akcijų grąžai, bet paimant ir makroekonominius rodiklius.

2. Tyrimų, susijusių su makroekonominių rodiklių netikėtumų poveikiu akcijų grąžai, buvo rasta mažai. Todėl šis tyrimas praplečia panašių tyrimų lauką ir įneša naujų rezultatų ir įžvalgų analizuojama tematika. Pagrindiniai šio tyrimo išskirtinumai lyginant su kitais panašios tematikos tyrimais:

a) akcijų grąža analizuojamos per labai trumpą laiko tarpą (minutės dažnumu iki 45 minučių);

b) akcijų grąža analizuojama pagal įvairius makroekonominių rodiklių netikėtumų reikšmių scenarijus;

c) modeliams sudaryti naudojami ne tik tradiciniai, bet ir inovatyvūs – mašininio ir giliojo mokymosi – metodai.

3. Atlikus makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tyrimų analizę buvo nustatyta, kad trūksta tyrimų, nagrinėjančių euro zonos akcijų rinką. Todėl tyrimui buvo pasirinktas EURO STOXX 50 indeksas – etalonas, taip praplečiant tyrimų rinkas analizuojama tematika.

4. Sukūrus makroekonominių rodiklių netikėtumų poveikio EURO STOXX 50 grąžai prognozavimo modelius tiek tradiciniais tiek mašininio mokymosi metodais buvo nustatyta, kad mašininio mokymosi modeliai yra kur kas tikslesni. Todėl disertacija gali būti naudinga panašios tematikos tyrėjams, pvz., tiriant makroekonominių rodiklių netikėtumų poveikį kitoje akcijų rinkoje, ir kaip vieną iš metodų pasirenkant mašininio mokymosi metodą.

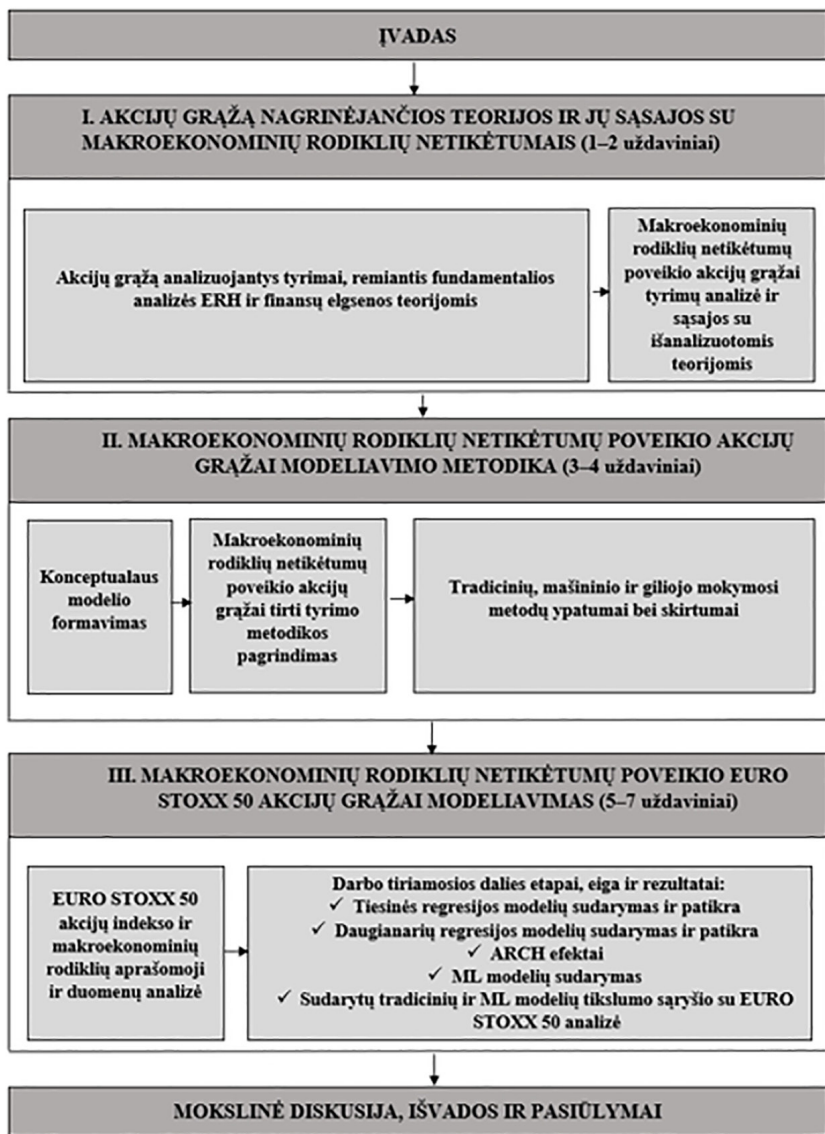
5. Atlikus modelių tikslumo ir EURO STOXX 50 grąžos sąryšio analizę nustatyta, kokios akumuliuotos grąžos su tam tikru tikslumu galima tikėtis konkrečią pardavimo minutę, todėl disertacija gali būti naudinga tiek profesionaliems, tiek neprofesionaliems investuotojams.

Ginamieji disertacijos teiginiai:

- Makroekonominių rodiklių netikėtumo reiškinys jungia fundamentalios analizės, efektyvios rinkos hipotezės ir finansų elgsenos teorijų principus bei leidžia atsirasti diskusijai dėl naujo įnašo vystant šias teorijas ir praktiką.
- Modeliuojant akcijų grąžą per trumpą laiko tarpą, tikslinga įtraukti makroekonominių rodiklių netikėtumų poveikį.
- Taikant mašininio mokymosi metodus akcijų grąžai prognozuoti, gaunami tikslesni modeliai, nei taikant tradicinius metodus.

Loginė disertacijos struktūra. Disertaciją sudaro įvadas, trys skyriai, mokslinė diskusija, išvados, literatūros sąrašas ir priedai. Disertacijos apimtis – 172 psl. (su priedais – 204 psl.). Naudotasi 137 šaltiniais.

Disertacinio tyrimo loginė schema pateikta 1 paveiksle.



Šaltinis: sudaryta autoriaus

1 pav. Disertacinio tyrimo loginė schema

Pirmajame disertacijos skyriuje išanalizuotos su makroekonominį rodiklių netikėtumais susijusios teorijos, su šiomis teorijomis susiję tyrimai, nagrinėjantys akcijų grąžą. Pateikti fundamentalios analizės lygiai, specifika, atlikimo būdai bei privalumai ir trūkumai. Nustatyti dažniausiai naudojami makroekonominiai rodikliai ir pateikti apibendrinti tyrimų rezultatai akcijų grąžai prognozuoti. Pristatyta efektyvios rinkos hipotezės teorija, jos formos ir su teorija susiję tyrimai, nagrinėjantys akcijų grąžą. Atskleista finansų elgsenos teorijos esmė, jos vaidmuo investicinių sprendimo priėmimo procese. Atliktas palyginimas tarp lūkesčių ir sentimentų sampratų ir paaiškinta, kodėl tarp šių sąvokų negalima dėti lygybės ženklo. Pateikta sąsaja tarp makroekonominį rodiklių netikėtumų ir išanalizuotų fundamentalios analizės, ERH, finansų elgsenos teorijomis, jų tyrimais. Pateikta, kaip makroekonominį rodiklių netikėtumų tyrimai galėtų praplėsti ar modifikuoti esančias teorijas, jų požiūrius, praplėsti taikomas praktikas, sumažinti ar panaikinti taikomų tyrimų ribotumus. Galiausiai atskleisti dažniausiai makroekonominį rodiklių netikėtumų poveikio akcijų grąžai modeliuoti tyrimuose naudojami metodai.

Antrasis disertacijos skyrius skirtas parengti makroekonominį rodiklių netikėtumų poveikio akcijų grąžai modeliuoti metodiką bei atskleisti mašininio mokymosi naudojamus metodus, modeliuojant akcijų grąžą ir jų skirtumą nuo tradicinių metodų. Skyriaus pradžioje sukurtas makroekonominį rodiklių netikėtumų poveikio akcijų grąžai tirti konceptualus modelis. Sudaryta ir pagrįsta tyrimo metodika: formuojamos ir argumentuojamos tyrimo hipotezės, paaiškinama sudaryta tyrimo loginė schema ir specifika. Remiantis mokslinių tyrimų analize, pateikti labiausiai su analizuojama tematika susiję tradicinių metodų ypatumai. Atrasta, kokiose tyrimų kryptyse dažniausiai naudojami dirbtinio intelekto metodai akcijų grąžai modeliuoti. Atskleisti statistinio modeliavimo ir mašininio mokymosi skirtumai. Išanalizuoti pagrindiniai mašininio ir giliojo mokymosi metodai ir ypatumai. Skyriaus gale pateikti tyrimo apribojimai.

Trečiasis disertacijos skyrius skirtas modeliuoti makroekonominį rodiklių netikėtumų poveikį EURO STOXX 50 akcijų grąžai. Skyriaus pradžioje pateikta EURO STOXX 50 akcijų indekso aprašomoji ir pasirinktų makroekonominį rodiklių duomenų analizė. Pirmame empirinio tyrimo etape sudaromi ir atrenkami tiesinės regresijos modeliai, tikrinamos šių modelių prielaidos. Antrajame empirinio tyrimo etape keliamas klausimas, ar galima sukurti daugianarius regresijos modelius. Trečiajame tyrimo etape patikrinami likę regresijos modeliai, ieškant ARCH efektų, ir esant poreikiui – kuriami GARCH modeliai. Tada tiems patiems duomenų rinkiniams yra kuria-

mi mašininio mokymosi metodais grįsti modeliai. Gauti tiek tradicinių, tiek mašininio mokymosi modelių rezultatai lyginami tarpusavyje ir nustatoma, kuris modelis geriausiai paaiškina EURO STOXX 50 indekso grąžą konkrečiu atveju. Skyriaus pabaigoje atliekama sukurtų modelių tikslumo ir EUTO STOXX grąžos sąryšio laiko eilutėje analizė grafiniu metodu. Pateikiama mokslinė tyrimo rezultatų diskusija.

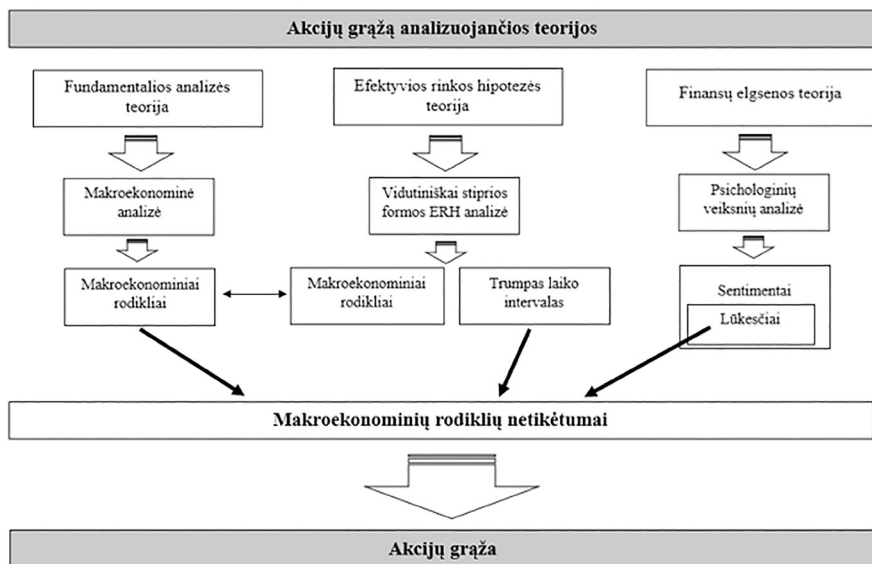
Pagrindiniai disertacijos teiginiai ir išvados.

Šiame tyrime makroekonominių rodiklių netikėtumo reiškinyms ir su juo susiję tyrimai yra suprantami ir aiškinami iš trijų didelių teorijų požiūrio perspektyvos: fundamentalios analizės teorijos, efektyvios rinkos hipotezės teorijos ir finansų elgsenos teorijos. Atlikus šių teorijų tyrimų ribotumą analizę ir nustačius sąsajas su makroekonominių rodiklių netikėtumo tyrimais išvelgiama, kad fundamentalios analizės teorijos tyrimai gali būti praplečiami, prognozuojant VP grąžą ne mėnesio, bet dienos, minučių ir kitu dažnumu. VP grąžos prognozavimas per trumpą laiką padėtų investuotojams ir mokslininkams aiškiau suprasti, kaip kinta akcijų grąža ir kaip greitai ji prisitaiko prie makroekonominių rodiklių netikėtumų, o tai padidintų uždarbio galimybes. Taip pat galima praplėsti ar modifikuoti fundamentalios analizės ir ERH teorijų suvokimą, ir į tyrimus įtraukti ne tik faktines, bet ir prognozinės rodiklių reikšmes, kurios bent iš dalies atspindėtų rinkos lūkesčius, kas yra svarbi dedamoji, parodanti finansų rinkos dalyvių psichologinę būklę. Prognozinės rodiklių reikšmės kaip kintamojo panaudojimas praplėstų esamus tyrimus ir leistų tyrėjams geriau suprasti, kaip VP grąža priklauso nuo psichologinių aspektų, o tai didina uždarbio galimybes. Galiausiai pastebima, kad finansų elgsenos tyrimai gali būti praplečiami, analizuojant ne tik tekstinę informaciją, kuria remiantis kuriami sentimentų rodikliai ir modeliuojamas jų poveikis akcijų grąžai, bet paimant ir makroekonominius rodiklius. Tai praplėstų finansų elgsenos teorijos tyrimų lauką ir suteiktų naujų kryptių praktikos vystymui.

Makroekonominių rodiklių netikėtumų poveikiui akcijų grąžai modeliuoti dažniausiai naudojami: regresijos analizės (mažiausių kvadratų), GJR-GARCH, ARMA-GARCH, SV, GJD, ES, BVAR metodai. Iš jų dažniausiai sutinkami yra regresijos analizės mažiausių kvadratų metodas ir ARMA-GARCH metodai. Pastebima, kad mašininio mokymosi metodai panašios tematikos tyrimuose nebuvo naudojami, bet užtat yra naudojami šiame tyrime, kas yra naujovė tokio tipo tyrimuose. Tradicinių ir kartu mašininio mokymosi metodų panaudojimas leidžia objektyviau įvertinti gautus tyrimų rezultatus, palyginti gautų prognozavimo modelių rezultatus tarpusavyje ir pasirinkti

geriausią prognozavimo modelį.

Apibendrinus ekonomikos teorijas ir empirinius tyrimus, susijusius su atskirų veiksmų taikymu akcijų grąžai aiškinti ir prognozuoti, sudarytas konceptualus teorinės dalies makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tirti modelis (žr. 2 pav.). Modeliu siekiama nustatyti, kaip akcijų grąža yra analizuojama, remiantis fundamentaliosios, efektyvios rinkos hipotezės ir finansų elgsenos teorijų požiūriais.



Šaltinis: sudaryta autoriaus.

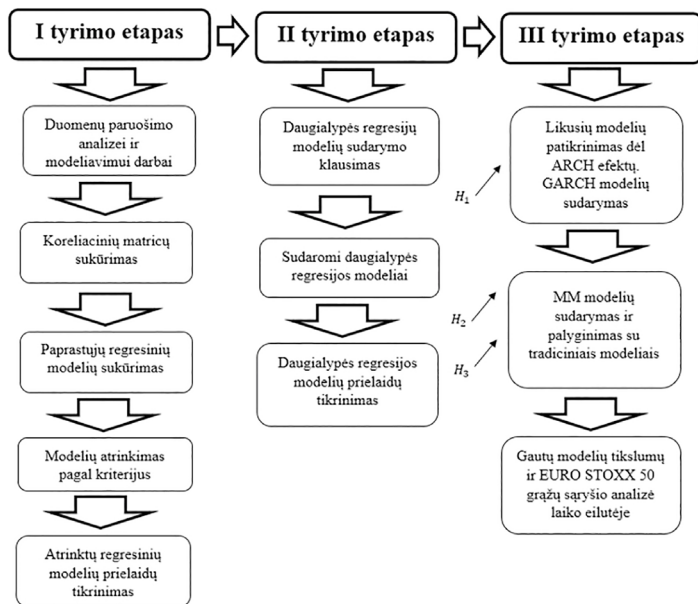
2 pav. Konceptualus teorinės dalies makroekonominių rodiklių netikėtumų poveikio akcijų grąžai tirti modelis

Disertacinio tyrimo autoriaus požiūrį į akcijų grąžos prognozavimą iliustruoja 2 pav., parodantis, kokiomis teorijomis remiamasi, formuojant disertacinio tyrimo modelį. Akcijų grąžos prognozavimas pagrįstas fundamentaliosios analizės, ERH, finansų elgsenos teorijomis. Iš fundamentaliosios analizės teorijos išskirta makroekonominė analizė, kuri apima makroekonominius rodiklius. Iš ERH išskirta vidutiniškai stiprios formos ERH, kuri apima makroekonominius rodiklius. Kadangi EHR tyrimais siekiama nustatyti, kaip greitai (minučių, valandos, dienos tikslumu) akcijų kainos ar grąžos prisitaiko prie naujos informacijos apie svarbius makroekonominius įvykius pasirinktoje

rinkoje, tai kaip atskiras svarbus veiksnys išskirtas trumpas laiko intervalas. Iš finansų elgsenos teorijos pabrėžta psichologinių veiksnių analizė, kuri apima sentimentus, o šie – lūkesčius.

Taigi makroekonominiai rodikliai, trumpas laiko intervalas ir lūkesčiai formuoja makroekonominių rodiklių netikėtumo reiškinių, kuris daro įtaką akcijų grąžai. Tai yra unikalus šio tyrimo autoriaus požiūris, kuris gali būti diskutuotinas. Verta paminėti, kad nagrinėjamuose darbuose makroekonominių rodiklių netikėtumai nebuvo prilyginami reiškiniui, tad šio darbo autorius negali diskutuoti ir lyginti savo nuomonės su kitais mokslininkais. Makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modelio privalumas tas, kad jį formuojant atsižvelgiama į visus tris akcijų grąžą lemiančius veiksnys. Tokia idėja išsprendžia minėtų teorijų tyrimų ribotumus bei leidžia atsirasti diskusijai dėl naujo įnašo vystant šias teorijas ir praktiką.

Išanalizavus akcijų grąžą nagrinėjančias teorijas ir pateikus jų sąsajas su makroekonominių rodiklių netikėtumais, sudaryta makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliavimo metodika, kuri apima tris duomenų analizės ir modeliavimo etapus (žr. 3 pav.).



Šaltinis: Sudaryta autoriaus.

3 pav. Tyrimo etapai

Pirmajame etape atliekami paruošimo duomenų analizei ir modeliavimo darbai, koreliacinių matricų sukūrimas pagal penkis scenarijus, paprastųjų regresijų modelių sukūrimas ir jų atranka pagal kriterijus bei prielaidas. Antrajame etape keliamas klausimas, ar po pirmojo etapo likusius regresijos modelius galima išplėsti, įtraukiant daugiau makroekonominių rodiklių, taip gaunant daugianarius regresijos modelius ir po to juos patikrinant pagal I etapo išsikeltus kriterijus ir prielaidas. Į trečiąjį tyrimo etapą papuola visi tiesiniai regresijos modeliai po pirmojo etapo ir visi daugianariai regresijos modeliai po antrojo etapo, kurie tenkina visus kriterijus ir prielaidas. Trečiojo etapo pirmajame žingsnyje esami regresijos modeliai tikrinami, ieškant ARCH efektų, ir jei juos regresijos modeliai turi, sudaromi GARCH modeliai. Sukūrus tradicinius modelius, tiems patiems duomenų rinkiniams yra kuriami mašininio mokymosi modeliai, kurių tikslumas ir paklaidos palyginamos su tradiciniais modeliais. Trečiojo etapo pabaigoje atliekama modelių tikslumo ir EURO STOXX 50 indekso grąžos sąryšio analizė 45 minučių laiko eilutėje.

Atlikus mašininio mokymosi taikymo modeliuojant akcijų kainą ir grąžos analizę pastebėta, kad regresijos tipo uždaviniams mokslininkai dažniausiai taiko sprendimų medžio, atsitiktinio miško, tiesinės regresijos, GBR ir giliojo mokymosi metodus. Pagrindinis skirtumas tarp tradicinių ir mašininio mokymosi metodų yra tas, kad tradiciniu metodu siekiama kuo labiau sumažinti vidutinę kvadratinę paklaidą ir rasti ryšių tarp kintamųjų reikšmingumą, tuo tarpu mašininio mokymosi metodo tikslas yra pasiekti geriausią testo rinkinio tikslumą. Šis atskleidimas leidžia mokslininkams ir investuotojams geriau suvokti, kada geriau naudoti tradicinius, o kada – mašininio mokymosi metodus.

Atlikus parengtos makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliavimo metodikos, taikant tradicinius metodus, patikrinimą, hipotezė, kad makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiką tarpą remiantis tradiciniais metodais, dalinai priimta. Dalinai todėl, kad iš visų tyrime pasirinktų makroekonominių rodiklių (26) pagal įvairius faktinių duomenų scenarijus tik kelių rodiklių poveikis EURO STOXX 50 grąžai buvo nustatytas kaip statistiškai reikšmingas. Patikrinimo metu iš viso buvo sudaryti 133 tiesiniai ir 5 daugianariai regresijos modeliai. Iš jų tik 5 tiesiniai regresijos modeliai atitiko visus išsikeltus kriterijus ir regresijos analizės prielaidas. Šie modeliai buvo tikrinami, ieškant ARCH efektų, tačiau jų nebuvo aptikta. Remiantis gautais rezultatais ir analizuojant, kas galėjo lemti mažą statistiškai patikimų prognozavimo modelių skaičių, buvo prieita prie tokių nuomonių: per mažas analizavimo laiko intervalas minutėmis; netinkama makroekonono-

minio rodiklio netikėtumo formulė; netinkami metodai; makroekonominių rodiklių netikėtumai nedaro tokios didelės įtakos akcijų grąžai kaip tikėtasi ir kt. Gauta išvada siūlo investuotojams ir mokslininkams atsargiai tikėtis gerų prognozavimo modelių rezultatų panašios tematikos tyrimuose euro zonos akcijų rinkoje, naudojant panašią tyrimo metodiką ir taikant tradicinius metodus.

Atlikus parengtos makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliavimo metodikos, taikant mašininio mokymosi metodus patikrinimą, hipotezė, kad makroekonominių rodiklių netikėtumai turi poveikį akcijų grąžai per trumpą laiko tarpą, remiantis mašininio mokymosi metodais, priimta. Su tais pačiais tradicinių modelių duomenų rinkiniais sudarius mašininio mokymosi modelius, buvo gauti validūs rezultatai. Idėja panaudoti mašininio mokymosi metodus šiame tyrime pasiteisino. Todėl rekomenduojama tęsti tyrimą ta pačia tematika, bet kaip atskaitos tašką (bazinius) prognozavimo modelius sukurti remiantis ne tradiciniais metodais, bet mašininio mokymosi metodais. Mokslininkams ir investuotojams tai gali būti papildomas postūmis domėtis kitokiais, inovatyvesniais metodais, prognozuojant akcijų grąžą.

Trečioji tyrimo hipotezė, teigianti, kad mašininio mokymosi metodai, palyginus su tradiciniais metodais, leidžia sukurti tikslesnius makroekonominių rodiklių netikėtumų poveikio akcijų grąžai prognozavimo modelius yra priimta. Mašininio mokymosi modelių tikslumas yra 2–3 kartus didesnis, o paklaidos 10 kartų mažesnės nei tradicinės tiesinės regresijos modelių. Remiantis gautais tyrimo rezultatais, rekomenduojama modeliuoti akcijų grąžą, remiantis ne tik tradiciniais, bet ir mašininio mokymosi metodais. Atlikus modelių tikslumo ir EURO STOXX 50 grąžos sąryšio analizę laiko eilutėje, rekomenduojama pardavimo sandorius atlikti taip: RBVP atveju – per pirmas 10 minučių, kur 4 minutę galima gauti patikimiausią grąžą; pramonės produkcijos atveju pagal du scenarijus – nuo 33 iki 45 min., kur patikimiausia grąža gaunama atitinkamai 40 ir 42 minutę; preliminarinių duomenų VKI atveju – nuo 33 iki 45 min., kur patikimiausia grąža gaunama 36 minutę; VKI, išskyrus energiją, maistą, alkoholį ir tabaką, – tarp 9 ir 23 min., kur patikimiausia grąža užfiksuota 10 minutę.

Tolesni tyrimai galėtų būti vykdomi šiomis kryptimis:

1. Siekiant panaikinti šio tyrimo ribotumus:

a) Akcijų grąžą paprastai veikia daug reiškinų, tačiau šiame tyrime pasirinktas tik makroekonominių rodiklių netikėtumo reiškinys, darant prielaidą, kad niekas kitas, išskyrus minėtą reiškinį, neveikia pasirinkto akcijų indekso. Siekiant panaikinti šį ribotumą, galima būtų pasirinkti ne vieną, o kelis reiškinus, kaip nepriklausomus

kintamuosius.

b) Tyrime darome prielaida, kad makroekonominių rodiklių netikėtų poveikis nesitęsia ilgiau nei 45 minutes. Siekiant papildyti esamus rezultatus, galima būtų prailginti šį laiką ir pažiūrėti, kokie rezultatai gaunami.

c) Nors tyrimo laikotarpis ir yra reprezentatyvus – 12 metų, tačiau patys makroekonominiai rodikliai pasirodo vidutiniškai maždaug kas mėnesį. Todėl prognozavimo modeliai nėra sudaryti iš daug duomenų, kas gali paveikti modelių tikslumo pasikeitimą, įtraukiant naujų duomenų. Taigi, siekiant tęsti tyrimus panašia tematika, būtina pridėti naujausius duomenis. Galbūt naudotis kitomis (ne „Bloomberg“) duomenų bazėmis, kur duomenys būtų ilgesnio termino, nes šiame tyrime senesnių, nei kad 2008 m. duomenų gauti nepavyko.

d) Prognozavimo modeliai sukurti ne akcijai ar indeksui, kuriuo yra prekiaujama akcijų biržoje, o etalonui (akcijų indeksui EURO STOXX 50). Etalonais paprastai nėra prekiaujama akcijų biržose, tad priklausomąjį kintamąjį būtų galima pasirinkti ne akcijų rinkos etaloną, o biržoje prekiaujančius fondus, akcijas ar kt. Taip gautus tyrimo rezultatus galima būtų iš karto panaudoti investicinėje veikloje.

2. Šeštoji šio tyrimo išvada parodė, kad idėja panaudoti mašininio mokymosi metodus pasiteisino. Todėl rekomenduojama tęsti tyrimą ta pačia tematika, bet kaip atskaitos tašką bazinius prognozavimo modelius sukurti, remiantis ne tradiciniais metodais, bet mašininio mokymosi metodais. Tada tikėtina, kad bazinių modelių, kurie tenkintų visus išsikeltus kriterijus ir prielaidas būtų daugiau, nei kad šiame tyrime (penkta šio tyrimo išvada parodė, kad, taikant tradicinius metodus, bazinių modelių galiausiai liko penki).

3. Paskutinė autoriaus idėja, kaip būtų galima tęsti tyrimą – keisti modeliavimo logiką ir duomenų struktūrą. Rekomenduojama sudaryti nepertraukiamas laiko eilutes (kas minutę, visus 12 ar daugiau metų), pasirinkti ne vieną, o du priklausomus kintamuosius, kurių vienas galėtų būti kaip atskaitos taškas, matuojant kito reakciją į makroekonominių rodiklių netikėtumus. Nepertraukiamos laiko eilutės leistų nagrinėti akcijų grąžą ir prieš makroekonominių rodiklių netikėtumus. Patys tyrimo metodai taip pat keistųsi, ir, ko gero, būtų tenkinami ARCH efektai, tad būtų galimybė sudaryti GARCH modelius bei panaudoti kitus ML modelius, tokius kaip RNN ir LSTM, ir galiausiai praplėsti vidutiniškai stiprios ERH teorijos tyrimus.

TYRIMŲ REZULTATŲ SKLAIDA

Mokslinių publikacijų disertacijos tema sąrašas

1. Ligita Gasparėnienė; Rita Remeikienė; Aleksejus Sosidko; Vigita Vėbraitė; Evaldas Raistenskis. Modeling of EURO STOXX 50 index price returns based on industrial production surprises: basic and machine learning approach. Entrepreneurship and sustainability issues, vol. 8, no. 2. S1. 2020. Straipsnis DB Clarivate Analytics Web of Science. Vilniaus universitetas.

<https://repository.mruni.eu/handle/007/17035>

2. Ligita Gaspareniene; Rita Remeikiene; Aleksejus Sosidko; Vigita Vebraite. A Modelling of S&P 500 Index Price Based on U.S. Economic Indicators: Machine Learning Approach. Inzinerine Ekonomika-Engineering Economics, 2021, 32(4), 362–375. DOI: <https://doi.org/10.5755/j01.ee.32.4.27985>.

<https://inzeke.ktu.lt/index.php/EE/article/view/27985>

3. Ligita Gasparėnienė; Aleksejus Sosidko. Evaluation of the unemployment rate announcement impact on Euro Stoxx 50 index returns based on semi-strong efficient market hypothesis. Whither our economies - 2019 : International scientific conference : conference proceedings, [vol.] 6. P1c - Straipsnis konferencijos medžiagoje kitose duomenų bazėse. Mykolo Romerio universitetas.

<https://repository.mruni.eu/handle/007/16038>

Pranešimai mokslinėse konferencijose disertacijos tema

1. Aleksejus Sosidko. Modeling of Euro stoxx 50 price returns based on core CPI Surprises: Basic and machine learning approach. at the 7th International Scientific Conference “WHITHER OUR ECONOMIES – 2020” held on 17 September, 2020 at Mykolas Romeris University, Lithuania

2. Aleksejus Sosidko. Evaluation of the unemployment rate announcement impact on Euro Stoxx 50 index returns based on semi-strong efficient market hypothesis. at the 6th International Scientific Conference “WHITHER OUR ECONOMIES – 2019” held on 19-20 September, 2019 at Mykolas Romeris University, Lithuania

INFORMACIJA APIE DISERTACIJOS AUTORIŲ

Vardas, Pavardė: Aleksejus Sosidko
El. paštas: A.sosidko@gmail.com

Išsilavinimas:

Nuo 2017 Mykolo Romerio universitete vykdoma ekonomikos krypties doktorantūra
2013 - 2015 Mykolo Romerio universitete pagal Finansų rinkų studijų programą įgytas ekonomikos magistro laipsnis.
2009 - 2012 Klaipėdos valstybinėje kolegijoje pagal verslo vadybos studijų programą įgytas profesinio bakalauro laipsnis.

Darbo patirtis:

Nuo 2021 Energijos Skirstymo Operatorius (ESO), duomenų valdymo komanda – duomenų analitikas, mašininio mokymosi inžinierius
2019 - 2020 Disertacijos rašymas, mokymasis programuoti, taikymas mašininio mokymosi metodų, atlikta stažuotė ir praktika.
2017 - 2019 OC VISION, duomenų analitikas
2016 - 2017 RJF BALTIC, analitikas
2015 - 2016 KELVISTA, ekonomistas
2014 - 2015 SWEDBANK, draudimo ir investavimo grupė - klientų aptarnavimo specialistas
2013 - 2015 RJF BALTIC, personalo atrankos specialistas

MYKOLAS ROMERIS UNIVERSITY

Aleksejus Sosidko

MODELLING THE SURPRISE EFFECT OF
MACROECONOMIC INDICATORS ON STOCK
RETURNS

Summary of Doctoral Dissertation
Social Sciences, Economics (S 004)

Vilnius, 2022

This doctoral dissertation was prepared at Mykolas Romeris University during 2017–2021 under the right to organize doctoral studies granted to Vytautas Magnus University in cooperation with ISM University of Management and Economics, Mykolas Romeris University and Vilnius University by the order of the Minister of Education, Science and Sports of the Republic of Lithuania No. V-160 dated on February 22, 2019.

Scientific Supervisor:

Prof. Dr. Ligita Gasparėnienė (Mykolas Romeris University, Social Sciences, Economics, S 004).

The doctoral dissertation will be defended in the Council of Economic Science of Vytautas Magnus University, ISM University of Management and Economics, Mykolas Romeris University and Vilnius University Šiauliai Academy:

Chairperson:

Prof. Dr. Asta Vasiliauskaitė (Mykolas Romeris University, Social Sciences, Economics, S 004).

Members:

Prof. Dr. Gintaras Černius (Mykolas Romeris University, Social Sciences, Economics, S 004);

Prof. Dr. Valdonė Darškuvienė (ISM University of Management and Economics, Social Sciences, Economics, S 004);

Assoc. Prof. Dr. Aleksandra Fedajev (University of Belgrade, Republic of Serbia, Social Sciences, Economics, S 004);

Prof. Dr. Kristina Levišauskaitė (Vytautas Magnus University, Social Sciences, Economics, S 004).

The doctoral dissertation will be defended in the public session of the Council of Economic Science at Mykolas Romeris University, held at 11:00 on April 8th, 2022, at Mykolas Romeris University, Room I-414.

Address: Ateities str. 20, LT–08303 Vilnius, Lithuania.

The doctoral dissertation is available in Martynas Mažvydas National Library of Lithuania and ISM University of Management and Economics, Mykolas Romeris University, Vilnius University Šiauliai Academy, Vytautas Magnus University.

MODELLING THE SURPRISE EFFECT OF MACROECONOMIC INDICATORS ON STOCK RETURNS

SUMMARY

Relevance of the topic. The rapid development of financial markets and easily available financial products are shaping the growing interest of scientists, professional and non-professional investors in stock return and its determinants. Corporate stocks are among the most popular securities (according to the World Bank statistics, total stock market capitalisation has increased ~1.72 times since 2010 and in 2020 accounted for ~\$92 trillion), and fluctuations in stock prices, the causes of return fluctuations, stock return analysis, forecasting and evaluation are considered a separate area of research.

Some scientific studies, aimed at forecasting stock return, are based on the concept of fundamental analysis. The major presumption of this analysis is that stock return fluctuations are determined by macroeconomic, industrial or sectoral, corporate activity and other factors, so the analysis of the relevant indicator values is an important component in forecasting stock returns. Meanwhile, other scientific studies suggest that the dynamics of stock returns are affected by rational and/or irrational behaviour of the financial market participants. Researchers of the rational behaviour are proponents of the Efficient Market Hypothesis, while the researchers of the irrational behaviour belong to the area of behavioural finance.

In general, financial market participants are more likely to entrust their investments to efficient equity markets that are stable, sound, and difficult to manipulate for speculative purposes (presuming that efficient markets exist in developed countries

and vice versa; according to the World Bank 2020 statistics, the total capitalisation of the stock markets in developed countries is ~2.5 times higher than that in developing countries: ~\$66 trillion and ~\$26 trillion, respectively). While every opportunity for arbitrage can unbalance even a moderately strong efficient stock market, some factors such as availability of information online, innovative IT solutions and high mobility of electronic money obviously diminish this likelihood. On the other hand, financial market participants seek to maximize returns within their risk tolerance. As a result, different levels of information processing, different numbers of powerful analytical programs, different degrees of return and risk perception, emotions and so forth reduce the efficiency of stock markets. With different levels of stock market efficiency, different types of behaviour inherent to financial market participants, different return expectations and risk tolerance, application of only fundamental or behavioural finance, or only the Efficient Market Hypothesis analysing and modelling methodologies is insufficient.

This understanding has led to the search for an economic phenomenon that not only encompasses theoretical approaches, but also complements, reduces or eliminates their limitations. Thus, the phenomenon representing the surprise effect of macroeconomic indicators was observed. Modelling the effects of this phenomenon on stock returns is an under-explored area. In particular, this is due to the limited availability of data, as this type of research tends to employ high-frequency stock price data that are difficult to obtain and require the knowledge of a programming language or the knowledge of how to use large databases. Second, for the sake of simplicity, many studies are still based on the theories of a single stock returns but disregard the fact that stock markets are becoming increasingly complex and unpredictable due to huge information flows. Third, there are doubts as to whether traditional methods, which are generally applicable to a single theory, are still suitable for this type of research, while development and selection of innovative methods is often a difficult task. Thus, the limited availability of data, complexity of the issue and the difficulties to link various theories and select appropriate methods make the topic of the surprise effect of macroeconomic indicators extremely intricate and complicated, but at the same time very relevant and interesting.

The problem investigation level. The attempts to explain and forecast stock returns have been made for decades, and there are many studies focused on the major determinants of the stock return fluctuations.

Some scientific studies addressing stock returns are based on fundamental fac-

tors – macroeconomic ((Graham and Dodd 1934), (Panfil and Szablewski 2013), (Gurgul and Wójtowicz 2014), (Sinha and Kohli 2015), (Figurska and Wisniewski 2016) (Pražak and Stavarek, 2017), (Pooja and Giri, 2017), (Chamdrashekar, Sakthivel, Sampath and Chittedi, 2018), (Ho, 2018), (Abed and Zardoub 2019), (Tetteh, Adenutsi and Amoah 2019), (Erol and Aytekin 2019), etc.), industrial or sectoral ((Panfil and Szablewski 2013), (Borowski 2014), etc.), and corporate activity analysis ((Graham and Dodd 1934), (Figurska and Wisniewski 2016), etc.). The analysis of the effect of macroeconomic indicators on stock returns revealed that researchers tend to focus on monthly stock index returns. Although the effect of the indicators was found to be statistically significant, a monthly stock index is often affected by a number of other indicators that are not considered. In addition, researchers tend to focus on the actual values of macroeconomic indicators, without considering the prevailing market expectations which can also affect stock returns.

Other scientific studies focused on stock returns are based on the rational or irrational behaviour of the financial market participants. Representatives of the rational behaviour theory are proponents of the Efficient Market Hypothesis ((Fama, 1965, 1970), (Malkiel, 1992), (Yen and Lee, 2008), (Fama and French, 2015), (Altinkilic, Hansen and Ye, 2015), (Singh, Leepsa and Kushwaha 2016), (Sofat, 2016), (Mackey and Macon, 2017), (Andrade and Santos, 2017), (Jose and Suresh, 2017), (Barghouthi and Ehsan, 2017), (Nagpal and Jain, 2018), etc.). The studies based on the above-mentioned theory are commonly referred to as event studies. They aim to determine how quickly (in terms of minutes, hours, days) stock prices adjust to new information about important macroeconomic events in a selected market. Nevertheless, the models of this type often lack the elements of behavioural finance where a model comprises not only actual but also forecasted values of macroeconomic indicators.

The studies of the irrational behaviour ((Kahneman and Tversky 1979), (Shefrin, 2001), (Leipus and Norvaiša, 2004), (Fischer and Gerhardt, 2007), (Chandra 2008), (DeBondt, Forbes et al., 2010) (Kartašova, 2016, 2012) (Das and Panja 2019), (Nasiri, Sarraf, Nourollahzadeh, Hamidian and Noorifard 2021), etc.) focus on the impact of psychological factors on stock returns and can be categorised as the behavioural finance research. These studies emphasise that decision-making in the area of securities is a complex process that is affected by the following factors: personal, technical and psychological. Psychological factors, in their turn, cover sentiments, and the latter – expectations. Although literature is rich in research directions, applicability and methods,

previous studies lack the advantage of the EMH research - high-frequency data analysis and stock return modelling in the short run.

The above-mentioned limitations of previous theories and studies, as well as understanding that stock markets are becoming increasingly complex and information flows are getting huge, prompted to search for new approaches and research methods. This way, the studies addressing the surprise effect of macroeconomic indicators were discovered. In the author's opinion, they not only unite the principles of previous theories, but also contribute to the development of previous theories and practices.

In scientific and non-scientific literature, the studies focused on the surprise effect of macroeconomic indicators on stock returns are commonly referred to as the studies of macroeconomic news, reports, surprises and expectations ((Hussain 2010), (Gupta and Reid 2012), (Harju and Hussain 2011), (Gurgul and Wójtowicz 2014), (Miao, Ramchander and Zumwalt 2014), (Chen, Liu, Lu and Tang 2015), (Nadleri and Schmidt 2016), (Cakan and Gupta 2017), (Alexiou, Vogiazas and Taqvi 2018), etc.). They consider not only actual, but also forecasted values of macroeconomic indicators, thus creating a surprise indicator which is the major variable in modelling stock returns in the short run.

However, the investigation of these studies revealed that:

- their high-frequency data analysis is insufficient. i.e. researchers still tend to select daily stock return, so it remains unclear how quickly (in terms of minutes) the stock market under consideration adjusts to the surprises of macroeconomic indicators;
- they hardly cover the euro area stock market, but focus on the US stock market;
- none of the studies splits the values of the surprise indicator into particular scenarios to create more accurate stock return forecasting models for each case of the surprise indicator;
- they still use traditional stock return modelling methods and disregard newer and more innovative machine learning methods;
- they lack application of the best modelling practices when more than a few models are developed based on different methods and are compared to identify the best model.

The aforementioned underdeveloped approaches and theories as well as the limitations of previous studies confirmed the relevance of this research and allowed to formulate the scientific problem.

Scientific problem: what is the essence of the surprise effect of macroeconomic indicators and how to evaluate and model the surprise effect of macroeconomic indicators on stock returns by employing traditional and machine learning methods?

Scientific research object – the surprise effect of macroeconomic indicators on stock returns.

Research purpose – to research the phenomenon representing the surprise effect of macroeconomic indicators and its relationship with stock returns, to develop and empirically test the models for forecasting the surprise effect of macroeconomic indicators on stock returns by employing traditional and machine learning methods.

Research objectives:

1. To analyse the stock return theories related to modelling the surprise effect of macroeconomic indicators on stock returns.

2. To review the research methods applied for modelling the surprise effect of macroeconomic indicators on stock returns.

3. To develop the methodology for modelling the surprise effect of macroeconomic indicators on stock returns.

4. To review the machine learning methods used for modelling stock returns and disclose their difference from traditional methods.

5. To test the methodology used for forecasting the surprise effect of macroeconomic indicators on EURO STOXX 50 return by employing traditional methods.

6. To test the methodology used for forecasting the surprise effect of macroeconomic indicators on EURO STOXX 50 return by employing machine learning methods.

7. To compare the empirical results with regard to forecasting the surprise effect of macroeconomic indicators on EURO STOXX 50 return by employing traditional and machine learning methods, and to research the relationship between the accuracy of the models and EURO STOXX 50 return in a time series.

Research hypotheses:

H_1 : Based on traditional methods, the surprises of macroeconomic indicators have an effect on stock returns in the short run.

H_2 : Based on machine learning methods, the surprises of macroeconomic indicators have an effect on stock returns in the short run.

H_3 : Machine learning methods allow to develop more accurate models for forecasting the surprise effect of macroeconomic indicators on stock returns compared to traditional methods.

Research methods. Scientific literature analysis, synthesis, generalization, comparison and graphical methods were applied to identify the most relevant approaches and studies, to analyse stock return, to provide the analysis of forecasting models, to identify their limitations and to define the surprise indicator.

The numerical and graphical analysis of the data of macroeconomic indicators was used when preparing the methodological-empirical part of the thesis. Correlation matrices were applied to estimate the index return per minute. Regression analysis and ARCH effect checks were used to construct the traditional models. Machine learning methods were employed to develop the innovative models: regression, a random forest, a decision tree, GBR and neural networks. The coefficients of determination and least squares error methods were applied to compare the models. The analysis of the relationship between the accuracy of the models and EURO STOXX 50 return was performed using comparative, numerical and graphical methods.

The data were processed with 'Microsoft Excel' software which was used to make the graphs of the relevant macroeconomic indicators and the relationship between the accuracy of the models and EURO STOXX 50 return. Modelling was performed by using the 'Jupyter Notebook' package. The queries, analyses and models were developed by using the 'Python' programming language. The data on the relevant macroeconomic indicators were extracted from the 'Bloomberg Terminal'

Limitations of the research. Stock returns are usually affected by many phenomena, but only the phenomenon representing the surprise effect of macroeconomic indicators was selected for this research. The selection was based on the presumption that no other factor affects the selected stock index in a such short period of time which is up to 45 minutes after realisation of a macroeconomic indicator.

The structure of the phenomenon representing the surprise effect of macroeconomic indicators in this research is based on three theories dealing with stock returns. It is presumed that the variable characterizing the phenomenon possesses the elements of fundamental analysis, behavioural finance and the efficient market hypothesis. This is a unique approach followed by the author of this thesis which can be either right or wrong.

The research proposes that the surprise effect of macroeconomic indicators does not last longer than 45 minutes. This presumption leans on the fact that macroeconomic indicators are usually realised on an hourly basis. The presumption is accepted to prevent inclusion of the fluctuations in stock index returns in the model that can be affected by unrealised but highly expected indicators in financial markets.

Although the research period is representative and covers 12 years, macroeconomic indicators are released on average monthly. Therefore, the forecasting models are not composed of much data, which may affect the accuracy of the models with inclusion of new data. Selection of the research period is related to data availability. The data older than for 2008 were not available, which can also be considered the limitation of this research because:

- a) it does not reveal the fluctuation in stock returns before the financial crisis;
- b) it covers less data, which makes forecasting models unstable and less reliable;
- c) it provides fewer modelling scenarios, for instance, it does not reveal the surprise effect of macroeconomic indicators on stock returns before the financial crisis and after it.

The forecasting models are not designed for a stock or an index that is traded on an exchange, but for a benchmark (the stock index EURO STOXX 50). Benchmarks are not usually traded on stock exchanges but are followed by a number of funds. However, the estimates or percentage changes in the prices of funds and benchmarks do not always coincide or have to coincide, which limits the results of the research to some extent: the results cannot be immediately applied to investment activities unless an ETF which is 100% synchronized with the EURO STOXX 50 benchmark is used. It is worth noting that the EURO STOXX 50 index, which is derived from 19 common EURO STOXX regional categorical sectoral indices, is the categorical sector leader in the euro area in terms of free market capitalization. The index accounts for about 60% of the total capitalization of the EURO STOXX single market index which, in its turn, covers about 95% of the free market capitalization in the countries represented.

Scientific and applicable value of the thesis.

1. After analysing the major theories explaining stock return, the limitations of the studies based on these theories are presented, thus moving to the studies into the phenomenon representing the surprise effect of macroeconomic indicators and their contribution to the development of the theories and practices dealing with stock return. It was found that the studies focused on the theory of fundamental analysis can be extended by analysing stock return on a daily, minute and other frequency basis rather than on a monthly basis. The understanding of fundamental analysis and EMH theories can be broadened or modified by including not only actual, but also forecasted indicator values that at least partially reflect market expectations, which is an important component representing psychological disposition of the financial market participants. The behavioural finance studies can be extended by including not only textual

information, which is used for building sentiment indicators and modelling their effect on stock returns, but also macroeconomic indicators.

2. Thus far, little research on the surprise effect of macroeconomic indicators on stock returns has been conducted. Therefore, this thesis broadens the area of the relevant research and provides new results and insights into the topic under consideration. The major peculiarities of this research compared to other similar studies are as follows:

a) stock returns are analysed over a very short period of time (in terms of minutes, up to 45 minutes);

b) stock returns are analysed considering various scenarios of the surprise effect of macroeconomic indicators;

c) the models are based not only on traditional, but also on innovative – machine learning and deep learning – methods.

3. The analysis of previous studies considering the surprise effect of macroeconomic indicators on stock returns revealed that literature lacks the studies focused on the euro area stock market. Therefore, this research employed the EURO STOXX 50 index – a benchmark, thus expanding the scope of the markets investigated in similar studies.

4. The models developed for forecasting the surprise effect of macroeconomic indicators on EURO STOXX 50 return by employing traditional and machine learning methods revealed that machine learning is much more accurate. Thus, this thesis can be useful for researchers analysing similar topics, for instance, the surprise effect of macroeconomic indicators on other stock markets based on machine learning methods.

5. The analysis of the relationship between the accuracy of the models and EURO STOXX 50 return revealed what accumulated returns with a certain accuracy can be expected at a particular point of sale; thus, the findings of the thesis can be useful for professional and non-professional investors.

Defended statements of the thesis:

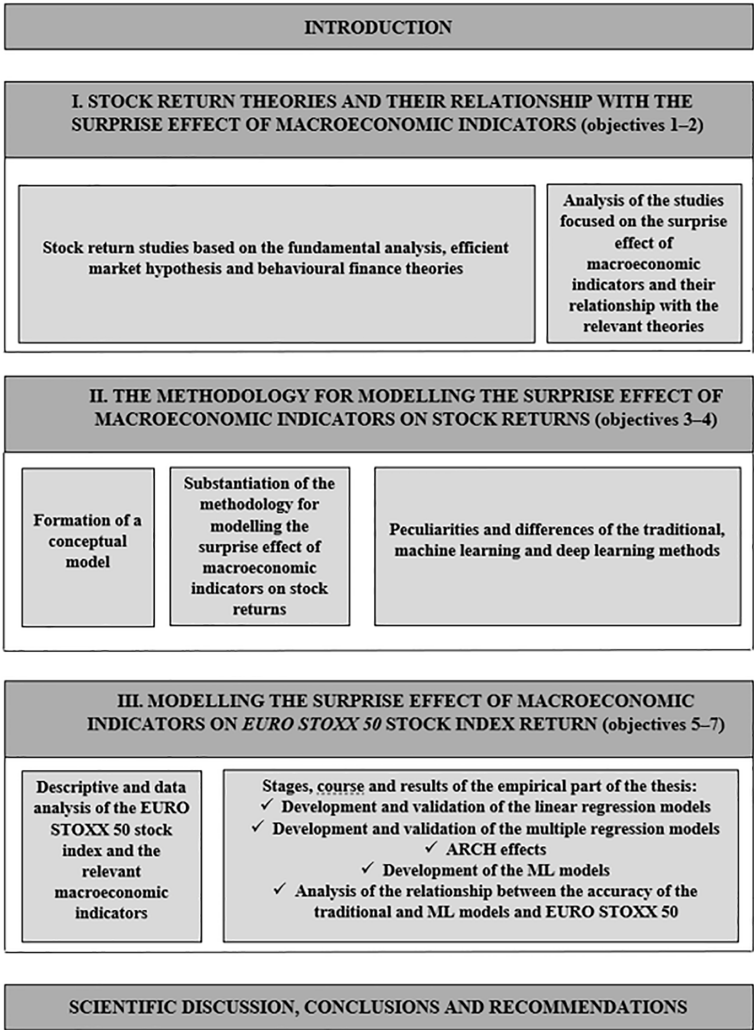
- The phenomenon representing the surprise effects of macroeconomic indicators combines the principles of fundamental analysis, efficient market hypothesis and behavioural finance, and allows for a discussion about a new contribution to the development of these theories and practices.

- When modelling stock returns in a short run, it is relevant to include the surprise effect of macroeconomic indicators.

- Machine learning methods applied for forecasting stock returns provide

more accurate models than traditional methods.

Logical structure of the thesis. The thesis consists of the introduction, three chapters, a scientific discussion, conclusions, references and appendices. The volume of the thesis is 172 pages (including appendices – 204 pages). The thesis covers 137 references. The logical scheme of the thesis is as follows (see fig. 1).



Source: compiled by the author

Fig. 1. Logical scheme of the thesis

The first chapter of the thesis focuses on the theories addressing the surprise effect of macroeconomic indicators and the studies based on these theories dealing with stock returns. This chapter reviews the levels, specifics, methods, advantages and disadvantages of fundamental analysis. It reveals the most common macroeconomic indicators and summarises the results of previous studies with regard to forecasting stock returns. It also reviews the theory of the efficient market hypothesis, its forms and the theory-related studies addressing stock returns. It reveals the essence of the behavioural finance and its role in the investment decision-making process. This chapter compares the concepts of expectations and sentiments and explains why they cannot be equalised. It presents the links between the surprise effect of macroeconomic indicators and the theories and studies of the fundamental analysis, EMH and behavioural finance. It reveals how the research into the surprise effect of macroeconomic indicators could expand or modify the existing theories, attitudes, applied practices, and reduce or eliminate the limitations of the applied research. Finally, it reviews the methods that are most commonly applied when modelling the surprise effect of macroeconomic indicators on stock returns.

The second chapter of the thesis focuses on the methodology for modelling the surprise effect of macroeconomic indicators on stock returns, reviews machine learning methods used for modelling stock return and discloses their differences from traditional methods. At the beginning of the chapter, a conceptual model to research the surprise effect of macroeconomic indicators on stock returns is developed. The research methodology is developed and substantiated: the research hypotheses are formed and argued, the logical scheme and specifics of the research are explained. Based on literature analysis, peculiarities of the traditional methods, which are most related to the topic under consideration, are provided. The chapter indicates which research areas most commonly employ artificial intelligence methods for modelling stock returns. It reveals the differences between the statistical modelling and machine learning, and reviews the key methods and features of machine learning and deep learning. The limitations of this research are provided at the end of this chapter.

The third chapter of the thesis focuses on modelling the surprise effect of macroeconomic indicators on EURO STOXX 50 index return. At the beginning of the chapter, a descriptive analysis of the EURO STOXX 50 stock index and the data representing the selected macroeconomic indicators is provided. In the first stage of the

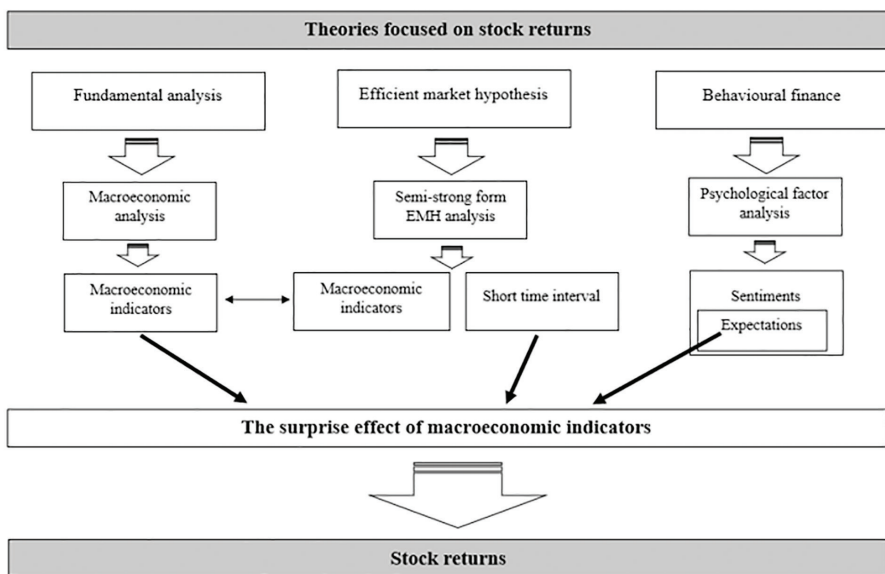
empirical research, the linear regression models are created and selected, and the pre-sumptions of these models are tested. The second stage of the empirical research raises the question of whether multiple regression models can be developed. In the third stage of the empirical research, the remaining regression models are tested for ARCH effects and, if necessary, GARCH models are developed. The models based on machine learning methods are then developed for the same data sets. The results generated by both traditional and machine learning models are compared, and the model that best explains the return of the EURO STOXX 50 index in a particular case is identified. At the end of the chapter, the time series analysis of the relationship between the accuracy of the models and the EURO STOXX return is performed by employing the graphical method. A scientific discussion of the research results is also presented.

The main statements and conclusions of the thesis

In this research, the phenomenon representing the surprise effect of macroeconomic indicators and the relevant studies are understood and interpreted from the perspective of three major theories: fundamental analysis, the efficient market theory and behavioural finance. The analysis of the limitations of these theories and their relationship with previous studies addressing the surprise effect of macroeconomic indicators revealed that the studies focused on fundamental analysis can be expanded by forecasting the return on securities in terms of a day, minutes and other relevant frequencies rather than a month. Forecasting the return on securities in the short run would help investors and researchers understand how stock returns are changing and how quickly they are adjusting to the surprises of macroeconomic indicators, which would raise earning potential. In addition, it is possible to broaden or modify the understanding of fundamental analysis and the efficient market hypothesis theory by researching not only actual, but also forecasted indicator values which at least partly reflect market expectations taking into account that the latter is an important component indicating psychological disposition of the financial market participants. The use of forecasted values as a variable would expand existing studies and would allow researchers to better understand how the return on securities depends on particular psychological aspects, which would raise earning potential. Finally, it is noted that the studies focused on behavioural finance can be expanded by analysing not only textual information, which is considered when building sentiment indicators and modelling their effect on stock returns, but also macroeconomic indicators. This approach would broaden the area of the behavioural finance research and provide the directions for developing new practices.

Regression analysis (least squares), GJR-GARCH, ARMA-GARCH, SV, GJD, ES and BVAR methods are the major ones used for modelling the surprise effect of macroeconomic indicators on stock returns. The least squares regression analysis and ARMA-GARCH methods are most common. It was observed that machine learning methods thus far have not been used in similar studies, but they are used in this research, which is an innovation in this type of research. Combination of the traditional and machine learning methods allows to evaluate the results more objectively, to compare the forecasting models and select the best forecasting model developed.

After reviewing the relevant economic theories and the empirical studies focused on application of various indicators for explaining and forecasting stock returns, a conceptual theoretical model representing the surprise effect of macroeconomic indicators on stock returns was developed (see fig. 2). The model aims to indicate how stock returns are analysed from the perspectives of fundamental analysis, the efficient market hypothesis and behavioural finance.



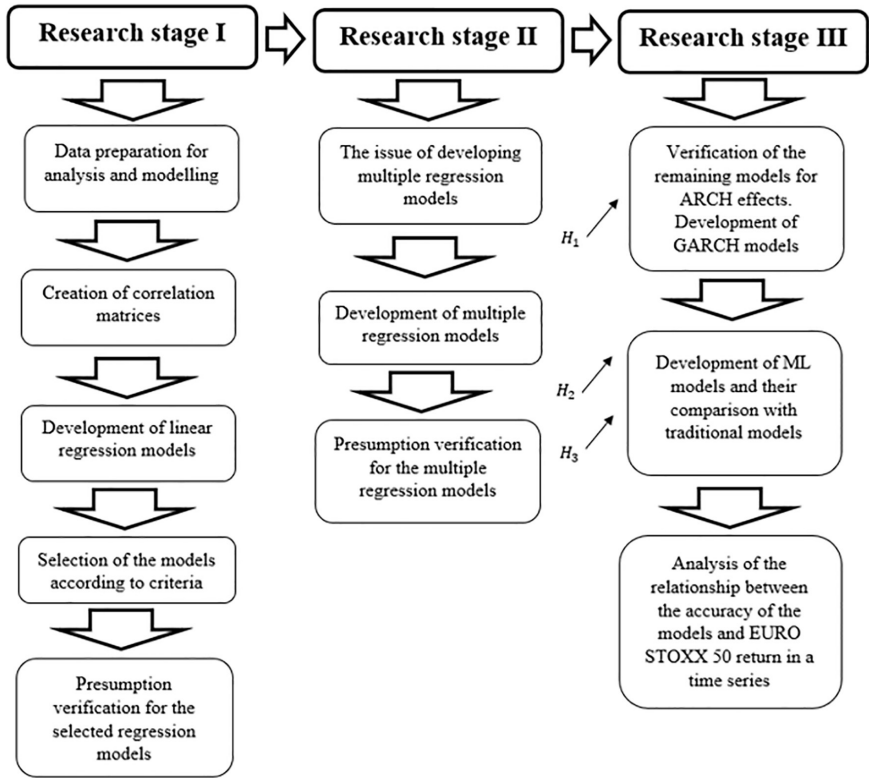
Source: compiled by the author.

Fig. 2. A conceptual theoretical model for researching the surprise effect of macroeconomic indicators on stock returns

Fig. 2 illustrates the approach of the author of this research towards forecasting stock returns. The figure indicates the theories that are employed for developing the model for the empirical research. Stock return forecasting is based on the theories of fundamental analysis, efficient market hypothesis and behavioural finance. Macroeconomic analysis comprising macroeconomic indicators is extracted from fundamental analysis. The semi-strong form EMH comprising macroeconomic indicators is extracted from the efficient market hypothesis. Since EMH aims to research how quickly (in terms of minutes, an hour, a day) stock prices or returns adjust to new information about important macroeconomic developments in a selected market, a short time interval is singled out as a separate important factor. Psychological factor analysis is extracted from the theory of behavioural finance that covers sentiments, and the latter, in their turn, cover expectations.

Thus, macroeconomic indicators, a short time interval and expectations are considered to shape the phenomenon representing the surprise effect of macroeconomic indicators on stock returns. This is a unique approach followed by the author of this thesis that may be debatable. It is worth noting that none of previous studies has treated the surprise effect of macroeconomic indicators as a phenomenon, so the author of this thesis cannot discuss and compare his attitudes with other scientists. The advantage of the model developed for forecasting the surprise effect of macroeconomic indicators on stock returns is that it considers all three factors which determine stock returns. This idea solves the limitations of the above-mentioned theories and allows for a discussion about a new contribution to the development of these theories and practices.

After analysing the theories focused on stock returns and revealing their connections with the surprise effect of macroeconomic indicators, the methodology for modelling the surprise effect of macroeconomic indicators on stock returns was developed. The methodology covers three data analysis and modelling stages (see fig. 3).



Source: compiled by the author.

Fig. 3. Research stages

The first stage covers data preparation for analysis and modelling, creation of correlation matrices by five scenarios, development of linear regression models and their selection by particular criteria and presumptions. The second stage raises the question of whether the regression models remaining after the first stage can be extended to include more macroeconomic indicators, thus obtaining multivariate regression models and then testing them by the criteria and presumptions selected in the first stage. The third stage of the research covers all linear regression models remaining after the first stage and all multiple regression models remaining after the second stage that meet all the criteria and presumptions. In the first step of the third stage, the regression models are verified for ARCH effects, and if they possess these effects, GARCH models

are developed. After developing the traditional models, machine learning models are created for the same data sets; the accuracy and errors of the machine learning models are compared with the ones of the traditional models. At the end of the third stage, the analysis of the relationship between the accuracy of the models and EURO STOXX 50 index return is conducted in a 45-minute time series.

The analysis of the use of machine learning for modelling stock prices and returns revealed that when solving regression-type problems, researchers tend to apply a decision tree, a random forest, linear regression, GBR and deep learning methods. The main difference between traditional and machine learning methods is that traditional methods aim to minimize the mean square error and find the significance of the relationship between variables, while machine learning methods aim to achieve the best accuracy of the test set. This finding allows researchers and investors to better understand when it is relevant to use traditional and machine learning methods.

After testing the methodology developed for modelling the surprise effect of macroeconomic indicators on stock returns by applying traditional methods, the hypothesis proposing that based on traditional methods, the surprises of macroeconomic indicators have an effect on stock returns in the short run was partially accepted. Partially because of all the macroeconomic indicators selected for the research (26), the effect of only a few indicators on EURO STOXX 50 return was found to be statistically significant under various actual data scenarios. A total of 133 linear and 5 multiple regression models were developed during the test. Of these, only 5 linear regression models met all the criteria and the presumptions of the regression analysis. These models were tested for ARCH effects but the latter were not detected. Leaning on the results and analysing what may have led to a small number of statistically reliable forecasting models, the author made the following findings: the time interval in minutes was unduly short; the formula representing the surprise effect of macroeconomic indicators was inappropriate; the methods were inappropriate; the surprises of macroeconomic indicators do not affect stock returns as much as expected, etc. The findings propose that investors and researchers should be cautious about expecting reliable results from the forecasting models suggested by similar studies that focus on the euro area stock market, use similar research methodologies and apply traditional methods.

After testing the methodology developed for modelling the surprise effect of macroeconomic indicators on stock returns by applying machine learning methods, the hypothesis proposing that based on machine learning methods, the surprises of

macroeconomic indicators have an effect on stock returns in the short run was accepted. The machine learning models developed for the same data sets as in the case of the traditional models yielded valid results. The idea to use machine learning methods in this research proved successful. Therefore, the author recommends continuing the research on the same topic but suggests developing reference (basic) forecasting models based on machine learning rather than traditional methods. For researchers and investors, this may become an additional incentive to take an interest in different, more innovative methods for forecasting stock returns.

The third hypothesis proposing that machine learning methods allow to develop more accurate models for forecasting the surprise effect of macroeconomic indicators on stock returns compared to traditional methods was accepted. Machine learning models provide 2-3 times greater accuracy and 10 times less errors than traditional linear regression models. Based on the research results, it is recommended that stock return modelling should be based on machine learning rather than traditional methods. After analysing the relationship between the accuracy of the models and EURO STOXX 50 return in a time series, it is recommended that sales transactions be executed as follows: in the case of RGDP – within the first 10 minutes when the most reliable return can be obtained in the 4th minute; in the case of industrial production – according to two scenarios: from the 33th to the 45th minute when the most reliable return can be obtained in the 40th and 42th minute, respectively; in the case of preliminary data on CPI - from the 33th to the 45th minute when the most reliable return can be obtained in the 36th minute; in the case of the data on CPI, excluding energy, food, alcohol and tobacco – between the 9th and the 23th minute when the most reliable return can be obtained in the 10th minute.

The further research could be conducted in the following directions:

1. To solve the limitations of this research:

a) Stock returns are generally affected by a number of phenomena, but only the surprise effect of macroeconomic indicators was selected for this research presuming that no other indicator affects a selected stock index so fast. To eliminate this limitation, not one but several phenomena could be selected as independent variables.

b) This research presumes that the surprise effect of macroeconomic indicators does not last longer than 45 minutes. To supplement the results obtained in this research, this time interval could be extended and the new results could be analysed.

c) Although the research period is representative and covers 12 years, macroeconomic indicators are released on average monthly. Therefore, the forecasting models are not composed of much data, which may affect the accuracy of the models with inclusion of new data. Thus, the further research on the similar topic should consider the newest data. Also, the data could be extracted from other (not “Bloomberg”) databases possessing longer-term data since the data older than for 2008 were not available for this research.

d) The forecasting models are not designed for a stock or an index that is traded on an exchange, but for a benchmark (the stock index EURO STOXX 50). Benchmarks are not usually traded on stock exchanges, so exchange-traded funds, stocks, etc. rather than a stock market benchmark could be selected as a dependent variable. This way, research results could be immediately used in investment activities.

2. The sixth conclusion of this research proposes that the use of machine learning methods proved successful. Therefore, the author recommends continuing the research on the same topic but suggests developing reference (baseline) forecasting models based on machine learning rather than traditional methods. It is then likely that there will be more baseline models, which meet all the criteria and presumptions raised, than in this research (the fifth conclusion of this research proposes that only five models based on traditional methods remained after testing).

3. The author’s last idea on how to continue the research is changing the modelling logic and data structure. The author recommends compiling uninterrupted time series (in terms of every minute, all 12 years or longer), selecting not one but two dependent variables, one of which could serve as a reference point when measuring the other’s response to the surprises of macroeconomic indicators. Uninterrupted time series would allow to examine stock returns before the surprise effect of macroeconomic indicators. The research methods would also change, and the ARCH effects would probably be met, so GARCH models could be developed; it is also possible to use other machine learning models, such as RNN or LSTM, and thus extend the semi-strong EMH research.

DISSEMINATION OF RESEARCH RESULTS

List of scientific publications on the topic of the thesis

Ligita Gasparėnienė; Rita Remeikienė; Aleksejus Sosidko; Vigita Vėbraitė; Evaldas Raistenskis. Modelling of EURO STOXX 50 index price returns based on industrial production surprises: basic and machine learning approach. *Entrepreneurship and sustainability issues*, vol. 8, no. 2. S1. 2020. Article in DB Clarivate Analytics Web of Science. Vilnius University.

<https://repository.mruni.eu/handle/007/17035>

Ligita Gasparėniene; Rita Remeikiene; Aleksejus Sosidko; Vigita Vebrate. A Modelling of S&P 500 Index Price Based on U.S. Economic Indicators: Machine Learning Approach. *Inzinerine Ekonomika-Engineering Economics*, 2021, 32(4), 362–375. DOI: <https://doi.org/10.5755/j01.ee.32.4.27985>.

<https://inzeko.ktu.lt/index.php/EE/article/view/27985>

Aleksejus Sosidko; Ligita Gasparėnienė. Evaluation of the unemployment rate announcement impact on Euro Stoxx 50 index returns based on semi-strong efficient market hypothesis. *Whither our economies - 2019: International scientific conference: conference proceedings*, [vol.] 6. P1c – Article in the Conference Proceeding placed in other databases. Mykolas Romeris University.

<https://repository.mruni.eu/handle/007/16038>

Reports in scientific conferences on the topic of the thesis

Aleksejus Sosidko. Modelling of Euro Stoxx 50 price returns based on core CPI Surprises: Basic and machine learning approach. At the 7th International Scientific Conference “WHITHER OUR ECONOMIES – 2020” held on 17 September, 2020 at Mykolas Romeris University, Lithuania.

Aleksejus Sosidko. Evaluation of the unemployment rate announcement impact on Euro Stoxx 50 index returns based on semi-strong efficient market hypothesis. At the 6th International Scientific Conference “WHITHER OUR ECONOMIES – 2019” held on 19-20 September, 2019 at Mykolas Romeris University, Lithuania.

INFORMATION ABOUT THE AUTHOR OF THE DISSERTATION

Name, Surname: Aleksejus Sosidko
E-mail: A.sosidko@gmail.com

Education:

From 2017 Doctoral studies in Economics at Mykolas Romeris University

2013 - 2015 Master's degree of Economics at Mykolas Romeris University under Financial Markets study programme.

2009 - 2012 Bachelor's degree of Economics at Klaipėda State University of Applied Sciences under Business Management study programme.

Darbo patirtis:

From 2021 Energijos Skirstymo Operatorius (ESO), data management team – data analyst, machine learning engineer

2019 - 2020 Dissertation writing, programming language learning, application of machine learning methods, internships completed.

2017 - 2019 OC VISION, data analyst

2016 - 2017 RJF BALTIC, analyst

2015 - 2016 KELVISTA, economist

2014 - 2015 SWEDBANK, insurance and investment group – customer support specialist

2013 - 2015 RJF BALTIC, HR specialist

Sosidko, Aleksejus

MAKROEKONOMINIŲ RODIKLIŲ NETIKĖTUMŲ POVEIKIO AKCIJŲ
GRAŽAI MODELIAVIMAS: daktaro disertacija. – Vilnius: Mykolo Romerio univer-
sitetas, 2022. P. 248.

Bibliogr. 162 –172 p.

Atlikta mokslinių tyrimų analizė leidžia teigti, kad stokojama mokslinių tyrimų apie makroekonominių rodiklių netikėtumų poveikio akcijų grąžai modeliavimą per trumpą laiko tarpą. Siekiant užpildyti šią spragą yra suformuotas disertacijos tikslas - iširti makroekonominių rodiklių netikėtumų reiškinį ir jo sąsajas su akcijų grąža bei sudaryti ir empiriškai patikrinti makroekonominių rodiklių netikėtumų poveikio akcijų grąžai prognozavimo modelius, panaudojant tradicinius ir mašininio mokymosi metodus. Mokslinė problema - kokia yra makroekonominių rodiklių netikėtumų reiškinio esmė, kaip ją įvertinti ir modeliuoti makroekonominių rodiklių netikėtumų poveikį akcijų grąžai tradiciniais ir mašininio mokymosi metodais.

Empiriniu tyrimu nustatyta, kad dauguma makroekonominių rodiklių netikėtumų esant skirtingiems scenarijais neturi statistiškai reikšmingo poveikio EURO STOXX 50 indekso grąžai per trumpą laiko tarpą. Tęsiant tyrimą su statistiškai reikšmingais makroekonominių rodiklių netikėtumo poveikio EURO STOXX 50 indekso grąžai modeliais ir jų duomenų rinkiniais, atskleista, jog remiantis mašininio mokymosi metodais galima sukurti kelis kartus tikslesnius EURO STOXX indekso grąžai prognozuoti modelius, nei kad taikant tradicinius metodus

Literature analysis suggests that there is a lack of research regarding modelling the surprise effect of macroeconomic indicators on stock returns in the short run. To fill this gap in the literature, the major purpose of this dissertation is to research the phenomenon representing the surprise effect of macroeconomic indicators and its relationship with stock returns, to develop and empirically test the models for forecasting the surprise effect of macroeconomic indicators on stock returns by employing traditional and machine learning methods. The scientific problem of the research: what is the essence of the surprise effect of macroeconomic indicators and how to evaluate and model the surprise effect of macroeconomic indicators on stock returns by employing traditional and machine learning methods?

The empirical research revealed that most surprises of macroeconomic indicators do not have any statistically significant effect on the return on the EURO STOXX 50 index under different scenarios in the short run. The study with statistically significant models and their data sets representing the potential surprise effect of macroeconomic indicators on the return of the EURO STOXX 50 index disclosed that machine learning methods can provide several times more accurate models for forecasting the return of the EURO STOXX index than traditional methods.

Aleksejus Sosidko

MAKROEKONOMINIŲ RODIKLIŲ NETIKĖTUMŲ POVEIKIO AKCIJŲ GRĄŽAI
MODELIAVIMAS

Daktaro disertacija
Socialiniai mokslai, ekonomika (S 004)

Mykolo Romerio universitetas
Ateities g. 20, Vilnius
Puslapis internete www.mruni.eu
El. paštas roffice@mruni.eu
Tiražas 20 egz.

Parengė spaudai Jovita Jankauskienė

Spausdino UAB „Šiaulių spaustuvė“
P. Lukšio g. 9G, 76200 Šiauliai
El. p. info@dailu.lt
<https://siauliuspaustuve.lt>

