



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

**Gilaus mokymosi metodų, skirtų prognozuoti rinkų
kintamumo indeksą akcijų rinkose, tyrimai**

Baigiamasis magistro projektas

Marius Šimašius

Projekto autorius

Prof. habi. dr. Rimvydas Simutis

Vadovas

Kaunas, 2022



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

**Gilaus mokymosi metodų, skirtų prognozuoti rinkų
kintamumo indeksą akcijų rinkose, tyrimai**

Baigiamasis magistro projektas

Valdymo technologijos (6211EX014)

Marius Šimašius

Projekto autorius

Prof. habil. dr. Rimvydas Simutis

Vadovas

Doc. dr. Arūnas Lipnickas

Recenzentas

Kaunas, 2022



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Marius Šimašius

Gilaus mokymosi metodų, skirtų prognozuoti rinkų kintamumo indeksą akcijų rinkose, tyrimai

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

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

Marius Šimašius

Patvirtinta elektroniniu būdu

Marius Šimašius. Gilaus mokymosi metodų, skirtų prognozuoti rinkų kintamumo indeksą akcijų rinkose, tyrimai. Magistro baigiamasis projektas / vadovas prof. habil. dr. Rimvydas Simutis; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Elektronikos inžinerija (inžinerijos mokslai).

Reikšminiai žodžiai: VIX, prognozavimas, gilaus mokymo tinklas, LSTM.

Kaunas, 2022. 67 p.

Santrauka

Šio darbo tikslas išanalizuoti ir ištirti klasikinių ir gilaus mokymo metodų galimybes prognozuoti rinkų kintamumo indeksą akcijų rinkose. Šiame darbe išanalizuoti vertybinių popierių rinkų ir kintamumo indekso VIX prognozavimo metodai ir algoritmai. Pritaikomi klasikiniai ARMA / ARMAX / NARMA / NARMAX ir gilaus mokymo modeliai sekančios dienos bei savaitės VIX indekso pokyčio prognozavimui, naudojant VIX ir kitus indeksus kaip modelių įėjimus. Atlikus eksperimentinius tyrimus, nustatyta, kad tik keletas modelių pasiekia pakankamą tikslumą prognozuoti VIX indekso pokyčio intervalą (auga, stabilus arba krenta) bei pokyčio kryptį, kad būtų naudojami kaip investavimo įrankiai investuotojams arba prekeiviams. Taip pat nustatyta, kad modelių vidutinės absoliutinės paklaidos yra per didelės, todėl nei vienas iš sudarytų gilaus mokymo modelių negali būti naudojamas kaip patikimas investavimo įrankis VIX indekso pokyčio absoliutinės vertės prognozavimui.

Marius Šimašius. Investigation of deep learning methods for volatility index prediction in stock markets. Master's Final Degree Project / supervisor prof. habil. dr. Rimvydas Simutis; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

Study field and area (study field group): Electronics Engineering (Engineering Sciences).

Keywords: VIX, prediction, deep learning network, LSTM.

Kaunas, 2022. 67.

Summary

The aim of this project is to analyze and investigate the possibilities of classical and deep learning methods to predict the market volatility index in stock markets. In this project, the methods and algorithms for forecasting the stock markets and the volatility index are analyzed. Classical ARMA / ARMAX / NARMA / NARMAX and deep learning models are applied to predict the change in VIX index for the following day and week, using VIX and other indices as model inputs. Experimental studies have shown that only a few models achieve sufficient accuracy to predict the interval of change in the VIX index (rising, stable, or falling) and the direction of change to be used as investment tools for investors or traders. It was also found that the mean absolute errors of the models are too high, so none of the developed deep learning models can be used as a reliable investment tool to predict the absolute value of the change in the VIX index.

Turinys

Lentelių sąrašas	8
Paveikslų sąrašas	10
Santrumpų sąrašas	11
Įvadas.....	12
1. Vertybinių popierių rinkų prognozavimo metodai ir dirbtinio intelekto metodų taikymas	14
1.1. Fundamentinė analizė.....	14
1.1.1. Fundamentinės analizės rodikliai	15
1.2. Techninė analizė.....	16
1.2.1. Techninės analizės rodikliai	17
1.3. Vertybinių popierių rinkos prognozė pasitelkus dirbtinį intelektą.....	18
1.3.1. Dirbtinių neuroninių tinklų taikymas	19
1.3.2. Gilaus mokymo tinklų taikymas.....	20
1.3.3. Neraiškiosios logikos taikymas	21
2. Modelių ir algoritmų skirtų VIX indekso prognozavimui analizė.....	24
2.1. Tradicinė tiesinė regresija.....	24
2.2. Pagrindinių komponentų analizė	27
2.3. Automatinis regresinis integruotas slankusis vidurkis	30
2.4. Rekurentinis tinklas	32
2.5. Gilaus mokymo modelis.....	35
3. Modelių parinkimas ir eksperimentinių duomenų paruošimas.....	39
3.1. Eksperimentiniai duomenys ir jų paruošimas.....	39
3.2. Programinės įrangos parinkimas	39
3.3. Ilgalaikė trumpalaikė atmintis arba LSTM modelis.....	40
4. Modelių realizavimas ir eksperimentiniai tyrimai	42
4.1. Tiesinių regresijos ARMA / ARMAX modelių paruošimas ir rezultatai.....	42
4.1.1. Sekančios dienos VIX indekso prognozavimo, naudojant ARMA modelius, rezultatai	43
4.1.2. Sekančios dienos VIX indekso prognozavimo, naudojant ARMAX modelius, rezultatai....	44
4.1.3. Sekančios savaitės VIX indekso prognozavimo, naudojant ARMA modelius, rezultatai ...	45
4.1.4. Sekančios savaitės VIX indekso prognozavimo, naudojant ARMAX modelius, rezultatai .	46
4.2. NARMA / NARMAX modelių paruošimas ir rezultatai.....	47
4.2.1. Sekančios dienos VIX indekso prognozavimo, naudojant NARMA modelius, rezultatai....	47
4.2.2. Sekančios dienos VIX indekso prognozavimo, naudojant NARMAX modelius, rezultatai.	48
4.2.3. Sekančios savaitės VIX indekso prognozavimo, naudojant NARMA modelius, rezultatai .	49
4.2.4. Sekančios savaitės VIX indekso prognozavimo, naudojant NARMAX modelius, rezultatai	50
4.3. Gilaus mokymo LSTM modelių paruošimas ir rezultatai	52
4.3.1. Sekančios dienos VIX indekso prognozavimo, naudojant LSTM modelius ir tik VIX įėjimus, rezultatai.....	52
4.3.2. Sekančios dienos VIX indekso prognozavimo, naudojant LSTM modelius bei VIX ir kitus įėjimus, rezultatai.....	54
4.3.3. Sekančios savaitės VIX indekso prognozavimo, naudojant LSTM modelius ir tik VIX įėjimus, rezultatai.....	57

4.3.4. Sekančios savaitės VIX indekso prognozavimo, naudojant LSTM modelius bei VIX ir kitus įėjimus, rezultatai.....	59
Rezultatai ir išvados	63
Rekomendacijos	65
Literatūros sąrašas	66
Priedai.....	68
1 priedas. Programinis kodas NARMA / NARMAX modeliams sudaryti ir testuoti	68
2 priedas. Programinis kodas gilaus mokymo LSTM modeliams sudaryti ir testuoti	71
3 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant ARMA modelius, rezultatai 75	
4 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant ARMAX modelius, rezultatai 76	
5 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant ARMA modelius, rezultatai 77	
6 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant ARMAX modelius, rezultatai 78	
7 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant NARMA modelius, rezultatai 79	
8 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant NARMAX modelius, rezultatai (20 tiksliausių)	80
9 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant NARMA modelius, rezultatai 81	
10 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant NARMAX modelius, rezultatai (20 tiksliausių)	82
11 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant LSTM modelius tik su VIX įėjimais, rezultatai (20 tiksliausių)	83
12 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant LSTM modelius su VIX ir kitais įėjimais, rezultatai (20 tiksliausių).....	84
13 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant LSTM modelius tik su VIX įėjimais, rezultatai (20 tiksliausių)	85
14 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant LSTM modelius su VIX ir kitais įėjimais, rezultatai (20 tiksliausių).....	86

Lentelių sąrašas

1 lentelė. Fuzzy sistemos įėjimo kintamųjų narystės funkcijos [11].....	23
2 lentelė. Įėjimo duomenys [12].....	25
3 lentelė. Įėjimo duomenų paskutiniai apskaičiuoti parametrai [12].....	26
4 lentelė. Daugiamačio linijinio regresijos modelio kokybės parametrų vertės [12].....	27
5 lentelė. Pagrindinių komponentų analizės modelio kokybės parametrų vertės [12].....	30
6 lentelė. Automatinio regresinio integruoto slankiojo vidurkio modelio kokybės parametrų vertės [12].....	32
7 lentelė. Įėjimų apibrėžimai rekurentiniam tinklui [12].....	33
8 lentelė. RNN modelio kokybės parametrų vertės [12].....	35
9 lentelė. Modelio rezultatai naudojant skirtingą iteracijų skaičių [13].....	35
10 lentelė. Rezultatų palyginimas su kitokio tipo mašininio mokymosi metodais [13].....	36
11 lentelė. Nulinės hipotezės kokybiniai rodikliai dviem testavimo intervalams.....	42
12 lentelė. Geriausių penkių ARMA modelių, skirtų sekančios dienos VIX indekso prognozei, rezultatai.....	43
13 lentelė. Geriausių penkių ARMAX modelių, skirtų sekančios dienos VIX indekso prognozei, rezultatai.....	44
14 lentelė. Geriausių penkių ARMA modelių, skirtų sekančios savaitės VIX indekso prognozei, rezultatai.....	45
15 lentelė. Geriausių penkių ARMA modelių, skirtų sekančios savaitės VIX indekso prognozei, rezultatai.....	46
16 lentelė. Geriausių penkių NARMA modelių, skirtų sekančios dienos VIX indekso prognozei, rezultatai.....	47
17 lentelė. Geriausių penkių NARMAX modelių, skirtų sekančios dienos VIX indekso prognozei, rezultatai.....	49
18 lentelė. Geriausių penkių NARMA modelių, skirtų sekančios savaitės VIX indekso prognozei, rezultatai.....	50
19 lentelė. Geriausių penkių NARMAX modelių, skirtų sekančios savaitės VIX indekso prognozei, rezultatai.....	51
20 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios dienos VIX indekso prognozei, rezultatai.....	52
21 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių krypties prognozei, rezultatai.....	53
22 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių intervalo prognozei, rezultatai.....	54
23 lentelė. LSTM modelių (su VIX indekso modelio įėjimais) pokyčių krypčių ir pokyčių intervalų prognozės apžvalga.....	54
24 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios dienos VIX indekso prognozei, rezultatai.....	55
25 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių krypties prognozei, rezultatai.....	56
26 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių intervalo prognozei, rezultatai.....	56
27 lentelė. LSTM modelių (su VIX ir kitų indeksų modelio įėjimais) pokyčių krypčių ir pokyčių intervalų prognozės apžvalga.....	57

28 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios savaitės VIX indekso prognozei, rezultatai	57
29 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių krypties prognozei, rezultatai.....	58
30 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių intervalo prognozei, rezultatai	59
31 lentelė. LSTM modelių (su VIX indekso modelio įėjimais) pokyčių krypčių ir pokyčių intervalų prognozės apžvalga.....	59
32 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios savaitės VIX indekso prognozei, rezultatai.....	60
33 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių krypties prognozei, rezultatai	61
34 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių intervalo prognozei, rezultatai.....	61
35 lentelė. LSTM modelių (su VIX ir kitų indeksų modelio įėjimais) pokyčių krypčių ir pokyčių intervalų prognozės apžvalga	62

Paveikslų sąrašas

1 pav. Fundamentinės analizės sudėtis [4]	14
2 pav. Techninės analizės struktūrinė schema [4]	17
3 pav. Neuroninio tinklo pavyzdys akcijų kainos prognozavimui [6].....	20
4 pav. Gilaus neuroninio tinklo pavyzdys [8]	21
5 pav. „Fuzzy“ sistemos struktūrinė schema	22
6 pav. Neraiškiaja logika paremtas vertybinių popierių prognozavimo modelis [11].....	22
7 pav. Modelio, skirto prognozuoti VIX vertę 3 dienas į priekį, sklaidos diagrama ir histograma [12]	27
8 pav. Modelio, skirto prognozuoti VIX vertę 3 dienas į priekį, sklaidos diagrama ir histograma [12]	27
9 pav. Kokybiniai modelio grafikai, panaudojant pagrindinių komponentų analizę [12].....	29
10 pav. Modelio, skirto prognozuoti VIX vertę 3 dienas į priekį, sklaidos diagrama ir histograma [12]	29
11 pav. Modelio, skirto prognozuoti VIX vertę 5 dienas į priekį, sklaidos diagrama ir histograma [12]	29
12 pav. Modelio, skirto prognozuoti VIX vertę 3 dienas į priekį, sklaidos diagrama [12]	32
13 pav. Liekanų diagramos naudojant autoregresinį integruoto slankiojo vidurkio modelį [12].....	32
14 pav. Duomenų patvirtinimo tikslumas ir nuostoliai per epochą, 3/5 dienų į priekį moduliams [12]	33
15 pav. Modelio, skirto prognozuoti VIX vertę 3 dienas į priekį, sklaidos diagrama ir histograma [12]	34
16 pav. Modelio, skirto prognozuoti VIX vertę 5 dienas į priekį, sklaidos diagrama ir histograma [12]	34
17 pav. Modelio vidutinės kvadratinės paklaidos pokytis praėjus nurodytam bandymų skaičiui [14]	37
18 pav. Modelio prognozės reikšmės palyginimas su realia VIX indekso reikšme [14]	38
19 pav. LSTM ląstelės struktūra [15]	40
20 pav. ARMA („Cubic SVM“) modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai.....	43
21 pav. ARMAX („Coarse Gaussian SVM“) modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai.....	44
22 pav. ARMA („Coarse Tree“) modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai.....	45
23 pav. ARMAX („Linear“) modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai.....	46
24 pav. NARMA modelio testavimo (2021m.) tikslo-prognozės ir paklaidų grafikai.....	48
25 pav. NARMAX modelio testavimo (2021m.) tikslo-prognozės ir paklaidų grafikai.....	49
26 pav. NARMA modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai	50
27 pav. NARMAX modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai	51
28 pav. LSTM modelio testavimo (2021m.) tikslo-prognozės ir paklaidų grafikai	53
29 pav. LSTM modelio testavimo (2021m.) tikslo-prognozės ir paklaidų grafikai	55
30 pav. LSTM modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai.....	58
31 pav. LSTM modelio testavimo (2021m.) tikslo-prognozės ir paklaidų grafikai	60

Santrumpų sąrašas

Santrumpos:

VIX – Čikagos pasirinkimo sandorių biržos sukurtas rinkų kintamumo indeksas;

ARMA – angliškas terminas „*Auto-Regressive Moving Average*“, kuris išvertus reiškia automatinis regresinis slankusis vidurkis. Šio tipo modeliai paremti tiesinės regresijos panaudojimu;

ARMAX – angliškas terminas „*Auto-Regressive Moving Average with Exogenous variables*“. Tai yra to pačio tipo modelis kaip ir ARMA, tačiau papildomai naudojami nepriklausomi kintamieji modelio tikslams pasiekti. Šio tipo modeliai taip pat paremti tiesinės regresijos panaudojimu;

NARMA – angliškas terminas „*Nonlinear Auto-Regressive Moving Average*“. Tai netiesiniai modeliai, kurių pagrindą sudaro rekurentinis tinklas;

NARMAX – angliškas terminas „*Nonlinear Auto-Regressive Moving Average with Exogenous variables*“. Tai yra to pačio tipo modelis kaip ir NARMA, tačiau papildomai naudojami nepriklausomi kintamieji modelio tikslams pasiekti;

LSTM – angliškas terminas „*Long-Short Term Memory*“. Tam tikra rekurentinių tinklų rūšis;

SVM – atraminių vektorių mašina (angl. *support vector machine*);

GPR – Gauso proceso regresija (angl. *Gaussian process regression*);

MAE – vidutinė absoliutinė paklaida (angl. *Mean Absolute Error*);

MSE – vidutinė kvadratinė paklaida (angl. *Mean Squared Error*);

RMSE – vidutinės kvadratinės paklaidos kvadratas (angl. *Root Mean Square Error*).

Įvadas

Per pastarąjį dešimtmetį atsiradus pažangesnei ir pigesnei aparatūriniai įrangai, padidėjo susidomėjimas akcijų rinkomis bei investavimo modelių kūrimu. Tai rodo, kad ieškoma būdų atrasti tinkamus modelius arba metodus investuotojams ir prekeiviams, kad būtų galima pagerinti sprendimų priėmimą ir padidinti investuojamą kapitalą. Pastaruoju metu didžiausias dėmesys į prekybos akcijų biržose procesus, jų modeliavimą ir strategijų sudarymą skiriamas informatikos, automatizavimo inžinierių bei dirbtinio intelekto tyrėjų. Visa tai galima spręsti iš vis daugėjančių straipsnių ir atliekamų darbų kiekio šiomis temomis. Nors modelių ir darbų vis daugėja, tačiau vienas iš indeksų didelio dėmesio taip ir nesulaukia. Tai yra investuotojų vadinamas „baimės rodiklis“ – Čikagos pasirinkimo sandorių biržos (angl. *Chicago Board Options Exchange*) sukurtas kintamumo indeksas (toliau VIX).

VIX kaip ir kiti biržoje esantys indeksai, pavyzdžiui, Dow indeksas (angl. *Dow Jones Industrial Average* (trump. DJIA)) yra apskaičiuojamas einamuoju laiku kiekvieną prekybos biržoje dieną. Tačiau yra vienas esminis skirtumas tarp šių indeksų, kad VIX parodo kintamumą, o DJIA matuoja kainą. VIX buvo pristatytas 1993 m. Jo pirminis tikslas buvo pateikti tikėtino trumpalaikio rinkos nepastovumo įvertinimą. Panaudojus blogiausių praėjusių laikų bei krizių vertybinių popierių rinkos duomenis, VIX indeksas galėjo būti panaudotas kaip ateityje vyksiančių įvykių įtakos rinkos nepastovumui įvertinimas. Šalia to buvo dar vienas tikslas – pagal ateities ir pasirinkimo sandorius išvesti tikėtiną rinkos kintamumo rodiklį [1].

Kai tik atsirado VIX indeksas, jo reikšmė priklausė nuo „S&P 100“ (toliau OEX) pasirinkimo sandorių kainos. Taip buvo todėl, kad OEX buvo labiausiai prekiaujamas indeksas tuo metu. Tai sudarė net iki 75 % visų to laiko indeksų pasirinkimo sandorių. Tik 2003m. buvo pristatyta nauja VIX skaičiavimo metodika, kuri priklausė ne nuo OEX, bet nuo „S&P 500“ (toliau SPX) indekso. Senuoju metodu skaičiuotas indeksas išliko ir buvo pervardintas į VXO. Naujojo VIX indekso pasikeitimai tuo neapsiribojo – į indekso skaičiavimus buvo įtrauktos „iš pinigų“ (angl. *out-of-the-money*) pasirinkimo sandoriai, nes šių sandorių kainos parodo svarbią informaciją apie investuotojų paklausą jų investicinių portfelių apsaugai, taip pat ir rinkos nepastovumui.

Investuotojams, kurie neketina naudoti pasirinkimo sandorių kaip savo investavimo strategijos, VIX gali atrodyti nesvarbus. Tačiau kintamumo indeksas vaidina svarbų vaidmenį kasdienių investuotojų perspektyvoje. Kai kurie VIX pavadino „baimės indeksu“ dėl to, kad jis linkęs kilti, kai rinkoje akcijų kainos krenta, ir mažėti, kai kainos kyla. Teoriškai tokia tendencija VIX neturėtų egzistuoti, jei rinka kiltų taip aukštai kaip ir leidžiasi. Tačiau istoriškai akcijų kainos linkusios labiau leistis nei kilti [2].

Nors biržos prekeiviai linkę aiškinti aukštą VIX indekso lygį kaip pavojaus tašką, ilgalaikiai investuotojai gali naudoti aukštą VIX rodiklį kaip signalą atidžiau pažvelgti į akcijas. Padidėjus VIX reikšmei, kai kurių akcijų kainos gali būti jau nukritusios, o kitų kainos dar gali kristi iki patrauklaus lygio. VIX kaip išankstinio perspėjimo sistemos naudojimas, norint pradėti ieškoti derybų galimybių, buvo protinga strategija, ypač pastaraisiais metais, kai ilgi mažo nepastovumo laikotarpiai buvo norma, o ne išimtis.

VIX yra ypač svarbus opcionių prekybininkams, tačiau jis taip pat turi vertę paprastiems investuotojams. Stebint VIX galima suprasti visos rinkos nuotaiką ir tai, ko investuotojai pasirinkimo sandorių rinkoje tikisi – gerų ar blogų laikų.

VIX savo funkcija padeda investuotojams pasirinkti tinkamą investavimo strategiją, tačiau dažnai atsiranda tokių situacijų, kurių tradiciniai VIX prognozavimo modeliai nenumato. Investuotojai dėl pasitikėjimo VIX dėl blogų prognozių gali prarasti didžiąją dalį savo kapitalo. Tam, kad tokių atvejų rizikos sumažėtų investuotojai bei investicinių fondų valdytojai nustumia tradicinius metodus į šoną ir kuria bei tobulina dirbtinio intelekto prognozavimo modelius. Panaudojus tradicinius metodus bei dirbtinį intelektą, prognozavimo modeliai gali apdoroti daugiau duomenų bei situacijų, pateikdami tikslesnius, realesnius rezultatus. Tikslesnės prognozės lemia mažesnę riziką ir augantį investicinių portfelių.

Darbo tikslas – išanalizuoti ir ištirti klasikinių ir gilaus mokymo metodų galimybes prognozuoti rinkų kintamumo indeksą akcijų rinkose.

Darbo uždaviniai:

- atlikti rinkų prognozavimo ir dirbtinio intelekto metodų taikymo vertybinių popierių rinkose apžvalgą;
- atlikti modelių ir algoritmų skirtų VIX prognozavimui analizę;
- pritaikyti gilaus mokymo metodus VIX prognozavimui, palyginti gautus metodus su klasikiniiais modeliais bei įvertinti prognozavimo galimybes;
- suformuoti išvadas ir pateikti rekomendacijas.

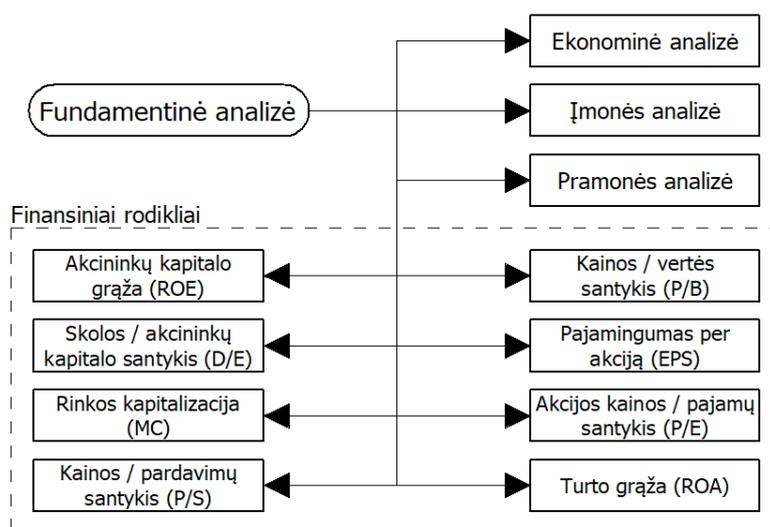
1. Vertybinių popierių rinkų prognozavimo metodai ir dirbtinio intelekto metodų taikymas

Vertybinių popierių rinkoje naudojamos trys rinkos prognozavimo metodai: fundamentinė analizė, techninė analizė ir prognozė pasitelkus dirbtinį intelektą ir įvairius juo paremtus metodus.

1.1. Fundamentinė analizė

Fundamentali analizė yra būdas prognozuoti akcijų kainų judėjimą. Šio tipo analizės remiasi įmonės metine finansų ataskaita, informacija apie įmonės balansą, įmonės vidinę situaciją, ateities planais ir perspektyvomis, palyginimu tarp konkurentų rinkoje, politikos pokyčiais ir kita informacija, susijusia su įmone. Taigi fundamentinė analizė tyrinėja įmonės finansinę situaciją ir jos veiklą, kad nuspręstų, ar verta investuoti į įmonės akcijas, ar ne. Finansiniai duomenys skelbiami kas ketvirtį ištikus metus. Kadangi fundamentali analizė remiasi daugiausia ataskaitomis, kurios rengiamos pakankamai retai, tokio tipo analizė dažnai naudojama ilgalaikiams kainų pokyčiams nuspėti. Trumpalaikėms ir vidutinės trukmės spekuliacijoms ši analizė paprastai netinka.

Fundamentinė analizė sudaroma naudojantis viešai prieinama informacija apie akciją, trimis aspektais, susijusiais su ekonomika, jos pramonės šaka ir pačia įmone. Ekonomikos aspektas remiasi jau prieš tai minėtomis finansinėmis ataskaitomis, kuriose nurodomi pinigų srautai, pajamos ir balansai. Balansas nurodo savininko nuosavybę, turtą ir įsipareigojimus. Turtu laikoma viskas, ką įmonė turi, kitaip sakant, viskas, kas turi arba gali turėti vertės ateityje. Įsipareigojimus dažniausiai sudaro banko paskola įkeitus nekilnojamą turtą, bet gali būti ir kitokie įsiskolinimai. Įmonės balansas parodo investuotojams, kaip ta įmonė surenka pinigus. Pajamų ataskaitos atlieka panašų darbą: jos parodo įmonės pajamas ir išlaidas, kurios laikomos sąnaudomis, susijusiomis su verslo valdymu. Grynosios pajamos apskaičiuojamos naudojant pajamų ir išlaidų skirtumą, tai iš esmės yra įmonės uždarbis. Tokia informacija padeda investuotojams įgyti žinių apie finansinį bendrovės akcijų paketą. Kai kuriems investuotojams to neužtenka, todėl papildomai naudojami koeficientai arba santykiniai rodikliai. Visa tai, iš ko susideda fundamentinė analizė, pateikta paveikslėlyje žemiau [3].



1 pav. Fundamentinės analizės sudėtis [4]

1.1.1. Fundamentinės analizės rodikliai

Akcininkų kapitalo grąža (toliau ROE) apžvelgia, kaip gerai buvo panaudotos akcininkų lėšos ir kokią grąžą atnešė investicijos. Kai ROE vertė yra maža, tai reiškia, kad akcininkų lėšos nebuvo panaudotos tinkamai. ROE apskaičiuojamas pagal šią formulę:

$$ROE = \frac{\text{Pelnas sumokėjus mokesčius}}{\text{Akcininkų kapitalas}} \quad (1)$$

Skolos / akcininkų kapitalo santykis (toliau D/E) parodo prieinamo kapitalo galią. Maža D/E vertė reiškia, kad kreditas nėra paimtas. D/E apskaičiuojamas pagal šią formulę:

$$\frac{D}{E} = \frac{\text{Visi įsiskolinimai}}{\text{Akcininkų kapitalas}} \quad (2)$$

Rinkos kapitalizacija (toliau MC) matuoja visų rinkoje esančių įmonės akcijų kainą. Pagal kapitalizaciją įmonės gali būti suskirstytos į tris grupes: mažos, vidutinės ir didelės kapitalizacijos įmonės. MC apskaičiuojamas pagal šią formulę:

$$MC = \text{Akcijų skaičius} \cdot \text{Akcijos kaina} \quad (3)$$

Kainos / pardavimų santykis (toliau P/S) nustato, kiek investuotojai pasiruošę sumokėti už įmonės pardavimų dolerį. Maža vertė rodo, kad akcija pakankamai neįvertinta, o didelė vertė nurodo atvirksčiai, kad akcijos pervertintos. Apskaičiuojama pagal formulę:

$$\frac{P}{S} = \frac{\text{Akcijos kaina}}{\text{Pardavimų pajamos per akciją}} \quad (4)$$

Kainos / vertės santykis (toliau P/B) yra pagrindinis akcijų vertės palyginimas su akcijų kaina. Šis rodiklis taip pat parodo akcijos pervertinimą, tačiau šiuo atveju svarbus įmonės turtas. P/B apskaičiuojamas pagal formulę:

$$\frac{P}{B} = \frac{\text{Akcijos kaina}}{\text{Visas nuosavas turtas per akciją}} \quad (5)$$

Pajamingumas per akciją (toliau EPS) – rodiklis, kuris pateikia įmonės pelningumo rodiklį ir gali būti nustatytas padalijus įmonės grynąsias pajamas iš viso akcijų skaičiaus. EPS galima apskaičiuoti:

$$EPS = \frac{\text{Grynosios pajamos}}{\text{Akcijų skaičius}} \quad (6)$$

Kainos / pajamų santykis (toliau P/E) yra labai svarbus akcijų įvertinimas, naudojamas norint įvertinti santykinį potencialios investicijos patrauklumą, pagrįstą įmonės akcijų kainos su jos uždario palyginimu. Jis apskaičiuojamas taip:

$$\frac{P}{E} = \frac{\text{Akcijos kaina}}{EPS} \quad (7)$$

Turto grąža (toliau ROA) reiškia uždario, kurį įmonė uždirba lyginant su bendru įmonės turtu ar ištekliais, dalį. Šis rodiklis gaunamas taip:

$$ROA = \frac{\text{Grynosios pajamos}}{\text{Visas nuosavas turtas}} \quad (8)$$

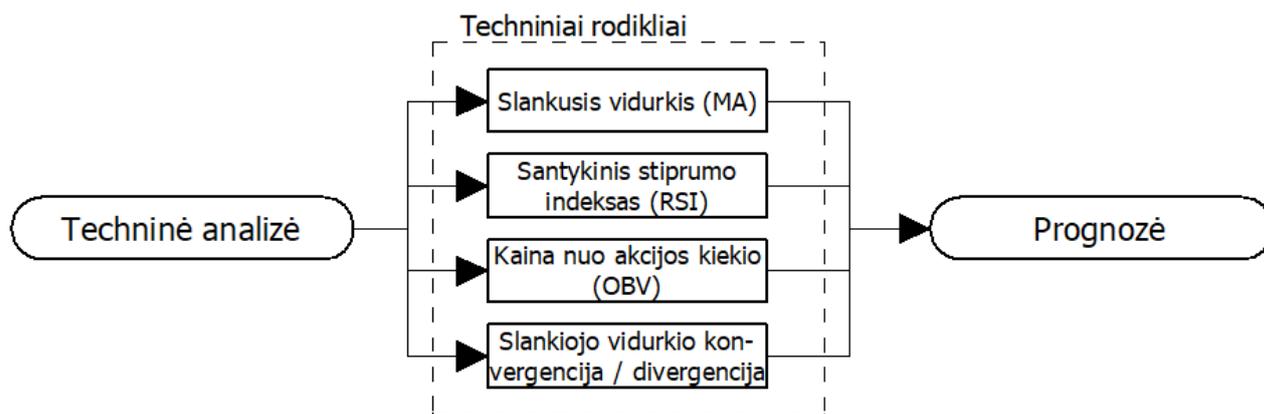
1.2. Techninė analizė

Techninė analizė yra dar vienas akcijų kainų vertybinių popierių rinkoje tyrimas siekiant priimti teisingus sprendimus dėl investavimo ir gauti maksimalų pelną. Techninė analizė prognozuoja būsimų akcijų kainų judėjimo kryptį rinkoje pagal kainų ir kiekių istoriją. Atidžiai išnagrinėjęs ankstesnius akcijų kainų pokyčius, investuotojas gali numatyti būsimus konkrečios akcijos kainų pasikeitimus. Kad ir kaip gražiai tai skambėtų, ši prognozė gali būti netiksli. Suteikiamas tik bendras vaizdas apie tai, kas turėtų nutikti akcijų kainai. Apskritai techninę analizę galima įvardinti kaip tendencijos nuspėjimą. Techninės analizės specialistai teigia, kad akcijų kainų tendencijas lemia akcijų pasiūlos ir paklausos disbalansas, kuris atsispindi pirkimo ir pardavimo kainose. Todėl vienu metu kainos gali tapti pervertintos, kitu – pakankamai neįvertintos. Iš nepastovių ir svyruojančių akcijų kainų duomenų techniniai analitikai bando išgauti modelius / šablonus, o pagal juos vykdyti pirkimus, kai kainos žemos, ir vykdyti pardavimus, kai jos aukštesnės. Techninė analizė iš esmės yra kokybinė analizė, nes naudojamos kainų diagramos, tiriami kainų modeliai ir naudojamos tam tikros formulės akcijų kainai prognozuoti [3].

Ši technika daugiausia naudinga investuotojams, kurie ieško trumpalaikių investicijų (dar vadinamų trumpalaikėmis arba dienine prekyba (angl. *day trading*)). Tai lengvai taikoma vertybiniams popieriams, kurių kainos labai veikia didelė pasiūla ir paklausa. Investicijos laikas pagal tam tikras strategijas gali būti trumpesnis nei dienos, savaitės, mėnesio ar metų. Pagal Dow teoriją pagrindiniai šios analizės principai yra šie [3]:

1. Atsižvelgiama tik į akcijos kainas, neatsižvelgiant į fundamentinę įmonės analizę. Tam tikros akcijos kaina jau yra suformuota pagal fundamentinius principus, tad lieka du veiksniai ką turime vertinti – pasiūla ir paklausa.
2. Akcijos kainos priklauso nuo dėsningumo ir tendencijų. Turima omenyje, kad jei kaina krenta jau kuris laikas, tai ir ilgesnėje perspektyvoje bus kainos mažėjimo tendencija. Ir atvirkščiai, jei kainos kyla, tai tokia tendencija ir turėtų išlikti. Tai tarp investuotojų vadinama „bulių arba meškų rinka“.
3. Investuotojų elgesys rinkoje yra šabloniškas ir esant panašioms situacijoms, kurios jau buvo praeityje, turėdami tam tikrą akciją investuotojai veikia taip pat arba panašiai. Taigi galima nuspėti, kuria linkme judės rinka ir galima tuo pasinaudojus pasipelninti.

Analitikai taiko įvairius metodus, įskaitant įvairias technikas ir įrankius, iš kurių vienas yra diagramų naudojimas. Diagramų naudojimas leidžia analitikams nustatyti kainų pokyčių modelius, taip pat finansų rinkų tendencijas ir padeda jiems panaudoti tokius modelius. Techniniai analitikai naudoja įvairius rinkos rodiklius. Rodikliai padeda įvertinti, ar turtas yra populiarus tarp investuotojų ir kokia tikėtina vertės judėjimo kryptis. Analitikai taip pat stebi ryšį tarp akcijos ir rinkos rodiklių. Dažniausiai investuotojai savo sprendimams priimti naudoja daugiau nei vieną rodiklį derinį savo analizėms [3].



2 pav. Techninės analizės struktūrinė schema [4]

1.2.1. Techninės analizės rodikliai

Techninės analizės rodiklius galima suskirstyti į įvairius tipus, atsižvelgiant į jų pateikimo būdą ir jiems labiausiai tinkančias rinkos sąlygas [3]:

- **Tendencijų rodikliai.** Kaip rodo pavadinimas, tendencijų rodikliai dažniausiai naudojami nustatant ir patvirtinant kainos tendencijas. Jie taip pat padeda nustatyti tam tikrus taškus, kurie rodo tendencijos pabaigą arba naujos tendencijos pradžią.
- **Pagreičio rodikliai.** Šie rodikliai yra naudingiausi siekiant nustatyti tam tikrus prekybos veiklos pokyčius, kurie gali atitikti tiek tendencijas, tiek tendencijas, kurioms nebūdingos rinkos sąlygos. Jie dažnai vadinami osciliatoriais.
- **Nepastovumo rodikliai.** Šie rodikliai padeda įvertinti kainos judėjimo kitimo laipsnį, apribotą tam tikru laikotarpiu, taip pat palyginti su kainų pokyčių istorija.
- **Sentimento ir stiprumo rodikliai.** Šie rodikliai naudojami kartu su kainomis pagrįstais rodikliais, kad būtų galima suprasti, kaip investuotojai reaguoja į kainų veiklą ar kaip numato ateitį.
- **Vertybinių popierių rinkos rodikliai.** Šie rodikliai parodo duomenis, susijusius su prekyba akcijomis, bei pateikia pagrindines išvalgas apie galimus kainų pokyčius, atsižvelgdami į investuotojų veiksmus.

Slankusis vidurkis gali būti dviejų tipų – paprastasis slankusis vidurkis (toliau SMA) ir eksponentinis slankusis vidurkis (toliau EMA). SMA apskaičiuojamas susumuojant naujausias akcijų uždarymo dienos pabaigoje kainas ir padalinant jas iš laikotarpių skaičiaus. Formulė atrodo taip:

$$SMA = \frac{\text{Akcijų uždarymo kainų suma}}{\text{Laikotarpių skaičius}} \quad (9)$$

Eksponentinis slankusis vidurkis pagal savo principą yra panašus į paprastąjį slankųjį vidurkį, išskyrus tai, kad EMA daugiau priklauso nuo naujausios dienos duomenų. Toks būdas suteikia daugiau reikšmės, nes jautrumas išlaikomas naujausioms kainoms. Šis rodiklis apskaičiuojamas šiomis formulėmis:

$$EMA_t = \text{Šiandieninė kaina} \cdot k + EMA_y \cdot (1 - k) \quad (10)$$

$$k = \frac{2}{d+1} \quad (11)$$

kur EMA_t ir EMA_y reiškia atitinkamai šiandienos ir vakarykštę rodiklio vertes, k – glotninimo koeficientas, d yra dienų skaičius EMA rodikliui apskaičiuoti.

Slankiojo vidurkio konvergencija arba divergencija (toliau MACD) yra techninis rodiklis, atsirandantis dėl dviejų skirtingų laikotarpių eksponentinio slankiojo vidurkio skirtumo. MACD rodiklis naudojamas prekyboje, prekiautojams ieškant pirkimo arba pardavimo rinkos signalų. Rodiklis „poruojamas“ su devynių dienų eksponentiniu slankiuoju vidurkiu, kuris vadinamas „signalo linija“, o šių dviejų rodiklių susikirtimo taškas indikuoja apie rinkos pokyčius. Kai MACD kreivė kerta EMA_9 kreivę iš apačios, tada kainos turėtų kilti ir verta nusipirkti akcijų. Jei MACD kerta signalo liniją iš viršaus – kainos kilimas baigėsi, todėl patartina parduoti vertybinius popierius. Rodiklis apskaičiuojamas randant skirtumą tarp 12 ir 26 dienų eksponentinių slankiųjų vidurkių:

$$MACD = \sum_{i=1}^n EMA_{12} - \sum_{i=1}^n EMA_{26} \quad (12)$$

Kainos nuo akcijos kiekio (toliau OBV) rodiklis yra laikomas pagreičio rodikliu, kuris pagal akcijų kiekio pokytį nuspėja akcijų kainų kitimo kryptį. Jei akcijų kainos yra mažėjančios, tai OBV reikšmė mažėja taip pat, ir atvirkščiai, būsimą akcijų kainos kilimą rodo auganti OBV vertė. Ši priklausomybė atrodo šitaip:

$$OBV = OBV_y + \begin{cases} \text{akcijų kiekis,} & \text{jei kaina šiandien} > \text{kaina vakar} \\ 0, & \text{jei kaina šiandien} = \text{kaina vakar} \\ -\text{akcijų kiekis,} & \text{jei kaina šiandien} < \text{kaina vakar} \end{cases} \quad (13)$$

čia OBV_y yra praėjusios dienos rodiklio vertė.

Santykinis stiprumo indeksas (toliau RSI) yra pagreičio rodiklis, naudojamas atliekant techninę analizę, kuris matuoja naujausių kainų pokyčių dydį, kad įvertintų per daug perkamas ar parduodamas akcijas. RSI rodomas kaip osciliatorius ir gali būti rodoma nuo 0 iki 100. Tradicinis RSI vertės supratimas: 70 ir didesnės vertės rodo, kad vertybiniai popieriai tampa pervertinti. Jei RSI yra 30 arba mažesnis – tai rodo nepakankamai įvertintą atvejį. RSI apskaičiuojamas pagal formulę žemiau:

$$RSI = 100 - \left(\frac{100}{1 + \frac{\text{vidutinis prieaugis}}{\text{vidutinis nuostolis}}} \right) \quad (14)$$

1.3. Vertybinių popierių rinkos prognozė pasitelkus dirbtinį intelektą

Akcijų vertės prognozavimas yra sudėtinga užduotis dėl rinkų sudėtingumo ir dinamikos bei daugybės neaiškių, susipynusių veiksnių. Surasti matematinę metodiką, kuri galėtų tiksliai numatyti būsimas vertybinių popierių kainas, yra nesibaigiantis tyrimas. Investuotojai nuolat stengiasi uždirbti didesnę nei vidutinę grąžą iš savo investicijų vertybinių popierių rinkoje. Todėl modelis, galintis numatyti akcijų kainą, juos labai domina. Kadangi techninė ir fundamentali analizė reikalauja labai daug laiko kiekvienai iš akcijų bei viena iš analizių neužtikrina efektyvios prognozės, pradėtos taikyti analizių kombinacijos panaudojant dirbtinį intelektą. Prognozuoti naudojamos įvairios technikos ir modeliai. Toliau bus apžvelgta, kaip keletas iš dirbtinio intelekto tipų gali būti taikoma vertybinių popierių kainų prognozavimui bei sprendimo pirkti, laikyti ar parduoti pasiūlymui.

1.3.1. Dirbtinių neuroninių tinklų taikymas

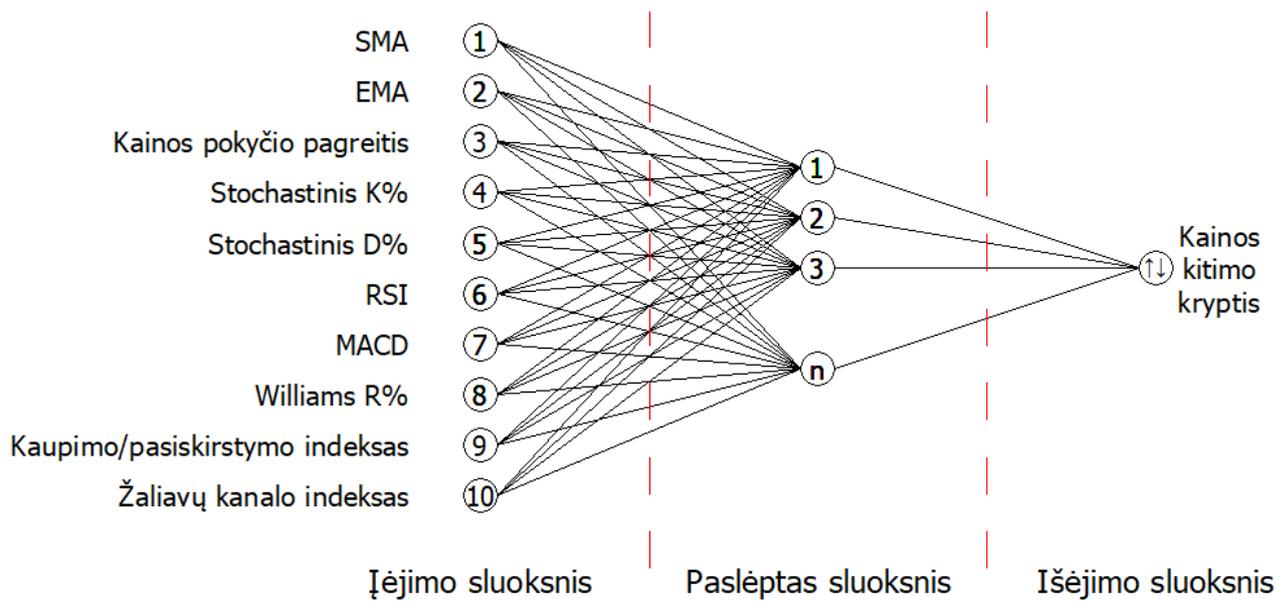
Neuroniniai tinklai labai sėkmingai taikomi signalo apdorojimo programoms. Finansinių, laike kintančių duomenų prognozavimas yra signalo apdorojimo problema, kuriai būdingas netiesiškumas ir nestacionarumas, todėl toks modelis labai sudėtingas. Pažangios intelektualiosios technikos naudojimas vertinamas kaip patobulinimas lyginant su tradicinių techninės analizės metodų naudojimu, pagal kuriuos akcijų kainos prognozuojamos remiantis praeities kainomis ir kiekiais rinkoje, pagrindinėmis dėsningumų koncepcijomis, kainų kitimo modeliais, kuriuos investuotojai paprastai naudoja priimdami sprendimus.

Daugiasluoksniai perceptronai yra pažangūs neuroniniai tinklai, mokomi naudojant standartinį atgalinio dauginimo algoritmą (angl. *back-propagation*). Šio tipo neuroninis tinklas priklauso prižiūrimiems tinklams, todėl jiems reikia norimo išėjimo, kad galėtų mokytis. Paprastai jie susideda iš trijų sluoksnių: įvesties, paslėpto ir išvesties sluoksnių (3 pav.). Įrodyta, kad jie apytiksliai atspindi optimalių statistinių klasifikatorių veikimą, esant sudėtingoms sąlygoms. Daugiasluoksniai perceptronai yra labiausiai paplitusi tinklo architektūra, naudojama finansiniams neuroniniams tinklams [5].

Vienas iš svarbiausių neuroninių tinklų modelio kūrimo žingsnių yra sprendimas, kokią informaciją naudoti jos mokymui. Pagrindinis prognozavimo tikslas, naudojant įvairias priemones, yra nuspręsti kada pirkti, laikyti ar parduoti vertybinius popierius, remiantis turima arba prieinama informacija. Įvesties duomenys gali būti neapdoroti duomenys, pavyzdžiui, iš viso nupirktų vienetų kiekis, kaina ar dienos pokyčiai. Įėjimo duomenys taip pat gali būti techniniai rodikliai, pavyzdžiui, slankusis vidurkis, santykinis stiprumo indeksas arba fundamentiniai rodikliai, tokie kaip pajamingumas per akciją, įvairūs santykiniai rodikliai ir kt. Šie duomenys taip pat gali apimti makroekonominis rodiklius, tokius kaip infliacija, palūkanų norma, bendrasis vidaus produktas ir kt.

Taip pat svarbu pasirinkti vidinę neuroninio tinklo struktūrą – kiek neuronų sudarys paslėptąjį sluoksnį. Kadangi nėra jokios teorijos, kuri nurodytų kokia struktūra yra optimaliausia ir kaip gauti geriausius rezultatus, todėl parinkimas daugiausiai priklauso nuo eksperimentų skaičiaus bei rezultatų. Todėl reikalingas didelis kiekis eksperimentų, efektyviausio ir optimaliausio modelio radimui.

Norint apmokyti neuroninį tinklą, reikia pateikti jam skirtingus įvesties duomenis, kad pagal kuo įvairesnes situacijas tinklas galėtų sumažinti savo empirinę paklaidą ir pagerintų veikimą. Neuroninio tinklo mokymui naudojamas algoritmas gali skirtis priklausomai nuo pasirinktos tinklo architektūros, tačiau dažniausiai pasirenkamas atgalinio dauginimo mokymo algoritmas, projektuojant finansinius neuroninius tinklus. Atgalinio dauginimo metodas – tai procesas, kai treniruotės metu gautos paklaidos perkeliama nuo išvesties sluoksnio į įvesties sluoksnį. Šis metodas būtinas, nes paslėpto sluoksnio neuronai mokomi remiantis ankstesnių sluoksnių paklaidomis. Išvesties sluoksnis yra vienintelis sluoksnis, kuriame gautą reikšmę galima palyginti su viso modelio tikslu. Kadangi naudojamas atgalinio dauginimo metodas, keičiasi paslėptojo sluoksnio ryšio svoriai. Kai tinklui pateikiami skirtingi įvesties duomenų paketai paklaida tarp modelio rezultato ir tikslo palaipsniui sumažinama iki minimumo. Mokymas tęsiasi tol, kol paklaidos bus pakankamai mažos, kad taptų priimtinos [5].



3 pav. Neuroninio tinklo pavyzdys akcijų kainos prognozavimui [6]

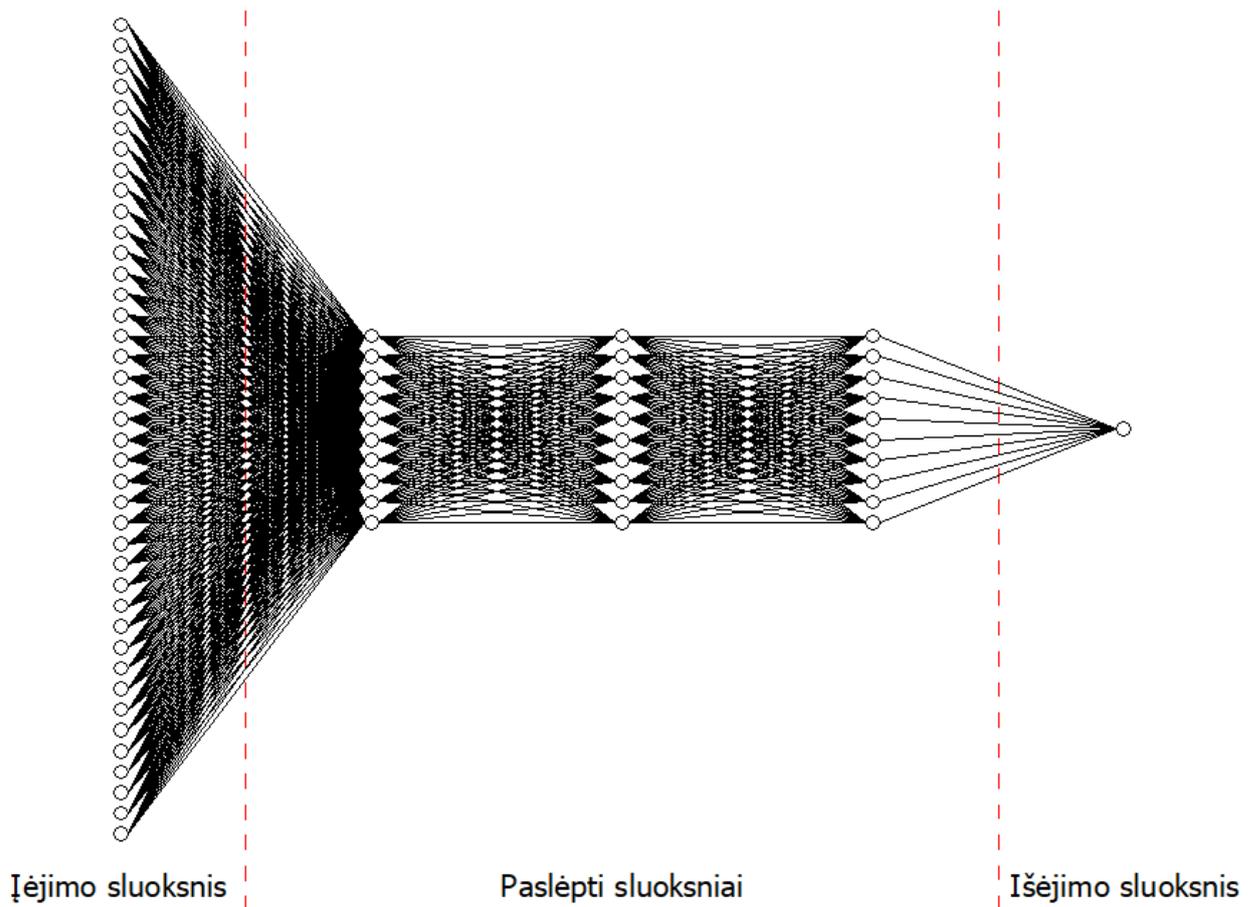
1.3.2. Gilaus mokymo tinklų taikymas

Gilus neuroninis tinklas yra specialus dirbtinio neuroninio tinklo tipas, pasižymintis savo architektūra, kurią sudaro didesnis paslėptų sluoksnių ir neuronų skaičius, lyginant su įprastiniu neuroniniu tinklu. Didesnis paslėptų sluoksnių skaičius parodo padidėjusio aukšto lygio funkcijų išgavimo galimybes kiekvienam pridėtam paslėptam sluoksniui. Taigi neapdorotų įvesties duomenų nereikia iš anksto apdoroti naudojant funkcijų išgavimo metodus, palyginti su įprastais neuroniniais tinklais.

Yong ir Rahim (2017) atliko tyrimą, kuriame buvo kuriama akcijos kainų nuspėjimo po t dienų bei prekybos sistema naudojant gilaus mokymo neuroninį tinklą. Prognozavimo principas buvo realizuojamas 1-10 dienų akcijos atidarymo, uždarymo, maksimalios ir mažiausios kainų duomenų paketu, laikomu modelio įėjimu, kad gauti numatomą uždarymo kainą ateityje, už t dienų. Darbo dienų skaičius gali būti parenkamas bet koks, optimaliausia remtis gautais rezultatais ir nuspręsti kiek duomenų imti. Taip pat reikia nepamiršti, kad kiekvienai už t dienų prognozei reikia modelį mokyti iš naujo [8].

Tokio modelio pavyzdys pateiktas 4 paveiksle. Straipsnyje kurto modelio architektūrą sudarė įvesties sluoksnis su 40 įvesties mazgų (10 dienų duomenys), 3 paslėpti sluoksniai, kurių sudėtis yra atitinkamai 10–10–10 neuronų ir išėjimo sluoksnis su vienu mazgu, kuris išduoda akcijų kainos prognozę už t dienų [8].

Gilaus mokymo neuroninio tinklo mokymosi algoritmui buvo naudojamas stochastinis gradientinis optimizavimas ir atgalinio dauginimo metodai. Apmokymas tokio modelio yra ilgas ir brangus procesas su 40, o tam tikrai atvejais ir daugiau įvesties kintamųjų bei dideliu neuronų skaičiumi. Spręsti šią problemą naudojamas kelių branduolių apdorojimo metodas, kur kiekvienas branduolys tvarko atskirus mokymo duomenų pogrupius. Apmokyto modelio rezultatas yra prognozės modelis, pagal kurį galima numatyti akcijos uždarymo kainą netolimoje ateityje [8].



4 pav. Gilaus neuroninio tinklo pavyzdys [8]

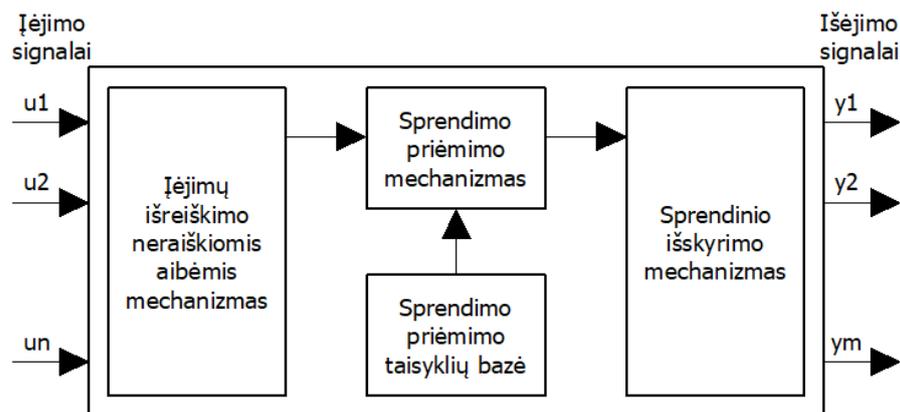
1.3.3. Neraiškiosios logikos taikymas

Neraiškioji logika arba „Fuzzy“ logika yra kintamojo apdorojimo būdas, leidžiantis apdoroti kelias vertes per tą patį kintamąjį. Neraiškioji logika bando išspręsti problemas naudojant neapibrėžtą duomenų spektrą, kuris leidžia gauti daugybę tikslų išvadų. „Fuzzy“ logika yra skirta spręsti problemas, atsižvelgiant į visą turimą informaciją ir priimant geriausią įmanomą sprendimą.

Praktikoje ši konstrukcija leidžia naudoti kelias „True“ sąlygos reikšmes. Vietoj to, kad „True“ reikšmė būtų lygiavertė 1, o „False“ būtų lygi 0 (arba atvirkščiai). Todėl „True“ sąlyga gali būti bet koks reikšmių skaičius, mažesnis už vieną ir didesnis už nulį.

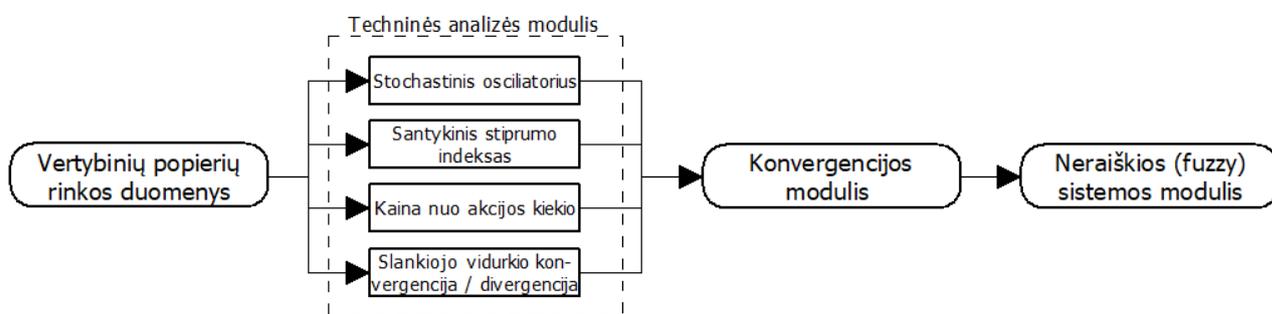
„Fuzzy“ architektūrą sudaro keturios pagrindinės dalys (5 pav.):

- Taisyklių bazė. Joje pateikiamos visos taisyklės ir sąlygos, kurias ekspertas (sistemos kūrėjas) siūlo kontroliuoti ir priimti sprendimą;
- Išreiškimas „Fuzzy“ aibėmis. Šiame žingsnyje konvertuojami aiškūs skaičiai į neaiškius rinkinius, kitaip tariant įėjimo reikšmė pakeičiama į reikšmę intervale $[0;1]$. Įvade dažniausiai sutinkami jutiklių duomenys, kurie perduodami tolesniam apdorojimui;
- Sprendimo priėmimas. Tai padeda nustatyti neaiškios įvesties ir taisyklių atitikties laipsnį. Remiantis atitiktimi, jis nustato, kurias taisykles reikia įgyvendinti pagal pateiktas įvesties narystės funkcijas. Po to taikomos taisyklės sujungiamos kuriant kontrolės veiksmus;
- Sprendimo išskyrimas. Galiausiai atliekamas išskyrimo procesas, kad „Fuzzy“ rinkiniai būtų paversti aiškia verte. Galimų būdų yra daugybė, todėl būtina pasirinkti, kuris tinka geriausiai.



5 pav. „Fuzzy“ sistemos struktūrinė schema

Investicinio sprendimo priėmimui galima taikyti neraiškios logikos („Fuzzy“) modelį. Acheme, Vincent ir kiti 2014 metais pritaikė modelį, kuris pagal keletą techninių rodiklių nusprendžia pirkti, laikyti arba parduoti vertybinius popierius. Sistemos architektūrą sudaro trys moduliai: techninės analizės modulis, konvergencijos modulis ir neraiškios sistemos modulis (6 pav.). Techninės analizės modulis pagal akcijų kainas apskaičiuoja keturis techninius rodiklius. Konvergencijos modulis paverčia techninius rodiklius į naujus pagalbinius kintamuosius, kad juos būtų galima naudoti sekančiame modulyje. Kiekvienas rodiklis nuvedamas į vieną neraiškiosios sistemos įėjimą, kad modelis būtų paprastas. Šio konvergencijos modulio išvestis tarnauja kaip neraiškiosios sistemos įvesties kintamasis, o neraiškiosios sistemos modulis generuoja prekybos signalą, pagrįstą taisyklių bazėje aprašytomis taisyklėmis [11].



6 pav. Neraiškiaja logika paremtas vertybinių popierių prognozavimo modelis [11]

Modelio taisyklių bazė kuriama naudojant „Mamdani“ sistemos pagrindą. Įėjimo kintamiesiems naudojamos Gauso narystės funkcijos, o išėjimui – trikampio narystės funkcijos. Sistemos rezultatas priklauso nuo keturių kintamųjų, kurie priskiriami techninei analizei: slankiojo vidurkio konvergencija / divergencija, santykinis stiprumo indeksas, stochastinis oscilatorius ir kainos nuo akcijos kiekio rodiklis (OBV). Šių kintamųjų įėjimo į „Fuzzy“ modelį narystės funkcijos aprašytos 1 lentelėje. Neaiškios loginės sistemos išvestis – pirkimo, pardavimo ar laikymo signalas, remiantis taisyklių bazėje apibrėžtomis taisyklėmis [11].

1 lentelė. Fuzzy sistemos įėjimo kintamųjų narystės funkcijos [11]

Įėjimo kintamasis	Narystės funkcijos	Narystės funkcijų reikšmė
Slankiojo vidurkio konverg. / diverg.	Žemas ir aukštas	Žemas, kai žemiau signalinės linijos; aukštas, kai virš signalinės linijos
Santykinis stiprumo indeksas	Žemas, vidutinis ir aukštas	Žemas kai vertė žemiau 30; vidutinis kai vertė tarp 30 ir 70; aukštas kai vertė virš 70
Stochastinis osciliatorius	Žemas, vidutinis ir aukštas	Žemas kai vertė žemiau 20; vidutinis kai vertė tarp 20 ir 80; aukštas kai vertė virš 80
Kainos nuo akcijos kiekio rodiklis	Žemas ir aukštas	Žemas, kai reikšmė mažėjanti; aukštas, kai reikšmė didėjanti

Nusprendus sistemos įėjimus ir išėjimus reikia sąryšio tarp jų. Sprendimai pagal įėjimų duomenis priimami remiantis neraiškiomis taisyklėmis. Šios taisyklės aprašomos sąlyga JEIGU – TADA taisyklių rinkiniais, kur sąlygos yra susijusios su narystės funkcijos kintamaisiais. Šie neraiškių taisyklių rinkiniai apibūdina sistemos elgesį kalbine forma, artima žmogaus mąstymo būdai. Sukūrus taisyklių ir narystės funkcijų rinkinius, galima patobulinti sistemą eksperimentuojant su skirtingomis taisyklėmis ir narystės funkcijomis, kad pasiektų tinkamų rezultatų. Modeliui taikomi taisyklių rinkiniai [11]:

1. Jeigu MACD yra aukštas ir RSI yra žemas ir SO yra žemas ir OBV yra aukštas TADA pirkti;
2. Jeigu MACD yra žemas ir RSI yra aukštas ir SO yra aukštas ir OBV yra žemas TADA pirkti;
3. Jeigu MACD yra aukštas ir RSI yra vidutinis ir SO yra vidutinis ir OBV yra aukštas TADA pirkti;
4. Jeigu MACD yra žemas ir RSI yra vidutinis ir SO yra aukštas ir OBV yra žemas TADA parduoti;
5. Jeigu RSI yra žemas ir SO yra žemas ir OBV yra aukštas TADA pirkti;
6. Jeigu RSI yra aukštas ir SO yra aukštas ir OBV yra žemas TADA parduoti;
7. Jeigu MACD yra žemas ir RSI yra aukštas ir SO yra aukštas TADA parduoti;
8. Jeigu MACD yra žemas ir RSI yra vidutinis ir SO yra vidutinis TADA laikyti;
9. Jeigu MACD yra aukštas ir RSI yra vidutinis ir SO yra vidutinis ir OBV yra žemas TADA laikyti.

2. Modelių ir algoritmų skirtų VIX indekso prognozavimui analizė

Šiame skyriuje bus apžvelgiami modeliai, kurie skirti prognozuoti būsimą rinkos nepastovumą. Šios apžvalgos tikslas išsiaiškinti, kokie modeliai priskiriami prie tradicinių bei susipažinti su mašininio mokymosi metodais. Taip pat apžvelgti jų modelius, įėjimus ir rezultatus, kurie buvo gauti atliekant mokslinius tyrimus. Pasinaudojant apžvalga bei surinktais duomenimis, bus nuspręsta kokia gilaus mokymo modelio struktūra bei įėjimai bus naudojami būsimo VIX indekso prognozavimo modelio kūrimui.

Tradiciniams modeliams priskiriami daugiamatės linijinės regresijos, pagrindinių komponentų analizės (angl. *principal components analysis* (trump. PCA)) ir automatinio regresinio integruoto slenkamojo vidurkio (angl. *AutoRegressive Integrated Moving Average* (trump. ARIMA)) modeliai. Mašininio mokymosi metodams priskiriamų modelių ir jų kombinacijų yra labai daug ir įvairių. Kadangi kuriamas modulis bus panaudojant gilaus mokymo metodą, tai ir dėmesys bus skiriamas rekurentinių tinklų bei su jais kombinuotų metodų analizei.

2.1. Tradicinė tiesinė regresija

Regresijos analizė neabejotinai yra plačiausiai naudojama statistinė rinkos rizikos modeliavimo metodika, kuri taikoma įvairiuose kontekstuose, pavyzdžiui, faktorių modeliai modeliuoti gražai arba automatiškai koreliuojami modeliai, skirti modeliuoti nepastovumą laike. Visi šie modeliai yra pagrįsti regresijos analize kartu su skirtingais požiūriais ir apibrėžimais.

Paprastą tiesinės regresijos modelį galima parašyti taip:

$$Y_{it} = \alpha_i + \beta_i X_{it} + \varepsilon_{it}, \quad (15)$$

lygtyje pateiktas priklausomas kintamasis Y_{it} , kaip tiesinė funkcija vieno ar kelių nepriklausomų kintamųjų X_{it} , atsižvelgiant į atsitiktinį trikdį ar paklaidą ε_{it} . Lygtyje β_i apibūdina kintamojo X_{it} įtaką Y_{it} arba kitaip tariant tiesės nuolydį, o α_i yra pradinė Y_{it} reikšmė, kai $X_{it} = 0$.

Yra žinoma, kad paprastos tiesinės regresijos atveju normalusis skirstinys taikomas priklausomiems ir nepriklausomiems kintamiesiems. Regresija įvertina vidutinę priklausomo kintamojo vertę tam tikriems nepriklausomų kintamųjų lygiams. Šio tipo regresijai, kai pagrindinis dėmesys skiriamas duomenų rinkinio tendencijų suvokimui, mažiausių kvadratų regresija yra labai efektyvus metodas. Nepaisant to, mažiausių kvadratų regresija gali prarasti savo efektyvumą, kai bandoma peržengti duomenų rinkinio vidurkį arba pasiekti ekstremumus. Konkrečiai kalbant, nežinomo ar savavališko susikirtimo paskirstymo atveju mažiausių kvadratų regresija neteikia visos būtinos informacijos, reikalingos sąlyginio kintamojo pasiskirstymui kiekybiškai įvertinti.

Praktikoje taikomi keletas tiesinės regresijos tipų: paprasta tiesinė regresija (aprašyta aukščiau), daugkartinė tiesinė regresija (naudoja du ar daugiau nepriklausomų kintamųjų rezultatui prognozuoti) ir daugiamatė tiesinė regresija (angl. *multivariate linear regression*). Pastaroji bus analizuojama plačiau. Ši regresija yra kompaktiškas būdas vienu metu aprašyti kelis priklausomus tiesinės regresijos modelius. Tai nėra atskiras statistinis tiesinis modelis. Bendrąja prasme jis aprašomas taip:

$$Y = XB + E \quad (16)$$

kur Y yra matrica su daugiamačiais matavimais (kiekvienas stulpelis yra vieno iš priklausomų kintamųjų matavimų rinkinys), X yra nepriklausomų kintamųjų stebėjimų matrica, kuri gali būti projektavimo matrica (kiekvienas stulpelis yra stebėjimų rinkinys vienam iš nepriklausomų kintamųjų). B yra matrica su parametrais, kurie paprastai turi būti įvertinti, o E yra matrica, kuri aprašo paklaidą (trikdį). Paprastai daroma prielaida, kad paklaidos nekoreliuoja atliekant matavimus ir atitinka daugiamačią normalųjį skirstinį. Jei paklaidos neatitinka daugiamačio normalaus pasiskirstymo gali būti naudojami apibendrinti tiesiniai modeliai, siekiant sušvelninti prielaidas apie Y ir U .

Bendresnėje daugiamačėje tiesinėje regresijoje yra po vieną aukščiau pateiktos formos lygtį kiekvienam iš priklausomų kintamųjų, kurie turi tą patį aiškinamųjų kintamųjų rinkinį ir todėl yra vertinami vienu metu:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \varepsilon_i \quad (17)$$

visiems stebėjimams, indeksuotiems kaip $i = 1, \dots, n$ ir visiems priklausomiems kintamiesiems, indeksuotiems kaip $j = 1, \dots, m$.

Būtina įsidėmėti, kad kiekvienas priklausomas kintamasis turi savo regresijos parametrų rinkinį, kurį reikia pritaikyti, skaičiavimo požiūriu bendroji daugiamačė regresija yra tiesiog standartinių kelių tiesinių regresijų, naudojant tuos pačius aiškinamuosius kintamuosius, seka.

Tyrime, kurį atliko James, Slobodan ir bendraautoriai (2018) kintamumo indekso VIX prognozavimui panaudojo finansų rinkoje labai dažnai naudojamą daugiamačės tiesinės regresijos modelį. Tyrimo metu buvo atliekami bandymai su keletu modelių, įėjimo kintamųjų buvo numatyta 71. Naudojant visus 71 parametrus, paprastosios mažiausių kvadratų (angl. *ordinary least squares*) regresijos determinacijos koeficientas R^2 buvo 86,9%. Su visais 71 kintamųjų regresijos modelis labai komplikotas bei nevisi kintamieji gali būti reikšmingi galutiniam prognozuojamam indeksui. Siekiant sumažinti įvesties matmenis, duomenys pirmiausia buvo normalizuoti. Kiekvienai regresijai buvo pašalinti kintamieji, kurių p reikšmės $> 0,05$ arba $< -0,05$. Antra, išlaikomi didžiausi kiekvienos įvesties absoliučia verte koeficientai. Trečia, paliekami tik didesnes pakoreguotas R^2 reikšmes turintys įvesties kintamieji, nes šie daugiau įtakoja bendrą pokytį. Ketvirta, buvo apskaičiuotas kiekvieno kintamojo dispersijos infliacijos koeficientas (angl. *variance inflation factor*), o tie, kurių $VIF > 10\%$, buvo pašalinti. Po šių procedūrų 71 kintamasis buvo sumažintas iki 13 įvesčių (duomenys pateikiami 2 lentelėje), o šių kintamųjų determinacijos koeficientas R^2 yra 80,8% 1 mėnesio VIX ateities sandoriams 3 dienas į priekį. Visų 13 įvesties kintamųjų galutiniai rezultatai pateikti 3 lentelėje [12].

2 lentelė. Įėjimo duomenys [12]

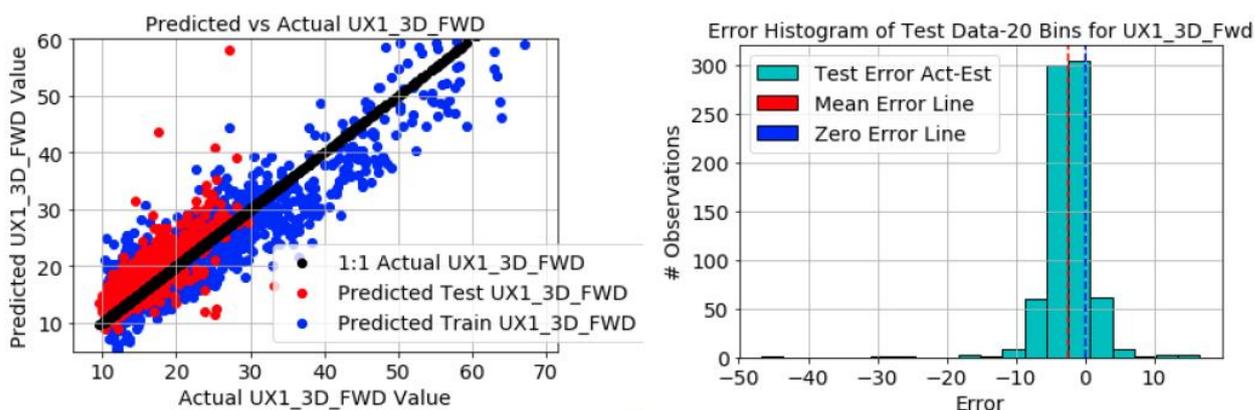
Įėjimas	Kintamojo vardas	Apibūdinimas
1	M3_200_100	Iškreiptas numanomas nepastovumo skirtumas trijų mėnesių, 200% OTM – 100% ATM
2	M1_150_100	Iškreiptas numanomas nepastovumo skirtumas vieno mėnesio, 150% OTM – 100% ATM
3	UX3_HILO	Dienos aukščiausios ir žemiausios vertės trijų mėnesių „VIX future“ skirtumas
4	VVIX_HILO	Dienos aukščiausios ir žemiausios vertės VVIX skirtumas

Įėjimas	Kintamojo vardas	Apibūdinimas
5	BOLL_XUPPER	=1, kai VIX kerta viršutinę Bolingerio juostą
6	UX7MUX2	„VIX future“ skirtumo 7-2 mėnesių termino struktūra
7	M2_120_80	Iškreiptas numanomas nepastovumo skirtumas dviejų mėnesių, 120% OTM – 80% OTM
8	SIGBUY14D3CD	=1, kai VIX kerta viršutinį 14 dienų slankųjį vidurkį (MA) 3 dienas iš eilės
9	M2_150_100	Iškreiptas numanomas nepastovumo skirtumas dviejų mėnesių, 150% OTM – 100% ATM
10	M2_200_100	Iškreiptas numanomas nepastovumo skirtumas dviejų mėnesių, 200% OTM – 100% ATM
11	UX6MUX4	„VIX future“ skirtumo 6-4 mėnesių termino struktūra
12	UX6_HILO	Dienos aukščiausios ir žemiausios vertės šešių mėnesių „VIX future“ skirtumas
13	M12_120_80	Iškreiptas numanomas nepastovumo skirtumas dvylikos mėnesių, 120% OTM – 80% OTM

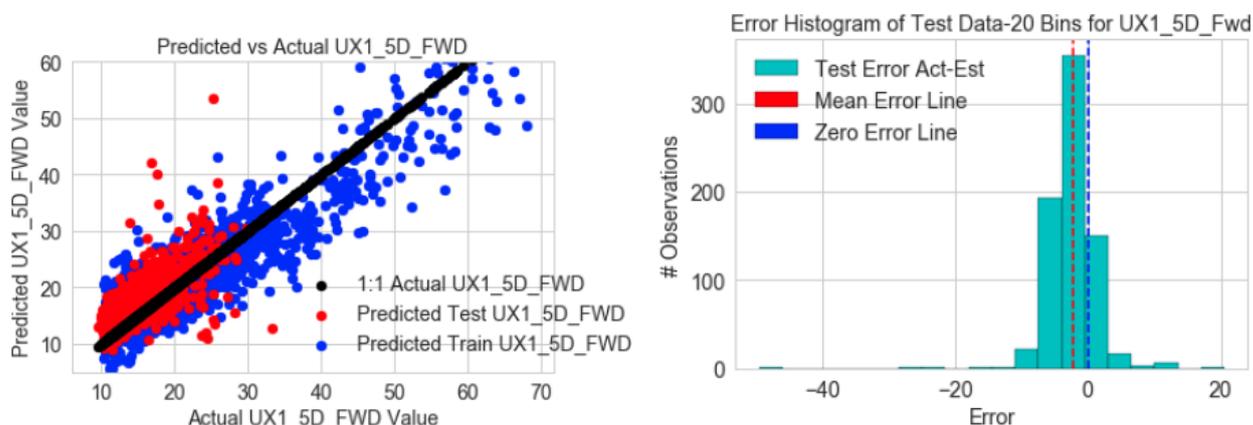
3 lentelė. Įėjimo duomenų paskutiniai apskaičiuoti parametrai [12]

Kintamasis	Koeficientas	Standartinė paklaida	<i>t</i>	<i>P</i> > <i>t</i> 	<i>R</i>²	Pakoreguotas <i>R</i>²
M3_200_100	-0,093	0,014	6,507	0,000	0,1935	0,0030
M1_150_100	0,034	0,016	2,154	0,031	0,3242	0,0003
UX3_HILO	0,160	0,017	9,529	0,000	0,3957	0,0063
VVIX_HILO	-0,061	0,009	-6,675	0,000	0,0102	0,0031
BOLL_XUPPER	-0,043	0,010	-4,403	0,000	0,0005	0,0014
UX7MUX2	-0,515	0,021	-24,402	0,000	0,6238	0,0416
M2_120_80	-0,368	0,015	-25,079	0,000	0,4629	0,0439
SIGBUY14D3CD	-0,030	0,009	-3,226	0,001	0,0094	0,0007
M2_150_100	0,158	0,022	7,279	0,000	0,3918	0,0037
M2_200_100	-0,055	0,013	-4,205	0,000	0,0838	0,0012
UX6MUX4	-0,063	0,021	-2,944	0,003	0,5706	0,0006
UX6_HILO	0,058	0,014	4,024	0,000	0,1629	0,0011
M12_120_80	-0,090	0,015	-6,092	0,000	0,3309	0,0026

7 ir 8 paveiksluose pateikta treniruočių bei testavimo išvesties daugiamatės tiesinės regresijos sklaidos diagramos atitinkamai 3 ir 5 dienoms į priekį. Diagramose taip pat vaizduojama identiška tobulos treniruočių duomenų rinkinio išvesties diagrama, kaip etalonas. Sklaidos diagramos rodo tiesinį ryšį tiek bandymo, tiek treniruočių įverčiams lyginant su realia indekso verte. Be to, 7 ir 8 paveiksluose parodytos paklaidų histogramos, kur lyginami apskaičiuoti bandymo duomenys su realiaisiais duomenų rinkiniais 3/5 dienas į priekį. Bandymų duomenų paklaidų histogramos yra iškreiptos (asimetrinės formos) dėl 2018 m. vasario mėnesio infliacijos, dėl kurios šoktelėjo nepastovumas.



7 pav. Modelio, skirto prognozuoti VIX vertę 3 dienas į priekį, sklaidos diagrama ir histograma [12]



8 pav. Modelio, skirto prognozuoti VIX vertę 3 dienas į priekį, sklaidos diagrama ir histograma [12]

4 lentelėje parodyta modelio kokybės rezultatų santrauka. Parametrų vertės buvo naudojamos intervale nuo 2006 metų liepos mėnesio iki 2018 metų liepos mėnesio. Moduliui buvo pateikti dviem būdais paskirstyti duomenys: 10 dalių kryžminis patvirtinimas ir tradicinis 75% mokymo /25 % testavimo duomenų padalijimas. Naudojant 10 dalių kryžminį patvirtinimą, testavimo duomenų vidutinė kvadratinė paklaida bei R^2 yra didesni nei tradicinio padalijimo [12].

4 lentelė. Daugiamačio linijinio regresijos modelio kokybės parametrų vertės [12]

Išėjimas	Tradicinis 75% mokymui / 25% testavimui pasiskirstymas						10 dalių kryžminis patvirtinimas	
	R^2_{train}	R^2_{test}	MSE_{train}	MSE_{test}	ρ_{train}	ρ_{test}	R^2_{test}	MSE_{test}
3 dienų	0,81	0,16	15,22	18,94	0,91	0,73	0,325	26,76
5 dienų	0,79	-0,05	17,25	22,09	0,89	0,63	0,315	29,34

2.2. Pagrindinių komponentų analizė

Pagrindinių komponentų analizė supaprastina didelio kiekio duomenų sudėtingumą, išlaikant tendencijas ir modelius. Tai daroma duomenų bazę paverčiant mažesnių gabaritų, kitaip tariant atliekant funkcijų santrauką. Dideli duomenų rinkiniai yra labai dažni daugelyje sričių ir atsiranda, kai matuojamos kelios proceso savybės. Šio tipo duomenys kelia keletą iššūkių, kuriuos sušvelnina pagrindinių komponentų analizė: skaičiavimo sąnaudos ir padidėjęs klaidų lygis dėl kelių bandymų pataisymų, kai bandoma kiekviena funkcija susieti su rezultatu. Pagrindinių komponentų analizė yra

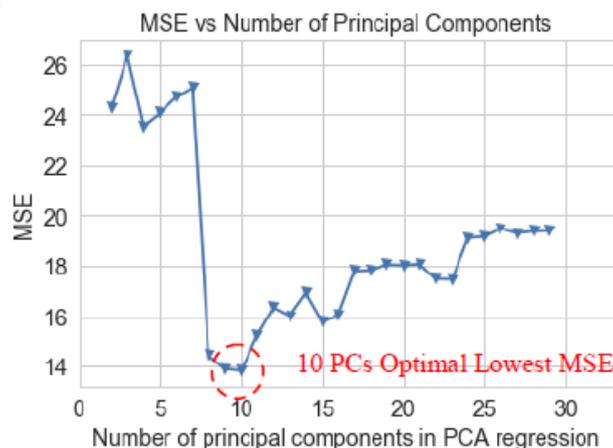
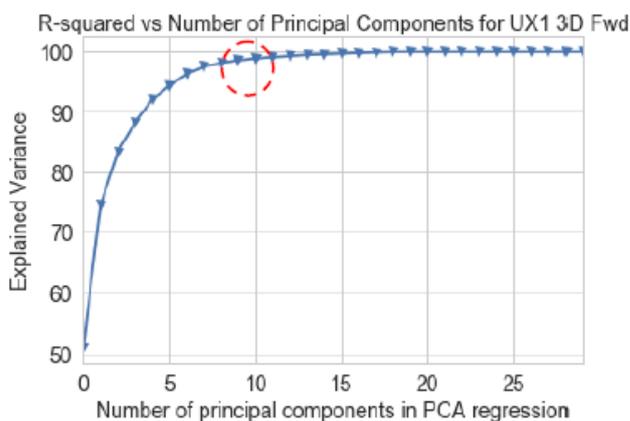
neprižiūrimas metodas ir panašus į grupavimą (angl. *clustering*) – jis randa modelius neatsižvelgdamas į išankstines žinias apie duomenų šaltinius.

Pagrindinių komponentų analizė sumažina duomenis geometriškai projektuodamas juos į mažesnius matmenis, vadinamus pagrindiniais komponentais (angl. *principal components*), siekiant rasti geriausią duomenų santrauką naudojant ribotą skaičių komponentų. Pirmasis komponentas pasirenkamas siekiant sumažinti bendrą atstumą tarp duomenų ir jų projekcijos į komponentą. Sumažindami šį atstumą taip pat maksimaliai padidiname projektuojamų taškų dispersiją σ^2 . Antrasis ir kiti komponentai parenkami panašiai, taikant papildomą reikalavimą, kad jie nekoreliuotų su visais ankstesniais komponentais. Šis reikalavimas nekoreliuoti reiškia, kad didžiausias galimas komponentų skaičius yra arba mėginių skaičius, arba funkcijų skaičius, atsižvelgiant į tai, kuris yra mažesnis. Pagrindinių komponentų atrankos proceso tikslas maksimaliai padidinti koreliaciją tarp duomenų ir jų projekcijų ir yra lygiavertis daugkartinei tiesinei regresijai projektuojamiems duomenims pagal kiekvieną pradinių duomenų kintamąjį.

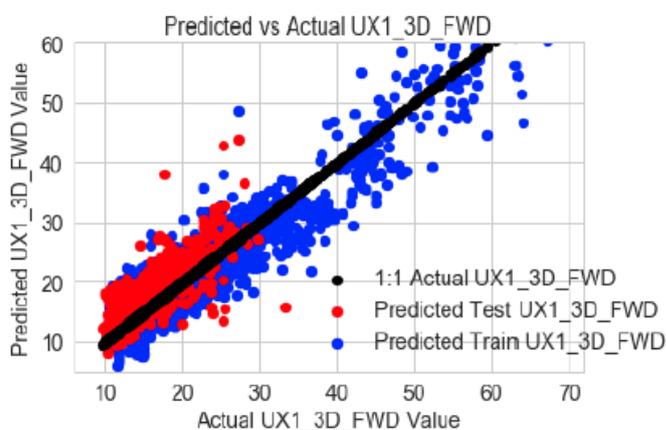
Iš bet kurio tikslo galima parodyti, kad pagrindiniai komponentai yra duomenų kovariacijos matricos savieji vektoriai. Pagrindiniai komponentai dažnai apskaičiuojami naudojant duomenų kovariacijos matricos savąjį skaidymą arba duomenų matricos vienaskaitos reikšmių skaidymą. Pagrindinių komponentų analizė yra pati paprasčiausia vektorinė daugiamatė analizė ir yra glaudžiai susijusi su faktorine analize.

Moksliniame tyrime, kurį atliko James, Slobodan ir bendraautorai (2018) buvo taip pat panaudota pagrindinių komponentų analizė VIX kintamumo indekso prognozavimui. Pirmiausia darbo pradžioje numatyto 71 įėjimo kintamojo duomenys normalizuojami. Toliau seka pagrindinių komponentų analizės pritaikymas, kuris sumažina duomenų rinkinio matmenis sukurdamas ortogonalinius faktorius. Savosios reikšmės ir savieji vektoriai naudojami sukurti įvesties kintamiesiems, kurie sudarys tiesinės regresijos modelį, kuris bus naudojamas šio tyrimo metu atliekamo bandymo ir mokymo duomenims įvertinti. Optimalus pagrindinių komponentų skaičius randamas skaičiuojant variantiškumą (dispersiją) ir mažiausią vidutinę kvadratinę paklaidą pridėdant vis po dar vieną komponentą. Tada įvertinama modelio kokybė [12].

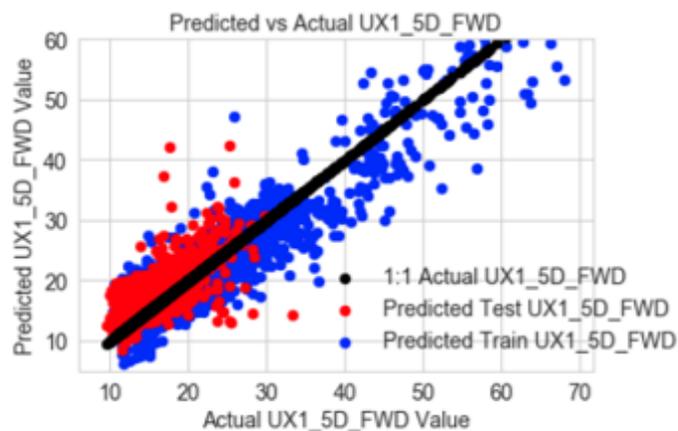
Duomenų kiekio sumažinimo pavyzdys naudojant pagrindinių komponentų analizę parodytas 9 paveiksle. Kairėje pusėje pateiktame grafike parodyta dispersijos priklausomybė nuo komponentų skaičiaus. Grafike matoma, kad dispersijos kitimas lėtėja didinant komponentų skaičių virš 10. Taip pat 9 paveiksle pateikta vidutinės kvadratinės paklaidos priklausomybė nuo komponentų skaičiaus (dešinėje). Čia mažiausia paklaida gaunama su 10 komponentų, todėl modelio duomenys nuo 71 įvesties parametro sumažinami iki 10 pagrindinių komponentų, kurie paaiškina daugiau nei 90% modelio dispersijos modeliui su 3 ir su 5 dienų prognoze į priekį [12].



9 pav. Kokybiniai modelio grafikai, panaudojant pagrindinių komponentų analizę [12]



10 pav. Modelio, skirto prognozuoti VIX vertę 3 dienas į priekį, sklaidos diagrama ir histograma [12]



11 pav. Modelio, skirto prognozuoti VIX vertę 5 dienas į priekį, sklaidos diagrama ir histograma [12]

10 ir 11 paveiksluose pateikta treniruočių bei testavimo išvesties pagrindinių komponentų analizės sklaidos diagramos atitinkamai 3 ir 5 dienas į priekį. Diagramose taip pat vaizduojama identiška tobulos treniruočių duomenų rinkinio išvesties diagrama, kaip etalonas. Sklaidos diagramos rodo tiesinį ryšį tiek bandymo, tiek treniruočių įverčiams lyginant su realia indekso verte. Be to, 10 ir 11 paveiksluose parodytos paklaidų histogramos, kur lyginami apskaičiuoti bandymo duomenys su

realiaisiais duomenų rinkiniais 3/5 dienas į priekį. Bandymo duomenų paklaidų histogramos yra iškreiptos kaip ir linijinės regresijos atveju.

5 lentelėje parodyta modelio kokybės rezultatų santrauka. Parametrų vertės buvo naudojamos intervale nuo 2006 metų liepos mėnesio iki 2018 metų liepos mėnesio. Moduliui buvo pateikti dviem būdais paskirstyti duomenys: 10 dalių kryžminis patvirtinimas ir tradicinis 75% mokymo /25 % testavimo duomenų padalijimas. Naudojant 10 dalių kryžminį patvirtinimą, testavimo duomenų vidutinė kvadratinė paklaida bei determinacijos koeficientas R^2 išlieka didesni nei tradicinio padalijimo [12].

5 lentelė. Pagrindinių komponentų analizės modelio kokybės parametrų vertės [12]

Išėjimas	Tradicinis 75% mokymui / 25% testavimui pasiskirstymas						10 dalių kryžminis patvirtinimas	
	R^2_{train}	R^2_{test}	MSE_{train}	MSE_{test}	ρ_{train}	ρ_{test}	R^2_{test}	MSE_{test}
3 dienų	0,86	0,22	11,80	19,38	0,93	0,70	0,339	29,10
5 dienų	0,84	0,03	13,77	21,93	0,92	0,61	0,334	30,39

2.3. Automatinis regresinis integruotas slankusis vidurkis

Automatinis regresinis integruotas slankusis vidurkis arba trumpai – ARIMA modeliai, teoriškai yra pati bendriausia modelių klasė skirta prognozuoti laiko eilutes, kurias galima padaryti „stacionariomis“ diferencijuojant, galbūt kartu su netiesinėmis transformacijomis, tokiomis kaip registravimas arba defliacija. Atsitiktinis kintamasis, kuris yra laiko eilutė, yra stacionarus, jei jo statistinės savybės laikui bėgant yra pastovios. Stacionari eilutė neturi tendencijos, jos svyravimai aplink vidurkį turi pastovią amplitudę ir svyruoja nuosekliai, t. y. jos trumpalaikiai atsitiktiniai laiko modeliai statistine prasme visada atrodo vienodi. Pastaroji sąlyga reiškia, kad jo autokoreliacijos (koreliacijos su ankstesniais nukrypimais nuo vidurkio) laikui bėgant išlieka pastovios, kad jo galios spektras laikui bėgant išlieka pastovus. Šios formos atsitiktinis kintamasis gali būti vertinamas kaip signalo ir triukšmo derinys, o signalas gali būti greito arba lėto vidurkio grįžtamasis modelis, sinusinis svyravimas, arba greitas ženklų kaitaliojimas, taip pat gali turėti sezoninį komponentą. ARIMA modelis gali būti vertinamas kaip „filtras“, kuris bando atskirti signalą nuo triukšmo, o signalas tada ekstrapoliuojamas į ateitį, kad būtų galima prognozuoti.

ARIMA prognozavimo lygtis stacionariai laiko eilutei yra tiesinė (t. y. regresijos tipo) lygtis, kurioje prognozės susideda iš priklausomo kintamojo vėlavimų ir (arba) prognozės paklaidų vėlavimų. Tai yra: numatoma Y vertė lygu konstanta ir (arba) vienos ar kelių naujausių Y reikšmių svertinė suma ir (arba) vienos ar kelių naujausių paklaidų reikšmių svertinė suma.

Jei prognozės susideda tik iš uždelstų Y reikšmių, tai yra grynas automatinės regresijos modelis, kuris yra ypatingas regresijos modelio atvejis ir kuris gali būti pritaikytas standartine regresijos programine įranga. Jei kai kurios prognozės yra paklaidų vėlavimai, tai tada ARIMA modelis nebūna tiesinės regresijos modeliu, nes nėra galimybės nurodyti paskutinio laikotarpio paklaidos kaip nepriklausomo kintamojo: paklaidos turi būti skaičiuojamos nuo – iki laikotarpio pagrindu, kai modelis pritaikomas prie duomenų. Techniniu požiūriu problema, naudojant vėluojančias paklaidas kaip prognozes, yra ta, kad modelio prognozės nėra tiesinės koeficientų funkcijos, nors tai yra tiesinės praeities duomenų funkcijos. Taigi, koeficientai ARIMA modeliuose, kuriuose yra uždelstų paklaidų, turi būti įvertinti netiesiniais optimizavimo metodais, o ne tiesiog sprendžiant lygčių sistemą.

Santrumpa ARIMA reiškia – Auto-Regressive Integrated Moving Average. Šis sutrumpinimas yra aprašomasis, fiksuojantis pagrindinius paties modelio aspektus. Trumpai tariant, jie yra:

- AR – Autoregresija. Modelis, kuriame naudojamas priklausomas ryšys tarp stebėjimo ir tam tikro skaičiaus vėluojančių stebėjimų;
- I: Integruota. Neapdorotų stebėjimų diferencijavimas (pavyzdžiui, stebėjimo atėmimas iš ankstesnio laiko etapo stebėjimo), kad laiko eilutė būtų stacionari;
- MA: Slenkamasis vidurkis. Modelis, kuris naudoja stebėjimo ir likutinės paklaidos priklausomybę iš slankiojo vidurkio modelio, taikomo vėluojantiems stebėjimams.

Kiekvienas iš šių komponentų yra aiškiai nurodytas modelyje kaip parametras. Naudojamas standartinis ARIMA(p, d, q) žymėjimas, kur parametrai pakeičiami sveikųjų skaičių reikšmėmis, kad būtų galima greitai nurodyti konkretų naudojamą ARIMA modelį.

ARIMA modelio parametrai apibrėžiami taip:

- p : į modelį įtrauktų vėlavimo stebėjimų skaičius, dar vadinamas vėlavimo tvarka;
- d : neapdorotų stebėjimų skirtumų skaičius, dar vadinamas skirtumo laipsniu;
- q : slankiojo vidurkio lango dydis, dar vadinamas slankiojo vidurkio tvarka.

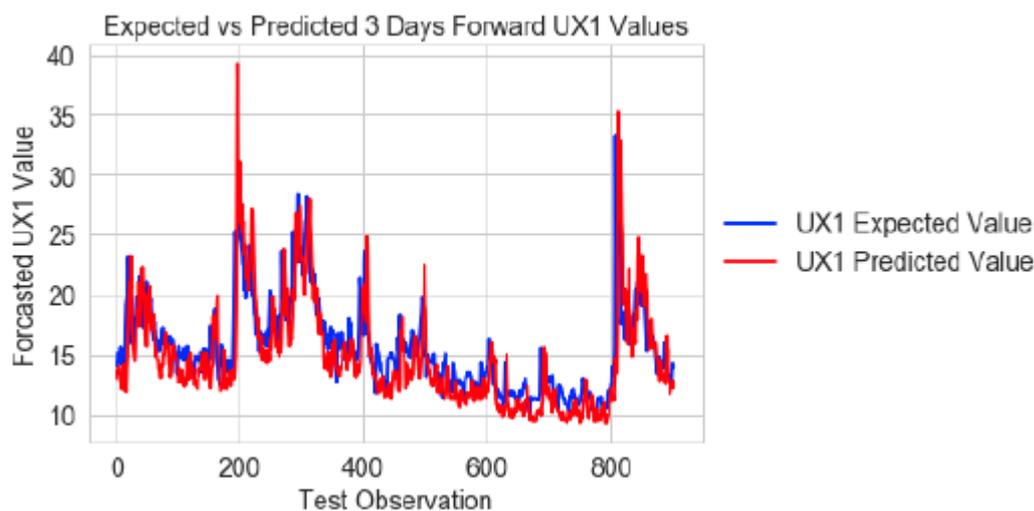
Bendroji prognozavimo lygtis yra tokia:

$$\hat{y}_t = \mu + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (18)$$

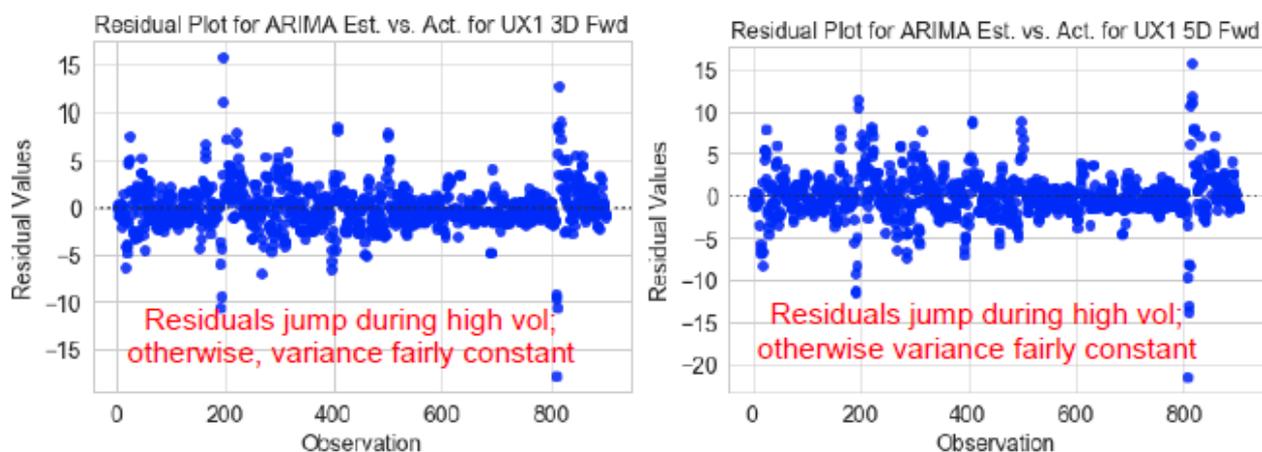
Čia slankiojo vidurkio parametrai θ yra apibrėžti taip, kad jų ženklai būtų neigiami lygtyje. Kai kas juos apibrėžia taip, kad vietoje jų būtų pliuso ženklai. Kai į lygtį įtraukiami tikrieji skaičiai, nekyla jokių dviprasmybių, tačiau svarbu atkreipti į tai dėmesį.

Tame pačiame tyrime James, Slobodan ir kiti (2018) panaudojo ir šį modelį VIX prognozavimui. ARIMA modelis pritaiko laiko eilutės duomenis, kad prognozuotų būsimus eilutės taškus. Šiame darbe tai taikoma vienmačiui atvejui, kai įvesties kintamasis yra atsako kintamasis, skirtas prognozuoti atsako kintamąjį ateityje [12].

Kad modelis veiktų, kintamasis turi turėti autokoreliaciją. Optimali automatinio regresinio integruoto slankaus vidurkio modelio delsa buvo lygi vienetui. 12 paveiksle pateiktas grafikas, kuriame parodytos faktinė ir apskaičiuota VIX vertė 3 dienos į priekį ARIMA modeliui. 13 paveiksle rodomos paklaidos, kurios šokinėja didelio nepastovumo judesių metu. Kitais atvejais dispersija paprastai yra nuoseklesnė tiek prognozuojamo VIX vertei 3, tiek 5 dienų į priekį diapazone.



12 pav. Modelio, skirto prognozuoti VIX vertę 3 dienas į priekį, sklaidos diagrama [12]



13 pav. Liekanų diagramos naudojant autoregresinį integruoto slankiojo vidurkio modelį [12]

6 lentelėje parodyta, kad ARIMA modelis turi gan aukštą determinacijos koeficientą (lyginant su ankščiau aptartais modeliais) ir mažą vidutinę kvadratinę paklaidą tiek 3, tiek 5 dienų prognozės modeliui [12].

6 lentelė. Automatinio regresinio integruoto slankiojo vidurkio modelio kokybės parametrų vertės [12]

Tradicinis 75% mokymui / 25% testavimui pasiskirstymas		
Išėjimas	R^2_{test}	MSE_{test}
3 dienų	0,52	6,44
5 dienų	0,36	8,63

2.4. Rekurentinis tinklas

Tipiniai neuroniniai tinklai buvo analizuojami 1.3.1 skyriuje, šiame skyriuje aptariami patobulinti neuroniniai tinklai ir jų taikymo pavyzdys. Modelį, kurį panaudojo James, Slobodan ir bendraautorai (2018) savo darbe yra patobulintas rekurentinis tinklas, kuris turi savotišką „atmintį“. Tradiciniuose rekurentiniuose tinkluose visi įėjimai ir išėjimai yra nepriklausomi, be ankstesnių lygių atminties. Tačiau šiame darbe naudojamas rekurentinis tinklas (angl. *Recurrent Neural Network*) turi „atmintį“, kad užfiksuotų informaciją apie tai, kas jau buvo apskaičiuota ankstesnėje laiko eilutėje. Trys iš

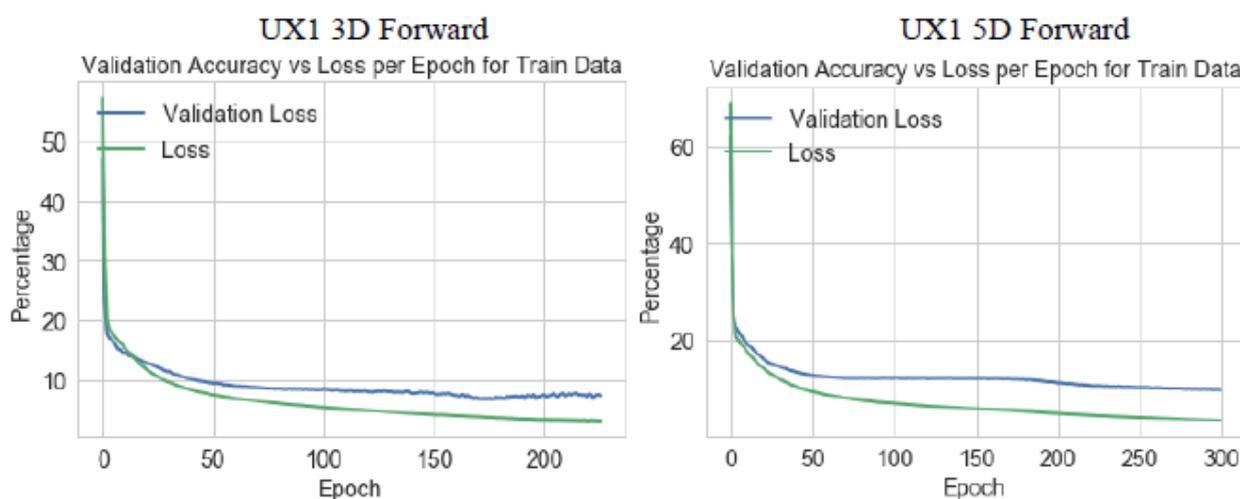
daugelio faktorių, kuriuos reikia optimizuoti šio tipo rekurentiniuose tinkluose yra epochų skaičius, partijos dydis ir iteracijų skaičius [12].

7 lentelėje apibrėžiami šie modelio įėjimai. Partijos dydžiui 44 darbo dienos yra optimalios rekurentiniam tinklui. Tai prasminga, nes rinkos paprastai turi trumpesnę atmintį.

7 lentelė. Įėjimų apibrėžimai rekurentiniam tinklui [12]

Įėjimo kintamasis	Apibrėžimas
1 epocha	Vienas visų treniruočių duomenų perdavimas pirmyn ir atgal
Partijos dydis	Bendras duomenų pavyzdžių skaičius vienoje partijoje vienam perėjimui pirmyn ir atgal
Iteracijos	Partijų arba ejų, reikalingų 1 epochai užbaigti, skaičius

Modelio kūrimui buvo panaudotas „GridSearchCV“ hiperparametrų optimizavimas rekurentiniam tinklui. Visi panaudoti šios funkcijos parametrai: „Adam“ optimizatorius; inicijavimo režimas yra vienodas (angl. *uniform*); nuostolių funkcija – vidutinė kvadratinė paklaida; aktyvinimo funkcija yra „relu“; neuronų skaičius kiekviename sluoksnyje – 150; metrinė išvestis yra tikslumas; epochų yra 300; partijos dydis yra 44 (maždaug dviejų mėnesių duomenys); iškritimo rodiklis yra 0, o mokymosi rodiklis yra 0,001. Naudojamas mažesnis sluoksnių ir neuronų skaičius dėl mažesnio duomenų rinkinio, kuriame yra tik 71 įėjimo kintamasis po 3009 įrašus kiekvienam. Paslėptų sluoksnių skaičius yra 1 su 10 neuronų su vienu išvesties sluoksniu mūsų atsako kintamajam. Tradicinio 75% mokymo /25 % testavimo duomenų padalijimo atveju treniruočių įvesties dydis yra 2256 x 71 [12].

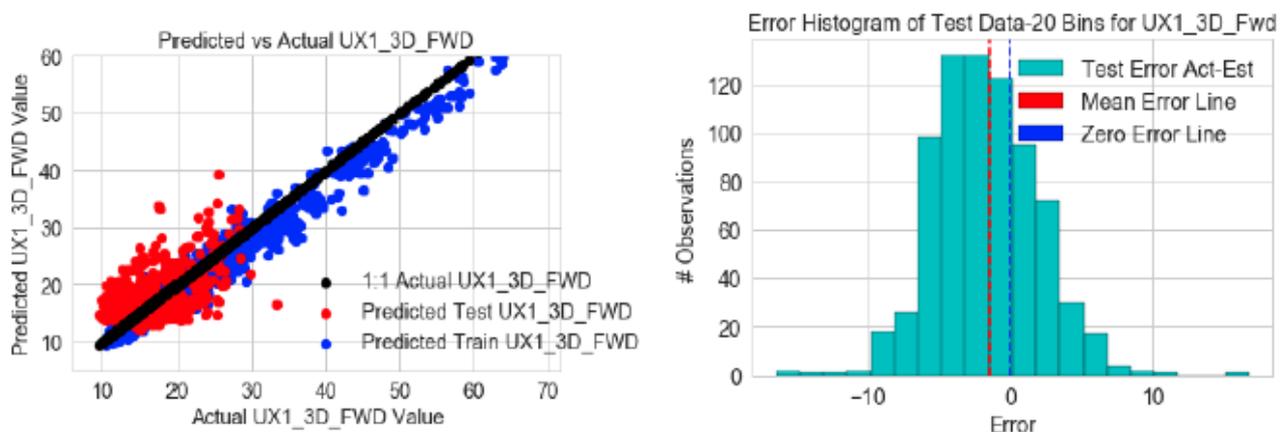


14 pav. Duomenų patvirtinimo tikslumas ir nuostoliai per epochą, 3/5 dienų į priekį moduliams [12]

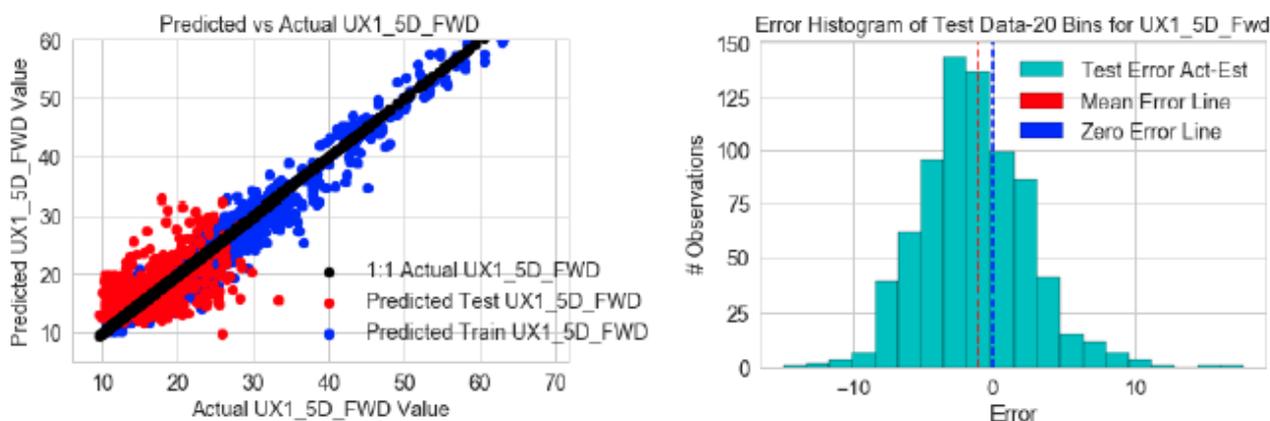
14 paveiksle parodytas treniruočių duomenų patvirtinimo tikslumas ir nuostoliai per epochą. Grafikuose matyti, kad po 200 epochų tiek 3, tiek ir 5 dienų modelių kokybė truputi pagerėja. Kuo mažesnis nuostolis, tuo geresnis modelis (nebent modelis buvo permokytas su mokymo duomenimis).

Nuostolis skaičiuojamas nuo mokymo ir patvirtinimo. Nuostoliai iš esmės parodo, kaip gerai modeliui sekasi su šiais dviem rinkiniais. Skirtingai nuo tikslumo, nuostoliai nėra matuojami procentais. Tai paklaidų, padarytų kiekvienam pavyzdžiui mokymo arba patvirtinimo rinkiniuose, suma [12].

15 ir 16 paveiksluose pateikta treniruočių bei testavimo išvesties rekurentinio tinklo modelio sklaidos diagramos atitinkamai 3 ir 5 dienoms į priekį. Diagramose taip pat vaizduojama identiška tobulos treniruočių duomenų rinkinio išvesties diagrama, kaip etalonas. Sklaidos diagramos rodo tiesinį ryšį tiek bandymo, tiek treniruočių įverčiams lyginant su realia indekso verte. Be to, 15 ir 16 paveiksluose parodytos paklaidų histogramos, kur lyginami apskaičiuoti bandymo duomenys su realiaisiais duomenų rinkiniais 3/5 dienas į priekį. Bandymo duomenų paklaidų histogramos yra artimesnės normaliajam pasiskirstymui, o tai rodo geresnę atitikimą bei įvertintų testo taškų sklaida yra arčiau etaloninės linijos, o tai rodo mažesnę dispersiją. Ta pati tendencija matoma 3 ir 5 dienų prognozės modeliams.



15 pav. Modelio, skirto prognozuoti VIX vertę 3 dienas į priekį, sklaidos diagrama ir histograma [12]



16 pav. Modelio, skirto prognozuoti VIX vertę 5 dienas į priekį, sklaidos diagrama ir histograma [12]

8 lentelėje parodyta 10 dalių kryžminio patvirtinimo ir tradicinio 75% mokymo /25 % testavimo duomenų padalijimo kokybės rezultatų suvestinė. Naudojant 10 dalių kryžminį patvirtinimą, bandymo duomenų vidutinė kvadratinė paklaida yra didesnė, o determinacijos koeficientas R^2 yra maždaug toks pat, kaip ir tradicinio padalijimo (3 dienų modeliui). Apskritai tiek tradicinio, tiek 10 dalių kryžminio patvirtinimo rezultatai yra labai geri, palyginti su iki šiol išanalizuotais modeliais [12].

8 lentelė. RNN modelio kokybės parametrų vertės [12]

Išėjimas	Tradicinis 75% mokymui / 25% testavimui pasiskirstymas						10 dalių kryžminis patvirtinimas	
	R^2_{train}	R^2_{test}	MSE_{train}	MSE_{test}	ρ_{train}	ρ_{test}	R^2_{test}	MSE_{test}
3 dienų	0,96	0,42	4,01	15,87	0,98	0,6	0,43	22,34
5 dienų	0,95	0,03	4,8	15,48	0,98	0,49	0,45	23,37

2.5. Gilaus mokymo modelis

Hemanth Kumar ir Basavaraj Patil (2018) savo moksliniame darbe tyrė gilaus mokymo metodų pritaikymą kintamumo indekso judėjimo krypties prognozavimui ir nustatė, kad šio tipo modeliai yra pranašesni prieš klasikinius ir kitus netiesinius modelius. Darbe buvo pateikta regresijos ir gilaus mokymosi ilgalaikės trumpalaikės atminties (angl. *Long short-term memory* (trump. LSTM)) metodais pagrįsto VIX tendencijų prognozavimo metodika. Ją sudaro duomenų bazė, kurioje yra modelio duomenys, toliau seka išankstinio apdorojimo blokas, skirtas pašalinti iškraipymus, trūkštumus ir triukšmingus duomenų rinkinius. Iš išvalytų duomenų apskaičiuojama pokyčio krypties vertė, kurią būsimas modelis turės nuprogozuoti iš VIX duomenų. Metodika taip pat susideda iš duomenų paruošimo ir modelio apmokymo naudojant gilaus mokymosi LSTM metodus prognozuojant mažėjimo ir augimo tendencijų tikslumą [13].

Modeliui kurti buvo panaudoti duomenys nuo 2008 m. sausio 1 d. iki 2018 m. vasario 2 dienos. Duomenis sudaro kintamumo indekso dienos uždarymo kainos vertės. Modeliui kurti numatyti duomenys transformuojami į matricos formatą, po 25 reikšmes kiekvienoje eilutėje. Eilutę sudaro VIX reikšmės visas 25 dienas atgal. Pavyzdžiui, pirmoji pirmos eilutės reikšmė antrąją dieną tampa antrąja verte, ir t. t. Naudojant tokio tipo duomenų išdėstymą, sumažinama paklaidų galimybė, nes tendencija priklauso nuo 25 verčių, o ne tik nuo šiandienos ir vakarykštės vertės [13].

Darbe buvo apmokytas modelis su LSTM tinklo 3 sluoksniais, įvesties, paslėpto ir išvesties sluoksniu. Įvesties sluoksnyje buvo 25 įvesties mazgai, 128 paslėpti mazgai ir 1 išvesties mazgas. Eksperimentiniai rezultatai buvo užfiksuoti iteracijomis nuo 250 iki 1500 intervalu 250. Iš 9 lentelėje pateiktų rezultatų matyti, jog LSTM modelis su regresija pagrįstu duomenų atrinkimo metodu pasiekė 71% krypties prognozės žemyn tikslumą, 77% – kilimo prognozės tikslumą, o bendras tikslumas – 74%. Didžiausias tikslumas buvo pasiektas naudojant LSTM metodą su 1500 iteracijų [13].

9 lentelė. Modelio rezultatai naudojant skirtingą iteracijų skaičių [13]

LSTM metodika (iteracijų skaičius)	Krypties žemyn prognozės tikslumas	Krypties aukštyn prognozės tikslumas	Bendras prognozės tikslumas
250	71,87%	72,80%	72,34%
500	68,31%	74,94%	71,70%
750	69,95%	73,06%	71,57%
1000	70,60%	72,05%	71,32%
1250	60,56%	78,23%	69,42%
1500	70,80%	76,56%	73,73%

Darbe taip pat buvo lyginamas gautas gilaus mokymo LSTM modelio veikimas su kitomis mašininio mokymosi metodais. Eksperimentai su regresija pagrįstais duomenų atrinkimo funkcija, naudojant

mašininio mokymosi metodus, tokius kaip sprendimų medis, regresija, atsitiktinis miškas, atraminių vektorių mašina ir rekurentiniai tinklai. Rezultatai, pateikti 10 lentelėje, rodo, kad gilaus mokymo LSTM technika pranoko visas kitas technikas.

10 lentelė. Rezultatų palyginimas su kitokio tipo mašininio mokymosi metodais [13]

Metodas	Krypties žemyn prognozės tikslumas	Krypties aukštyn prognozės tikslumas	Bendras prognozės tikslumas
Sprendimų medis	71,20%	64,41%	67,64%
Atsitiktinis miškas	68,40%	72,00%	70,20%
Gradiento padidėjimas	69,13%	71,09%	70,11%
Atraminių vektorių mašina	70,80%	72,00%	71,40%
Regresija	67,47%	79,42%	73,73%
Rekurentinis tinklas	69,60%	72,88%	71,32%
LSTM metodas	70,80%	76,56%	73,73%

Kitame moksliniame straipsnyje Osterrieder ir bendraautoriai (2018) išanalizavo gilaus mokymo modelio pritaikymą VIX indekso prognozavimui. Pasirinkta aprašomo modelio architektūra susideda iš vieno LSTM sluoksnio su 50 mazgų ir iš vieno išėjimo sluoksnio su vienu mazgu. Inicijuoti naudojamas „Glorot/Xavier“ iniciatorius, stačiakampis (angl. *orthogonal*) iniciatorius pasikartojantiems svoriams ir nulio poslinkio vektoriui. Aktyvinimo funkcijai naudojama hiperbolinė tangento funkcija – tanh. Modelyje nenaudojamas partijos normalizavimas, nes partijos dydis yra pakankamai mažas. Duomenys normalizuojami skaičiuojant kainų logaritminę gražą. Normalizavimui naudojamas atkritimo koeficientas, kurio vertė yra 0,1. Naudojama „ADAM“ optimizavimo priemonė, kurios pradinis mokymosi greitis yra 0,9 impulso mažėjimo hiperparametru ir 0,999 mastelio mažinimo hiperparametru [14].

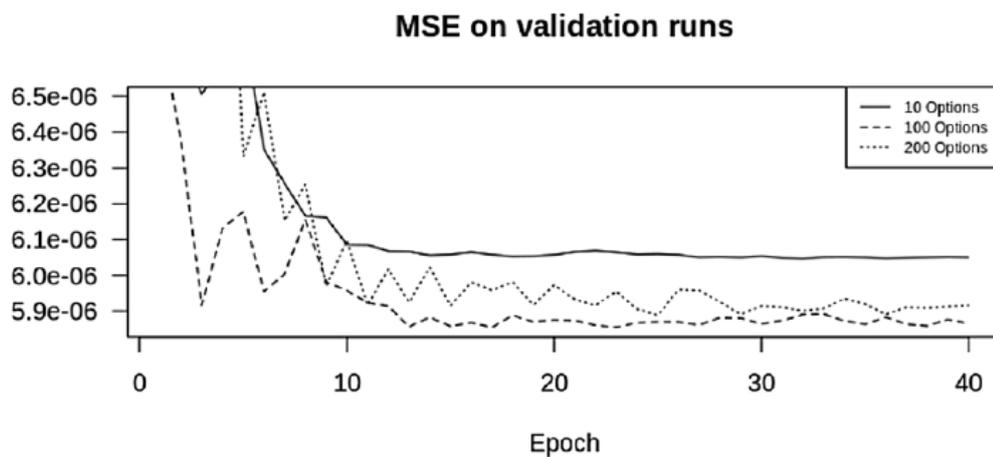
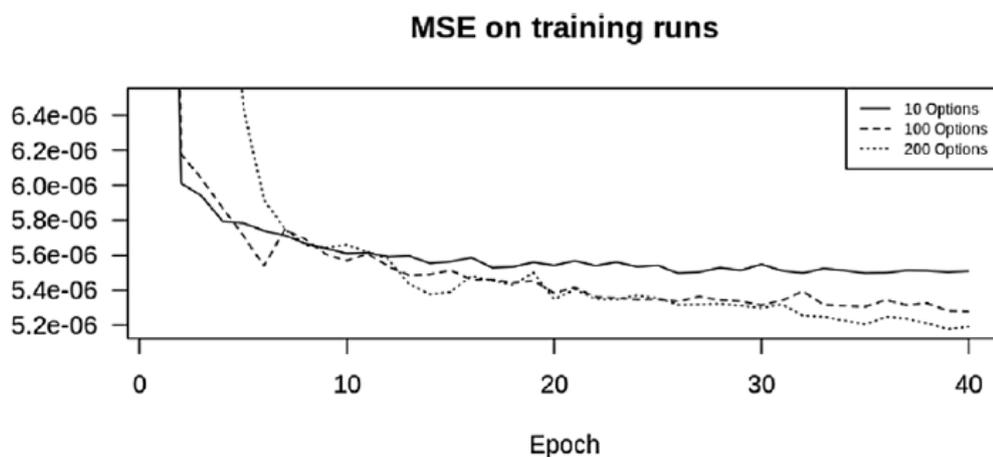
Duomenys modeliui gaunami tiesiogiai iš CBOE. Duomenų rinkinius sudaro SPX opcionai, taip pat VIX indeksas, VIX ateities sandoriai ir VIX opcionų sandoriai. Naudojami visų duomenų rinkinių dieniniai duomenys: S&P500 opcionams duomenys fiksuojami kas vieną minutę, pats VIX fiksuojamas kas 15 s, o VIX ateities sandoriams ir opcionams duomenys imami kas 1 s. Pasirinktas laikotarpis yra 2 mėnesiai – nuo 2018 m. sausio 2 dienos iki 2018 m. vasario 28 dienos, o dienos duomenys pateikiami prekybos dienomis nuo 8:31 iki 15:15 CST laiku [14].

Nuo 2018 m. sausio mėn. iki 2018 m. vasario mėn. gaunama vidutiniškai 500 galimų opcionų per dieną. Atliekant dienos analizę, apskaičiuojami tinkami opcionai nuo 08:30 (CDT) iki 09:00 (CDT) ir paliekamas šis opcionų rinkinys pastovus per visą dieną. Tada skaičiavimai prasideda 9:01 val. (CDT). Duomenys suskirstyti į dvi grupes: mokymo ir testavimo duomenų rinkiniai, kur sausio mėnuo naudojamas mokymui, o vasario mėnuo – modelio tikslumui tikrinti [14].

Įprastą dieną VIX replikacijai reikia apie 350 opcionų, kurį sudaro 250 pardavimo opcionų ir 100 pirkimo opcionų. Straipsnyje aprašytas modelis apmokomas atitinkamai 10, 100, 200 opcionų, vienodai padalintų tarp pardavimo ir pirkimo opcionų. Kaip jau buvo minėta mokymo rinkinys yra dieniniai duomenys 2018 m. sausio mėn., testavimo rinkinys yra 2018 m. vasario mėn., iš viso atitinkamai 1,68 milijono ir 1,52 milijono stebėjimų (šimtui opcionų) [14].

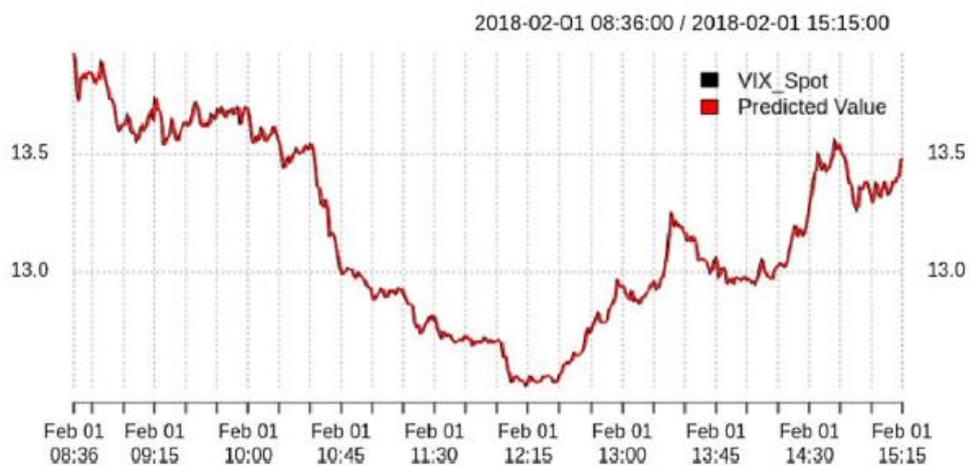
17 paveiksle parodyta prognozės vidutinė kvadratinė paklaida kaip iteracijų (angl. *epoch*) skaičiaus funkcija. Iš grafiko galima daryti išvadą, kad naudojant 100 parinkčių vietoje 10, prognozuojant VIX

vidutinė kvadratinė paklaida sumažėja maždaug 3%, o padvigubėjus opcionų skaičių iki 200 pagerėjimas neįreikiamas. Iš to galima daryti išvadą, kad prognozei naudoti visus 200 bei 100 variantų tikrai nereikia, užtenka ir 10, nes modelio tikslumo pagerėjimas yra tik nežymus. Taigi galimas metodikos supaprastinimas.



17 pav. Modelio vidutinės kvadratinės paklaidos pokytis praėjus nurodytam bandymų skaičiui [14]

Panaudojus 10 opcionų rinkinį VIX indekso prognozavimui, numatomos VIX taškų grąžos lyginamos su tikrosiomis vertėmis. Gauta vidutinė kvadratinė paklaida prognozei lygi $4,08 \cdot 10^{-5}$. O palyginimo grafikas pateiktas 18 paveiksle [14].



18 pav. Modelio prognozės reikšmės palyginimas su realia VIX indekso reikšme [14]

Iš grafiko matyti, kad tiek prognozuojama, tiek tikroji vertė beveik sutampa. Papildomam modelio įvertinimui buvo tikrinama, kaip dažnai modelis numato teisingą kainos judėjimo kryptį. Naudojant kategorinę kryžminę entropiją, kaip praradimo funkciją, opciono grąžos ženklą, kaip investies duomenis ir VIX grąžos ženklą kaip išvestį. Buvo gauta, kad teisinga judėjimo kryptis nustatyta 61,28% visų atvejų [14].

3. Modelių parinkimas ir eksperimentinių duomenų paruošimas

Atlikus literatūros analizę, nuspręsta, kad šalia numatyto gilaus mokymo modelio bus kuriami ARMA, ARMAX, NARMA ir NARMAX modeliai, kurie kaip klasikiniai metodai bus naudojami prognozavimo palyginimui su gilaus mokymo modeliu. Tokiu būdu bus lyginami gauti rezultatai naudojant tuos pačius įėjimus visiems modeliams ir bus galima spręsti, ar gilaus mokymo metodas yra pranašesnis prieš tradicinius modelius.

Kuriamų modelių tikslas bus prognozuoti sekančios dienos bei ateinančios savaitės VIX indekso vertę. Taigi modeliai pagal savo paskirtį galėtų būti naudojami spekuliantų, prekeivių (angl. *day trader*) bei investuotojų, kuriems prognozės indikuotų galimą akcijų judėjimo kryptį ir iš to galėtų priimti sprendimą pirkti, parduoti ar laikyti investuotus pinigus akcijų forma.

3.1. Eksperimentiniai duomenys ir jų paruošimas

Modeliavimui bus naudojami duomenys, kurie labiausiai susiję su ekonomine situacija pasaulyje bei indikuoja investuotojų emocijas. Šiuos duomenis sudarys akcijos ir indeksai: VIX, DOW JONES INDUSTRIAL AVERAGE, NASDAQ Composite, S&P500, auksas, sidabras ir nafta. Duomenys bus parsisiunčiami iš „Yahoo Finance“ internetinės svetainės, iš kurios gausime dieninius bei savaitinius duomenis prognozavimui. Numatoma, kad bus naudojami duomenys nuo 2007 metų sausio 1 dienos iki 2022 metų kovo 31 dienos. Planuojama, kad nuo 2007 iki 2020 metų galo duomenys bus naudojami modelių apmokymui. Testavimui ir modelių kokybės įvertinimui duomenis sudarys du duomenų rinkiniai: pirmąjį sudarys tik 2021 metų duomenys, antrąjį – 2021 metai ir 2022 metų pirmieji trys mėnesiai.

Duomenys modeliams iš „Yahoo Finance“ bus gaunami absoliutinėmis vertėmis. Kadangi yra planuojama prognozuoti kainos kitimą procentais, todėl visos vertės bus keičiamos į procentinius pokyčius. Esant situacijai, kad tam tikrą dieną (savaitę) duomenys nebuvo užfiksuoti biržose dėl techninių nesklandumų, bus naudojama prieš tai buvusios dienos (savaitės) vertė pokyčiui skaičiuoti.

3.2. Programinės įrangos parinkimas

Modeliams kurti nuspręsta naudoti MATLAB programinę įrangą su jau esamais programiniais paketais:

- Tradiciniams regresijos modeliams ARMA ir ARMAX modeliuoti bus naudojamas „regressionLearner“ paketas. ARMA modeliui bus naudojami tik VIX indekso duomenys. Tuo tarpu ARMAX modeliui bus naudojamos visos ankstesniame skyriuje išvardintų indeksų ir akcijų vertės.
- NARMA bei NARMAX modelių pagrindas yra paprastas rekurentinis tinklas. Šiems moduliams numatytas naudoti „nnstart“ programinis paketas. NARMA modeliui bus naudojami tik VIX indekso duomenys. Tuo tarpu NARMAX modeliui bus naudojamos visos ankstesniame skyriuje išvardintų indeksų ir akcijų vertės.
- Gilaus mokymo modeliui kurti numatyta naudoti „Deep learning“ programinius paketus. Modelis bus paremtas LSTM (angl. *long-short term memory*) metodika. Tai populiarus metodas naudojamas kuriant akcijų investuotojams skirtus modelius. Šiam modeliui bus naudojamos visos ankstesniame skyriuje išvardintų indeksų ir akcijų vertės.

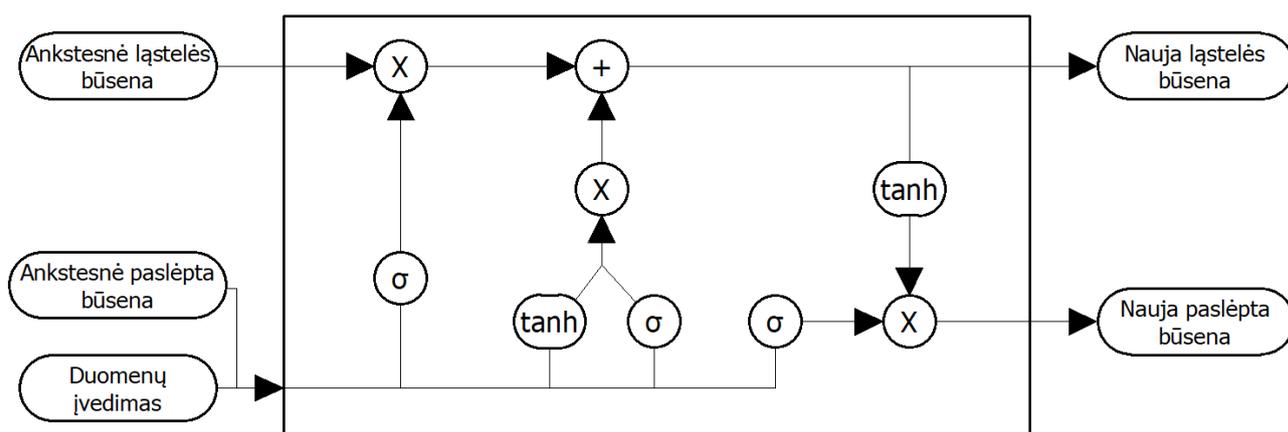
3.3. Ilgalaikė trumpalaikė atmintis arba LSTM modelis

LSTM tinklai buvo specialiai sukurti siekiant įveikti ilgalaikės priklausomybės problemą, su kuria susiduria pasikartojantys rekurentiniai tinklai (dėl nykstančio gradiento problemos). LSTM turi grįžtamąjį ryšį, todėl jie skiriasi nuo tradicinių grįžtamojo ryšio rekurentinių tinklų. Ši savybė leidžia LSTM apdoroti ištais duomenų sekas (pvz., laiko eilutes), nenagrinėjant kiekvieno sekos taško atskirai, o išsaugant naudingą informaciją apie ankstesnius sekos duomenis, kad būtų lengviau apdoroti naujus duomenų taškus. [15]

Bendrai LSTM išvestis tam tikru momentu priklauso nuo trijų dalykų (19 pav.):

- dabartinės ilgalaikės tinklo atminties, kitaip tariant ląstelės būsenos;
- išvesties ankstesniu laiko momentu – žinoma kaip ankstesnė paslėpta būseną;
- įvesties duomenų dabartiniu laiko momentu.

LSTM naudoja daugybę duomenų apdorojimo būdų, kitaip vadinamų vartais (angl. *gates*), kurie kontroliuoja, kaip informacija iš duomenų sekos patenka į tinklą, yra saugoma tinkle ir palieka jį. Tipiniame LSTM yra trys vartai: užmiršimo, įvesties ir išvesties vartai (angl. *forget, input and output*). Šie vartai gali būti laikomi filtrais ir kiekvienas yra traktuojamas kaip atskiras rekurentinis tinklas. Toliau apie kiekvieną iš jų.



19 pav. LSTM ląstelės struktūra [15]

Užmiršimo vartai pašalina nereikalingą informaciją prieš susijungiant su ląstelės būseną. Lygiai taip pat, kaip žmonės nusprendžia neatsižvelgti į tam tikrus įvykius ar informaciją, kuri nėra susijusi ar reikalinga sprendimui priimti. Naudojamos 2 įvestys – nauja informacija ir ankstesnės ląstelės išvestis. Šios įvestys paleidžiamos per sigmoidinius vartus, kad išfiltruotų nereikalingus duomenis, o tada daugybos būdu sujungia juos su ląstelės būseną.

Įvesties vartai prideda informaciją prie ląstelės būsenos. Žmogaus ekvivalentas – atsižvelgiama į naujai pateiktą informaciją šalia jau turimos informacijos. Panašiai kaip užmiršimo vartai, čia naudojami sigmoidiniai vartai, kad nustatyti, kiek informacijos reikia saugoti. Taip pat naudojama tanh funkcija, kad sukurti pridėtinės informacijos vektorius. Tada padauginami sigmoidinių vartų ir tanh funkcijų rezultatai ir pridedama naudinga informacija prie ląstelės būsenos.

Išėjimo vartai parenka naudingą informaciją pagal ląstelės būseną, ankstesnę ląstelės išvestį ir naujus duomenis. Tai daroma paimant ląstelės būseną, kai įvesties ir užmiršimo vartai susilieja, ir

paleidžiama per tanh funkciją, kad sukurti vektorių. Tada papildomai paimami nauji duomenys ir ankstesnę ląstelės išvestį ir praleidžiami per sigmoidinę funkciją, kad surasti, kokias reikšmes reikia išvesti. Tada šių dviejų operacijų rezultatai padauginami ir grąžinami kaip šios ląstelės išvestis.

Visas šis duomenų judėjimo per ląsteles procesas vyksta vienoje ląstelėje. Tačiau tikrame modelyje viename sluoksnyje gali būti bet koks ląstelių kiekis, taip pat modelio sluoksnių kiekis, prieš pasiekiant galutinę modelio išvadą. Modelis paleidžiamas dar, ir dar kartą, tol kol pasiekiamas tam tikras iteracijų skaičius, kada gaunamas tikslesnis atsakymas. Kuo didesnis tikslumas; tuo geresnė prognozė.

4. Modelių realizavimas ir eksperimentiniai tyrimai

Šiame skyriuje bus pristatomas kiekvieno modelio paruošimas bei modelio parametrai eksperimentams atlikti. Toliau bus pristatyti geriausi penki testavimo rezultatai kiekvienam modeliui atskirai. Didesnė dalis rezultatų lentelių forma pateikta prieduose.

Atliekant kokybinę modelių analizę, svarbiausias prognozavimo palyginimo kriterijus yra vidutinė absoliutinė paklaida (angl. *Mean Absolute Error*), kuri nusako modelio gebėjimą tiksliai prognozuoti kintamumo indekso VIX reikšmę sekančiam laikotarpiui (dienai arba savaitei). Tai padės palyginti skirtingų modelių tikslumą prognozuoti. Esant mažesnei paklaidai, prognozavimas bus tikslesnis. Gilaus mokymo LSTM modeliai bus testuojami kaip tiksliai sugeba prognozuoti sekančio laikotarpio pokyčio kryptį, nevertinant skaitinės vertės. Šis parametras nusakys, kiek procentų iš visų testavimo duomenų kryptį nustatyta teisingai. Šalia šio parametro bus skaičiuojamas krypties nuspėjimo kriterijus vertinant skaitinę vertę ir klasifikuojant trimis intervalais: prognozuojamo parametro vertė auga (daugiau nei 5% augimas), išlieka pastovi (prognozuojama VIX indekso vertė tarp -5% ir 5%) arba krenta (mažiau nei -5% augimas). Na ir galiausiai, gilaus mokymo LSTM modelių rezultatams palyginti bus naudojama hipotezė, kuri reiškia, kad sekančios dienos (savaitės) VIX indekso pokytis bus 0%. Šios hipotezės kokybiniai parametrai pateikti 11 lentelėje. Šioje ir toliau pateiktose lentelėse vidutinės kvadratinės paklaidos (toliau MSE) matavimo vienetai yra procentai kvadratu (%²), o vidutinės absoliutinės paklaidos (toliau MAE) matavimo vienetai yra procentai (%).

11 lentelė. Nulinės hipotezės kokybiniai rodikliai dviem testavimo intervalams

Intervalas	MSE (2021m.)	MAE (2021m.)	MSE (2021m.+2022m.)	MAE (2021m.+2022m.)
Dienos prognozė	89,9418	6,3485	84,5379	6,3508
Savaitės prognozė	324,5094	13,0870	323,4137	12,8933

4.1. Tiesinių regresijos ARMA / ARMAX modelių paruošimas ir rezultatai

Kaip jau buvo minėta trečiame skyriuje, šiems modeliams kurti pasitelktas MATLAB programinis paketas „*regressionLearner*“. Visiems šiuo programiniu paketu kurtiems modeliams buvo naudotas įvedamų duomenų kryžminis patvirtinimas penkiomis dalimis (angl. *cross-validation folds*). Tokiu būdu modelis pats įvertina, kurios duomenų rinkinio dalys užtikrina geriausius apmokyto modelio rezultatus, todėl tik iš atrinktų duomenų rinkinio dalių gaunamas galutinis modelis. „*RegressionLearner*“ programinis paketas, taip pat leido pasirinkti kokius modelio tipus galėsime apmokyti ir naudoti. Kad rasti tiksliausią modelį, buvo išbandyti visi tipai. Juos sudaro šešios grupės: linijiniai regresijos, regresijos medžių, atraminių vektorių mašinų, gausinių procesų regresijos, grupinio medžių (angl. *ensembles of trees*) ir neuroninių tinklų modelių tipai. Šie dar papildomai išsiskaido į 4-8 tipus. Visi šie modelių tipai eksperimentiniu metu išbandomi tiek su dieniniais, tiek su savaitiniais įėjimo duomenimis.

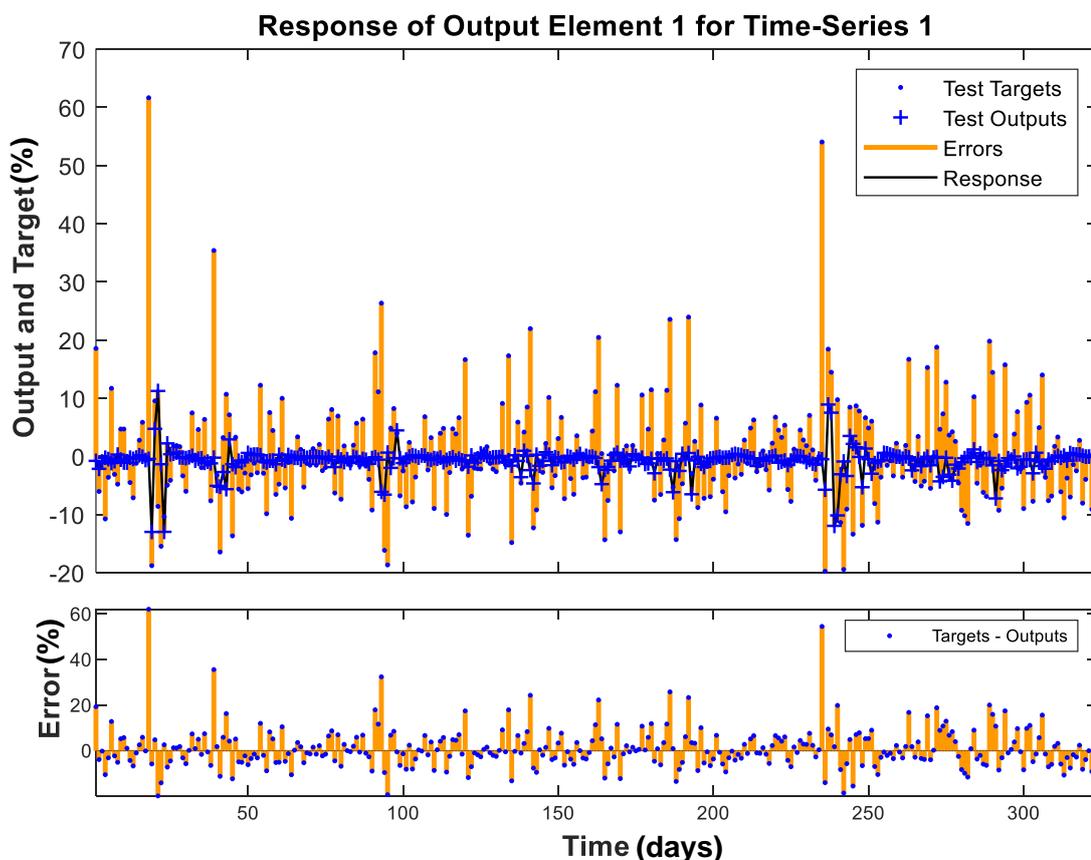
Visi tiesinių regresijos ARMA / ARMAX modelių rezultatai tiek lentelių tiek ir paveikslėlių forma pateikiami sekančiuose skyriuose.

4.1.1. Sekančios dienos VIX indekso prognozavimo, naudojant ARMA modelius, rezultatai

Visų sekančios dienos tiesinių regresijos ARMA modelių rezultatai pateikti priede Nr. 3. Geriausių testavimo rezultatų pasiekę penki modeliai pateikti 12 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 metų testavimo duomenis. Šiuo atveju geriausią rezultatą pasiekė „Cubic SVM“ modelio tipas, kur vidutinė absoliutinė paklaida, naudojant 2021 metų testavimo duomenis, gauta 6,0415 %, o papildomai kartu su 2022 metų trijų mėnesių įėjimo duomenimis – 6,1422 %. Tai tiksliausias modelis, ištestavus abiem laiko intervalais. Šio konkretaus modelio testavimo tikslo-prognozės ir paklaidų grafikai pateikti 20 paveiksle.

12 lentelė. Geriausių penkių ARMA modelių, skirtų sekančios dienos VIX indekso prognozei, rezultatai

Modelio tipas	Mokymas		Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
	MSE	MAE	MSE	MAE	MSE	MAE
Cubic SVM	76,091	5,4826	87,705	6,0415	83,754	6,1422
Coarse Gaussian SVM	65,697	5,2716	87,087	6,1117	83,098	6,1941
Medium Gaussian SVM	66,796	5,3550	88,246	6,1357	84,722	6,2243
Quadratic SVM	66,765	5,3155	88,276	6,1363	84,057	6,2171
Robust Linear	65,770	5,3005	87,591	6,1568	83,691	6,2461
Nulinės hipotezės kokybiniai rodikliai palyginimui			89,9418	6,3485	84,5379	6,3508



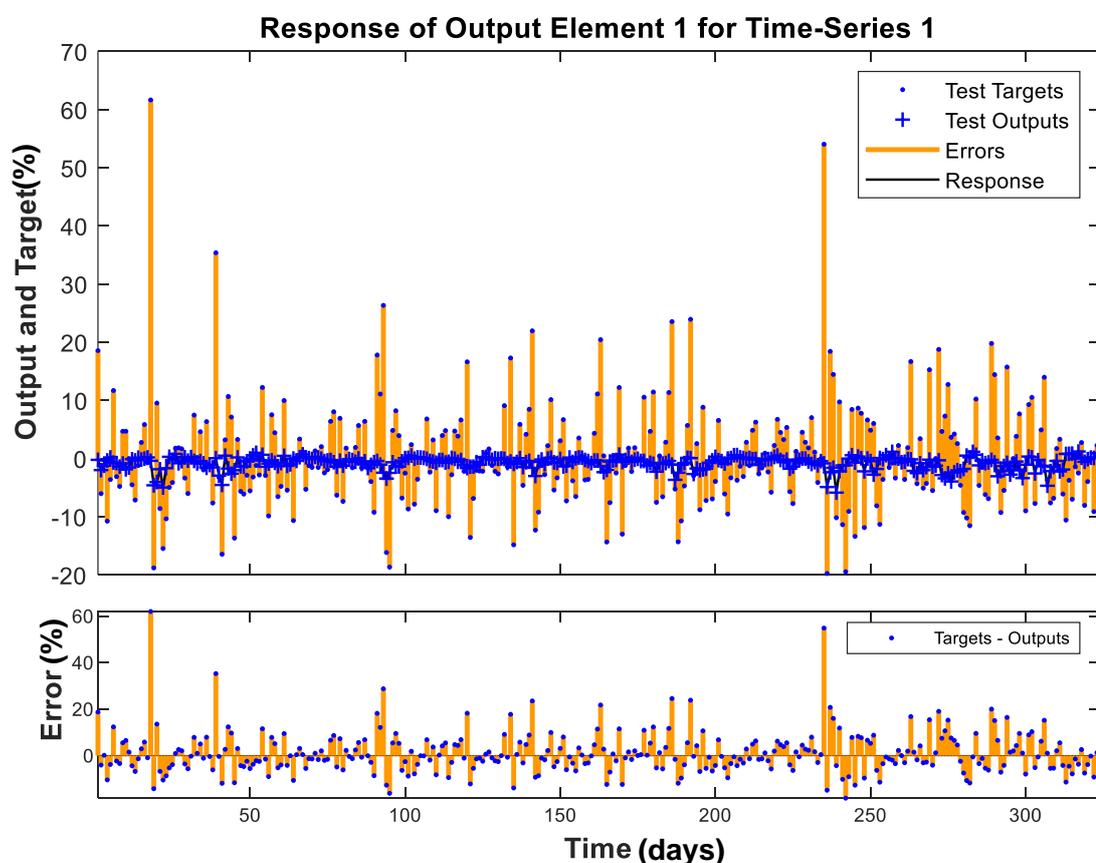
20 pav. ARMA („Cubic SVM“) modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai

4.1.2. Sekančios dienos VIX indekso prognozavimo, naudojant ARMAX modelius, rezultatai

Visų sekančios dienos tiesinių regresijos ARMAX modelių rezultatai pateikti priede Nr. 4. Geriausių testavimo rezultatų pasiekę penki modeliai pateikti 13 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 metų testavimo duomenis. Šiuo atveju geriausią rezultatą pasiekė „Coarse Gaussian SVM“ modelio tipas, kur vidutinė absoliutinė paklaida, naudojant 2021 metų testavimo duomenis, gauta 6,1249 %, o papildomai kartu su 2022 metų trijų mėnesių įėjimo duomenimis – 6,1864 %. Tai tiksliausias modelis, ištestavus abiem laiko intervalais. Šio konkretaus modelio testavimo tikslo-prognozės ir paklaidų grafikai pateikti 21 paveiksle.

13 lentelė. Geriausių penkių ARMAX modelių, skirtų sekančios dienos VIX indekso prognozei, rezultatai

Modelio tipas	Mokymas		Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
	MSE	MAE	MSE	MAE	MSE	MAE
Coarse Gaussian SVM	65,360	5,2704	87,401	6,1249	83,069	6,1864
Robust Linear	66,279	5,3249	87,591	6,1539	83,312	6,2201
Linear SVM	66,159	5,3113	88,289	6,1718	83,821	6,2237
Medium Gaussian SVM	66,594	5,3568	89,988	6,2127	85,178	6,2391
Boosted Trees	65,542	5,4256	86,095	6,2553	81,848	6,3031
Nulinės hipotezės kokybiniai rodikliai palyginimui			89,9418	6,3485	84,5379	6,3508



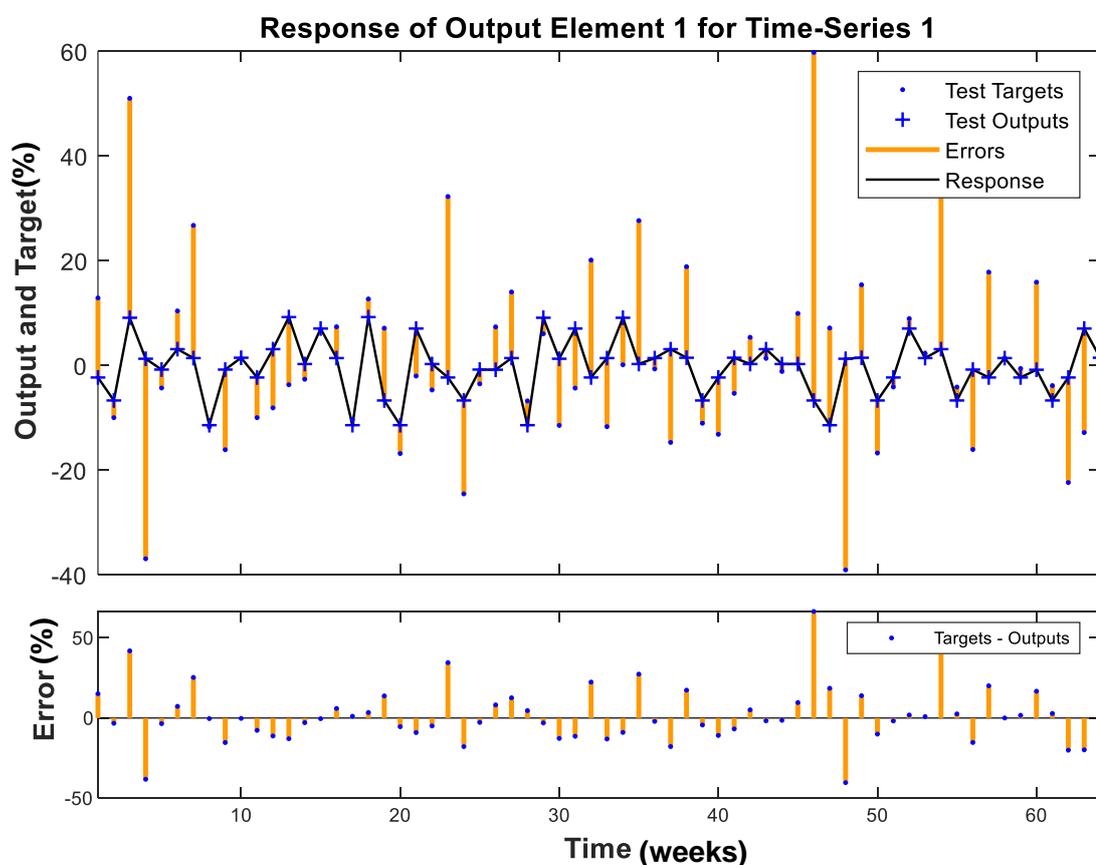
21 pav. ARMAX („Coarse Gaussian SVM“) modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai

4.1.3. Sekančios savaitės VIX indekso prognozavimo, naudojant ARMA modelius, rezultatai

Visų sekančios savaitės tiesinių regresijos ARMA modelių rezultatai pateikti priede Nr. 5. Geriausius testavimo rezultatus pasiekę penki modeliai pateikti 14 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 ir 2022 metų trijų mėnesių testavimo duomenimis. Šiuo atveju geriausią rezultatą pasiekė „Coarse Tree“ modelio tipas, kur vidutinė absoliutinė paklaida, naudojant 2021 metų testavimo duomenis, gauta 12,506 %, o papildomai kartu su 2022 metų trijų mėnesių įėjimo duomenimis – 12,339 %. Tai tiksliausias modelis, ištestavus abiem laiko intervalais. Šio konkretaus modelio testavimo tikslo-prognozės ir paklaidų grafikai pateikti 22 paveiksle.

14 lentelė. Geriausių penkių ARMA modelių, skirtų sekančios savaitės VIX indekso prognozei, rezultatai

Modelio tipas	Mokymas		Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
	MSE	MAE	MSE	MAE	MSE	MAE
Coarse Tree	314,36	12,405	320,37	12,506	317,41	12,339
Squared Exponential GPR	290,45	11,741	295,35	12,624	299,46	12,503
Rational Quadratic GPR	293,07	11,867	295,35	12,624	299,46	12,503
Matern 5/2GPR	291,27	11,787	295,33	12,662	299,42	12,511
Exponential GPR	292,61	11,837	296,27	12,686	300,41	12,516
Nulinės hipotezės kokybiniai rodikliai palyginimui			324,5094	13,0870	323,4137	12,8933



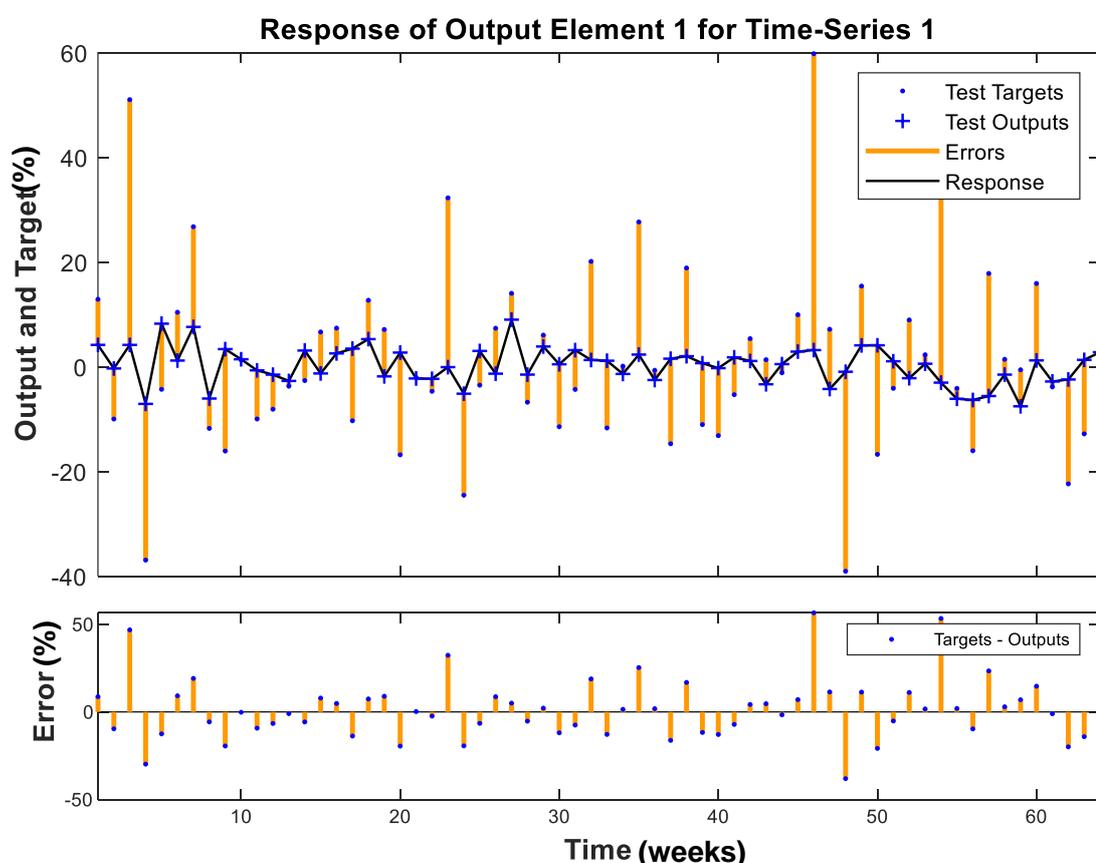
22 pav. ARMA („Coarse Tree“) modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai

4.1.4. Sekančios savaitės VIX indekso prognozavimo, naudojant ARMAX modelius, rezultatai

Visų sekančios savaitės tiesinių regresijos ARMAX modelių rezultatai pateikti priede Nr. 6. Geriausių testavimo rezultatų pasiekę penki modeliai pateikti 15 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 metų testavimo duomenis. Šiuo atveju geriausią rezultatą pasiekė „Linear“ modelio tipas, kur vidutinė absoliutinė paklaida, naudojant 2021 metų testavimo duomenis, gauta 12,437 %, o papildomai kartu su 2022 metų trijų mėnesių įėjimo duomenimis – 12,489 %. Tai tiksliausias modelis, ištestavus abiem laiko intervalais. Šio konkretaus modelio testavimo tikslo-prognozės ir paklaidų grafikai pateikti 23 paveiksle.

15 lentelė. Geriausių penkių ARMA modelių, skirtų sekančios savaitės VIX indekso prognozei, rezultatai

Modelio tipas	Mokymas		Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
	MSE	MAE	MSE	MAE	MSE	MAE
Linear	313,13	12,456	285,78	12,437	298,20	12,489
Squared Exponential GPR	288,15	11,808	295,12	12,809	298,65	12,547
Rational Quadratic GPR	288,96	11,828	295,12	12,809	298,65	12,547
Matern 5/2GPR	288,14	11,815	294,65	12,809	298,58	12,551
Exponential GPR	288,31	11,821	295	12,821	299,12	12,569
Nulinės hipotezės kokybiniai rodikliai palyginimui			324,5094	13,0870	323,4137	12,8933



23 pav. ARMAX („Linear“) modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai

4.2. NARMA / NARMAX modelių paruošimas ir rezultatai

Šiems modeliams kurti buvo numatytas MATLAB programinis paketas „nnstart“, tačiau pradėjus eksperimentą, pastebėta, kad skirtingų kombinacijų testavimui programinis paketas yra neefektyvus laiko atžvilgiu, dėl rankiniu būdu numatyto duomenų saugojimo. Taigi programinio paketo pagrindu buvo sukurtas programinis kodas modeliams sudaryti ir testuoti, kuris pateiktas 1 priede. Programinis kodas susideda iš rekurentinio tinklo modelio sukūrimo, treniravimo, testavimo su dviejų laiko intervalų duomenimis, grafikų sudarymo bei išsaugojimo ir galiausiai visų kokybinių duomenų išsaugojimo. Rekurentiniam tinklui apmokyti panaudotas Levenbergo-Markardo (angl. *Levenberg–Marquardt*) algoritmas. O treniravimui pasirinktas treniravimo duomenų paskirstymas 90% / 5% / 5% (mokymas / patvirtinimas / testavimas). Tačiau reikėtų paminėti, kad šie 5% testavimo rezultatai neįeina į galutinius rezultatus ir yra išskirta tik dėl programinės įrangos specifikos. Programinis kodas numatytas sudaryti visų įėjimo kintamųjų kombinacijų modelius, taip pat visus juos išbandyti naudojant nuo 1 iki 15 neuronų paslėptame sluoksnyje. Bendras visų modelių kombinacijų skaičius yra 960 (įskaitant NARMA ir NARMAX modelius).

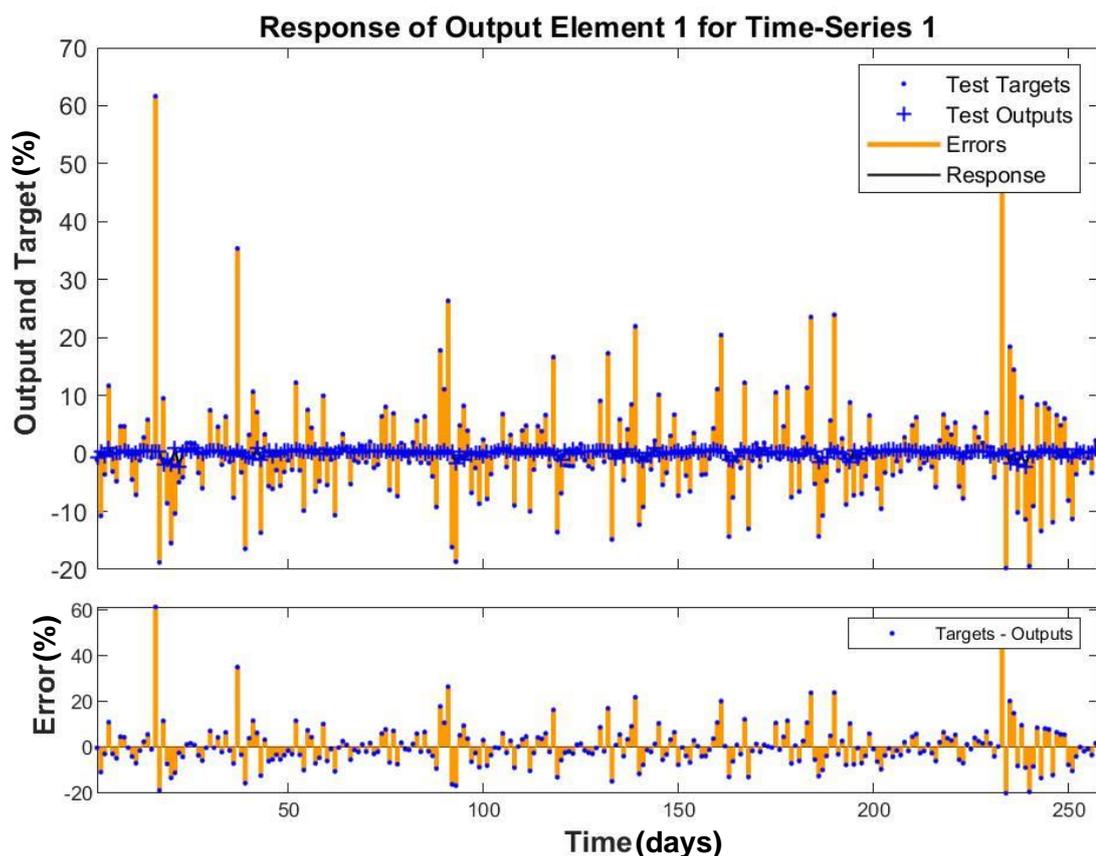
Šie modeliai eksperimentiniu metu išbandomi tiek su dieniniais, tiek su savaitiniais duomenimis. Visi NARMA / NARMAX modelių rezultatai tiek lentelių tiek ir paveikslėlių forma pateikiami sekančiuose skyriuose.

4.2.1. Sekančios dienos VIX indekso prognozavimo, naudojant NARMA modelius, rezultatai

Visų sekančios dienos NARMA modelių rezultatai pateikti priede Nr. 7. Geriausius testavimo rezultatus pasiekę penki modeliai pateikti 16 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 metų testavimo duomenis. Geriausią rezultatą naudojant 2021 metų testavimo duomenis pasiekė 4 neuronus turintis modelis, kurio vidutinė absoliutinė paklaida 6,2434 %. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausią rezultatą pasiekė 3 neuronus turintis NARMA modelis, kurio vidutinė absoliutinė paklaida 6,2746 %. 24 paveiksle pateikti NARMA modelio su 4 neuronais testavimo tikslo-prognozės ir paklaidų grafikai, naudojant 2021 metų testavimo duomenis.

16 lentelė. Geriausių penkių NARMA modelių, skirtų sekančios dienos VIX indekso prognozei, rezultatai

Įėjimai	Neuronų skaičius	Mokymas		Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
		MSE	MAE	MSE	MAE	MSE	MAE
VIX	4	64,4313	5,3499	87,4015	6,2434	82,4651	6,2774
VIX	3	65,2112	5,3292	89,5544	6,2568	84,3372	6,2746
VIX	5	63,9949	5,3713	88,0878	6,2798	83,2217	6,3267
VIX	12	64,5197	5,3215	89,4467	6,2965	84,0885	6,3144
VIX	7	63,3116	5,3513	91,3082	6,2968	85,9167	6,3405
Nulinės hipotezės kokybiniai rodikliai palyginimui				89,9418	6,3485	84,5379	6,3508



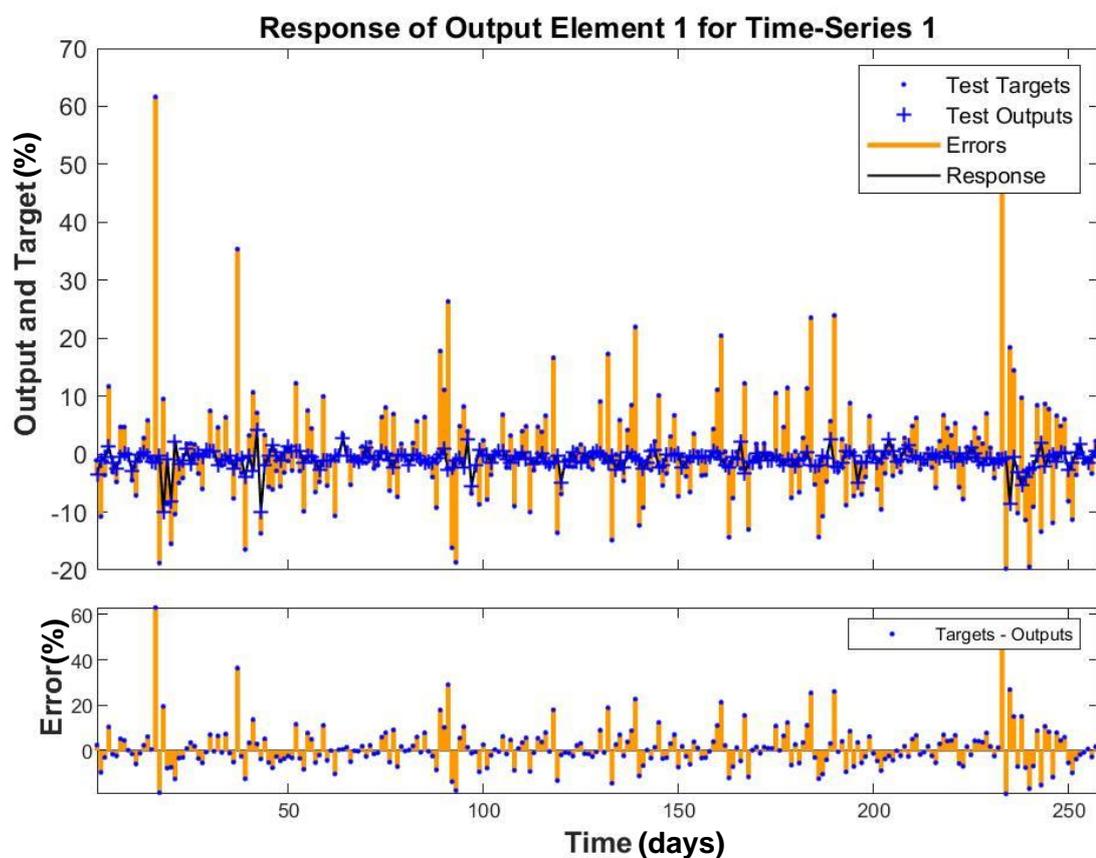
24 pav. NARMA modelio testavimo (2021m.) tikslo-prognozės ir paklaidų grafikai

4.2.2. Sekančios dienos VIX indekso prognozavimo, naudojant NARMAX modelius, rezultatai

Dvidešimt geriausių sekančios dienos NARMAX modelių rezultatai pateikti priede Nr. 8. Geriausių testavimo rezultatus pasiekę penki modeliai pateikti 17 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 metų testavimo duomenis. Geriausią rezultatą naudojant VIX, DJI ir naftos modelio įėjimus, bei 2021 metų testavimo duomenis pasiekė 15 neuronų turintis modelis, kurio vidutinė absoliutinė paklaida 6,1743 %. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausią rezultatą pasiekė VIX, S&P500, NASDAQ, aukso, sidabro ir naftos modelio įėjimus bei 3 neuronus turintis NARMAX modelis, kurio vidutinė absoliutinė paklaida – 6,1946 %. 25 paveiksle pateikti modelio su VIX, DJI ir naftos įėjimais ir 15 neuronų testavimo tikslo-prognozės ir paklaidų grafikai, naudojant 2021 metų testavimo duomenis.

17 lentelė. Geriausių penkių NARMAX modelių, skirtų sekančios dienos VIX indekso prognozei, rezultatai

Modelio įėjimai	Neuronų skaičius	Mokymas		Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
		MSE	MAE	MSE	MAE	MSE	MAE
VIX+DJI+OIL	15	64,5635	5,2974	91,4344	6,1743	85,8354	6,2221
VIX+SP500+OIL	10	66,5061	5,3028	87,8527	6,1753	83,0658	6,2087
VIX+SP500+DJI+OIL	9	62,2270	5,2695	89,0106	6,1760	83,6677	6,2153
VIX+SP500+DJI+SILVER	13	63,8463	5,3667	88,0292	6,1853	83,0134	6,2279
VIX+DJI+NASDAQ	5	64,6091	5,3117	88,9383	6,1932	83,6421	6,2300
Nulinės hipotezės kokybiniai rodikliai palyginimui				89,9418	6,3485	84,5379	6,3508



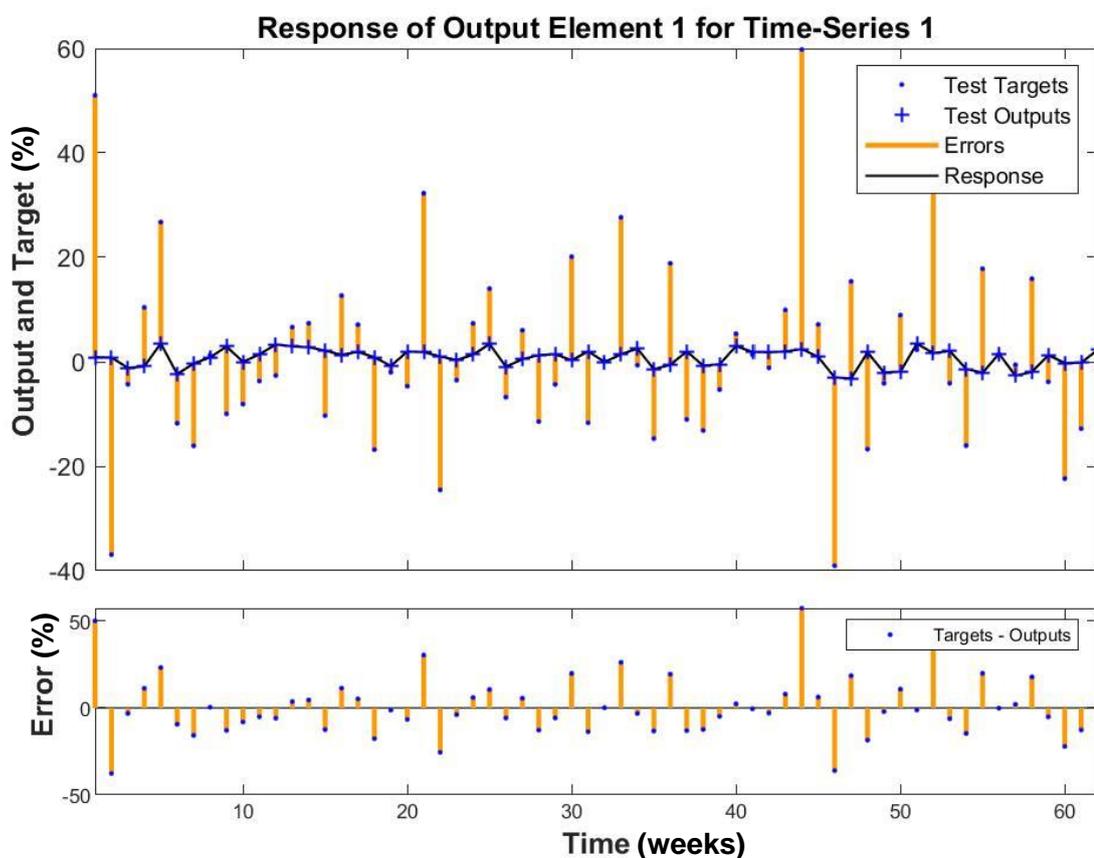
25 pav. NARMAX modelio testavimo (2021m.) tikslo-prognozės ir paklaidų grafikai

4.2.3. Sekančios savaitės VIX indekso prognozavimo, naudojant NARMA modelius, rezultatai

Visų sekančios savaitės NARMA modelių rezultatai pateikti priede Nr. 9. Geriausių testavimo rezultatus pasiekę penki modeliai pateikti 18 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 ir 2022 metų trijų mėnesių testavimo duomenimis. Šiuo atveju geriausių rezultatą pasiekė 1 neuroną turintis modelis, kur vidutinė absoliutinė paklaida naudojant 2021 metų testavimo duomenis gauta 12,8909 %, o papildomai kartu su 2022 metų trijų mėnesių įėjimo duomenimis – 12,8497 %. Tai tiksliausias modelis, ištestavus abiem laiko intervalais. 26 paveiksle pateikti NARMA modelio su 1 neuronu testavimo tikslo-prognozės ir paklaidų grafikai, naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis.

18 lentelė. Geriausių penkių NARMA modelių, skirtų sekančios savaitės VIX indekso prognozei, rezultatai

Įėjimai	Neuronų skaičius	Mokymas		Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
		MSE	MAE	MSE	MAE	MSE	MAE
VIX	1	290,4974	11,7633	317,1947	12,8909	317,6556	12,8497
VIX	6	285,2703	11,5043	330,9855	13,0484	336,6936	12,9527
VIX	3	280,3666	11,5586	333,3689	13,1118	329,5282	13,1277
VIX	2	291,3957	11,8581	327,7258	13,2854	325,8677	13,1492
VIX	10	285,2729	11,9487	336,5265	13,6809	331,4147	13,3095
Nulinės hipotezės kokybiniai rodikliai palyginimui				324,5094	13,0870	323,4137	12,8933



26 pav. NARMA modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai

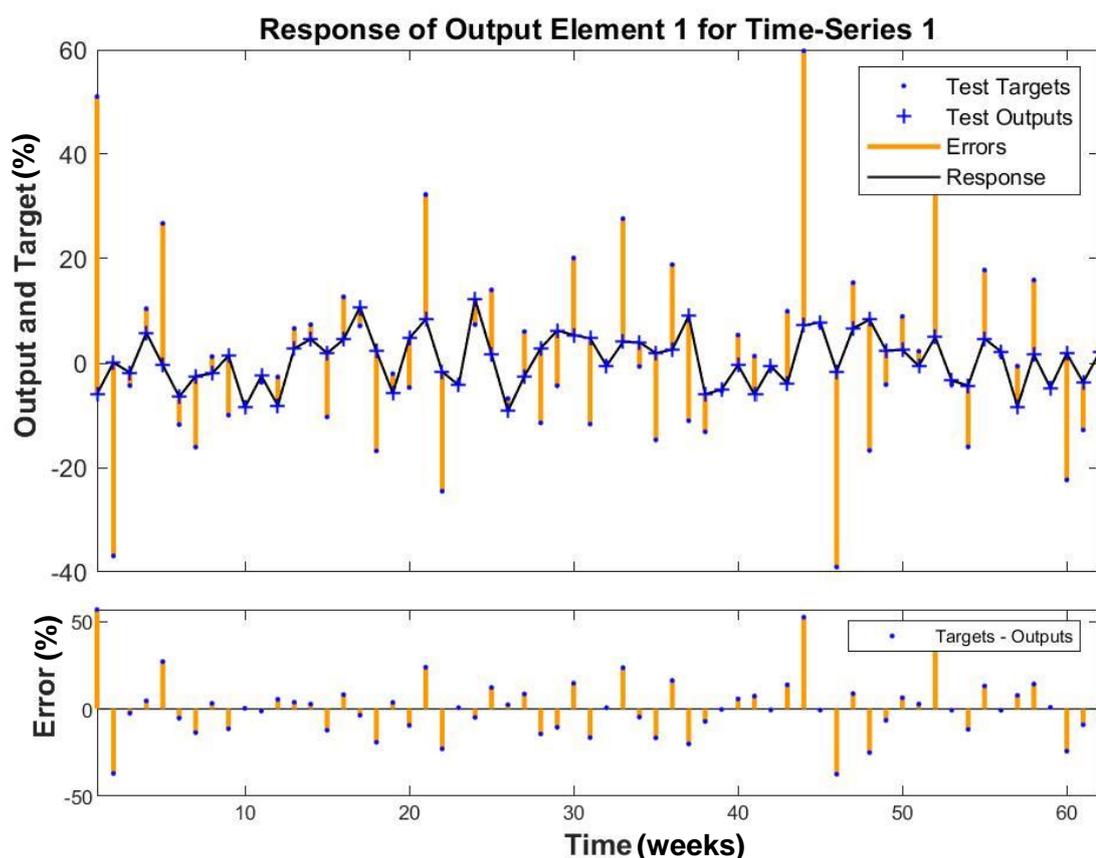
4.2.4. Sekančios savaitės VIX indekso prognozavimo, naudojant NARMAX modelius, rezultatai

Dvidešimt geriausių sekančios savaitės NARMAX modelių rezultatai pateikti priede Nr. 10. Geriausius testavimo rezultatus pasiekę penki modeliai pateikti 19 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 ir 2022 metų trijų mėnesių testavimo duomenimis. Geriausių rezultatą naudojant VIX ir NASDAQ modelio įėjimus, bei 2021 metų testavimo duomenis pasiekė 11 neuronų turintis modelis, kurio vidutinė absoliutinė paklaida 12,2115 %. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausių rezultatą pasiekė VIX, DJI, NASDAQ, aukso, sidabro ir naftos modelio įėjimus bei 10

neuronų turintis NARMAX modelis, kurio vidutinė absoliutinė paklaida 12,1392 %. 27 paveiksle pateikti modelio su VIX, DJI, NASDAQ, aukso, sidabro ir naftos įėjimais ir 10 neuronų testavimo tikslo-prognozės ir paklaidų grafikai, naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis.

19 lentelė. Geriausių penkių NARMAX modelių, skirtų sekančios savaitės VIX indekso prognozei, rezultatai

Modelio įėjimai	Neuronų skaičius	Mokymas		Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
		MSE	MAE	MSE	MAE	MSE	MAE
VIX+DJI+NASDAQ+GOLD+SILVER+OIL	10	308,4734	12,3308	314,6637	12,4887	302,9675	12,1392
VIX+NASDAQ+OIL	4	281,6600	11,6142	311,4919	12,2771	311,5493	12,1584
VIX+SP500+GOLD	4	295,2214	11,7513	321,6171	12,5770	320,7042	12,4355
VIX+SP500+NASDAQ+GOLD+SILVER+OIL	12	291,2242	12,2091	302,9229	12,3638	302,8917	12,4637
VIX+NASDAQ	4	279,7374	11,7102	314,8589	12,5854	311,1953	12,4829
Nulinės hipotezės kokybiniai rodikliai palyginimui				324,5094	13,0870	323,4137	12,8933



27 pav. NARMAX modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai

4.3. Gilaus mokymo LSTM modelių paruošimas ir rezultatai

Šiems modeliams kurti, buvo naudotas MATLAB programinis paketas „Deep learning“, kuris buvo aprašomas programinės įrangos dokumentacijoje (skyrelis „Long Short-Term Memory Networks“). Šio pavyzdžio pagrindu buvo sukurtas programinis kodas modeliams sudaryti ir testuoti (pateikta 2 priede). Modelio struktūrą sudaro keturi sluoksniai: „Sequence Input Layer“, „LSTM layer“, „Fully Connected Layer“ ir „Regression Layer“. Modelio apmokymui buvo naudojamas „Adam“ optimizatorius ir treniravimo duomenų maišymas prieš kiekvieną iteraciją. Atliekant eksperimentinius tyrimus buvo nuspręsta, iširti plačią kombinacijų erdvę šio tipo modeliams, todėl programiniame kode numatytos visų įėjimo kintamųjų, LSTM sluoksnių nuo 30 iki 240 skaičiaus žingsniu 30 ir iteracijų nuo 10 iki 1500 įvairiais žingsniais kombinacijos. Bendrai dieninėms (savaitinėms) prognozėms sudaromi 8704 modeliai. Iš jų 136 modeliai prognozuoja VIX indekso pokytį naudojant tik VIX įėjimo istorinius pokyčių duomenis, o likę 8568 modeliai naudoja VIX ir kitų indeksų įėjimo duomenų kombinacijas. Programinis kodas susideda iš gilaus mokymo LSTM modelio sukūrimo, treniravimo, testavimo su dvejų laiko intervalų duomenimis, grafikų sudarymo bei išsaugojimo ir galiausiai visų kokybinių duomenų išsaugojimo. Procesas vykdomas automatiškai sudarant visas numatytas modelio kombinacijas.

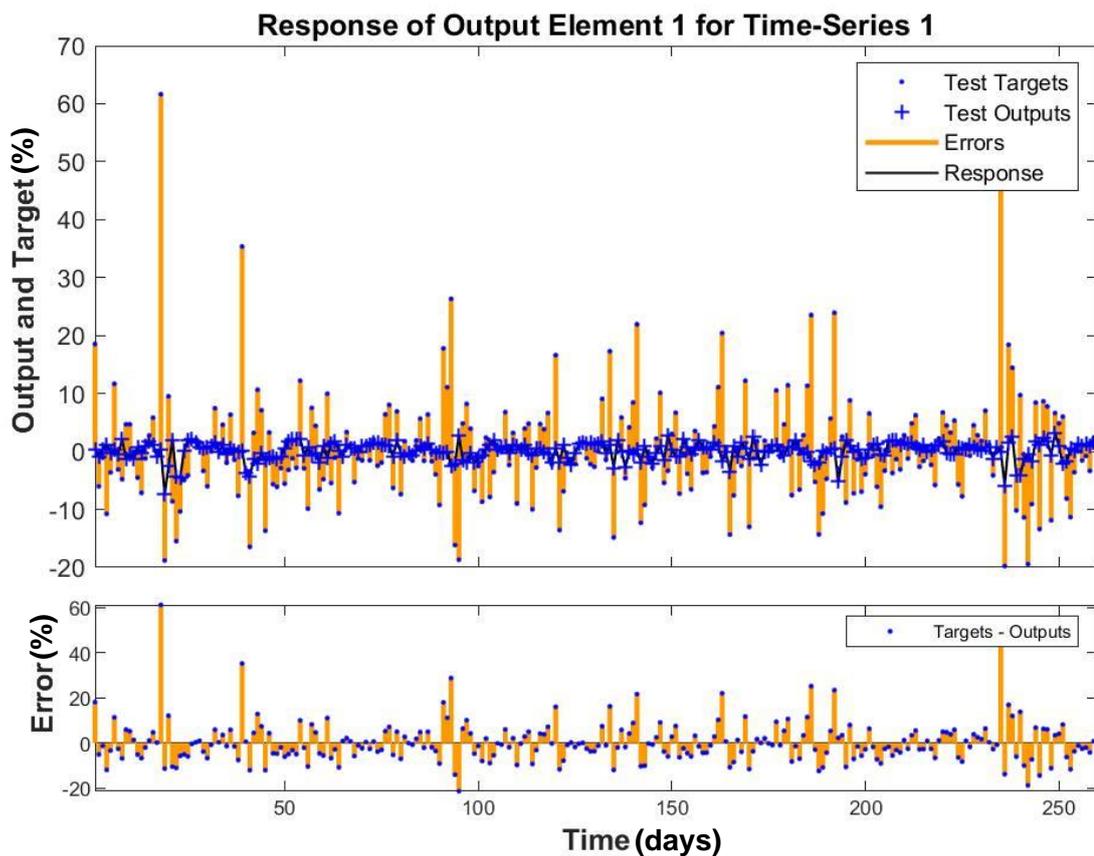
Šie modeliai eksperimentų metu išbandomi tiek su dieniniais, tiek su savaitiniais duomenimis. Visi gilaus mokymo LSTM modelių rezultatai tiek lentelių, tiek ir paveikslėlių forma pateikiami sekančiuose skyriuose.

4.3.1. Sekančios dienos VIX indekso prognozavimo, naudojant LSTM modelius ir tik VIX įėjimus, rezultatai

Dvidešimt geriausių sekančios dienos gilaus mokymo LSTM modelių, kuriems naudojami tik VIX įėjimo duomenys rezultatai pateikti priede Nr. 11. Geriausius testavimo rezultatus pasiekę penki modeliai pateikti 20 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 metų testavimo duomenis. Geriausią rezultatą naudojant 2021 metų testavimo duomenis pasiekė 210 LSTM sluoksnius ir 30 iteracijų turintis modelis, kurio vidutinė absoliutinė paklaida 6,2123 %. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausią rezultatą pasiekė 120 LSTM sluoksnius ir 40 iteracijų turintis modelis, kurio vidutinė absoliutinė paklaida 6,2777 %. 28 paveiksle pateikti gilaus mokymo LSTM modelio su 210 LSTM sluoksniais ir 30 iteracijomis testavimo tikslo-prognozės ir paklaidų grafikai, naudojant 2021 metų testavimo duomenis.

20 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios dienos VIX indekso prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Mokymo MSE	Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
				MSE	MAE	MSE	MAE
VIX	210	30	61,9142	86,2116	6,2123	82,1823	6,2796
VIX	210	40	61,2883	86,5973	6,2147	82,7878	6,2906
VIX	240	40	61,0526	86,1844	6,2236	82,3698	6,2942
VIX	240	30	61,9763	86,6852	6,2362	82,4660	6,2920
VIX	120	40	61,7378	86,7523	6,2393	82,3301	6,2777
Nulinės hipotezės kokybiniai rodikliai palyginimui				89,9418	6,3485	84,5379	6,3508



28 pav. LSTM modelio testavimo (2021m.) tikslo-prognozės ir paklaidų grafikai

Geriausius pokyčio krypties prognozės rezultatus pasiekę penki modeliai pateikti 21 lentelėje. Duomenys pateikti pagal 2021 metų testavimo duomenis, kadangi gautas didžiausias teisingos prognozės procentas. Geriausią rezultatą naudojant 2021 metų testavimo duomenis pasiekė 30 LSTM sluoksnius ir 150 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 57,3077 % pokyčio kryptį. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausią rezultatą pasiekė 120 LSTM sluoksnius ir 1500 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 55,5556 % pokyčio kryptį.

21 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių krypties prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Pokyčių krypties prognozė, % (2021m.)	Pokyčių krypties prognozė, % (2021m.+2022m.)
VIX	30	150	57,3077	54,6296
VIX	120	1500	54,6154	55,5556
VIX	30	1000	54,2308	55,2469
VIX	180	250	54,2308	54,0123
VIX	30	200	54,2308	52,4691

Geriausius pokyčio intervalo prognozės rezultatus pasiekę penki modeliai pateikti 22 lentelėje. Duomenys pateikti pagal 2021 metų testavimo duomenis, kadangi gautas didžiausias teisingos prognozės procentas. Geriausią rezultatą naudojant 2021 metų testavimo duomenis pasiekė 240 LSTM sluoksnius ir 300 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo

58,0769 % pokyčio intervalų. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausią rezultatą pasiekė 30 LSTM sluoksnius ir 500 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 55,5556 % pokyčio intervalų.

22 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių intervalo prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Pokyčių intervalo prognozė, % (2021m.)	Pokyčių intervalo prognozė, % (2021m.+2022m.)
VIX	240	300	58,0769	55,2469
VIX	90	350	58,0769	54,9383
VIX	30	500	57,6923	55,5556
VIX	90	200	57,3077	54,3210
VIX	180	100	56,9231	55,2469

Modelių pokyčių kryptių ir intervalų prognozavimo apžvalga pateikta 23 lentelėje, kurioje nurodyta kiek procentų visų modelių, naudojančių VIX indekso duomenis prognozavimui, nuspėjo prognozuojamo indekso pokyčio kryptį teisingai, nevertinant skaitinės vertės. Taip pat pateikta kiek procentų modelių, naudojančių VIX indekso duomenis prognozavimui, nuspėjo prognozuojamo indekso pokyčio intervalą teisingai. Intervalo prognozę papildomai charakterizuoja reikšmingų intervalų rezultatai, kurie parodo kiek procentų modelių peržengė 30 % teisingos prognozės reikšmingiems intervalams, kurie gali būti indikacija investuotojui.

23 lentelė. LSTM modelių (su VIX indekso modelio įėjimais) pokyčių kryptių ir pokyčių intervalų prognozės apžvalga

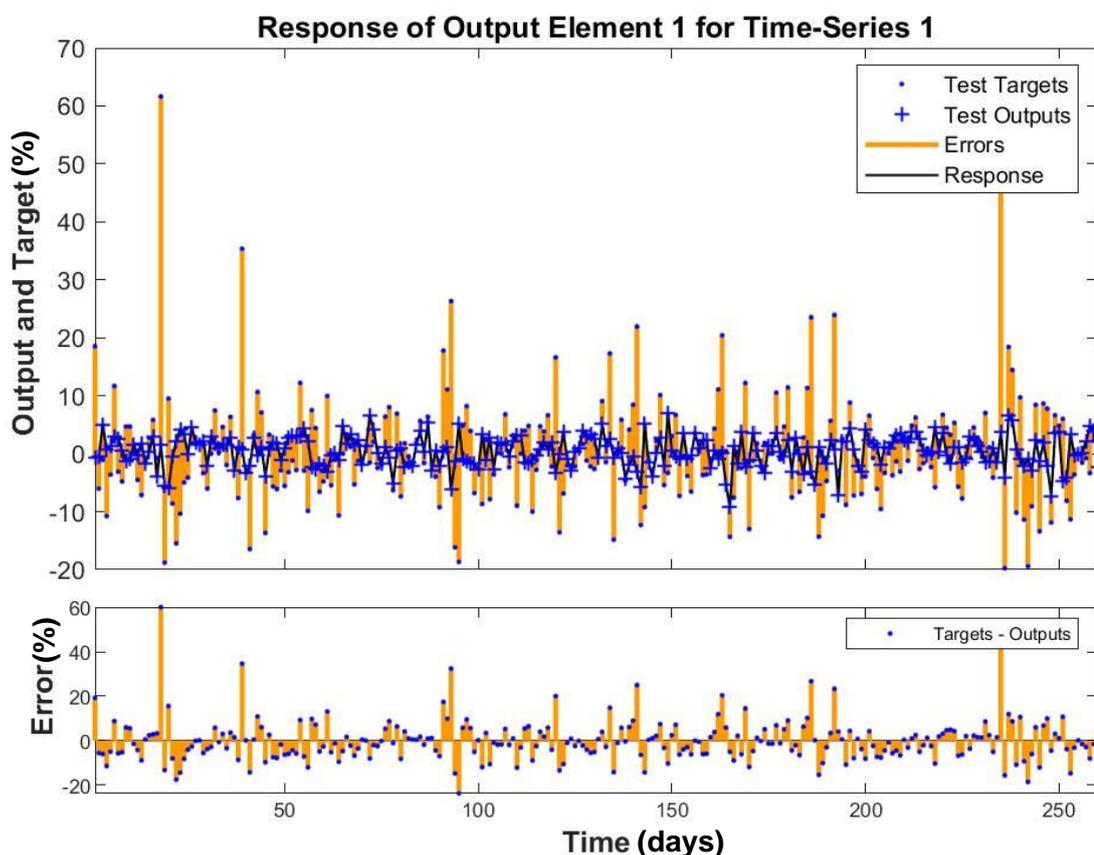
Prognozė	>50% taškų (2021m.)	>55% taškų (2021m.)	>50% taškų (2021m.+2022m.)	>55% taškų (2021m.+2022m.)
Pokyčių kryptis	75% modelių	0,74% modelių	73,54% modelių	1,47% modelių
Pokyčių intervalas	85,29% modelių	29,41% modelių	79,41% modelių	2,21% modelių
Reikšmingi pokyčių intervalai (auga, krenta)	>30% reikšmingų taškų – 1,47% modelių; Modelio didžiausias teisingų prognozių procentas – 33,90%.		>30% reikšmingų taškų – 1,47% modelių; Modelio didžiausias teisingų prognozių procentas – 30,67%.	

4.3.2. Sekančios dienos VIX indekso prognozavimo, naudojant LSTM modelius bei VIX ir kitus įėjimus, rezultatai

Dvidešimt geriausių sekančios dienos gilaus mokymo LSTM modelių, kuriems naudojami VIX ir kiti įėjimo duomenys, rezultatai pateikti priede Nr. 12. Geriausius testavimo rezultatus pasiekę penki modeliai pateikti 24 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 metų testavimo duomenis. Šiuo atveju geriausią rezultatą pasiekė VIX, S&P500, NASDAQ ir sidabro modelio įėjimus, 30 LSTM sluoksnius ir 100 iteracijų turintis modelis, kur vidutinė absoliutinė paklaida naudojant 2021 metų testavimo duomenis gauta 6,0908 %, o papildomai kartu su 2022 metų trijų mėnesių įėjimo duomenimis 6,1832 %. Tai tiksliausias modelis, ištestavus abiem laiko intervalais. 29 paveiksle pateikti gilaus mokymo LSTM modelio su VIX, S&P500, NASDAQ, ir sidabro įėjimais, 30 LSTM sluoksnių ir 100 iteracijų testavimo tikslo-prognozės ir paklaidų grafikai, naudojant 2021 metų testavimo duomenis.

24 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios dienos VIX indekso prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Mokymo MSE	Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
				MSE	MAE	MSE	MAE
VIX+S&P500+ NASDAQ+SILVER	30	100	56,6826	86,8470	6,0908	83,3783	6,1832
VIX+S&P500+NASDAQ+ GOLD+SILVER+OIL	240	10	61,8872	87,3141	6,2120	83,2999	6,2879
VIX+OIL	240	30	59,7451	86,5351	6,2128	82,7400	6,2979
VIX+SILVER	180	20	61,9746	86,9177	6,2173	83,3746	6,3239
VIX+DJI+SILVER+ OIL	240	10	62,3365	87,0844	6,2191	82,9261	6,3034
Nulinės hipotezės kokybiniai rodikliai palyginimui				89,9418	6,3485	84,5379	6,3508



29 pav. LSTM modelio testavimo (2021m.) tikslo-prognozės ir paklaidų grafikai

Geriausius pokyčio krypties prognozės rezultatus pasiekę penki modeliai pateikti 25 lentelėje. Duomenys pateikti pagal 2021 metų testavimo duomenis, kadangi gautas didžiausias teisingos prognozės procentas. Geriausią rezultatą naudojant 2021 metų testavimo duomenis pasiekė VIX ir DJI modelio įėjimus, 30 LSTM sluoksnius ir 1250 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 59,2308 % pokyčio kryptį. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausią rezultatą pasiekė VIX, S&P500 ir DJI modelio įėjimus,

150 LSTM sluoksnius ir 500 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 58,9506 % pokyčio kryptį.

25 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių krypties prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Pokyčių krypties prognozė, % (2021m.)	Pokyčių krypties prognozė, % (2021m.+2022m.)
VIX+DJI	30	1250	59,2308	58,0247
VIX+S&P500+DJI	90	1500	59,2308	57,0988
VIX+S&P500+NASDAQ+SILVER+OIL	180	250	59,2308	56,1728
VIX+S&P500	150	400	58,8462	58,0247
VIX+DJI+NASDAQ	30	500	58,8462	57,7160

Geriausius pokyčio intervalo prognozės rezultatus pasiekę penki modeliai pateikti 26 lentelėje. Duomenys pateikti pagal 2021 metų testavimo duomenis, kadangi gautas didžiausias teisingos prognozės procentas. Geriausią rezultatą naudojant 2021 metų testavimo duomenis pasiekė VIX ir naftos modelio įėjimus, 210 LSTM sluoksnius ir 100 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 58,4615 % pokyčio intervalų. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausią rezultatą pasiekė VIX, NASDAQ ir naftos modelio įėjimus, 240 LSTM sluoksnius ir 50 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 56,7901 % pokyčio intervalų.

26 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių intervalo prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Pokyčių intervalo prognozė, % (2021m.)	Pokyčių intervalo prognozė, % (2021m.+2022m.)
VIX+OIL	210	100	58,4615	56,1728
VIX+NASDAQ+OIL	240	50	58,0769	56,7901
VIX+DJI	60	250	57,6923	55,8642
VIX+NASDAQ+OIL	180	50	57,6923	55,5556
VIX+NASDAQ	180	100	57,6923	55,2469

Modelių pokyčių kryptį ir intervalų prognozavimo apžvalga pateikta 27 lentelėje, kurioje nurodyta kiek procentų visų modelių, naudojančių VIX ir kitų indeksų duomenis prognozavimui, nuspėjo prognozuojamo indekso pokyčio kryptį teisingai, nevertinant skaitinės vertės. Taip pat pateikta kiek procentų modelių, naudojančių VIX ir kitų indeksų duomenis prognozavimui, nuspėjo prognozuojamo indekso pokyčio intervalą teisingai. Intervalo prognozę papildomai charakterizuoja reikšmingų intervalų rezultatai, kurie parodo kiek procentų modelių peržengė 30 % teisingos prognozės reikšmingiems intervalams, kurie gali būti indikacija investuotojui.

27 lentelė. LSTM modelių (su VIX ir kitų indeksų modelio įėjimais) pokyčių kryptių ir pokyčių intervalų prognozės apžvalga

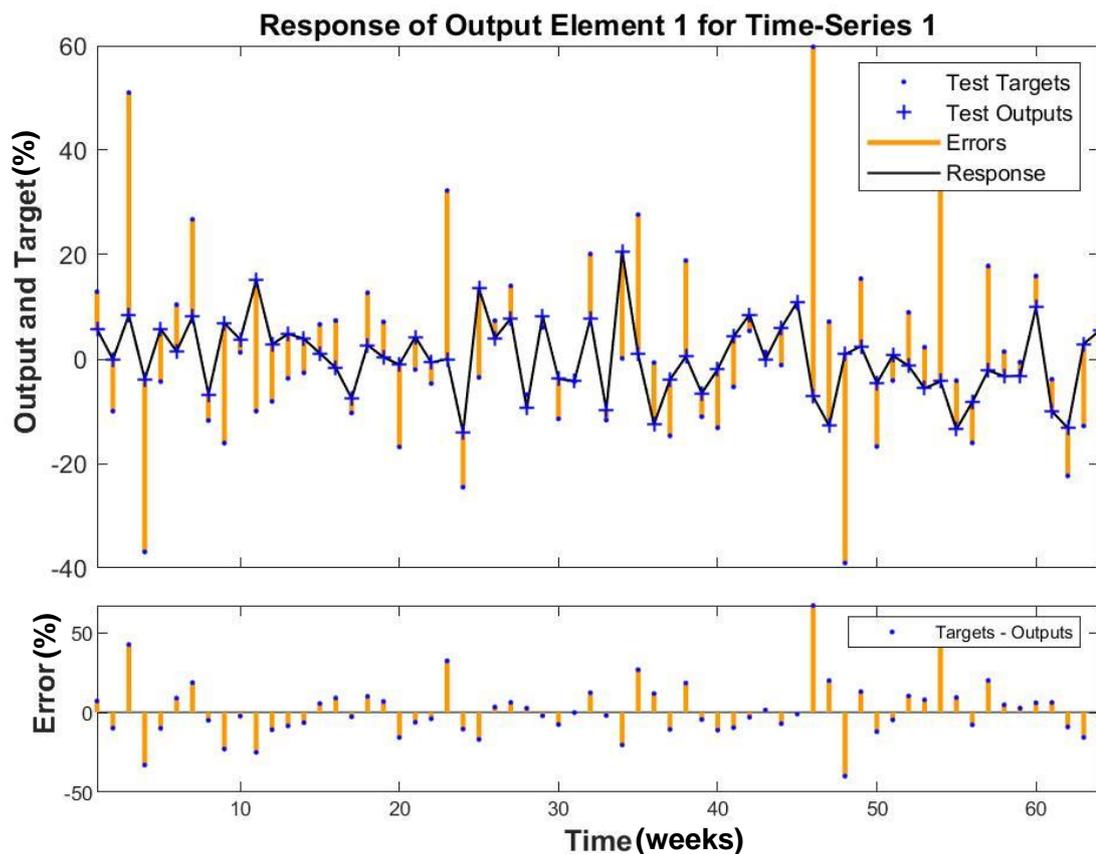
Prognozė	>50% taškų (2021m.)	>55% taškų (2021m.)	>50% taškų (2021m.+2022m.)	>55% taškų (2021m.+2022m.)
Pokyčių kryptis	52,18% modelių	2,31% modelių	53,42% modelių	1,68% modelių
Pokyčių intervalas	47,71% modelių	9,44% modelių	41,06% modelių	0,26% modelių
Reikšmingi pokyčių intervalai (auga, krenta)	>30% reikšmingų taškų – 6,55% modelių; Modelio didžiausias teisingų prognozių procentas – 43,22%.		>30% reikšmingų taškų – 6,29% modelių; Modelio didžiausias teisingų prognozių procentas – 41,33%.	

4.3.3. Sekančios savaitės VIX indekso prognozavimo, naudojant LSTM modelius ir tik VIX įėjimus, rezultatai

Dvidešimt geriausių sekančios savaitės gilaus mokymo LSTM modelių, kuriems naudojami tik VIX įėjimo duomenys rezultatai pateikti priede Nr. 13. Geriausių testavimo rezultatus pasiekę penki modeliai pateikti 28 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 ir 2022 metų trijų mėnesių testavimo duomenimis. Šiuo atveju geriausią rezultatą pasiekė 30 LSTM sluoksnius ir 1000 iteracijų turintis modelis, kur vidutinė absoliutinė paklaida naudojant 2021 metų testavimo duomenis gauta 12,7760 %, o papildomai kartu su 2022 metų trijų mėnesių įėjimo duomenimis 12,6973 %. Tai tiksliausias modelis, ištestavus abiem laiko intervalais. 30 paveiksle pateikti gilaus mokymo LSTM modelio su 30 LSTM sluoksniais ir 1000 iteracijų testavimo tikslo-prognozės ir paklaidų grafikai, naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis.

28 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios savaitės VIX indekso prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Mokymo MSE	Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
				MSE	MAE	MSE	MAE
VIX	30	1000	225,9355	316,5406	12,7760	317,4887	12,6973
VIX	120	40	277,7287	314,7676	13,0787	315,0601	12,7880
VIX	30	30	287,6027	312,5217	12,9663	313,9275	12,7923
VIX	30	350	256,6351	312,8195	12,9258	316,2268	12,7927
VIX	30	20	289,5510	320,9085	13,0481	320,3940	12,8057
Nulinės hipotezės kokybiniai rodikliai palyginimui				324,5094	13,0870	323,4137	12,8933



30 pav. LSTM modelio testavimo (2021m.+2022m.) tikslo-prognozės ir paklaidų grafikai

Geriausius pokyčio krypties prognozės rezultatus pasiekę penki modeliai pateikti 29 lentelėje. Duomenys pateikti pagal 2021 metų testavimo duomenis, kadangi gautas didžiausias teisingos prognozės procentas. Geriausią rezultatą naudojant 2021 metų testavimo duomenis pasiekė 30 LSTM sluoksnius ir 1000 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 66,6667 % pokyčio krypčių. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausią rezultatą pasiekė 30 LSTM sluoksnius ir 30 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 64,0625 % pokyčio krypčių.

29 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių krypties prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Pokyčių krypties prognozė, % (2021m.)	Pokyčių krypties prognozė, % (2021m.+2022m.)
VIX	30	1000	66,6667	62,5000
VIX	30	30	62,7451	64,0625
VIX	30	50	62,7451	62,5000
VIX	30	250	62,7451	62,5000
VIX	30	20	60,7843	62,5000

Geriausius pokyčio intervalo prognozės rezultatus pasiekę penki modeliai pateikti 30 lentelėje. Duomenys pateikti pagal 2021 metų testavimo duomenis, kadangi gautas didžiausias teisingos

prognozės procentas. Geriausią rezultatą naudojant 2021 metų testavimo duomenis pasiekė 60 LSTM sluoksnius ir 1500 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 45,0980 % pokyčio intervalų. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausią rezultatą pasiekė 30 LSTM sluoksnius ir 1000 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 42,1875 % pokyčio intervalų.

30 lentelė. Geriausių penkių LSTM modelių (su VIX indekso modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių intervalo prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Pokyčių intervalo prognozė, % (2021m.)	Pokyčių intervalo prognozė, % (2021m.+2022m.)
VIX	60	1500	45,0980	40,6250
VIX	30	1000	43,1373	42,1875
VIX	120	1500	41,1765	39,0625
VIX	30	350	39,2157	40,6250
VIX	60	300	39,2157	35,9375

Modelių pokyčių krypčių ir intervalų prognozavimo apžvalga pateikta 31 lentelėje, kurioje nurodyta kiek procentų visų modelių, naudojančių VIX indekso duomenis prognozavimui, nuspėjo prognozuojamo indekso pokyčio kryptį teisingai, nevertinant skaitinės vertės. Taip pat pateikta kiek procentų modelių, naudojančių VIX indekso duomenis prognozavimui, nuspėjo prognozuojamo indekso pokyčio intervalą teisingai. Intervalo prognozę papildomai charakterizuoja reikšmingų intervalų rezultatai, kurie parodo kiek procentų modelių peržengė 30 % teisingos prognozės reikšmingiems intervalams, kurie gali būti indikacija investuotojui.

31 lentelė. LSTM modelių (su VIX indekso modelio įėjimais) pokyčių krypčių ir pokyčių intervalų prognozės apžvalga

Prognozė	>50% taškų (2021m.)	>55% taškų (2021m.)	>50% taškų (2021m.+2022m.)	>55% taškų (2021m.+2022m.)
Pokyčių kryptis	82,35% modelių	25,74% modelių	72,79% modelių	17,65% modelių
Pokyčių intervalas	0% modelių	0% modelių	0% modelių	0% modelių
Reikšmingi pokyčių intervalai (auga, krenta)	>30% reikšmingų taškų – 8,09% modelių; Modelio didžiausias teisingų prognozių procentas – 36,8%.		>30% reikšmingų taškų – 6,62% modelių; Modelio didžiausias teisingų prognozių procentas – 35,6%.	

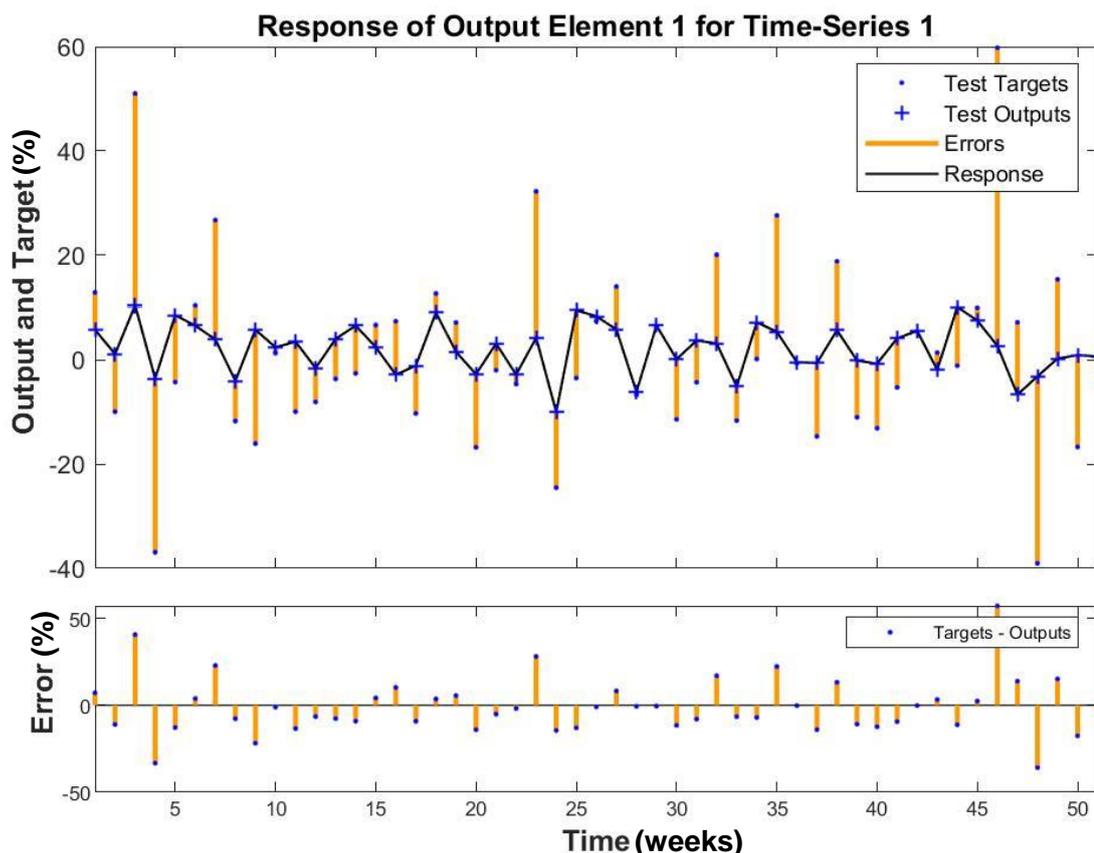
4.3.4. Sekančios savaitės VIX indekso prognozavimo, naudojant LSTM modelius bei VIX ir kitus įėjimus, rezultatai

Dvidešimt geriausių sekančios savaitės gilaus mokymo LSTM modelių, kuriems naudojami VIX ir kiti įėjimo duomenys rezultatai pateikti priede Nr. 14. Geriausius testavimo rezultatus pasiekę penki modeliai pateikti 32 lentelėje. Duomenys pateikti pagal gautą mažiausią vidutinę absoliutinę paklaidą, kuri buvo gauta naudojant 2021 metų testavimo duomenis. Šiuo atveju geriausią rezultatą pasiekė VIX, S&P500, NASDAQ ir aukso modelio įėjimus, 30 LSTM sluoksnius ir 250 iteracijų turintis modelis, kur vidutinė absoliutinė paklaida naudojant 2021 metų testavimo duomenis gauta 12,0266 %, o papildomai kartu su 2022 metų trijų mėnesių įėjimo duomenimis 12,1875 %. Tai tiksliausias modelis, ištestavus abiem laiko intervalais. 31 paveiksle pateikti gilaus mokymo LSTM

modelio su VIX, S&P500, NASDAQ ir aukso indeksų įėjimais, 30 LSTM sluoksnių ir 250 iteracijų testavimo tikslo-prognozės ir paklaidų grafikai, naudojant 2021 metų testavimo duomenis.

32 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios savaitės VIX indekso prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Mokymo MSE	Testavimas (2021m.)		Testavimas (2021m.+2022m.)	
				MSE	MAE	MSE	MAE
VIX+S&P500+NASDAQ+GOLD	30	250	242,8015	265,1277	12,0266	285,0305	12,1875
VIX+NASDAQ	30	300	248,9979	272,5086	12,1244	292,7816	12,2384
VIX+S&P500+DJI+NASDAQ	60	300	214,3162	284,3153	12,1740	305,4879	12,6620
VIX+DJI+NASDAQ	30	500	219,2583	276,3627	12,2086	296,1458	12,7063
VIX+S&P500+DJI+NASDAQ	30	750	191,6768	301,1619	12,2637	326,0121	12,8423
Nulinės hipotezės kokybiniai rodikliai palyginimui				324,5094	13,0870	323,4137	12,8933



31 pav. LSTM modelio testavimo (2021m.) tikslo-prognozės ir paklaidų grafikai

Geriausius pokyčio krypties prognozės rezultatus pasiekę penki modeliai pateikti 33 lentelėje. Duomenys pateikti pagal 2021 ir 2022 metų testavimo duomenis, kadangi gautas didžiausias teisingos prognozės procentas. Geriausių rezultatą naudojant 2021 metų testavimo duomenis pasiekė VIX, DJI,

NASDAQ ir aukso modelio įėjimus, 30 LSTM sluoksnius ir 1250 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 68,6275 % pokyčio kryptį. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausią rezultatą pasiekė tas pats modelis, kuris iš testavimo duomenų teisingai prognozavo 70,3125 % pokyčio kryptį.

33 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių krypties prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Pokyčių krypties prognozė, % (2021m.)	Pokyčių krypties prognozė, % (2021m.+2022m.)
VIX+DJI+NASDAQ+GOLD	30	1250	68,6275	70,3125
VIX+S&P500+DJI+NASDAQ+SILVER	30	250	68,6275	68,7500
VIX+DJI+NASDAQ+GOLD+OIL	30	50	62,7451	67,1875
VIX+S&P500+NASDAQ+GOLD+OIL	60	500	68,6275	65,6250
VIX+GOLD+SILVER+OIL	90	10	66,6667	65,6250

Geriausius pokyčio intervalo prognozės rezultatus pasiekę penki modeliai pateikti 34 lentelėje. Duomenys pateikti pagal 2021 metų testavimo duomenis, kadangi gautas didžiausias teisingos prognozės procentas. Geriausią rezultatą naudojant 2021 metų testavimo duomenis pasiekė VIX, DJI, aukso ir sidabro modelio įėjimus, 60 LSTM sluoksnius ir 750 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 54,9020 % pokyčio intervalų. O naudojant 2021 ir 2022 metų trijų mėnesių įėjimo testavimo duomenis geriausią rezultatą pasiekė VIX, S&P500, DJI, NASDAQ, aukso, sidabro ir naftos modelio įėjimus, 30 LSTM sluoksnius ir 750 iteracijų turintis modelis, kuris iš testavimo duomenų teisingai prognozavo 51,5625 % pokyčio intervalų.

34 lentelė. Geriausių penkių LSTM modelių (su VIX ir kitų indeksų modelio įėjimais), skirtų sekančios dienos VIX indekso pokyčių intervalo prognozei, rezultatai

Įėjimai	LSTM sluoksniai	Iteracijos	Pokyčių intervalo prognozė, % (2021m.)	Pokyčių intervalo prognozė, % (2021m.+2022m.)
VIX+DJI+GOLD+SILVER	60	750	54,9020	50,0000
VIX+SP500+GOLD+OIL	30	1500	52,9412	46,8750
VIX+NASDAQ+GOLD+SILVER	60	1250	52,9412	42,1875
VIX+SP500+DJI+NASDAQ+GOLD+SILVER+OIL	30	750	52,9412	51,5625
VIX+SP500+DJI+NASDAQ	30	750	50,9804	45,3125

Modelių pokyčių kryptį ir intervalų prognozavimo apžvalga pateikta 35 lentelėje, kurioje nurodyta kiek procentų visų modelių, naudojančių VIX ir kitų indeksų duomenis prognozavimui, nuspėjo prognozuojamo indekso pokyčio kryptį teisingai, nevertinant skaitinės vertės. Taip pat pateikta kiek procentų modelių, naudojančių VIX ir kitų indeksų duomenis prognozavimui, nuspėjo prognozuojamo indekso pokyčio intervalą teisingai. Intervalo prognozę papildomai charakterizuoja reikšmingų intervalų rezultatai, kurie parodo kiek procentų modelių peržengė 30 % teisingos prognozės reikšmingiems intervalams, kurie gali būti indikacija investuotojui.

35 lentelė. LSTM modelių (su VIX ir kitų indeksų modelio įėjimais) pokyčių kryptių ir pokyčių intervalų prognozės apžvalga

Prognozė	>50% taškų (2021m.)	>55% taškų (2021m.)	>50% taškų (2021m.+2022m.)	>55% taškų (2021m.+2022m.)
Pokyčių kryptis	68,95% modelių	23,94% modelių	56,63% modelių	21,90% modelių
Pokyčių intervalas	0,13% modelių	0% modelių	0,01% modelių	0% modelių
Reikšmingi pokyčių intervalai (auga, krenta)	>30% reikšmingų taškų – 40,93% modelių; Modelio didžiausias teisingų prognozių procentas – 60,5%.		>30% reikšmingų taškų – 30,17% modelių; Modelio didžiausias teisingų prognozių procentas – 57,8%.	

Rezultatai ir išvados

Pagrindiniai darbo rezultatai:

- Geriausią sekančios dienos VIX indekso pokyčio prognozės rezultatą pasiekė VIX, S&P500, NASDAQ ir sidabro modelio įėjimus, 30 LSTM sluoksnių ir 100 iteracijų turintis gilaus mokymo LSTM modelis, kurio vidutinė absoliutinė paklaida, naudojant 2021 metų testavimo duomenis, gauta 6,0908 %. Geriausią sekančios savaitės VIX indekso pokyčio prognozės rezultatą pasiekė VIX, S&P500, NASDAQ ir aukso modelio įėjimus, 30 LSTM sluoksnių ir 250 iteracijų turintis gilaus mokymo LSTM modelis, kurio vidutinė absoliutinė paklaida, naudojant 2021 metų testavimo duomenis, gauta 12,0266 %.
- Geriausią sekančios dienos VIX indekso pokyčio krypties rezultatą pasiekė VIX ir DJI modelio įėjimus, 30 LSTM sluoksnių ir 1250 iteracijų turintis modelis, kuris iš 2021m. testavimo duomenų teisingai prognozavo 59,2308 % pokyčio krypčių. Geriausią sekančios savaitės VIX indekso pokyčio krypties rezultatą pasiekė VIX, DJI, NASDAQ ir aukso modelio įėjimus, 30 LSTM sluoksnių ir 1250 iteracijų turintis modelis, kuris iš 2021m. testavimo duomenų teisingai prognozavo 68,6275 % pokyčio krypčių.
- Geriausią sekančios dienos VIX indekso pokyčio intervalo rezultatą pasiekė VIX ir naftos modelio įėjimus, 210 LSTM sluoksnių ir 100 iteracijų turintis modelis, kuris iš 2021m. testavimo duomenų teisingai prognozavo 58,4615 % pokyčio intervalų (reikšmingų intervalų 39,83 %). Geriausią sekančios savaitės VIX indekso pokyčio intervalo rezultatą pasiekė VIX, DJI, aukso ir sidabro modelio įėjimus, 60 LSTM sluoksnių ir 750 iteracijų turintis modelis, kuris iš 2021m. testavimo duomenų teisingai prognozavo 54,9020 % pokyčio intervalų (reikšmingų intervalų 60,52 %).
- Atlikus tyrimą pastebėta, kad dieninių ir savaitinių prognozių modelių įėjimams naudojant VIX ir papildomai kitus indeksus (įvairias jų kombinacijas), gaunami modeliai su geresniais rezultatais – sumažėja vidutinė absoliutinė paklaida bei pagerėja pokyčių krypčių ir intervalų prognozavimas.
- Lyginant tradicinius ARMA / ARMAX / NARMA / NARMAX modelius ir jų geriausius rezultatus su gilaus mokymo modeliais pagal vidutinę absoliutinę paklaidą, pastebėta, kad NARMA / NARMAX modeliai veikė taip pat arba prasčiau nei gilaus mokymo modeliai. O ARMA modeliai naudojant tik VIX indekso įėjimo duomenis prognozuoti pokyčių parodė geresnius (keliomis dešimtosiomis arba šimtosiomis dalimis procento) tiek sekančio dienos, tiek savaitės prognozės rezultatus, lyginant su gilaus mokymo modeliu. Tačiau papildomai panaudojus kitus indeksus modelių įėjimams, pasireiškė gilaus mokymo LSTM modelių pranašumas ir vidutinės absoliutinės paklaidos skirtumas tarp modelių buvo 0,1-0,4%.
- Modelių testavimui naudojant du skirtingus intervalų duomenų rinkinius nepastebėtas žymus modelių rezultatų pagerėjimas visiems kurtiems modeliams. Tai rodo, kad papildomų trejų mėnesių laikotarpyje buvo didelių VIX indekso nuokrypių, kurie nebuvo teisingai prognozuojami. Tai lėmė vidutinės absoliutinės paklaidos stabilumą tiek sekančios dienos, tiek savaitės prognozių modeliams.
- Nustatyta, kad apie 52 % (4573 modeliai) sekančios dienos prognozių modelių geba teisingai prognozuoti virš 50 % visų VIX indekso pokyčio krypčių teisingai. O 1,5 % (146 modeliai) visų sekančios dienos prognozių modelių geba nustatyti virš 55 % VIX indekso pokyčio krypčių teisingai. Taip pat nustatyta, kad 56 % (4951 modeliai) sekančios savaitės prognozių modelių geba teisingai nustatyti virš 50 % visų VIX indekso pokyčio krypčių teisingai. O apie

- 21 % (1900 modeliai) visų sekančios savaitės modelių geba nustatyti virš 55 % VIX indekso pokyčio krypčių teisingai.
- Nustatyta, kad 41 % (3626 modeliai) sekančios dienos prognozių modelių geba teisingai nustatyti virš 50 % visų VIX indekso pokyčių intervalų teisingai. O tik apie 0,5 % (25 modeliai) visų sekančios dienos modelių geba nustatyti virš 55 % VIX indekso pokyčių intervalų teisingai. Taip pat nustatyta, kad tik 0,13 % (11 modelių) sekančios savaitės prognozių modelių geba teisingai nustatyti virš 50 % visų VIX indekso pokyčių intervalų teisingai. O nei vienas iš visų sekančios savaitės modelių nesugeba nustatyti virš 55 % VIX indekso pokyčių intervalų teisingai. Išanalizavus reikšmingų intervalų (augš arba kris) kieki, nė vienas iš modelių, skirtų sekančios dienos, nepasiekia net 50 % teisingos prognozės. Tačiau 0,07 % (6 modeliai) sekančios savaitės prognozės modeliai, geba teisingai nustatyti virš 50 % reikšmingų intervalų.
 - Palyginus nulinės hipotezės ir modelių gautas vidutines kvadratinės paklaidas, galima teigti, kad 16,67 % (1451 modeliai) visų sekančios dienos prognozių modelių yra tikslesni. 39,55 % (3442 modeliai) visų sekančios savaitės prognozių modelių yra tikslesni už nulinę hipotezę. Tai reiškia, kad šie modeliai duos geresnį rezultatą už prielaidą, kad ryt VIX indekso pokytis bus 0 %.

Pagal gautus rezultatus galima suformuoti šias išvadas:

1. Nežiūrint į tai, kad kai kuriose mokslinėse publikacijose paskelbti gana aukšti VIX indikatorius prognozavimo rezultatai, šiame darbe atlikta apie 19400 įvairios struktūros modelių analizė parodė, kad tokius rezultatus sudėtinga pasiekti, o publikacijose skelbiamus rezultatus sudėtinga patikrinti dėl nepilnai aprašomų eksperimento sąlygų. Darbe gautų modelių kokybė VIX indekso pokyčio vertės prognozei yra nepakankama investavimo / prekybos strategijų formavimui.
2. Gilaus mokymo LSTM modelių tikslumas prognozuojant sekančios dienos (59,2308 %) ir savaitės (68,6275 %) VIX kitimo kryptį gali būti naudingas investuotojams ir prekyviams kaip prekybos strategijų indikatorius.
3. Gilaus mokymo LSTM modelių tikslumas prognozuojant sekančios savaitės (54,9020 %) VIX kitimo intervalą (VIX augš, bus stabilus arba kris) gali būti naudingas investuotojams ir prekyviams, padedant priimti prekybos strategijas.
4. Gilaus mokymo tinklų, naudojant VIX ir kitus modelio įėjimus, prognozavimo kokybė geresnė už klasikinių modelių.
5. Norint gerinti LSTM modelių tikslumą reikėtų ieškoti kitų įėjimo kintamųjų, modelio parametru, modelių mokymo ir testavimo duomenų laiko intervalų kombinacijų.

Rekomendacijos

1. Realiam investavimui ir prekybai kaip pagalbinį indikacinį įrankį yra tikslinga naudoti: dieninėms pokyčio krypties prognozėms, modelį turintį VIX ir DJI modelio įėjimus, 30 LSTM sluoksnių ir 1250 iteracijų; savaitinėms pokyčio krypties prognozėms, modelį turintį VIX, DJI, NASDAQ ir aukso modelio įėjimus, 30 LSTM sluoksnių ir 1250 iteracijų; savaitinėms pokyčio intervalo prognozėms, modelį turintį VIX, DJI, aukso ir sidabro modelio įėjimus, 60 LSTM sluoksnių ir 750 iteracijų;
2. Siekiant geresnių modelių rezultatų, tolesniuose tyrimuose reikėtų peržiūrėti ir paanalizuoti kitus galimus modelių įėjimus (akcijos, indeksai, fundamentinės ir techninės analizės rodikliai), modelių architektūrą bei parametrus. Modeliams labai svarbūs tinkamai parinkti mokymo ir testavimo duomenys, todėl renkantis duomenis, reikėtų kritiškai vertinti potencialius akcijų rinkos laikotarpius.
3. Atlikus eksperimentinį darbą, pastebėta, kad pokyčio prognozavimas kurtiems modeliams yra pakankamai sudėtinga užduotis ir didesnių VIX pokyčių prognozuoti nepavyksta. Taip pat pastebėta, kad didelį potencialą turi VIX indekso pokyčio prognozavimas intervalais – auga, yra stabilus, krenta. Pasiekus didesnių modelių tikslumą, ir viršijus 50% teisingų reikšmingų intervalo pokyčių prognozes, modeliai galėtų būti naudojami formuoti pelningas VIX indekso prekybos strategijas. Todėl tolesniuose tyrimuose reikėtų koncentruotis į šią užduotį.

Literatūros sąrašas

1. WHALEY, R.E. Understanding the VIX. *The Journal of Portfolio Management*, 2009, vol. 35, no. 3. pp. 98. Prieiga per: <http://jpm.pm-research.com/content/35/3/98.abstract> DOI 10.3905/JPM.2009.35.3.098.
2. AHONIEMI, K. Modeling and Forecasting Implied Volatility - an Econometric Analysis of the VIX Index, July 17, 2008 [žiūrėta 2021-05-27] DOI 10.2139/ssrn.1033812.
3. VANIPRIYA, C. Sentiment Analysis for Predicting the Trends of the Stock. *Inflibnet*, 2016 [žiūrėta 2021-05-25]. pp. 8-15. Prieiga per: <http://shodhganga.inflibnet.ac.in:8080/jspui/handle/10603/166775>.
4. NTI, I.k., ADEKOYA, A. and WEYORI, B. A Systematic Review of Fundamental and Technical Analysis of Stock Market Predictions. *Artificial Intelligence Review*, April 1, 2020, vol. 53 [žiūrėta 2021-05-16] DOI 10.1007/s10462-019-09754-z.
5. MARWALA, L. Forecasting the Stock Market Index using Artificial Intelligence Techniques, Sep 13, 2010.
6. PATEL, J., SHAH, S., THAKKAR, P. and KOTTECHA, K. Predicting Stock Market Index using Fusion of Machine Learning Techniques. *Expert Systems with Applications*, March 1, 2015, vol. 42, no. 4 [žiūrėta 2021-05-17]. pp. 2162-2172. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S0957417414006551> ISSN 0957-4174. DOI 10.1016/j.eswa.2014.10.031.
7. YANG, B., HAO, J. and ZHANG, S. Stock Market Prediction using Artificial Neural Networks. *Advanced Engineering Forum*, September 1, 2012, vol. 6-7 [žiūrėta 2021-05-17]. pp. 1055-1060 DOI 10.4028/www.scientific.net/AEF.6-7.1055.
8. YONG, B., ABDULLAH, A.S. and ABDUL RAHIM, M.R. A Stock Market Trading System using Deep Neural Network. Springer Singapore, 2017 ISBN 9789811064623.
9. GU, Y., et al. Prediction of Stock Performance using Deep Neural Networks. *Applied Sciences*, November 17, 2020, vol. 10 [žiūrėta 2021-05-20]. pp. 8142 DOI 10.3390/app10228142.
10. HWANG, H. and OH, J. Fuzzy Models for Predicting Time Series Stock Price Index. *International Journal of Control, Automation and Systems*, June 1, 2010, vol. 8 [žiūrėta 2021-05-17]. pp. 702-706 DOI 10.1007/s12555-010-0325-2.
11. IJEGWA, A.D., VINCENT, O.R., FOLORUNSO, O. and ISAAC, O. A Predictive Stock Market Technical Analysis using Fuzzy Logic. *Comput. Inf. Sci.*, 2014 [žiūrėta 2021-05-25] DOI 10.5539/cis.v7n3p1.
12. HOSKER, J., DJURDJEVIC, S., NGUYEN, H. and SLATER, R. Improving VIX Futures Forecasts using Machine Learning Methods. *SMU Data Science Review*, -01-18, 2019, vol. 1, no. 4 [žiūrėta 2021-09-23]. Prieiga per: <https://scholar.smu.edu/datasciencereview/vol1/iss4/6>.
13. P. Hemanth Kumar and S. Basavaraj Patil. A Hybrid Regression and Deep Learning LSTM Based Technique for Predicting Volatility Index (VIX) Direction of Change (Trend). *Indian Journal of Science and Technology*, 2018, vol. 11, no. 47 [žiūrėta 2021-10-18]. pp. 1-9. Prieiga per: <https://indjst.org/> ISSN 0974-5645. DOI 10.17485/ijst/2018/v11i47/138080.
14. OSTERRIEDER, J., KUCHARCZYK, D., RUDOLF, S. and WITTEWER, D. Neural Networks and Arbitrage in the VIX: A Deep Learning Approach for the VIX. *Digital Finance*, 2020, vol. 2, no. 1 [žiūrėta 2021-10-15]. pp. 97-115 ISSN 2524-6186. DOI 10.1007/s42521-020-00026-y.

15. KUMAR, J., GOOMER, R. and SINGH, A.K. Long Short Term Memory Recurrent Neural Network (LSTM-RNN) Based Workload Forecasting Model for Cloud Datacenters. *Procedia Computer Science*, January 1, 2018, vol. 125 [žiūrēta 2021-10-30]. pp. 676-682. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S1877050917328557> ISSN 1877-0509. DOI 10.1016/j.procs.2017.12.087.
16. SHANG, H.L., YANG, Y. and KEARNEY, F. Intraday Forecasts of a Volatility Index: Functional Time Series Methods with Dynamic Updating. *Annals of Operations Research*, 2019, vol. 282, no. 1. pp. 331-354. [žiūrēta 2022-02-15] Prieiga per: <https://doi.org/10.1007/s10479-018-3108-4> ISSN 1572-9338. DOI 10.1007/s10479-018-3108-4.
17. ROSILLO, R., GINER, J. and DE LA FUENTE, D. The Effectiveness of the Combined use of VIX and Support Vector Machines on the Prediction of S&P 500. *Neural Computing and Applications*, 2014, vol. 25, no. 2. pp. 321-332. [žiūrēta 2022-02-17] Prieiga per: <https://doi.org/10.1007/s00521-013-1487-7> ISSN 1433-3058. DOI 10.1007/s00521-013-1487-7.
18. FERNANDES, M., MEDEIROS, M.C. and SCHARTH, M. Modeling and Predicting the CBOE Market Volatility Index. *Journal of Banking & Finance*, March 1, 2014, vol. 40 [viewed May 17, 2022]. pp. 1-10. [žiūrēta 2022-02-17] Prieiga per: <https://www.sciencedirect.com/science/article/pii/S0378426613004172> ISSN 0378-4266. DOI 10.1016/j.jbankfin.2013.11.004.
19. YU, M.Y. Predicting the Volatility Index Returns using Machine Learning. , 2017 [žiūrēta 2022-02-18] Prieiga per: <https://tspace.library.utoronto.ca/handle/1807/79328>.
20. BAI, Y. and CAI, C.X. Predicting VIX with Adaptive Machine Learning. Rochester, NY: /01/26, 2022 [žiūrēta 2022-02-21] Prieiga per: <https://papers.ssrn.com/abstract=3866415> DOI 10.2139/ssrn.3866415.
21. HIRSA, A., et al. The VIX Index Under Scrutiny of Machine Learning Techniques and Neural Networks. , February 3, 2021 [žiūrēta 2022-02-25].

Priedai

1 priedas. Programinis kodas NARMA / NARMAX modeliams sudaryti ir testuoti

```
prog=0; overl=960;
for qi1=0:1
    for qi2=0:1
        for qi3=0:1
            for qi4=0:1
                for qi5=0:1
                    for qi6=0:1
                        Bi=InTrain_VISI_D(:,1:5);
                        Ti=InTest_VISI_D(:,1:5);
                        if qi1==1 %Nafta
                            Bi=[Bi (InTrain_VISI_D(:,31:35))];
                            Ti=[Ti (InTest_VISI_D(:,31:35))];
                        end
                        if qi2==1 %Sidabras
                            Bi=[Bi (InTrain_VISI_D(:,26:30))];
                            Ti=[Ti (InTest_VISI_D(:,26:30))];
                        end
                        if qi3==1 %Auksas
                            Bi=[Bi (InTrain_VISI_D(:,21:25))];
                            Ti=[Ti (InTest_VISI_D(:,21:25))];
                        end
                        if qi4==1 %NASDAQ
                            Bi=[Bi (InTrain_VISI_D(:,16:20))];
                            Ti=[Ti (InTest_VISI_D(:,16:20))];
                        end
                        if qi5==1 %DJI
                            Bi=[Bi (InTrain_VISI_D(:,11:15))];
                            Ti=[Ti (InTest_VISI_D(:,11:15))];
                        end
                        if qi6==1 %SP500
                            Bi=[Bi (InTrain_VISI_D(:,6:10))];
                            Ti=[Ti (InTest_VISI_D(:,6:10))];
                        end
                    end

filename = 'NARMA_NARMAX.xlsx';
sheet = 'NARMAX';
metod = ['NARMAX_VIX' repmat('+SP500',qi6) repmat('+DJI',qi5)
repmat('+NASDAQ',qi4) repmat('+GOLD',qi3) repmat('+SILVER',qi2)
repmat('+OIL',qi1)];
X = tonndata(Bi,false,false);
T = tonndata(OutTrain_D,false,false);
X1 = tonndata(Ti,false,false);
T1 = tonndata(OutTest_D,false,false);

for i = 1:15
    %Rekurentinio tinklo parametrø aprašymas/modelio sukūrimas
    trainFcn = 'trainlm';
    inputDelays = 1:2;
    hiddenLayerSize = i;
    net = timedelaynet(inputDelays,hiddenLayerSize,trainFcn);
    [x,xi,ai,t] = preparets(net,X,T);
    net.divideParam.trainRatio = 90/100;
    net.divideParam.valRatio = 5/100;
    net.divideParam.testRatio = 5/100;
    [net,tr] = train(net,x,t,xi,ai);
    y = net(x,xi,ai);
    ee = gsubtract(t,y);
    performance = perform(net,t,y);
end
```

```

trainTargets = gmultiply(t, tr.trainMask);
valTargets = gmultiply(t, tr.valMask);
testTargets = gmultiply(t, tr.testMask);
trainPerformance = perform(net, trainTargets, y);
valPerformance = perform(net, valTargets, y);
testPerformance = perform(net, testTargets, y);
[r1, m1, b1] = regression(trainTargets, y);
[r2, m2, b2] = regression(valTargets, y);
[r3, m3, b3] = regression(testTargets, y);
r1 = r1(1); r2 = r2(1); r3 = r3(1);

%Mokymo grafikø sukûrimas ir iðsaugojimas
mkdir([metod, num2str(i)])
figure, plotperform(tr)
saveas(gcf, fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'], 'Train1.jpeg'));
figure, plottrainstate(tr)
saveas(gcf, fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'], 'Train2.jpeg'));
figure,
ploterrhist(gsubtract(trainTargets, y), 'Training', gsubtract(valTargets, y), 'Valida
tion', gsubtract(testTargets, y), 'Test')
saveas(gcf, fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'], 'Train3.jpeg'));
figure,
plotregression(trainTargets, y, 'Training', valTargets, y, 'Validation', testTargets, y
, 'Test', t, y, 'All')
saveas(gcf, fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'], 'Train4.jpeg'));
figure,
plotresponse(trainTargets, 'Training', valTargets, 'Validation', testTargets, 'Test',
y)
saveas(gcf, fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'], 'Train5.jpeg'));
figure, ploterrcorr(ee)
saveas(gcf, fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'], 'Train6.jpeg'));
figure, plotinerrcorr(x, ee)
saveas(gcf, fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'], 'Train7.jpeg'));
close all

%Sukurto modelio testavimas ir grafikø sukûrimas
MAE = (sum(abs(cell2mat(ee))))/3648;
[x1, xil, ail, t1] = preparets(net, X1, T1);
y1 = net(x1, xil, ail);
e1 = gsubtract(t1, y1);
MAE1 = (sum(abs(cell2mat(e1))))/258;
MSE1 = perform(net, t1, y1);
[r4, m4, b4] = regression(t1, y1);
r4 = r4(1);

figure, ploterrhist(e1, 'Test')
saveas(gcf, fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'], 'Test1.jpeg'));
figure, plotregression(t1, y1, 'Test')
saveas(gcf, fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'], 'Test2.jpeg'));
figure, plotresponse(t1, 'Test', y1)
saveas(gcf, fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'], 'Test3.jpeg'));
figure, ploterrcorr(e1)

```

```

saveas(gcf,fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'],'Test4.jpeg'));
figure, plotinerrcorr(x1,e1)
saveas(gcf,fullfile(['C:\Users\Marius\Desktop\aaaDuomenys\' metod num2str(i)
'\'],'Test5.jpeg'));
close all

%Duomenø iðsaugojimas á Excel
A = {['NARMAX_VIX' repmat('+SP500',qi6) repmat('+DJI',qi5) repmat('+NASDAQ',qi4)
repmat('+GOLD',qi3) repmat('+SILVER',qi2) repmat('+OIL',qi1)], i,
trainPerformance, r1, valPerformance, r2, testPerformance, r3, performance, MAE,
MSE1, r4, MAE1, width(Bi)};
[numbers, strings, raw] = xlsread(filename,sheet);
lastRow = size(raw, 1);
nextRow = lastRow + 1;
cellReference = sprintf('A%d', nextRow);
xlswrite(filename,A, sheet, cellReference)

%Progreso sekimas
Bi=0; Ti=0;
prog=prog+1;
disp(['Progress: ' num2str((prog/overl)*100)])
end
end
        qi6=0;
        end
        qi5=0;
        end
        qi4=0;
        end
        qi3=0;
        end
        qi2=0;
end
end

```

2 priedas. Programinis kodas gilaus mokymo LSTM modeliams sudaryti ir testuoti

```
prog=0; overl=8704; cont=0;
for qi1=0:1
    for qi2=0:1
        for qi3=0:1
            for qi4=0:1
                for qi5=0:1
                    for qi6=0:1
                        Bi=InTrain_VISI_D(:,1:5);
                        Ti=InTest_VISI_D(:,1:5);
                        Ti2022=InTest2022_VISI_D(:,1:5);
                        if qi1==1 %Nafta
                            Bi=[Bi (InTrain_VISI_D(:,31:35))];
                            Ti=[Ti (InTest_VISI_D(:,31:35))];
                            Ti2022=[Ti2022 (InTest2022_VISI_D(:,31:35))];
                        end
                        if qi2==1 %Sidabras
                            Bi=[Bi (InTrain_VISI_D(:,26:30))];
                            Ti=[Ti (InTest_VISI_D(:,26:30))];
                            Ti2022=[Ti2022 (InTest2022_VISI_D(:,26:30))];
                        end
                        if qi3==1 %Auksas
                            Bi=[Bi (InTrain_VISI_D(:,21:25))];
                            Ti=[Ti (InTest_VISI_D(:,21:25))];
                            Ti2022=[Ti2022 (InTest2022_VISI_D(:,21:25))];
                        end
                        if qi4==1 %NASDAQ
                            Bi=[Bi (InTrain_VISI_D(:,16:20))];
                            Ti=[Ti (InTest_VISI_D(:,16:20))];
                            Ti2022=[Ti2022 (InTest2022_VISI_D(:,16:20))];
                        end
                        if qi5==1 %DJI
                            Bi=[Bi (InTrain_VISI_D(:,11:15))];
                            Ti=[Ti (InTest_VISI_D(:,11:15))];
                            Ti2022=[Ti2022 (InTest2022_VISI_D(:,11:15))];
                        end
                        if qi6==1 %SP500
                            Bi=[Bi (InTrain_VISI_D(:,6:10))];
                            Ti=[Ti (InTest_VISI_D(:,6:10))];
                            Ti2022=[Ti2022 (InTest2022_VISI_D(:,6:10))];
                        end
                    end
                end
            end
        end
    end

filename = 'LSTM.xlsx';
sheet = 'LSTM';
metod = ['LSTM_VIX' repmat('+SP500',qi6) repmat('+DJI',qi5)
repmat('+NASDAQ',qi4) repmat('+GOLD',qi3) repmat('+SILVER',qi2)
repmat('+OIL',qi1)];
input = num2cell(Bi',1);
output = num2cell(OutTrain_D',1);
XTest = num2cell(Ti',1);
TTest = num2cell(OutTest_D',1);
XTest2022 = num2cell(Ti2022',1);
TTest2022 = num2cell(OutTest2022_D',1);

for j=1:8
    for i=0:2
        %Ciklo praleidimo funkcija
        %     if cont==0
        %         if j==8 && i==8 && qi1==1 && qi2==1 && qi5==1 && qi6==1
        %             cont=1
        %         else
```

```

%         prog=prog+1;
%         disp(['Progress: ' num2str((prog/overl)*100) ']; VIX'
repmat('+SP500',qi6) repmat('+DJI',qi5) repmat('+NASDAQ',qi4)
repmat('+GOLD',qi3) repmat('+SILVER',qi2) repmat('+OIL',qi1) ' progC-'
num2str(prog)])
%         continue
%     end
% end
%Gilaus mokymo LSTM tinklo parametrø apraðymas/modelio sukûrimas
numChannels = size(input{1},1);
numLayer = j * 30;
numEpoch = 500 + i * 250;
layers = [
    sequenceInputLayer(numChannels)
    lstmLayer(numLayer)
    fullyConnectedLayer(size(output{1},1))
    regressionLayer];
options = trainingOptions("adam", ...
    MaxEpochs=numEpoch, ...
    SequencePaddingDirection="left", ...
    Shuffle="every-epoch", ...
    Plots="training-progress", ...
    Verbose=0);
%Funkcija procesoriaus utilizavimui - ExecutionEnvironment='cpu', ...

[net,info] = trainNetwork(input,output,layers,options);

%Treniravimo grafiko iðsaugojimas

mkdir(['LSTM\ ', metod, 'L', num2str(numLayer), 'E', num2str(numEpoch)])
currentfig = findall(groot, 'Tag', 'NNET_CNN_TRAININGPLOT_UIFIGURE');
exportapp(currentfig,['LSTM\ ' metod 'L' num2str(numLayer) 'E' num2str(numEpoch)
'\Train1.jpeg']);
close (currentfig)

%LSTM tinklo testavimas naudojant 2021 duomenis
YTest = predict(net,XTest,SequencePaddingDirection="left");
e = gsubtract(TTest,YTest');

%Grafikø sudarymas ir iðsaugojimas
t=(1:length(OutTest_D))';
figure, ploterrhist(e,'Test')
saveas(gcf,fullfile(['LSTM\ ' metod 'L' num2str(numLayer) 'E' num2str(numEpoch)
'\'],'Test1.jpeg'));
figure, plotregression(TTest,YTest','Test')
saveas(gcf,fullfile(['LSTM\ ' metod 'L' num2str(numLayer) 'E' num2str(numEpoch)
'\'],'Test2.jpeg'));
figure, plotresponse(TTest,'Test',YTest')
saveas(gcf,fullfile(['LSTM\ ' metod 'L' num2str(numLayer) 'E' num2str(numEpoch)
'\'],'Test3.jpeg'));
figure, ploterrcorr(e)
saveas(gcf,fullfile(['LSTM\ ' metod 'L' num2str(numLayer) 'E' num2str(numEpoch)
'\'],'Test4.jpeg'));
figure, plot(t,cell2mat(YTest),t,OutTest_D)
legend('Prediction','Real')
saveas(gcf,fullfile(['LSTM\ ' metod 'L' num2str(numLayer) 'E' num2str(numEpoch)
'\'],'Test5.jpeg'));
close all

%LSTM tinklo testavimas naudojant 2021+2022 3men. duomenis
YTest2022 = predict(net,XTest2022,SequencePaddingDirection="left");
e2022 = gsubtract(TTest2022,YTest2022');

```

```

%Grafikø sudarymas ir iðsaugojimas
t2022=(1:length(OutTest2022_D))';
figure, ploterrhist(e2022,'Test')
saveas(gcf,fullfile(['LSTM\ ' metod 'L' num2str(numLayer) 'E' num2str(numEpoch)
'\'],'Test2022_1.jpeg'));
figure, plotregression(TTest2022,YTest2022,'Test')
saveas(gcf,fullfile(['LSTM\ ' metod 'L' num2str(numLayer) 'E' num2str(numEpoch)
'\'],'Test2022_2.jpeg'));
figure, plotresponse(TTest2022,'Test',YTest2022')
saveas(gcf,fullfile(['LSTM\ ' metod 'L' num2str(numLayer) 'E' num2str(numEpoch)
'\'],'Test2022_3.jpeg'));
figure, ploterrcorr(e2022)
saveas(gcf,fullfile(['LSTM\ ' metod 'L' num2str(numLayer) 'E' num2str(numEpoch)
'\'],'Test2022_4.jpeg'));
figure, plot(t2022,cell2mat(YTest2022),t2022,OutTest2022_D)
legend('Prediction','Real')
saveas(gcf,fullfile(['LSTM\ ' metod 'L' num2str(numLayer) 'E' num2str(numEpoch)
'\'],'Test2022_5.jpeg'));
close all

%Krypties ir intervalo prognozės kriterijø skaièiavimas
TestY=cell2mat(YTest);
TestY2022=cell2mat(YTest2022);
Atitinka2022=0; Atitinka=0;
klasifikavimas2022=0; klasifikavimas=0;
for k2022=1:length(OutTest2022_D)
    if sign(TestY2022(k2022))==sign(OutTest2022_D(k2022))
        Atitinka2022=Atitinka2022+1;
    end
    if (TestY2022(k2022)>5 && OutTest2022_D(k2022)>5) || (TestY2022(k2022)<-5 &&
OutTest2022_D(k2022)<-5) || (TestY2022(k2022)>-5 && TestY2022(k2022)<5 &&
OutTest2022_D(k2022)>-5 && OutTest2022_D(k2022)<5)
        klasifikavimas2022=klasifikavimas2022+1;
    end
end
for k=1:length(OutTest_D)
    if sign(TestY(k))==sign(OutTest_D(k))
        Atitinka=Atitinka+1;
    end
    if (TestY(k)>5 && OutTest_D(k)>5) || (TestY(k)<-5 && OutTest_D(k)<-5) ||
(TestY(k)>-5 && TestY(k)<5 && OutTest_D(k)>-5 && OutTest_D(k)<5)
        klasifikavimas=klasifikavimas+1;
    end
end

%Duomenø iðsaugojimas á Excel
A = {[ 'LSTM_VIX' repmat('+SP500',qi6) repmat('+DJI',qi5) repmat('+NASDAQ',qi4)
repmat('+GOLD',qi3) repmat('+SILVER',qi2) repmat('+OIL',qi1)], numLayer,
numEpoch, mean(info.TrainingRMSE.^2), mean(info.TrainingRMSE),
mean(cell2mat(e).^2), sqrt(mean(cell2mat(e).^2)), mean(abs(cell2mat(e))), ...
    Atitinka, (Atitinka/length(OutTest_D))*100, klasifikavimas,
(klasifikavimas/length(OutTest_D))*100, mean(cell2mat(e2022).^2),
sqrt(mean(cell2mat(e2022).^2)), mean(abs(cell2mat(e2022))), Atitinka2022,
(Atitinka2022/length(OutTest2022_D))*100, klasifikavimas2022,
(klasifikavimas2022/length(OutTest2022_D))*100,
mean(gsubtract(zeros(length(OutTest2022_D),1),OutTest2022_D).^2),
sqrt(mean(gsubtract(zeros(length(OutTest2022_D),1),OutTest2022_D).^2))};
[numbers, strings, raw] = xlsread(filename,sheet);
lastRow = size(raw, 1);
nextRow = lastRow + 1;
cellReference = sprintf('A%d', nextRow);
xlswrite(filename,A, sheet, cellReference)

```

```

%Progreso sekimas
TestY=0; TestY2022=0;
prog=prog+1;
disp(['Progress: ' num2str((prog/overl)*100) '; VIX' repmat('+SP500',qi6)
repmat('+DJI',qi5) repmat('+NASDAQ',qi4) repmat('+GOLD',qi3)
repmat('+SILVER',qi2) repmat('+OIL',qi1) 'L' num2str(numLayer) 'E'
num2str(numEpoch)])
end
end
Bi=0; Ti=0; Ti2022=0;
end
        qi6=0;
        end
        qi5=0;
        end
        qi4=0;
        end
        qi3=0;
        end
        qi2=0;
end

```

3 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant ARMA modelius, rezultatai

Modelio tipas	Mokymas				Testavimas (2021m.)				Testavimas (2021m.+2022m.)			
	RMSE	R2	MSE	MAE	RMSE	R2	MSE	MAE	RMSE	R2	MSE	MAE
Linear	8,0336	0	64,539	5,3762	9,3645	0,02	87,695	6,3129	9,1163	0,02	83,106	6,3578
Interactions Linear	8,113	-0,02	65,821	5,411	9,3496	0,03	87,415	6,2619	9,1097	0,02	82,987	6,3326
Robust Linear	8,1098	-0,02	65,77	5,3005	9,359	0,03	87,591	6,1568	9,1483	0,01	83,691	6,2461
Stepwise Linear	8,0945	-0,01	65,521	5,402	9,3275	0,03	87,002	6,2567	9,0931	0,02	82,685	6,328
Fine Tree	9,8637	-0,5	97,292	7,0251	10,738	-0,28	115,31	7,6675	10,549	-0,32	111,28	7,7227
Medium Tree	8,8841	-0,22	78,928	6,2529	9,8681	-0,08	97,38	6,7616	9,8363	-0,15	96,754	6,9746
Coarse Tree	8,4067	-0,09	70,673	5,7557	9,4175	0,01	88,69	6,4264	9,1837	0	84,341	6,4646
Linear SVM	8,0966	-0,01	65,555	5,2965	9,3733	0,02	87,858	6,1645	9,1467	0,01	83,662	6,2359
Quadratic SVM	8,171	-0,03	66,765	5,3155	9,3955	0,02	88,276	6,1363	9,1683	0	84,057	6,2171
Cubic SVM	8,723	-0,18	76,091	5,4826	9,3651	0,02	87,705	6,0415	9,1517	0,01	83,754	6,1422
Fine Gaussian SVM	8,2552	-0,05	68,148	5,5354	9,522	-0,01	90,669	6,2736	9,3341	-0,03	87,125	6,3594
Medium Gaussian SVM	8,1729	-0,03	66,796	5,355	9,3939	0,02	88,246	6,1357	9,2044	0	84,722	6,2243
Coarse Gaussian SVM	8,1054	-0,02	65,697	5,2716	9,3321	0,03	87,087	6,1117	9,1158	0,02	83,098	6,1941
Boosted Trees	8,122	-0,02	65,966	5,4554	9,4098	0,01	88,545	6,3396	9,1708	0	84,104	6,3863
Bagged Trees	8,1853	-0,04	67	5,5298	9,4223	0,01	88,779	6,446	9,165	0	83,998	6,4478
Squared Exponential GPR	8,2985	-0,06	68,865	5,5682	9,4864	0	89,992	6,3372	9,2388	-0,01	85,356	6,3858
Matern 5/2GPR	8,3522	-0,08	69,76	5,6133	9,4229	0,01	88,79	6,2567	9,1859	0	84,381	6,3141
Exponential GPR	8,237	-0,05	67,848	5,543	9,3983	0,02	88,328	6,2706	9,1942	0	84,533	6,3343
Rational Quadratic GPR	8,2734	-0,06	68,449	5,5454	9,2687	0,04	85,908	6,1837	9,0441	0,03	81,795	6,2531
Narrow Neural Network	8,2367	-0,05	67,843	5,5494	9,6858	-0,04	93,814	6,5686	9,3469	-0,03	87,365	6,541
Medium Neural Network	8,587	-0,14	73,737	5,7987	9,2549	0,05	85,654	6,2627	9,1037	0,02	82,877	6,4086
Wide Neural Network	9,9007	-0,52	98,024	6,7088	10,473	-0,22	109,67	7,144	10,352	-0,27	107,17	7,3286
Bilayered Neural Network	9,3578	-0,35	87,568	5,9316	9,4425	0,01	89,162	6,2824	9,3248	-0,03	86,951	6,4492
Trilayered Neural Network	10,288	-0,64	105,84	6,0181	10,206	-0,16	104,17	6,6755	9,8264	-0,14	96,558	6,6318

4 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant ARMAX modelius, rezultatai

Modelio tipas	Mokymas				Testavimas (2021m.)				Testavimas (2021m.+2022m.)			
	RMSE	R2	MSE	MAE	RMSE	R2	MSE	MAE	RMSE	R2	MSE	MAE
Linear	8,1046	-0,02	65,684	5,427	9,4041	0,02	88,437	6,3342	9,1147	0,02	83,079	6,333
Interactions Linear	28,327	-11,4	802,4	8,0737	11,726	-0,53	137,49	7,9455	11,394	-0,54	129,83	7,8678
Robust Linear	8,1412	-0,02	66,279	5,3249	9,359	0,03	87,591	6,1539	9,1275	0,01	83,312	6,22
Stepwise Linear	-	-	-	-	-	-	-	-	-	-	-	-
Fine Tree	10,382	-0,67	107,78	7,4764	11,879	-0,57	141,12	8,2476	11,473	-0,56	131,63	8,149
Medium Tree	9,275	-0,33	86,026	6,5526	9,9934	-0,11	99,869	7,0198	9,9754	-0,18	99,509	7,1667
Coarse Tree	8,6465	-0,16	74,762	5,9667	9,9832	-0,11	99,665	6,9388	9,8914	-0,16	97,84	7,0883
Linear SVM	8,1338	-0,02	66,159	5,3113	9,3962	0,02	88,289	6,1718	9,1554	0,01	83,821	6,2237
Quadratic SVM	27,546	-10,73	758,81	6,643	9,5895	-0,02	91,958	6,262	9,3629	-0,04	87,664	6,3162
Cubic SVM	302,9	-1416,98	91746	18,45	10,568	-0,24	111,68	6,8759	10,603	-0,33	112,43	7,1498
Fine Gaussian SVM	8,0751	-0,01	65,207	5,3287	9,4389	0,01	89,094	6,2558	9,1734	0	84,152	6,2669
Medium Gaussian SVM	8,1605	-0,03	66,594	5,3568	9,4862	0	89,988	6,2127	9,2292	-0,01	85,178	6,2391
Coarse Gaussian SVM	8,0846	0,01	65,36	5,2704	9,3488	0,03	87,401	6,1249	9,1142	0,02	83,069	6,1864
Boosted Trees	8,0958	-0,01	65,542	5,4256	9,2788	0,04	86,095	6,2553	9,047	0,03	81,848	6,3031
Bagged Trees	8,1919	-0,04	67,107	5,5231	9,3699	0,02	87,794	6,3705	9,1403	0,01	83,545	6,4035
Squared Exponential GPR	8,1196	-0,02	65,928	5,4887	9,5491	-0,01	91,185	6,4201	9,2905	-0,02	86,314	6,4718
Matern 5/2GPR	8,0697	-0,01	65,12	5,4122	9,4909	0	90,076	6,3697	9,228	-0,01	85,155	6,3679
Exponential GPR	8,0803	-0,01	65,291	5,4319	9,5581	-0,02	91,356	6,4243	9,2734	-0,02	85,997	6,4202
Rational Quadratic GPR	8,1245	-0,02	66,008	5,4884	9,5288	-0,01	90,797	6,4282	9,3085	-0,03	86,648	6,4899
Narrow Neural Network	10,177	-0,6	103,58	6,417	10,13	-0,14	102,62	6,8369	9,7551	-0,13	95,162	6,8945
Medium Neural Network	12,812	-1,54	164,13	8,0664	11,696	0,52	136,8	8,3113	11,175	-0,48	124,89	7,9204
Wide Neural Network	19,241	-4,72	370,2	11,9	14,917	-1,48	222,53	10,523	16,14	-2,09	260,49	12,322
Bilayered Neural Network	15,911	-2,91	253,15	7,0421	14,17	-1,23	200,8	8,1972	11,431	-0,55	130,67	7,5936
Trilayered Neural Network	13,952	-2,01	194,66	7,2794	11,179	-0,39	124,96	7,5713	10,658	-0,35	113,6	7,1655

5 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant ARMA modelius, rezultatai

Modelio tipas	Mokymas				Testavimas (2021m.)				Testavimas (2021m.+2022m.)			
	RMSE	R2	MSE	MAE	RMSE	R2	MSE	MAE	RMSE	R2	MSE	MAE
Linear	17,108	0,01	292,7	11,904	17,324	0,07	300,13	13,045	17,466	0,05	305,07	12,903
Interactions Linear	17,444	-0,03	304,29	12,111	17,984	0	323,43	13,736	18,022	-0,01	324,8	13,59
Robust Linear	17,334	-0,02	300,48	11,642	17,312	0,07	299,7	12,764	17,525	0,04	307,13	12,786
Stepwise Linear	17,24	-0,01	297,21	12,02	17,863	0,01	319,07	13,515	17,87	0,01	319,33	13,341
Fine Tree	20,392	-0,41	415,85	14,812	24,161	-0,81	583,76	17,336	22,543	-0,58	508,19	16,321
Medium Tree	19,005	-0,23	361,18	13,511	19,994	-0,24	399,77	14,981	19,218	-0,15	369,35	14,601
Coarse Tree	17,73	-0,07	314,36	12,405	17,899	0,01	320,37	12,506	17,816	0,01	317,41	12,339
Linear SVM	17,45	-0,03	304,51	11,622	17,61	0,04	310,13	12,809	17,827	0,01	317,81	12,846
Quadratic SVM	17,532	-0,04	307,35	11,629	18,932	-0,11	358,42	13,831	18,956	-0,12	359,34	13,812
Cubic SVM	20,521	-0,43	421,11	12,744	17,476	0,06	305,4	12,825	17,766	0,02	315,64	12,855
Fine Gaussian SVM	17,195	0	295,65	11,628	18,101	-0,01	327,63	12,788	18,332	-0,05	336,06	12,776
Medium Gaussian SVM	17,347	-0,02	300,9	11,513	17,684	0,03	312,74	12,643	18,039	-0,01	325,42	12,783
Coarse Gaussian SVM	17,378	-0,03	301,99	11,539	17,732	0,03	314,43	12,902	17,892	0	320,11	12,89
Boosted Trees	17,558	-0,05	308,28	12,216	18,299	-0,04	334,84	13,639	18,124	-0,02	328,49	13,25
Bagged Trees	17,22	-0,01	296,52	11,95	17,834	0,02	318,04	13,186	17,644	0,03	311,32	12,943
Squared Exponential GPR	17,043	0,01	290,45	11,741	18,186	0,09	295,35	12,624	17,305	0,07	299,46	12,503
Matern 5/2GPR	17,067	0,01	291,27	11,787	17,185	0,09	295,33	12,662	17,304	0,07	299,42	12,511
Exponential GPR	17,106	0,01	292,61	11,837	17,213	0,08	296,27	12,686	17,332	0,07	300,41	12,516
Rational Quadratic GPR	17,119	0	293,07	11,867	17,186	0,09	295,35	12,624	17,305	0,07	299,46	12,503
Narrow Neural Network	18,779	-0,2	352,64	13,007	22,243	-0,53	494,75	16,508	21,989	-0,5	483,5	16,331
Medium Neural Network	21,45	-0,56	460,11	15,251	21,331	-0,41	454,99	15,488	22,18	-0,53	491,97	16,64
Wide Neural Network	32,633	-2,62	1064,9	22,656	31,581	-2,08	997,35	24,827	30,608	-1,92	936,82	24,496
Bilayered Neural Network	24,954	-1,12	622,69	15,349	23,05	-0,64	531,32	16,532	22,441	-0,57	503,58	15,842
Trilayered Neural Network	25,957	-1,29	673,74	15,781	55,206	-8,43	3047,7	21,295	50,561	-6,96	2556,5	20,051

6 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant ARMAX modelius, rezultatai

Modelio tipas	Mokymas				Testavimas (2021m.)				Testavimas (2021m.+2022m.)			
	RMSE	R2	MSE	MAE	RMSE	R2	MSE	MAE	RMSE	R2	MSE	MAE
Linear	17,696	-0,07	313,13	12,456	16,905	0,12	285,78	12,437	17,268	0,07	298,2	12,489
Interactions Linear	663,46	-1500,72	440179	281,66	49,017	-6,43	2402,7	40,156	63,379	-11,5	4016,9	49,305
Robust Linear	17,69	-0,07	312,93	12,126	17,095	0,1	292,23	12,83	17,313	0,07	299,73	12,972
Stepwise Linear	-	-	-	-	-	-	-	-	-	-	-	-
Fine Tree	21,613	-0,59	467,13	15,709	20,575	-0,31	423,33	15,203	23,101	-0,66	533,66	17,836
Medium Tree	19,336	-0,28	373,88	13,864	20,054	-0,24	402,15	15,21	19,021	-0,13	361,78	14,514
Coarse Tree	17,502	-0,05	306,31	12,357	18,594	-0,07	345,72	13,601	18,712	-0,09	350,14	13,72
Linear SVM	17,721	-0,07	314,04	12,032	17,584	0,04	309,19	13,094	17,718	0,02	313,94	13,084
Quadratic SVM	20,367	-0,42	414,82	13,561	18,197	-0,02	331,14	13,377	19,288	-0,16	372,01	14,296
Cubic SVM	29,033	-1,88	842,89	16,203	18,496	-0,06	342,09	13,629	20,98	-0,37	440,16	15,905
Fine Gaussian SVM	17,182	-0,01	295,21	11,608	17,959	0	322,54	12,987	17,969	0	322,88	12,808
Medium Gaussian SVM	17,168	-0,01	294,73	11,449	17,502	0,05	306,33	12,995	17,873	0,01	319,45	13,142
Coarse Gaussian SVM	17,344	-0,03	300,82	11,65	17,52	0,05	306,95	12,828	17,696	0,03	313,13	12,844
Boosted Trees	17,185	-0,01	295,32	12,072	17,797	0,02	316,73	13,344	17,75	0,02	315,08	13,319
Bagged Trees	17,369	-0,03	301,69	12,225	17,477	0,06	305,45	12,994	17,486	0,05	305,77	12,816
Squared Exponential GPR	16,975	0,02	288,15	11,808	17,179	0,09	295,12	12,809	17,282	0,07	298,65	12,547
Matern 5/2GPR	16,975	0,02	288,14	11,815	17,165	0,09	294,65	12,809	17,28	0,07	298,58	12,551
Exponential GPR	16,98	0,02	288,31	11,821	17,176	0,09	295	12,821	17,295	0,07	299,12	12,569
Rational Quadratic GPR	16,999	0,01	288,96	11,828	17,179	0,09	295,12	12,809	17,282	0,07	298,65	12,547
Narrow Neural Network	33,149	-2,75	1098,9	24,353	24,025	-0,79	577,22	19,239	24,243	-0,83	587,74	19,084
Medium Neural Network	37,058	-3,69	1373,3	27,629	33,493	-2,47	1121,8	27,613	38,366	-3,58	1471,9	31,317
Wide Neural Network	29,345	-1,94	861,12	21,167	24,617	-0,87	605,97	19,389	28,107	-1,46	789,99	21,861
Bilayered Neural Network	47,799	-6,79	2284,8	24,037	45,804	-5,49	2098	24,245	42,833	-4,71	1834,7	23,619
Trilayered Neural Network	58,503	-10,68	3422,6	24,368	46,997	-5,83	2208,8	22,362	42,893	-4,73	1839,8	21,239

7 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant NARMA modelius, rezultatai

Įėjimai	Neuronų skaičius	Mokymas			Testavimas (2021m.)			Testavimas (2021m.+2022m.)		
		R	MSE	MAE	MSE	R	MAE	MSE	R	MAE
VIX	1	0,0963	64,1724	5,3719	90,0098	-0,0055	6,3607	84,5013	-0,0043	6,3696
VIX	2	0,1079	64,0835	5,3688	90,7287	-0,0492	6,3943	85,1923	-0,0482	6,3985
VIX	3	0,0644	65,2112	5,3292	89,5544	0,0665	6,2568	84,3372	0,0720	6,2746
VIX	4	0,0712	64,4313	5,3499	87,4015	0,1889	6,2434	82,4651	0,1625	6,2774
VIX	5	0,1032	63,9949	5,3713	88,0878	0,1118	6,2798	83,2217	0,0817	6,3267
VIX	6	0,0885	65,1270	5,5716	90,0466	0,0418	6,5121	84,8916	0,0255	6,5263
VIX	7	0,1617	63,3116	5,3513	91,3082	-0,0088	6,2968	85,9167	-0,0139	6,3405
VIX	8	0,2094	62,8291	5,3158	96,4336	0,0061	6,5464	89,2521	0,0247	6,5039
VIX	9	0,0944	64,5798	5,3440	93,2403	-0,1382	6,4350	87,5020	-0,1319	6,4308
VIX	10	0,2176	61,9931	5,3653	99,1676	-0,1041	6,6203	90,9176	-0,0582	6,5362
VIX	11	0,0958	65,0403	5,5576	90,0994	0,0548	6,4236	84,8297	0,0488	6,4698
VIX	12	0,1174	64,5197	5,3215	89,4467	0,0490	6,2965	84,0885	0,0503	6,3144
VIX	13	0,1860	62,8005	5,3242	90,1246	0,0203	6,3683	84,3170	0,0460	6,3866
VIX	14	0,1710	63,2178	5,3005	90,3631	-0,0156	6,3185	84,7860	-0,0052	6,3340
VIX	15	0,1841	62,8571	5,4017	90,6662	0,0244	6,4122	85,1161	0,0226	6,4258

8 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant NARMAX modelius, rezultatai (20 tiksliausių)

Įėjimai	Neuronų skaičius	Mokymas			Testavimas (2021m.)			Testavimas (2021m.+2022m.)		
		R	MSE	MAE	MSE	R	MAE	MSE	R	MAE
VIX+DJI+OIL	15	0,1731	64,5635	5,2974	91,4344	0,0518	6,1743	85,8354	0,0689	6,2221
VIX+SP500+OIL	10	0,2046	66,5061	5,3028	87,8527	0,1285	6,1753	83,0658	0,1117	6,2087
VIX+SP500+DJI+OIL	9	0,2298	62,2270	5,2695	89,0106	0,0947	6,1760	83,6677	0,1003	6,2153
VIX+SP500+DJI+SILVER	13	0,1186	63,8463	5,3667	88,0292	0,1103	6,1853	83,0134	0,1001	6,2279
VIX+DJI+NASDAQ	5	0,1240	64,6091	5,3117	88,9383	0,0892	6,1932	83,6421	0,0952	6,2300
VIX+SP500+DJI+OIL	8	0,1455	64,0482	5,3262	89,3370	0,0514	6,2038	84,5315	0,0319	6,2618
VIX+NASDAQ+GOLD	8	0,1753	63,7645	5,2913	89,1269	0,0917	6,2044	84,4676	0,0707	6,2461
VIX+SP500+DJI+NASDAQ+GOLD+OIL	5	0,2247	62,4437	5,3142	87,3023	0,1424	6,2069	82,0060	0,1476	6,2192
VIX+SP500+DJI	7	0,1884	62,9746	5,3302	88,2088	0,1005	6,2073	83,3093	0,0851	6,2630
VIX+DJI+OIL	7	0,1869	64,3841	5,3756	86,7462	0,1692	6,2103	81,8794	0,1531	6,2645
VIX+SP500+NASDAQ	4	0,0726	64,6559	5,3366	88,0532	0,1270	6,2103	82,7728	0,1298	6,2335
VIX+DJI+NASDAQ+SILVER	9	0,2154	63,1183	5,2660	91,1181	0,0454	6,2129	86,5357	0,0392	6,2447
VIX+DJI+NASDAQ+GOLD+OIL	13	0,1211	64,9574	5,3224	89,0551	0,0782	6,2163	83,3428	0,1123	6,2154
VIX+NASDAQ+GOLD+OIL	4	0,1835	63,4469	5,2896	88,8333	0,0978	6,2173	84,0309	0,0871	6,2358
VIX+DJI+NASDAQ+GOLD+SILVER+OIL	4	0,1123	64,4070	5,3266	88,0109	0,1216	6,2214	83,4740	0,0963	6,2413
VIX+NASDAQ+OIL	8	0,2057	62,6435	5,3527	87,3706	0,1400	6,2215	82,1940	0,1377	6,2357
VIX+SP500+NASDAQ+GOLD+SILVER	4	0,1185	64,2066	5,3151	87,3074	0,1522	6,2225	82,5091	0,1341	6,2274
VIX+OIL	11	0,2000	62,8886	5,3026	88,4912	0,1001	6,2231	82,9586	0,1138	6,2408
VIX+DJI+NASDAQ+GOLD	9	0,1245	65,5187	5,3605	90,9640	0,0372	6,2233	85,3454	0,0594	6,2458
VIX+DJI+NASDAQ	3	0,1364	64,1435	5,3414	87,3789	0,1478	6,2233	82,2762	0,1418	6,2428

9 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant NARMA modelius, rezultatai

Įėjimai	Neuronų skaičius	Mokymas			Testavimas (2021m.)			Testavimas (2021m.+2022m.)		
		R	MSE	MAE	MSE	R	MAE	MSE	R	MAE
VIX	1	0,0966	290,4974	11,7633	317,1947	0,2782	12,8909	317,6556	0,2122	12,8497
VIX	2	0,0898	291,3957	11,8581	327,7258	0,1431	13,2854	325,8677	0,0771	13,1492
VIX	3	0,2268	280,3666	11,5586	333,3689	0,0741	13,1118	329,5282	0,0802	13,1277
VIX	4	0,1652	285,5011	11,6093	334,4892	0,0601	13,6510	334,0266	0,0402	13,5806
VIX	5	0,1983	290,2819	11,8752	331,8251	0,0860	13,3854	345,8870	-0,0166	13,8072
VIX	6	0,2283	285,2703	11,5043	330,9855	0,0927	13,0484	336,6936	0,0179	12,9527
VIX	7	0,1490	287,3165	11,6202	355,2682	-0,1133	13,8507	354,8298	-0,1242	13,8323
VIX	8	0,2806	271,7868	11,4660	339,6928	0,0949	13,5308	346,3856	0,0377	13,4968
VIX	9	0,3509	257,1961	11,2056	333,1981	0,1416	13,4851	343,2841	0,1075	14,1492
VIX	10	0,1914	285,2729	11,9487	336,5265	0,0307	13,6809	331,4147	0,0381	13,3095
VIX	11	0,2446	280,2491	11,8456	374,3624	-0,1242	14,5727	392,3468	-0,2018	15,1424
VIX	12	0,0211	344,9770	13,5807	451,7923	-0,2287	16,5885	478,5077	-0,2795	17,0768
VIX	13	0,3688	258,3624	11,3193	386,9109	-0,0030	14,7526	384,6961	0,0241	15,1442
VIX	14	0,3093	274,0311	11,3308	416,4708	-0,1061	15,2602	422,9882	-0,1063	15,4257
VIX	15	0,3924	274,9589	11,0636	358,0015	0,1003	13,6582	466,3358	0,0275	15,1932

10 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant NARMAX modelius, rezultatai (20 tiksliausių)

Įėjimai	Neuronų skaičius	Mokymas			Testavimas (2021m.)			Testavimas (2021m.+2022m.)		
		R	MSE	MAE	MSE	R	MAE	MSE	R	MAE
VIX+DJI+NASDAQ+GOLD+SILVER+OIL	10	0,0554	308,4734	12,3308	314,6637	0,2308	12,4887	302,9675	0,2766	12,1392
VIX+NASDAQ+OIL	4	0,2113	281,6600	11,6142	311,4919	0,2491	12,2771	311,5493	0,2313	12,1584
VIX+SP500+GOLD	4	0,0701	295,2214	11,7513	321,6171	0,2080	12,5770	320,7042	0,1904	12,4355
VIX+SP500+NASDAQ+GOLD+SILVER+OIL	12	0,1541	291,2242	12,2091	302,9229	0,3084	12,3638	302,8917	0,2769	12,4637
VIX+NASDAQ	4	0,2224	279,7374	11,7102	314,8589	0,2262	12,5854	311,1953	0,2232	12,4829
VIX+DJI+NASDAQ+SILVER	11	0,2362	279,9264	11,7101	304,5205	0,2846	12,5389	300,8577	0,2885	12,4878
VIX+DJI+NASDAQ+GOLD+SILVER+OIL	14	0,1655	285,3011	11,7579	298,8832	0,3558	12,6706	292,4498	0,3762	12,5269
VIX+SP500+NASDAQ	9	0,2130	280,3496	11,8024	305,3665	0,3357	12,3577	312,2579	0,2191	12,5311
VIX+NASDAQ+GOLD+OIL	4	0,1900	284,7073	11,6452	324,8901	0,1394	12,6546	316,7479	0,2012	12,5353
VIX+SP500+DJI+NASDAQ+OIL	8	0,2127	284,4469	12,0952	318,9811	0,2132	13,0363	307,5695	0,2567	12,5395
VIX+NASDAQ+GOLD+SILVER	13	0,0981	296,1148	11,7924	325,5434	0,1472	12,7599	318,3628	0,1978	12,5469
VIX+DJI+NASDAQ+GOLD+SILVER	11	0,3313	264,7774	11,3333	310,4110	0,2595	12,8378	303,5080	0,2727	12,5639
VIX+SP500+DJI+GOLD+SILVER	5	0,0089	296,5502	11,8606	317,7042	0,2419	12,8995	316,7637	0,2132	12,5963
VIX+SP500+DJI+GOLD+OIL	13	0,0247	307,0113	12,3914	336,7036	0,0894	13,1746	327,9466	0,1422	12,6163
VIX+SP500+DJI+GOLD+SILVER	8	0,2629	276,6960	11,4279	317,8427	0,2029	12,5563	319,0363	0,1634	12,6190
VIX+SP500+NASDAQ+SILVER+OIL	7	0,0311	321,6985	12,3179	326,4881	0,1761	12,8827	321,2838	0,1900	12,6317
VIX+SP500+GOLD+SILVER	12	-0,0017	302,1599	11,9950	330,6511	0,0898	12,7328	327,8374	0,0797	12,6378
VIX+SP500+DJI+NASDAQ+SILVER	5	0,3317	265,8214	11,4761	308,9169	0,2629	12,9148	304,4402	0,2673	12,6417
VIX+SP500+SILVER	12	0,4066	252,2604	10,7272	324,2143	0,1781	12,9183	318,3090	0,1951	12,6435
VIX+NASDAQ+SILVER	4	0,2160	281,6204	11,5325	329,0993	0,0972	12,7922	330,4902	0,0537	12,6652

11 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant LSTM modelius tik su VIX įėjimais, rezultatai (20 tiksliausių)

Įėjimai	LSTM sluoksniai	Iteracijos	Mokymas		Testavimas (2021m.)			Testavimas (2021m.+2022m.)		
			MSE	RMSE	MSE	RMSE	MAE	MSE	RMSE	MAE
VIX	210	30	61,9142	7,7603	86,2116	9,2850	6,2123	82,1823	9,0654	6,2796
VIX	210	40	61,2883	7,7174	86,5973	9,3058	6,2147	82,7878	9,0988	6,2906
VIX	240	40	61,0526	7,6999	86,1844	9,2836	6,2236	82,3698	9,0758	6,2942
VIX	240	30	61,9763	7,7609	86,6852	9,3105	6,2362	82,4660	9,0811	6,2920
VIX	120	40	61,7378	7,7455	86,7523	9,3141	6,2393	82,3301	9,0736	6,2777
VIX	150	30	62,0653	7,7611	86,4719	9,2990	6,2410	82,3072	9,0723	6,3022
VIX	30	500	56,0896	7,3862	88,3550	9,3997	6,2452	84,3755	9,1856	6,3445
VIX	180	50	60,6474	7,6788	87,3567	9,3465	6,2512	83,1322	9,1177	6,3049
VIX	150	50	61,0252	7,7029	86,8475	9,3192	6,2525	82,9556	9,1080	6,3111
VIX	90	50	61,5348	7,7373	87,0372	9,3294	6,2542	82,8705	9,1033	6,3127
VIX	120	50	61,3622	7,7224	87,5258	9,3555	6,2557	83,0644	9,1140	6,3005
VIX	150	40	61,4383	7,7262	87,4329	9,3506	6,2626	83,1845	9,1206	6,3140
VIX	180	30	62,1485	7,7696	86,7520	9,3141	6,2631	82,5827	9,0875	6,3137
VIX	90	40	62,1355	7,7674	87,2092	9,3386	6,2632	82,9069	9,1053	6,3175
VIX	240	50	60,4791	7,6709	87,8677	9,3738	6,2677	83,8666	9,1579	6,3270
VIX	150	20	62,7251	7,8074	87,1503	9,3354	6,2684	82,7879	9,0988	6,3237
VIX	210	20	62,5966	7,7960	86,7255	9,3127	6,2713	82,5477	9,0856	6,3334
VIX	180	40	61,3155	7,7141	87,7157	9,3657	6,2734	83,5719	9,1418	6,3186
VIX	150	150	55,8843	7,3737	89,3124	9,4505	6,2744	85,1387	9,2271	6,3448
VIX	60	50	62,1425	7,7659	87,7911	9,3697	6,2806	83,2322	9,1232	6,3113

12 priedas. Sekančios dienos VIX indekso prognozavimo, naudojant LSTM modelius su VIX ir kitais įėjimais, rezultatai (20 tiksliausių)

Įėjimai	LSTM sluoksniai	Iteracijos	Mokymas		Testavimas (2021m.)			Testavimas (2021m.+2022m.)		
			MSE	RMSE	MSE	RMSE	MAE	MSE	RMSE	MAE
VIX+SP500+NASDAQ+SILVER	30	100	56,6826	7,4052	86,8470	9,3192	6,0908	83,3783	9,1312	6,1832
VIX+SP500+NASDAQ+GOLD+SILVER+OIL	240	10	61,8872	7,7631	87,3141	9,3442	6,2120	83,2999	9,1269	6,2879
VIX+OIL	240	30	59,7451	7,6162	86,5351	9,3024	6,2128	82,7400	9,0962	6,2979
VIX+SILVER	180	20	61,9746	7,7523	86,9177	9,3230	6,2173	83,3746	9,1310	6,3239
VIX+DJI+SILVER+OIL	240	10	62,3365	7,7657	87,0844	9,3319	6,2191	82,9261	9,1064	6,3034
VIX+SP500+SILVER+OIL	210	10	62,3825	7,7742	86,9600	9,3252	6,2250	83,0802	9,1148	6,3171
VIX+SP500+DJI+NASDAQ	60	50	59,9566	7,6297	86,8927	9,3216	6,2254	81,7869	9,0436	6,2315
VIX+SP500+NASDAQ+SILVER	210	10	62,5862	7,7982	87,5264	9,3556	6,2278	83,0695	9,1142	6,2764
VIX+SP500+NASDAQ+GOLD+OIL	180	20	59,6743	7,6095	87,8386	9,3722	6,2280	83,7807	9,1532	6,2934
VIX+SP500+SILVER	180	20	60,9148	7,6920	87,1775	9,3369	6,2316	83,3398	9,1291	6,3167
VIX+NASDAQ+SILVER+OIL	240	20	59,0489	7,5733	87,3972	9,3486	6,2321	83,9598	9,1630	6,3178
VIX+NASDAQ	60	30	62,4157	7,7882	86,7372	9,3133	6,2325	81,8064	9,0447	6,2393
VIX+SP500+SILVER+OIL	120	20	60,5055	7,6616	87,4233	9,3500	6,2337	83,2293	9,1230	6,3025
VIX+SP500+SILVER+OIL	30	50	59,9229	7,6267	87,7409	9,3670	6,2341	84,2685	9,1798	6,3516
VIX+SP500+DJI+NASDAQ+GOLD+SILVER+OIL	240	10	61,6666	7,7319	87,6964	9,3646	6,2349	83,6215	9,1445	6,3049
VIX+SILVER+OIL	150	30	58,7236	7,5513	87,1963	9,3379	6,2354	84,3664	9,1851	6,3950
VIX+SP500	120	30	61,7019	7,7318	86,4465	9,2977	6,2363	82,1333	9,0627	6,2830
VIX+SP500+DJI+NASDAQ+SILVER	240	10	62,4819	7,7831	87,0745	9,3314	6,2372	82,5303	9,0846	6,2719
VIX+SP500+NASDAQ+SILVER+OIL	180	20	59,7937	7,6130	87,9197	9,3766	6,2373	83,9053	9,1600	6,2929
VIX+SILVER+OIL	150	20	60,8007	7,6849	87,1877	9,3374	6,2382	83,5867	9,1426	6,3442

13 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant LSTM modelius tik su VIX įėjimais, rezultatai (20 tiksliausių)

Įėjimai	LSTM sluoksniai	Iteracijos	Mokymas		Testavimas (2021m.)			Testavimas (2021m.+2022m.)		
			MSE	RMSE	MSE	RMSE	MAE	MSE	RMSE	MAE
VIX	30	1000	225,9355	14,8531	316,5406	17,7916	12,7760	317,4887	17,8182	12,6973
VIX	120	40	277,7287	16,4812	314,7676	17,7417	13,0787	315,0601	17,7499	12,7880
VIX	30	30	287,6027	16,7920	312,5217	17,6783	12,9663	313,9275	17,7180	12,7923
VIX	30	350	256,6351	15,8565	312,8195	17,6867	12,9258	316,2268	17,7828	12,7927
VIX	30	20	289,5510	16,8857	320,9085	17,9139	13,0481	320,3940	17,8996	12,8057
VIX	30	50	285,7546	16,7445	312,2465	17,6705	13,0003	313,5486	17,7073	12,8241
VIX	30	200	266,5879	16,1533	304,2791	17,4436	12,8605	310,1483	17,6110	12,8278
VIX	60	30	285,8968	16,7402	315,6046	17,7653	13,0687	317,0314	17,8054	12,8310
VIX	240	10	285,2346	16,7054	314,8951	17,7453	13,0767	316,4476	17,7890	12,8337
VIX	60	20	286,7247	16,7679	317,1467	17,8086	13,1160	317,6240	17,8220	12,8387
VIX	60	40	282,1109	16,6300	313,6760	17,7109	13,1474	314,7074	17,7400	12,8484
VIX	30	100	278,3576	16,5090	309,9621	17,6057	13,0323	313,5292	17,7068	12,8504
VIX	30	40	285,9228	16,7326	315,0110	17,7485	13,1024	314,0128	17,7204	12,8522
VIX	180	20	279,8493	16,5873	315,0351	17,7492	13,1520	315,8445	17,7720	12,8537
VIX	150	10	292,6430	16,9778	316,1627	17,7810	13,1213	316,7192	17,7966	12,8675
VIX	90	10	292,2347	16,8200	319,2298	17,8670	13,1052	319,5621	17,8763	12,8717
VIX	120	10	286,7732	16,8040	317,0197	17,8050	13,1004	317,5321	17,8194	12,8821
VIX	150	40	271,9526	16,3261	314,6924	17,7396	13,1549	316,2850	17,7844	12,8894
VIX	90	40	280,7918	16,6007	314,2454	17,7270	13,1772	314,8333	17,7435	12,8950
VIX	90	50	277,4247	16,4974	314,1400	17,7240	13,2029	314,3610	17,7302	12,8953

14 priedas. Sekančios savaitės VIX indekso prognozavimo, naudojant LSTM modelius su VIX ir kitais įėjimais, rezultatai (20 tiksliausių)

Įėjimai	LSTM sluoksniai	Iteracijos	Mokymas		Testavimas (2021m.)			Testavimas (2021m.+2022m.)		
			MSE	RMSE	MSE	RMSE	MAE	MSE	RMSE	MAE
VIX+SP500+NASDAQ+GOLD	30	250	242,8015	15,3871	265,1277	16,2827	12,0266	285,0305	16,8828	12,1875
VIX+NASDAQ	30	300	248,9979	15,5895	272,5086	16,5078	12,1244	292,7816	17,1109	12,2384
VIX+SP500+DJI+NASDAQ	60	300	214,3162	14,4117	284,3153	16,8617	12,1740	305,4879	17,4782	12,6620
VIX+DJI+NASDAQ	30	500	219,2583	14,5793	276,3627	16,6242	12,2086	296,1458	17,2089	12,7063
VIX+SP500+DJI+NASDAQ	30	750	191,6768	13,5603	301,1619	17,3540	12,2637	326,0121	18,0558	12,8423
VIX+SP500+NASDAQ	30	350	242,5038	15,3815	269,9062	16,4288	12,2642	284,5139	16,8675	12,4824
VIX+SP500+DJI+NASDAQ+SILVER	30	250	234,9644	15,1107	270,3625	16,4427	12,2731	280,9607	16,7619	12,3735
VIX+NASDAQ+GOLD+OIL	30	350	213,3405	14,3545	283,1695	16,8276	12,3138	298,6426	17,2813	12,6447
VIX+SP500+NASDAQ+GOLD+OIL	30	250	226,7704	14,8357	268,5142	16,3864	12,3572	278,0482	16,6748	12,4434
VIX+SP500+NASDAQ+GOLD+SILVER	30	350	218,4214	14,5322	279,1893	16,7090	12,3721	301,4235	17,3616	12,5934
VIX+SP500+DJI+NASDAQ	30	300	240,3538	15,2920	283,4585	16,8362	12,3816	300,1234	17,3241	12,6167
VIX+DJI+NASDAQ+GOLD+OIL	30	350	204,7078	14,0271	276,0518	16,6148	12,3887	298,8420	17,2870	12,9448
VIX+SP500+DJI+NASDAQ+GOLD+SILVER	60	150	226,6000	14,8110	279,7004	16,7242	12,4090	288,0660	16,9725	12,5321
VIX+SP500+DJI+NASDAQ+GOLD+SILVER+OIL	30	150	248,6050	15,5621	283,4746	16,8367	12,4268	290,2507	17,0367	12,2764
VIX+NASDAQ	30	750	203,5505	14,0353	303,4576	17,4200	12,4274	333,9020	18,2730	13,2204
VIX+SP500+DJI+GOLD+SILVER+OIL	30	500	175,7889	12,8948	252,9369	15,9040	12,4275	288,9806	16,9994	13,1114
VIX+DJI+NASDAQ	60	200	241,0245	15,3365	285,2339	16,8889	12,4479	301,2159	17,3556	12,5779
VIX+NASDAQ+OIL	90	150	220,4167	14,6163	278,6675	16,6933	12,4553	292,6959	17,1084	12,8539
VIX+DJI+NASDAQ	120	150	229,6163	14,9583	295,5120	17,1905	12,4559	313,8242	17,7151	12,8782
VIX+SP500+NASDAQ+GOLD+SILVER	30	750	156,1453	12,0464	304,8358	17,4595	12,4604	335,8479	18,3262	13,3499