



VILNIAUS UNIVERSITETAS
MATEMATIKOS IR INFORMATIKOS FAKULTETAS
INFORMATIKOS INSTITUTAS
KOMPIUTERINIO IR DUOMENŲ MODELIAVIMO KATEDRA

Magistro baigiamasis darbas

**Sistemos mokymosi algoritmai duomenų klasifikavimui ir
prognozavimui**

Atliko:

Svajūnas Mazėtis

parašas

Vadovas:

prof. dr. Tadas Meškauskas

Vilnius
2019

Turinys

Sutartinis terminų žodynas	4
Santrauka	5
Summary	6
Įvadas	7
1. Kintamumo apibrėžimas	9
1.1. Kas yra kintamumas?	9
1.2. Kintamumo skaičiavimas	9
2. Kintamumo prognozavimo metodai	10
2.1. Susijusių darbų apžvalga	10
2.2. ARMA šeimos metodai	11
2.3. GARCH metodai	13
2.4. Neuroninių tinklų metodai	13
2.4.1. Dirbtiniai neuroniniai tinklai	13
2.4.2. Aktyvacijos funkcija	14
2.4.3. Neuroninių tinklų tipai	16
2.4.4. LSTM rekurentinis neuroninis tinklas	17
2.4.5. Dirbtinių neuroninių tinklų apmokymas	18
2.4.6. Klaidos sklidimo atgal algoritmas	18
2.5. Logistinė regresija	18
3. Eksperimentinės dalies rezultatų vertinimo metodologija	19
3.1. Šaknis iš vidutinės kvadratinės paklaidos (RMSE)	19
3.2. Vidutinė absoliuti procentinė paklaida (MAPE)	20
3.3. ROC analizė	20
3.3.1. Klaidų matrica	21
3.3.2. ROC erdvė	22
3.3.3. ROC kreivė	23
4. Kintamumo prognozavimo eksperimentai ir jų vertinimas	24
4.1. Valiutų kurso duomenys pirminiams eksperimentams	24
4.2. Pirminis metodų tyrimas naudojant valiutų kurso duomenis	24
4.2.1. ARIMA metodų tyrimas	25
4.2.2. LSTM metodų tyrimas	28
4.2.3. Logistinės regresijos metodo tyrimas	32
4.3. Naudojami duomenys	33
4.4. Signalų klasifikavimas remiantis Hursto eksponente ir autokoreliacija	35
4.4.1. Hursto eksponentė	36
4.4.2. Autokoreliacija	38
4.5. Finansinių ir kvazi-periodinių signalų kintamumų prognozavimo eksperimentai	39
4.5.1. LSTM metodų tyrimas	39
4.5.2. ARIMA metodų tyrimas	42
4.6. Kintamumų pokyčių prognozavimas remiantis tiesioginėmis signalų reikšmėmis	45

4.7. Kintamumų prognozavimas keletą žingsnių į priekį	47
4.7.1. LSTM metodai	47
4.7.2. ARIMA metodai	51
4.8. Ilgalaikės kintamumo krypties prognozavimas naudojant LSTM metodus	56
4.8.1. Mažiausių kvadratų metodas	56
4.8.2. Ilgalaikės kintamumo krypties prognozavimas remiantis kintamumo reikšmėmis	57
4.8.3. Ilgalaikės kintamumo krypties prognozavimas remiantis tiesioginėmis reikšmėmis	57
4.8.4. Ilgalaikės kintamumo krypties prognozavimas remiantis Hursto eksponentėmis	58
Išvados ir rekomendacijos	60
Ateities tyrimų gairės	62
Literatūros šaltiniai	63
Priedai	66
A. LSTM metodų keleto žingsnių prognozių eksperimentų rezultatai	67
B. ARIMA metodų keleto žingsnių prognozių eksperimentų rezultatai	71
C. LSTM metodų eksperimentų rezultatai remiantis tiesioginėmis signalo reikšmėmis	75
D. Ilgalaikės kintamumo krypties prognozavimo eksperimentų rezultatai	76

Sutartinis terminų žodynas

1. Kintamumas (angl. *volatility*) – finansų srityje apibrėžiamas kaip kainų ar pajamų nepastovumas.
2. ARMA (angl. *Auto-Regressive Moving Average*) – autoregresinis slenkančio vidurkio laiko eilučių modelis.
3. ARIMA (angl. *Auto-Regressive Integrated Moving Average*) – autoregresinis integruoto slenkančio vidurkio modelis.
4. GARCH (angl. *Generalized Auto-Regressive Conditional Heteroskedasticity*) – autoregresinis sąlyginio heteroskedastiškumo modelis.
5. NNR (angl. *Neural Network Regression*) – regresiniai neuroniniai tinklai.
6. RNN (angl. *Recurrent Neural Networks*) – rekurentiniai neuroniniai tinklai.
7. ANN (angl. *Artificial Neural Networks*) – dirbtiniai neuroniniai tinklai.
8. Aktyvacijos funkcija (angl. *activation function*) – privalomas dirbtinių neuroninių tinklų, kurie apmokami atkurti netiesinius modelius, parametras.
9. LSTM (angl. *Long Short Term Memory*) – ilgos trumpalaikės atminties neuroniniai tinklai.
10. Logistinė regresija (angl. *logistic regression*) – statistinis modelis, kai vienam dažniausiai dvinariam (angl. *binary*) dydžiui (priklausomajam) daro įtaką vienas ar keli nepriklausomi kintamieji.
11. MSE (angl. *Mean Squared Error*) – vidutinė kvadratinė paklaida.
12. RMSE (angl. *Root Mean Squared Error*) – šaknis iš vidutinės kvadratinės paklaidos.
13. MPE (angl. *Mean Percentage Error*) – vidutinė procentinė paklaida.
14. MAPE (angl. *Mean Absolute Percentage Error*) – vidutinė absoliuti procentinė paklaida.
15. ROC (angl. *Receiver Operating Characteristic*) kreivė – grafikas, kuris parodo klasifikatoriaus jautrumo ir specifiškumo sąryšį.
16. AUC (angl. *Area Under the Curve*) – plotas po ROC kreive.
17. Autokoreliacija (angl. *autocorrelation*) – signalo koreliacijos funkcija su pačiu savimi.

Santrauka

Darbe analizuojami kintamumo prognozavimo metodai. Aprašomos kintamumo prognozavimui naudojamos metodikos: ARIMA, GARCH, dirbtinių neuroninių tinklų (vienas iš jų LSTM modelis) bei logistinės regresijos metodika. Pateikiama metodikų vertinimo metodologija: RMSE, MAPE ir ROC analizė. Atliekami eksperimentai, kurių metu, pasitelkiant faktinius kintamumo duomenis, pradinės signalo reikšmes (pvz. akcijų kainas), išvestinį dydį - Hursto eksponentę, buvo prognozuojama sekanti kintamumo reikšmė bei ilgalaikio kintamumo judėjimo kryptis. Gauti eksperimentų rezultatai parodė, kad kintamumų prognozuojamumas priklauso nuo signalų kilmės. Kvazi-periodinių signalų rezultatai, gauti eksperimentų metu, buvo geresni nei finansinių signalų, kurių kitos kintamumo reikšmės krypties prognozavimo tikslumas buvo tik nežymiai geresnis už atsitiktinio spėjimo. Ilgalaikės kintamumo krypties prognozių rezultatai buvo geresni nei tik kitos reikšmės prognozių. Kintamumo kryptis buvo prognozuota tiksliausiai naudojant rekurentinių neuroninių tinklų LSTM metodus. Naudojant ARIMA metodiką dažniausi buvo gaunami geresni kintamumo reikšmių prognozavimo rezultatai (mažesni RMSE ir MAPE įverčiai).

Summary

Machine Learning Algorithms For Classification and Forecasting of Data

The main goal of this paper is to review main volatility forecasting methods, implement them and test practically, give conclusions and recommendations based on results of experiments. This paper describes volatility forecasting methods. Described methods are ARIMA, GARCH, artificial neural networks, long short term memory model (LSTM) and logistic regression. RMSE, MAPE and ROC curve evaluation techniques of forecasting models are also described and calculated in the experimental part.

Next volatility value and direction of its movement was forecasted during the experiments. The experiments were performed on financial and quasi-periodical (meteorological, social) data. Forecasting the direction of volatility movement was a challenging task. ROC curve analysis results showed that volatility movement predictions depended on data type and best results (highest AUC value) were reached when quasi-periodical data forecasts were performed. Their AUC values were between 0.55-0.58. Financial data forecasts were just above random guess ($AUC \approx 0.51$), however the best performance between all the models was noticed by LSTM neural network model. The most accurate volatility value forecasts (lowest RMSE and MAPE rates) were reached when forecasts were performed by ARIMA models. During long-term (100 values) volatility movement forecast experiments better results were reached. AUC values were captured as high as 0.7-0.8 for quasi-periodical and ~ 0.6 for financial signals

Performed experiments and related works analysis suggest that the best volatility forecasting results could be reached by joining two or more models (at least one of them should be artificial neural networks model) together and creating hybrid forecasting model.

Įvadas

Prognozavimas nuo seno yra neatsiejama žmogaus veiklos dalis. Senovėje žmonės pasitelkę įvairius indikatorius spėdavo orą, pagal orų spėjimus planuodavo savo darbus. Buvo pastebėta, kad spėjimai pasitvirtina retai, todėl žmonės pradėjo rinkti įvairius duomenis ir nebe spėti, bet prognozuoti orus. Prognozavimas nuo spėjimo skiriasi tuo, kad spėjant remiamasi tik subjektyviu mastymu, intuicija, o prognozuojant būsimus įvykius remiamasi dažniausiai istoriniais duomenimis, kurie gali atskleisti pasikartojimus, struktūrą ir pan. Nuo prognozių priklausydavo ekonominė gerovė – laiku pasėtas ar nuimtas derlius galėdavo reikšti turtą ar nepriteklių.

Bėgant laikui atsiradus tarptautiniams mainams tarp šalių ir išsivysčius pramonei atsirado valiutų ir akcijų rinkos. Norėdami šiose rinkose uždirbti žmonės vėlgi turėjo pasitelkti prognozes. Tie, kurie sugebėdavo tiksliausiai numatyti ateitį, galėdavo gauti finansinę naudą. Tai buvo paskata pradėti analizuoti finansinius rodiklius, indeksus bei remiantis duomenimis bandyti prognozuoti ateities įvykius. Taip XX a. pr. atsirado ekonometrijos mokslas. Buvo pradėti tirti realaus pasaulio ekonominiai, finansiniai duomenys, pradėti vystyti ekonometriniai modeliai, analizuojami istoriniai duomenys bei daromos prognozės. Iš pradžių prognozėms buvo naudojamas pats paprasčiausias tiesinės regresijos modelis. Nors šis modelis plačiai naudojamas iki šiol, tačiau pastebėta, kad ekonominių ir finansinių rodiklių prognozėms jo nepakanka, todėl norint pasiekti geresnių prognozavimo rezultatų pradėti kurti ir modifikuoti nauji metodai.

Pradžioje finansų rinkos dalyviai daugiausia tyrė ir kūrė prognozavimo modelius akcijų kainų ir akcijų indeksų numatymui. Pagrindinis tikslas buvo prognozuoti kainas ir priimant atitinkamus sprendimus rinkoje uždirbti kuo daugiau pelno. Vėliau vystantis rinkoms, atsiradus profesionaliems investuotojams, akcijų fondams tapo svarbu ne tik bandyti numatyti kainą, tačiau ir įvertinti riziką, su kuria susiduria įvairių finansinio turto rūšių turėtojai. Taip finansų rinkose atsirado poreikis įvertinti kintamumą (angl. *volatility*). Kintamumas mokslininkų pradėtas plačiau analizuoti ir tirti XX a. devintajame dešimtmetyje.

Kintamumo prognozavimo problema nėra standartinė. Dauguma tyrėjų nagrinėja kitų finansinių duomenų, kaip akcijų, valiutų ar indeksų tendų prognozavimą. Kintamumo prognozavimas, bent teoriškai, turėtų būti dėkingesnis uždavinys nei kainų prognozavimas, nes prognozuojant kintamumą, prognozuojama, kad kaina kils, bet nėra nusakoma to kitimo kryptis t.y. ar kaina mažės ar didės. Kintamumo prognozavimu labiausiai susidomėta paskutiniu metu – maždaug 10 – 20 metų laikotarpiu.

Šiame darbe nagrinėjami ir lyginami kintamumo, kaip finansinių duomenų, prognozavimo metodai. Kokybiškas kintamumo duomenų prognozavimas leistų finansų rinkose geriau įvertinti rizikas ir jas valdyti, parinkti portfelius, tai taip pat padėtų pasirinkimo sandorių (angl. *option*) įvertinimui.

Atliekant susijusių darbų analizę nebuvo rasta darbų nagrinėjančių kintamumo prognozavimo galimybes remiantis rekurentinių neuroninių tinklų LSTM metodika. Šio magistro baigiamojo **darbo tikslas**: iširti LSTM metodiką, jos parametru įtaką, tiek trumpalaikiam, tiek ilgalaikiam kintamumo prognozavimui, gautus eksperimentų rezultatus palyginti su laiko eilučių ARIMA metodų skirtingų modelių eksperimentų rezultatais bei pateikti išvadas.

Šio darbo uždaviniai:

- Išnagrinėti kintamumo sąvoką ir skaičiavimus.
- Išanalizuoti naudojamus kintamumo prognozavimo metodus.
- Išnagrinėti dirbtinių neuroninių tinklų teoriją.
- Suklasifikuoti tiriamus signalus.

- Parašyti programas ir atlikti vienos, keleto kintamumo reikšmių bei ilgalaikio kintamumo judėjimo krypties prognozavimo eksperimentus remiantis LSTM ir ARIMA metodikomis.
- Panaudoti kitus netradicinius būdus kintamumo prognozavimui naudojant LSTM metodiką.
- Atlikti gautų prognozavimo rezultatų statistinę analizę ir pateikti išvadas.

Pirmajame darbo skyriuje pateikiamas kintamumo apibrėžimas, kintamumo skaičiavimo formulės ir pavyzdžiai. Antrajame skyriuje pateikiama susijusių darbų analizė, dirbtinių neuroninių tinklų teorija bei kintamumo prognozavimo metodai: ARMA šeimos, GARCH, dirbtinių neuroninių tinklų bei logistinės regresijos. Trečioje darbo dalyje apžvelgiama eksperimentinės dalies rezultatų vertinimo metodologija: šaknis iš vidutinės kvadratinės paklaidos (RMSE), vidutinė absoliuti procentinė paklaida (MAPE) bei ROC analizė. Ketvirtoje darbo dalyje aprašomi įvairaus pobūdžio signalų kintamumo prognozavimo eksperimentai pasitelkiant ARIMA, LSTM ir logistinės regresijos metodikas. Plačiau tyrinėjama LSTM metodika, kuria remiantis atliekamos trumpalaikio ir ilgalaikio kintamumo prognozės. Pateikiami rezultatai bei jų vertinimas. Visi eksperimentai atlikti „Python“ programavimo kalba. ARIMA modelio inicijavimui buvo papildomai naudota „Statsmodels“ biblioteka, LSTM modelio – „Keras“ biblioteka su „TensorFlow“ platforma, o logistinės regresijos – „Scikit-learn“ biblioteka. Visi kiti programavimo darbai, kaip duomenų nuskaitymas, kintamumo dydžio ir pokyčių skaičiavimas, inicijuotų modelių apmokymas, prognozavimas, rezultatų vertinimas RMSE, MAPE ir ROC analizės būdu, autokoreliacijos skaičiavimas, grafikų atvaizdavimas buvo suprogramuota autoriaus. Eksperimentams naudoti duomenys aprašyti 4.3 skyriuje. Eksperimentų rezultatai parodė, jog kintamumo judėjimo krypties prognozavimo rezultatai priklausė nuo prognozuojamų signalų pobūdžio: finansinių signalų buvo tik nežymiai didesni ($AUC \approx 0.51$) už atsitiktinius, o kvazi-periodinių signalų prognozavimo eksperimentų rezultatai buvo teigiamiesni. Tarp tirtų modelių kintamumo judėjimo kryptį geriausiai prognozavo rekurentinių neuroninių tinklų modelis LSTM. Tirtos ilgalaikio kintamumo judėjimo krypties prognozavimo galimybės pasitelkiant ne tik buvusias faktines kintamumo reikšmes, pradines signalo reikšmes, bet ir išvestinį dydį – Hursto eksponentę. Vis dėlto geriausi rezultatai fiksuoti modelius apmokant prieš tai buvusiomis kintamumo reikšmėmis. Naudojant ARIMA metodiką dažniausiai buvo gaunami geresni konkrečių kintamumo reikšmių prognozavimo rezultatai (mažesni RMSE ir MAPE įverčiai). Darbo pabaigoje pateikiamos išvados, rekomendacijos bei ateities tyrimų gairės.

Šis darbas yra tęstinis, todėl dalis informacijos buvo panaudota iš praeitame semestre paruošto „Mokslo tiriamojo darbo“. Skyriai, panaudoti iš praeitame semestre paruošto darbo:

- 1. „Kintamumo apibrėžimas“
- 2. „Kintamumo prognozavimo metodai“
- 3. „Eksperimentinės dalies rezultatų vertinimo metodologija“
- Dalis 4. „Kintamumo prognozavimo eksperimentai ir jų vertinimas“ skyriaus iki 4.2. „Pirminis metodų tyrimas naudojant valiutų kurso duomenis“ poskyrio (imtinai).

1. Kintamumo apibrėžimas

1.1. Kas yra kintamumas?

Kintamumas (angl. *volatility*) finansų srityje apibrėžiamas kaip kainų ar pajamų nepastovumas, svyravimas. Dažnai jis suprantamas kaip rizikos matmuo. Kintamumas nenurodo kainos judėjimo krypties, bet svyravimo amplitudę. Kuo tam tikro finansinio instrumento kintamumo rodiklis didesnis tuo didesnę riziką prisiima finansų rinkos dalyvis turėdamas ar prekiaudamas atitinkamu instrumentu ir atvirkščiai – jei kintamumo rodikliai maži – rizika mažesnė. Dažniausiai, nors ir ne visada, didelis kintamumas reiškia ir didesnę galimybę uždirbti. Taigi, kintamumo rodiklis svarbus kiekvienam finansų rinkos dalyviui, nes leidžia planuoti veiksmus finansų rinkoje priklausomai nuo siekiamų tikslų.

Kintamumas skirstomas į istorinį kintamumą (angl. *historic volatility*), kuris apskaičiuojamas remiantis faktiniais istoriniais rinkos rodikliais ir numanomą kintamumą (angl. *implied volatility*), kuris nustatomas remiantis rinkoje parduodamomis išvestinių priemonių kainomis. Šiam darbe bus nagrinėjamas kintamumo prognozavimas remiantis istorinio kintamumo duomenimis. Kintamumo finansų rinkose prognozavimas laikomas sudėtinga užduotimi dėl rodiklių nereguliarumo, didelių svyravimų ir signalų triukšmų [32].

1.2. Kintamumo skaičiavimas

Finansuose kintamumas skaičiuojamas kaip logaritminių grąžų standartinis nuokrypis per tam tikrą laikotarpį. Dažniausiai skaičiuojamas metinis (angl. *annualized*) kintamumas. Kintamumo nustatymui reikalingi periodiškai (kiekvieną valandą, dieną, savaitę, mėnesį ar pan.) fiksuoti duomenys. Metinis kintamumas (σ_P) skaičiuojamas pagal formulę:

$$\sigma_P = \sigma_{SD} \sqrt{P}, \quad (1.1)$$

kur P - laiko periodų skaičius per metus, σ_{SD} - standartinis nuokrypis per atitinkamą laiko periodą.

Pavyzdžiui, jeigu apskaičiuotas vienos dienos kintamumas (standartinis nuokrypis) mėnesio bėgyje $\sigma_{dienos} = 0.5$, o metuose yra 261 prekybinės dienos tuomet metinis kintamumas skaičiuojamas taip:

$$\sigma_{metinis} = 0.5 \sqrt{261} = 8.078 \quad (1.2)$$

Metinio kintamumo skaičiavimo formulę galima analogiškai taikyti ir kitokių periodų kintamumo skaičiavimui. Pavyzdžiui, jeigu turėdami apskaičiuotą metinį kintamumą norėtume įvertinti mėnesinį, mėnuo turėtų būti atitinkamai paverčiamas į metinę išraišką $P = 1/12$:

$$\sigma_{mėnesinis} = 8.078 \sqrt{1/12} = 2.332 \quad (1.3)$$

Žinant kiek kartų per metus (pvz. 261) buvo fiksuotas kintamumas, remiantis dienos kintamumo rodikliu taip pat galima paskaičiuoti mėnesinį ($P = 261/12$):

$$\sigma_{mėnesinis} = 0.5 \sqrt{\frac{261}{12}} = 2.332 \quad (1.4)$$

Kadangi, kintamumas skaičiuojamas kaip logaritminių grąžų standartinis nuokrypis, pradinuose skaičiavimuose naudojamos standartinio nuokrypio bei logaritminių grąžų skaičiavimo formulės. Standartinio nuokrypio skaičiavimo formulė:


$$SD = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2}, \quad (1.5)$$

kur N - reikšmių skaičius, \bar{x} - reikšmių vidurkis, x_i - i -toji reikšmė. Logaritminių grąžų R skaičiavimo formulė:

$$R = \ln \left(\frac{V_i}{V_{i-1}} \right), \quad (1.6)$$

kur V_i kaina dabartinio periodo metu, o V_{i-1} kaina buvusio periodu metu. Dažniausiai naudojamos periodo pabaigos kainos.

Remiantis šiomis trimis formulėmis (1.1, 1.5, 1.6) galima apskaičiuoti metinį (ar kito periodo) kintamumą. Dažnai kintamumas skaičiuojamas kaip 1 dienos standartinis nuokrypis per 1 mėnesio periodą ir paverčiamas į metinę išraišką. Remiantis tokia logika skaičiuojamas ir VIX, JAV akcijų biržų, kintamumo indeksas [33]. Apskaičiuotas metinis EUR/USD kintamumo grafikas pateikiamas žemiau 1 paveikslėlyje.



1 pav. Iliustracija kairėje: EUR/USD kurso grafikas. Iliustracija dešinėje: EUR/USD kurso kintamumo grafikas.

2. Kintamumo prognozavimo metodai

2.1. Susijusių darbų apžvalga

Kadangi kintamumo prognozavimo problema aktyviai pradėta nagrinėti paskutiniu metu (10 - 20 metų laikotarpiu) kintamumo prognozavimą nagrinėjančių darbų nėra daug. Autoriai Keith Pilbeam ir Kjell Noralf Langeland [24] tyrinėjo autoregresijos sąlyginio heteroskedastiškumo (angl. *Generalized AutoRegressive Conditional Heteroskedasticity*) geriau žinomų kaip GARCH (p, q) modelių galimybes valiutų kursų kintamumo prognozavimui, tačiau priėjo išvados, kad GARCH modeliai nėra tinkami kintamumo prognozavimui kuomet kintamumas yra labai mažas arba

labai didelis. Autoriai teigia, kad GARCH modelio veikimas galimai galėtų būti pagerintas į modelį įtraukiant neuroninius tinklus, bet tolimesnių tyrimų nepateikia. Autoriai Christian L. Dunis ir Xuehuan Huang [12] tyrė GARCH, regresinių neuroninių tinklų (angl. *Neural Network Regression, NNR*) ir rekurentinių neuroninių tinklų (angl. *Recurrent Neural Network, RNN*) bei jų kombinacijų panaudojimą valiutų kursų kintamumo prognozavimui. Mokslininkai priėjo išvados kad tarp trijų lygintų modelių rekurentinių neuroninių tinklų modelio prognozės buvo tiksliausios (ypač trumpuoju laikotarpiu). Modelių kombinacijos (hibridiniai modeliai) taip pat davė gerų rezultatų.

Yi Xiao et al. [32], tyrė valiutų kursų kintamumo prognozavimą, teigė, kad tradiciniai ekonometriniai ir laiko eilučių modeliai nusileidžia paprasčiausiam atsitiktinio klaidžiojimo (angl. *Random Walk*) modeliui, nes finansų rinkos indeksai dažniausiai kinta atsitiktine nenuspėjama kryptimi ir yra netiesiniai. Tradiciniai modeliai, tokie kaip ARMA šeimos modeliai, neįvertina finansinių indeksų reikšmių kitimo netiesiškumo. Todėl tokie modeliai naudojami atskirai nėra tinkami tiksliam prognozavimui. Tai paskatino mokslininkus ir finansų rinkos dalyvius ieškoti tikslesnių prognozavimo modelių. Ilgainiui pastebėta, kad modeliai, kuriuose naudojamos dirbtinio intelekto (angl. *Artificial Intelligence, AI*) sistemos, pavyzdžiui, tokios kaip dirbtiniai neuroniniai tinklai, leidžia pasiekti geresnių rezultatų nei tradiciniai statistiniai prognozavimo modeliai. Dėl šios priežasties įvairių rūšių neuroniniai tinklai buvo pradėti taikyti finansinių indeksų prognozėms. Taip pat neuroninių tinklų modeliai pasižymi lankstumu ir plačiu taikymu duomenų modeliavime ir prognozavime. Yi Xiao et al. [32] taip pat pastebėjo, kad mokslininkai tirdami neuroninių tinklų panaudojimą prognozavimui iš pradžių lygindavo vieną neuroninį tinklą su kitu ir atmetimo būdu atrinkdavo neuroninį tinklą, kurio prognozių rezultatai buvo geresni. Tačiau kai kuriais atvejais netgi tas neuroninio tinklo tipas, kurį atskirai nagrinėjant rezultatai būdavo prasti, naudojant kartu su kitu metodu, galėdavo būti vertingas. Tad buvo pradėti analizuoti ir naudoti prognozavimo modeliai apimantys keletą neuroninių tinklų tipų.

Hemanth Kumar et al. Kumar et al. [21] tyrė akcijų indeksų kintamumo prognozavimus metodus, kuriuose naudojami ARIMA ir ARFIMA kartu su neuroniniais tinklais. Autoriai padarė eksperimentus priėjo išvados, kad tiksliausiai kintamumą prognozavo ARIMA modelis naudojamas kartu su neuroniniais tinklais.

Anupam Tarsauliya et al. [30] tyrė akcijų kainų ir akcijų indeksų kintamumo prognozavimą pasitelkiant dirbtinius neuroninius tinklus, GARCH modelius bei hibridinius modelius, kuriuose apjungtos abi metodikos. Autorių eksperimentų metu gauti rezultatai parodė, kad būtent hibridiniai modeliai, kuomet buvo apjungtos GARCH ir dirbtinių neuroninių tinklų metodikos davė geriausius rezultatus.

Šioje darbo dalyje bus aptariami ARMA, GARCH, neuroninių tinklų ir hibridiniai kintamumo prognozavimo metodai bei logistinės regresijos metodika.

2.2. ARMA šeimos metodai

Autoregresinį slenkančio vidurkio laiko eilučių modelį (angl. *Auto-Regressive Moving Average, ARMA*) 1951 m. aprašė Peter Whittle, o 1970 m. Išpopuliarino George E. P. Box ir Gwilym Jenkins. ARMA modelis yra autoregresinio modelio (angl. *Auto-Regressive, AR*) ir slenkančio vidurkio (angl. *Moving Average, MA*) modelių junginys.

Autoregresijos p eilės modelis AR (p) aprašomas matematine lygtimi:

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t, \quad (2.1)$$

kur $\varphi_1, \dots, \varphi_p$ yra koeficientai, c konstanta, o atsitiktinis dydis ε_t - „baltasis triukšmas“ (angl. *white noise*). Iš šios formulės (2.1) galima matyti, kad kiekviena modelio reikšmė - tai prieš tai buvusios reikšmės (arba reikšmių) funkcija. Jeigu naudojamas pirmos eilės - AR (1) modelis, tai bus naudojama tik prieš tai buvusi reikšmė, jei eilę didiname, pavyzdžiui, AR (2), tuomet bus naudojamos 2 paskutinės reikšmės ir t. t.

Slenkančio vidurkio q eilės modelis MA(q) aprašomas matematine lygtimi:

$$X_t = \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}, \quad (2.2)$$

kur $\theta_1, \dots, \theta_q$ yra koeficientai, $\varepsilon_t, \varepsilon_{t-1}, \dots$ - atsitiktinis dydis „baltasis triukšmas“ su 0 vidurkiu. Pagal MA funkciją kiekviena reikšmė apskaičiuojama remiantis dabartine triukšmo reikšme ir viena (kai $q = 1$) arba keliomis buvusiomis triukšmo reikšmėmis.

Žinant AR ir MA modelius galima apibrėžti ARMA (p, q) modelį su p eilės autoregresijos parametru ir q eilės slenkančio vidurkio parametru. Tai bus AR (p) ir MA (q) modelių suma:

$$X_t = c + \varepsilon_t + \sum_{i=1}^p \varphi_i X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i}, \quad (2.3)$$

ARMA modeliai gali būti naudojami tik stacionarioms laiko eilutėms prognozuoti [9]. Todėl pats ARMA modelis nėra tinkamas nestacionarių reikšmių kaip kintamumas prognozavimui. Tam naudojamas ARMA modelio plėtinys įtraukiantis skirtumų panaudojimą - autoregresinis integruoto slenkančio vidurkio modelis (angl. *Auto-Regressive Integrated Moving Average, ARIMA*), dar žinomas Box&Jenkins modelio vardu. Matematinė ARIMA (p, d, q) modelio išraiška pateikiama žemiau:

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right) (1 - L)^d X_t = \delta + \left(1 + \sum_{i=1}^q \theta_i L^i\right) \varepsilon_t, \quad (2.4)$$

kur L - atsilikimo parametras (angl. *lag operator*). Taip pat papildomai lyginant su ARMA modeliu atsiranda parametras d - diferencialo eilės numeris.

Svarbiausios ARIMA modelio savybės [9]:

- Daugeliu atveju pakanka d lygaus 1. Jeigu $d = 0$, gaunamas ARMA (p, q) modelis.
- ARIMA ($p, 0, 0$) modelis yra AR (p) atitikmuo.
- Analogiškai, ARIMA ($0, 0, q$) modelis yra MA (q) atitikmuo.
- ARIMA ($0, 1, 0$) dar žinomas kaip atsitiktinio klaidžiojimo (angl. *random walk*) modelis. Jis dažnai naudojamas nestacionariems duomenims (akcijų kainoms ir pan.)

Taip pat plačiai naudojamas ARIMA modelio plėtinys ARFIMA (angl. *Auto-Regressive Fractionally Integrated Moving Average*). Pagrindinis skirtumas, kad ARFIMA modelyje, kitaip nei ARIMA, galima naudoti trupmeninius diferencialo eilės numerius d . ARFIMA modelis yra naudingas modeliuojant laiko eilutes su ilga atmintimi [9]. ARIMA modelio išraiška $(1 - L)^d$ yra interpretuojama naudojant binarinę teoremą (angl. *binomial theorem*).

Verta paminėti, kad literatūroje teigiama, jog ARIMA šeimos modelių apmokymui reikėtų naudoti bent 50 reikšmių, o rekomenduotina 100 arba daugiau [31].

ARIMA metodikos panaudojimas kintamumo prognozavimui praktikoje pateikiamas eksperimentinės darbo dalies 4.2.1, 4.5.2 ir 4.7.2 skyriuose.

2.3. GARCH metodai

Apibendrinto autoregresijos sąlyginio heteroskedastiškumo modelį (GARCH) pirmasis 1986 m. aprašė mokslininkas T. Bollerslev. Ilgainiui GARCH modeliai patapo vieni plačiausiai taikomų nelineinių prognozėms [12]. GARCH modeliai išnaudoja kvadratinių grąžų autokoreliacijos savybes.

Apibendrinta GARCH (p, q) formulė pateikiama žemiau:

$$\sigma_t^2 = \omega + \alpha_1 \epsilon_{t-1}^2 + \dots + \alpha_q \epsilon_{t-q}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_p \sigma_{t-p}^2 = \omega + \sum_{i=1}^q \alpha_i \epsilon_{t-i}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2, \quad (2.5)$$

kur ω - konstanta, α_i - autoregresijos koeficientas, β_i - slenkančio vidurkio koeficientas, p ir q - autoregresijos ir slenkančiųjų vidurkių eilė.

Kai GARCH modelyje parametrai $p = 1$ ir $q = 1$, gauname paprasčiausią GARCH (1, 1) modelį, dar vadinamą standartiniu. Toks modelis prognozę atlieka pasitelkdamas ilgalaikį vidutinį kintamumą, paskutinį rinkos kintamojo pokytį bei buvusio periodo kintamumą. GARCH (1, 1) yra plačiai taikomas finansuose, nes tokio modelio prognozavimo tikslumas yra ganėtinai aukštas [13]. Pažymėję $\omega = \gamma V$ gauname GARCH (1, 1) formulę, pateikiamą žemiau:

$$\sigma_t^2 = \gamma V + \alpha \epsilon_{t-1}^2 + \beta \sigma_{t-1}^2, \quad (2.6)$$

kur V - ilgalaikis vidutinis kintamumo lygis su svoriu γ ; ϵ_{t-1} - praeito periodo kintamumo pokytis su svoriu α ; σ_{t-1} - praeito periodo kintamumas su svoriu β . Svorijų suma turi būti lygi vienetui t.y. $\gamma + \alpha + \beta = 1$. Taigi, apskaičiavus α ir β , γ bus lygu išraiškai $1 - \alpha - \beta$. Kadangi ilgalaikis kintamumas visada yra teigiamas, tai $\alpha + \beta < 1$.

Kaip buvo minėta skyriaus įžangoje tiek GARCH tiek ARMA šeimos modelių naudojamų atskirai rezultatai nebūdavo patys geriausi [12, 32], todėl toliau analizuojami neuroninių tinklų metodai, kurie kintamumo prognozavimui gali būti naudojami tiek kartu su GARCH ir ARMA šeimos modeliais tiek atskirai.

2.4. Neuroninių tinklų metodai

2.4.1. Dirbtiniai neuroniniai tinklai


Dirbtiniai neuroniniai tinklai (angl. *Artificial Neural Networks, ANN*) - tai sistema, kurios pagrindas yra tarpusavyje sujungti dirbtiniai neuronai. Dirbtinių neuroninių tinklų veikimo principas remiasi biologiniais neuroniniais tinklais, kurie sudaro gyvūnų smegenis. Neuroninis tinklas apmokomas suteikiant pavyzdinę informaciją: įvesties (angl. *input*) duomenis ir išvestį (angl. *output*). Nagrinėjant kintamumo prognozavimą įvestis galėtų būti istoriniai duomenys, o išvestis po tų duomenų sekęs kintamumo dydis arba kintamumo pokytis (didėjimas ar mažėjimas). Gavę šią informaciją dirbtiniai neuroniniai tinklai ją išmoksta ir vėliau, suteikus įvesties duomenis, pateikia atsakymą (išvestį) remdamiesi išmokta informacija.

Dirbtinis neuronas - pagrindinis komponentas iš kurių susideda dirbtiniai neuroniniai tinklai. Įprastai toks neuronas turi keletą įvesčių su atitinkamais svoriais (dar vadinamais sinapsėmis), aktyvacijos funkciją ir vieną išvestį. Tokį neuroną galima aprašyti formule (2.7):

$$y = \varphi \left(\sum_{j=0}^n w_j x_j \right), \quad (2.7)$$

kur y - išvestis, x_j - įvestys, w_j - įvesčių svoriai, o φ - aktyvacijos funkcija.

Taip pat šią formulę galima atvaizduoti grafiškai (2 pav.):



2 pav. Dirbtinio neurono diagrama.


2.4.2. Aktyvacijos funkcija

Aktyvacijos funkcija (angl. *activation function*) yra privalomas dirbtinių neuroninių tinklų, kurie apmokami atkurti netiesinius modelius, parametras. ANN, kurie neturi aktyvacijos funkcijos, gali atlikti tik tiesines transformacijas. Aktyvacijos funkcija yra labai svarbi neuroninių tinklų dalis, nes didžiąja dalimi ji apsprendžia, ar tam tikras neuronas bus aktyvintas ar ne t. y. aktyvacijos funkcija nusprendžia, ar informacija, kuri pasiekia neuroną yra reikšminga ar ne. Jei informacija nereikšminga – aktyvacijos funkcija ją ignoruoja.

Kadangi kintamumo dydis kinta netiesiškai neuroninis tinklas skirtas apdoroti kintamumo dydį irgi turėtų turėti netiesinę aktyvacijos funkciją, nes naudojant tiesines aktyvacijos funkcijas gaunami tiesiniai rezultatai. Plačiausiai naudojamos netiesinės aktyvacijos funkcijos yra sigmoidinė (angl. *sigmoid*), hiperbolinis tangentas (angl. *hyperbolic tangent*) ir ReLU (angl. *Rectified linear unit*) [17, 26, 28].

Sigmoidinės funkcijos (dar vadinama logistine) formulė (2.8) ir grafikas (3 pav.) pateikiami žemiau:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.8)$$



3 pav. Iliustracija kairėje: sigmoidinės funkcijos grafikas. Iliustracija dešinėje: hiperbolinio tangento funkcijos grafikas.

Pagrindinis sigmoidinės funkcijos privalumas, kad ji yra netiesinė. Taip pat, kaip galima matyti iš formulės, sigmoidinės funkcijos reikšmės visada kinta intervale (0, 1), taigi nėra rizikos neurono persimokymui (angl. *over-fitting*). Kai kuriais atvejais įgyjamos reikšmės gali būti lengvai interpretuojamos kaip įvykio atsitikimo tikimybė intervale (0, 1). Dar vienas privalumas – turi

lengvai skaičiuojamą išvestinę, kuri naudojama apmokant modelius. Vienas didžiausių trūkumų - turi nykstančio gradiento (angl. *vanishing gradient*) problemą [16]. Ši problema gali kilti kai per apmokymo ciklą funkcijos įgyjamos reikšmės pasiekia kreivės galus (kai kreivė praktiškai yra horizontalioje padėtyje) - x reikšmių kitimas lemia labai mažą y reikšmių pokytį, t.y. gradientas tampa labai mažas arba praktiškai išnyksta. Tokiu atveju neuronas nebesimoko arba mokymasis tampa labai lėtas. Taip pat kėlimas laipsniu reikalauja daugiau kompiuterinių resursų nei kiti matematiniai skaičiavimai, todėl kai kuriais atvejais tai irgi gali būti sigmoidinės funkcijos trūkumas.


Hiperbolinis tangentas yra labai panašus į sigmoidinę funkciją ir laikomas praplėsta sigmoidinės funkcijos versija. Hiperbolinio tangento funkcijos grafikas pateiktas 3 paveikslėlyje, formulė (2.9) pateikiama žemiau:

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.9)$$

Hiperbolinio tangento funkcija įgyja reikšmes intervale $(-1, 1)$, taigi taip pat nėra rizikos neurono persimokymui. Ši funkcija yra labai panaši į sigmoidinę ir turi tas pačias savybes. Pagrindinis skirtumas nuo sigmoidinės, kad įgyja ne tik teigiamas, bet ir neigiamas reikšmes. Kitas skirtumas - įgyjamo gradiento dydis. Hiperbolinio tangento funkcijoje gradientas bus didesnis (dėl didesnio tiesės nuolydžio) nei sigmoidinėje funkcijoje.

Trečioji funkcija - **ReLU** šiuo metu laikoma pačia sėkmingiausia ir plačiausiai naudojama aktyvacijos funkcija [26]. Ji taip pat įvardijama kaip tinkamiausia efektyviam neuroninio tinklo mokymui. ReLU formulė (2.9) ir grafikas (pav. 4) pateikiami žemiau:

$$f(x) = \max(0, x) \quad (2.10)$$



4 pav. ReLU funkcijos grafikas.

ReLU funkcija įgyja reikšmes x , kai x teigiamas, o visais kitais atvejais ReLU funkcijos reikšmė lygi 0. Taigi reikšmės kinta intervale $[0, \infty)$. Iš formulės gali pasirodyti, kad ReLU yra tiesinė funkcija, bet, kaip ir sigmoidinė bei hiperbolinis tangentas, ši funkcija nėra tiesinė.

ReLU aktyvacijos funkcijoje, kitaip nei sigmoidinės bei hiperbolino tangento funkcijose, kai kurie neuronai gali būti išjungiami. Kai visi neuronai yra aktyvūs dirbtinis neuroninis tinklas gali būti labai tankus ir reikalaujantis daug resursų - neuroninis tinklas tampa „brangus“. Tuo tarpu ReLU aktyvacijos funkcijos tinklas būna ne toks tankus, efektyvesnis bei, žinoma, reikalaujantis mažiau resursų [16, 22]. Kitas privalumas, kad ReLU aktyvacijos funkcijoje nėra nykstančio gradiento problemos - gradientas yra konstanta [22].

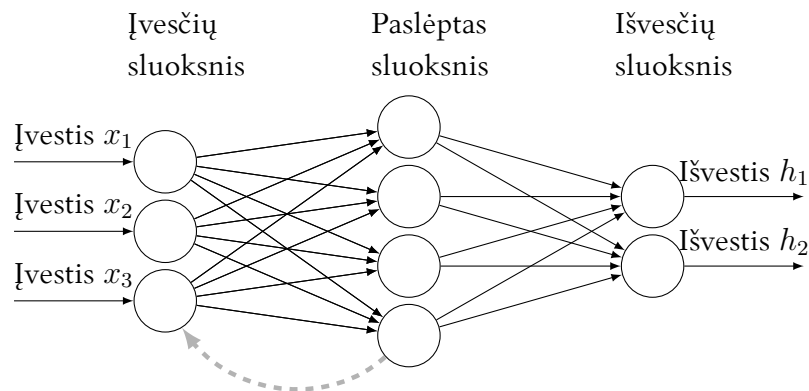
Pagrindinis ReLU minusas, kad funkcija gali įgyti labai dideles reikšmes t. y. neuronas gali persimokyti, kai tuo tarpu sigmoidinėje ir hiperboliniame tangente įgyjamos reikšmės yra apribotos.

Visos trys pateiktos aktyvacijos funkcijos turi privalumų ir trūkumų ir jų pasirinkimas labiausiai priklauso nuo naudojamo dirbtinio neuroninio tinklo, tačiau šiuo metu plačiau praktikoje naudojama ReLU funkcija ir jos modifikacijos, kadangi teigiama, kad ji daugeliu atvejų turi daugiau pliusų nei minusų [23].

Kitos plačiai naudojamos aktyvacijos funkcijos yra linijinė (angl. *linear*), vienetinė (angl. *identity*), žingsninė (angl. *step*) ar dvejetainė žingsninė (angl. *binary step-function*), tačiau jos nėra tinkamos spręsti netiesiniams uždaviniams [17], todėl nebus plačiau nagrinėjamos.

2.4.3. Neuroninių tinklų tipai

Neuronai tinkluose gali būti susijungę (susiję) įvairiais būdais. Tarpusavio neuronų susijungimas vadinamas topologija [18]. Yra labai daug variantų (topologijų) kaip neuronai gali būti susijungę tarpusavyje. Išskiriamos dvi pagrindinės topologijų grupės: tiesioginio sklidimo (angl. *feed forward*), kai informacija perduodama tik viena kryptimi, be ciklų, nuo įvesčių iki išvesties, ir rekurentinė (angl. *recurrent*), kuomet dalis informacijos perduodama ir priešinga kryptimi, atsiranda ciklai. Atitinkamai savo topologijų tipams dirbtiniai neuroniniai tinklai skirstomi į dvi pagrindines grupes: tiesioginio sklidimo neuroninius tinklus (angl. *Feed-forward Neural Networks, FNN*) ir rekurentinius neuroninius tinklus (angl. *Recurrent Neural Networks, RNN*). Abiejų grupių neuroninius tinklus galima atvaizduoti grafiškai (5 pav.)



5 pav. Pagrindinės dirbtinių neuroninių tinklų grupės: tiesioginio sklidimo tinklai (be sąryšio pažymėto punktyrine linija) ir rekurentiniai tinklai (kartu su sąryšiu pažymėtu punktyrine linija).

Rekurentiniuose tinkluose informacijos sklidimas sudėtingesnis, o dėl informacijos sklidimo ir priešinga kryptimi atsiranda atmintis. Dėl atminties rekurentiniai tinklai yra tinkamesni laiko eilučių prognozėms. Danko Brezak et al. [10] tyrinėję neuroninių tinklų panaudojimą laiko eilučių prognozėms priėjo išvados, kad rekurentiniai neuroniniai tinklai duoda geresnius rezultatus nei tiesioginio sklidimo neuroniniai tinklai.


Tiek tiesioginio sklidimo tiek rekurentinių tinklų grupės gali turėti konkrečius tipus. Toliau bus apžvelgiamas rekurentinės tinklų grupės LSTM tinklas, kuriame yra pašalinta nykstančio gradiento problema. Pašalinta nykstančio gradiento problema leidžia tinklui sėkmingai išmokti

ilgalaikes priklausomybes ir todėl jis gali būti naudojamas tokiems uždaviniams kaip kintamumo prognozavimas.

2.4.4. LSTM rekurentinis neuroninis tinklas

Ilgos trumpalaikės atminties neuroniniai tinklai (angl. *Long Short Term Memory, LSTM*) – tai rekurentiniai neuroniniai tinklai galintys išmokti ilgalaikes priklausomybes. Pagrindinis LSTM privalumas lyginant su kitais rekurentiniais neuroniniais tinklais, kad jie gali selektyviai „prisiminti“ arba „pamiršti“ informaciją.

LSTM neuroninis tinklas sudarytas iš LSTM blokų. LSTM bloko architektūrą gali būti įvairių. Dažniausiai pasitaikanti sandara, kai blokas sudarytas iš atminties ląstelės (angl. *memory cell*), įvesties vartų (angl. *input gate*), išvesties vartų (angl. *output gate*) ir užmaršties vartų (angl. *forget gate*). Tokia sandara bei šių dalių tarpusavio sąryšiai pavaizduoti 6 paveikslėlyje.



6 pav. Dažnai naudojama LSTM bloko sandara. Žymėjimai: c_t – atminties ląstelė, i_t – įvesties vartai, f_t – užmaršties vartai, o_t – išvesties vartai, \times simbolis – sandauga tarp elementų, \tanh – hiperbolinis tangentas.

Atminties ląstelė yra svarbiausia LSTM architektūros dalis [15]. Ji atsakinga už informacijos „atsiminimą“ neapibrėžtą laiką. Atminties ląstelės valdymas vyksta per visus 3 vartus. Įvesties vartai kontroliuoja naujų reikšmių patekimą į ląstelę. Į ląstelę turi patekti tik svarbi informacija. Analogiškai, išvesties vartai kontroliuoja reikšmių išvestis iš atminties ląstelės. Užmaršties vartų paskirtis – kontroliuoti kiek informacijos bus „pamiršta“ t.y. informacija, kuri nėra reikalinga arba nereikšminga LSTM modeliui suprasti sąryšius, yra pašalinama. Tokiu būdu optimizuojamas LSTM modelio veikimas.

Šiuo metu LSTM neuroniniai tinklai laikomi vieni sėkmingiausiai pritaikomų praktikoje. Savo technologijose LSTM naudoja tokios kompanijos kaip „Apple“, „Amazon“ ar „Google“.

Kintamumo prognozavimo eksperimentai pasitelkiant LSTM neuroninius tinklus bei jų rezultatai aprašyti eksperimentinėje darbo dalyje – 4 skyriuje.

2.4.5. Dirbtinių neuroninių tinklų apmokymas

Apmokymo metu neuroninis tinklas išmoka įvesties ir išvesties duomenų priklausomybę. Apmokymas yra dviejų pagrindinių tipų: mokymas su mokytoju (angl. *supervised learning*) bei mokymas be mokytojo (angl. *unsupervised learning*). Taip pat egzistuoja ir hibridinis apmokymo (angl. *hybrid learning*) būdas, kuris apjungia mokymo su mokytoju ir be tipus.

Mokymas su mokytoju yra plačiausiai paplitęs neuroninio tinklo apmokymo būdas. Esminė šio būdo savybė – žinomos tinklo išvesčių reikšmės atitinkamoms įvesčių reikšmėms [27]. Tokia-me mokymo procese dalyvauja išorinis mokytojas, kuris suteikia informaciją – įvesčių ir išvesčių reikšmes.

Mokymas be mokytojo vyksta be išorinio įsikišimo. Kitaip nei mokymo su mokytoju atveju, nėra žinomos tinklo išvesčių reikšmės. Dirbtinis neuroninis tinklas apsimoko bei susiderina pats. Šis būdas dažnai naudojamas kai norime surinkti tam tikrus duomenis ir juos suskirstyti pagal bendrus požymius – klasterius, atvaizduoti grafiškai ar identifikuoti struktūrą (angl. *pattern*).

Hibridinis mokymas tai mokymosi su mokytoju ir be junginys. Dalis tinklo parametrų nustatomi remiantis mokymu su mokytoju, o likusi dalis su mokymu be mokytojo.

Tinklų apmokymo būdas priklauso nuo sprendžiamos problemos tipo. Apmokant dirbtinius neuroninius tinklus kintamumo prognozavimui bus naudojamas mokymo su mokytoju apmokymas.

2.4.6. Klaidos sklidimo atgal algoritmas


Mokymo su mokytoju atveju dirbtinio neuroninio tinklo apmokymas vyksta kaidos sklidimo atgal (angl. *error back propagation*) algoritmo pagalba. Jo pagalba nustatomi neurono įėjimų svoriai (w_j). Veikimo principas – algoritmas skaičiuoja klaidų dydžius (skirtumus tarp apskaičiuotos išvesties reikšmės ir tikrosios išvesties reikšmės) ir remiantis tuo koreguoja įėjimų svorius, dar vadinamus sinapsėmis. Šis procesas vyksta kol gaunama sinapsių kombinacija, kai klaidos funkcijos reikšmė yra mažiausia. Tokie įvesčių svoriai (w_j) ir yra laikomi sprendiniu.

2.5. Logistinė regresija

Nors logistinė regresija (angl. *logistic regression*) nebuvo sutikta analizuotoje literatūroje kaip kintamumo prognozavimo būdas, tačiau teoriškai galėtų būti naudinga kintamumo judėjimo kryptiai nustatyti. Logistinė regresija – statistinis modelis, kai vienam dažniausiai dvinariam (angl. *binary*) dydžiui (priklausomajam) daro įtaką vienas ar keli nepriklausomi kintamieji. Paprastai priklausomasis dvinaris dydis žymimas „1“ arba „0“. Kintamumo prognozavimo atveju dvinaris dydis galėtų būti kintamumo didėjimas ar mažėjimas lyginant su prieš tai buvusiu laikotarpiu (atitinkamai žymimas „1“ arba „0“). Skirtingai nuo kitų šiame darbe nagrinėtų modelių, logistinė regresija naudojama ne konkrečioms reikšmėms prognozuoti, bet tikimybei, pavyzdžiui, kad kintamumas didės. Modelis remdamasis pateiktomis reikšmėmis (angl. *input*) prognozuoja išvesties (angl. *output*) tikimybę.

Logistinę regresiją galima išreikšti per logistinę funkciją (angl. *logistic function*). Logistinė funkcija yra sigmoidinė funkcija, kurios įvestis gali būti bet kokia reali reikšmė (h), o rezultatas (įvykio tikimybė) visada bus intervale (0, 1). Formulė (2.11) ir grafikas (7 pav.) pateikiami žemiau.

$$\sigma(h) = \frac{1}{1 + e^{-h}} \quad (2.11)$$



7 pav. Logistinės regresijos grafiko pavyzdys.

Jeigu h yra kintamojo x tiesinė funkcija, kurią galima užrašyti $h = \beta_0 + \beta_1 x$, tuomet logistinę funkciją (įvykio tikimybę) galima aprašyti žemiau pateikta išraiška (2.12).

$$p(x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x)}} \quad (2.12)$$

Ši funkcija (2.12) ir yra pagrindinė logistinės regresijos formulė. Praktikoje $p(x)$ funkcija interpretuojama, kaip sėkmingo įvykio ar teigiamo pokyčio tikimybė. Kintamumo prognozavimu atveju tai bus interpretuojama kaip tikimybė, kad kintamumas didės.

Kintamumo pokyčio prognozavimo eksperimentai bei eksperimentų rezultatai pateikiami eksperimentinės darbo dalies 4.2.3 skyriuje.

3. Eksperimentinės dalies rezultatų vertinimo metodologija

Kintamumo prognozavimo rezultatų statistiniam vertinimui autoriai naudoja įvairius metodus. Hemanth Kumar et al. Kumar et al. [21] rezultatus vertino remiantis net 7 įverčiais. Buvo skaičiuojama vidutinė paklaida, šaknis iš vidutinės kvadratinės paklaidos, vidutinė absoliuti paklaida, vidutinė procentinė paklaida, vidutinė absoliuti procentinė paklaida, vidutinė absoliutaus mastelio paklaida (angl. *Mean Absolute Scaled Error, MASE*) bei paklaidų autokoreliacija praėjusiame žingsnyje (angl. *Auto-correlation of errors at lag 1, ACF1*). Xiao Yi et al. [32] apsiribojo vidutine absoliučia paklaida, vidutine absoliučia procentine paklaida ir šaknimi iš vidutinės kvadratinės paklaidos. Šiame darbe taip pat bus naudojami pastarieji du metodai ir, kadangi bus vertinamos net tik prognozuojamos konkrečios reikšmės, bet ir jų judėjimo kryptys, papildomai bus naudojama ROC analizė.

3.1. Šaknis iš vidutinės kvadratinės paklaidos (RMSE)

Modelių prognozavimo tikslumo (kokybės) įvertinimams dažniausiai naudojamos metrikos, kuriuose skaičiuojamos absoliučios paklaidos ar paklaidų kvadratai. Labai dažnai naudojama vidutinė kvadratinė paklaida (angl. *Mean Squared Error, MSE*). Šios metrikos skaičiavimo formulė

pateikiama žemiau:

$$MSE = \frac{1}{N} \sum_{i=0}^N (p_i - f_i)^2, \quad (3.1)$$

kur p_i - prognozuota reikšmė, f_i - faktinė reikšmė.

Šaknis iš vidutinės kvadratinės paklaidos (angl. *Root Mean Squared Error, RMSE*) yra kitas dar labiau paplitęs prognozavimo modelių vertinimo būdas. RMSE naudojamas plačiau už MSE dėl lengvesnio reikšmės interpretavimo. Kvadratinė šaknis iš vidutinės kvadratinės paklaidos skaičiuojama iš MSE dydžio ištraukiant šaknį:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=0}^N (p_i - f_i)^2} \quad (3.2)$$

3.2. Vidutinė absoliuti procentinė paklaida (MAPE)

Kadangi tiek MSE tiek RMSE reikšmės matematiškai priklauso nuo matavimo skalės, yra manančių, kad šios metrikos nėra ypač tinkamos prognozavimo modelių palyginimui [11]. Taigi yra siūloma rinktis metrikas, kuriose skaičiuojamas prognozavimo paklaidos santykis su faktinėmis reikšmėmis. Iš tokių metrių plačiai žinomos yra vidutinė procentinė paklaida (angl. *Mean Percentage Error, MPE*) bei vidutinė absoliuti procentinė paklaida (angl. *Mean Absolute Percentage Error, MAPE*). Abi metrikos yra lengvai suprantamos ir apskaičiuojamos. MPE formulė pateikiama žemiau:

$$MPE = \frac{100\%}{N} \sum_{i=1}^N \frac{f_i - p_i}{f_i}, \quad (3.3)$$

kur f_i - faktinė reikšmė, p_i - prognozuota reikšmė. Kaip galima matyti iš pačios formulės (3.3) ji turi esminį trūkumą - neigiamos ir teigiamos reikšmės padengia vienos kitas. Pavyzdžiui, matuodami dviejų dienų modelio prognozės tikslumą, kai vieną dieną prognozuota reikšmė nukrypusi nuo faktinės -5%, o kitą +5%, gautume MPE 0%, nors akivaizdu, kad modelio prognozė nėra 100% tiksli. Todėl modelių prognozavimo kokybei nustatyti tikslingiau naudoti nežymiai pakoreguotą MPE metrikos variantą - MAPE, kuri skaičiuoja vidutinę absoliutinę procentinę paklaidą:

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{f_i - p_i}{f_i} \right| \quad (3.4)$$

Naudojant tą patį aukščiau pateiktą pavyzdį (kai vieną dieną prognozuota reikšmė nukrypusi nuo faktinės -5%, o kitą +5%), MAPE reikšmė būtų lygi 5%, o tai geriau atspindi prognozavimo modelio tikslumą.

3.3. ROC analizė

Pasitelkiant ROC (angl. *Receiver Operating Characteristic, ROC*) analizę galima grafiškai ir ro-diklių pagalba įvertinti nagrinėjamus prognozavimo modelius, kai prognozuojamos ne konkrečios

kintamumo reikšmės, o du įvykiai: kintamumas didės (teigiama reikšmė) arba kintamumas mažės (neigiama reikšmė). ROC analizė pirmą kartą buvo panaudota radarų signalų analizei XX a. šeštojo dešimtmečio pradžioje, tačiau pastaruoju metu ypač dažnai naudojama sistemos mokymosi (angl. *machine learning*) ir duomenų gavybos (angl. *data mining*) tyrimuose [14].

3.3.1. Klaidų matrica

Klaidų matrica (angl. *confusion matrix*) ROC analizėje naudojama rezultatų klasterizacijai. Kaip ir buvo minėta, kintamumo prognozavimo modelių analizei „teigiama“ reikšmė bus laikoma kintamumo reikšmės augimas lyginant su prieš tai buvusią dieną ir žymima „1“, o „neigiama“ – kintamumo reikšmės sumažėjimas lyginant su prieš tai buvusią dieną bei žymima „0“. Remiantis šia logika prognozių rezultatus galima suskirstyti į 4 tipus:

- Teisingai priskirta teigiama reikšmė (angl. *true positive, TP*) – modelis prognozavo kintamumo didėjimą ir kintamumas iš tikrųjų didėjo.
- Klaidingai priskirta teigiama reikšmė (angl. *false positive, FP*) – modelis prognozavo kintamumo didėjimą, bet iš tikrųjų jis sumažėjo.
- Klaidingai priskirta neigiama reikšmė (angl. *false negative, FN*) – modelis prognozavo kintamumo sumažėjimą, tačiau kintamumas didėjo.
- Teisingai priskirta neigiama reikšmė (angl. *true negative, TN*) – modelis prognozavo kintamumo sumažėjimą ir kintamumas iš tikrųjų sumažėjo.

Remiantis aukščiau aprašytu rezultatų klasterizavimu galima sudaryti klaidų matricos lentelę (1 lentelė).

		Faktinė reikšmė		Iš viso:
		Teigiama	Neigiama	
Prognozuojama reikšmė	Teigiama	TP (angl. <i>true positive</i>)	FP (angl. <i>false positive</i>)	TP + FP
	Neigiama	FN (angl. <i>false negative</i>)	TN (angl. <i>true negative</i>)	FN + TN
Iš viso:		TP + FN	FP + TN	N (TP + FP + FN + TN)

1 lentelė. Klaidų matricos lentelė, naudojama kintamumo prognozavimo modelių rezultatų analizei.

Remiantis pateikta 1 lentele apskaičiuojami du išvestiniai dydžiai, kurie bus reikalingi atvaizduojant ROC analizę grafiškai:

- Teisingai priskirtų teigiamų reikšmių rodiklis (angl. *True Positive Rate, TPR*) – tai santykis tarp teisingai priskirtų teigiamų reikšmių ir visų faktinių teigiamų reikšmių. TPR rodiklis dar vadinamas „Jautrumu“. Formulė (3.5) pateikiama žemiau:

$$TPR = \frac{TP}{TP + FN} \quad (3.5)$$

- Klaidingai priskirtų teigiamų reikšmių rodiklis (angl. *False Positive Rate, FPR*) – tai klaidingai priskirtų teigiamų reikšmių ir visų faktinių neigiamų reikšmių santykis. Matematinė išraiška (3.6):

$$FPR = \frac{FP}{TN + FP} \quad (3.6)$$

Taip pat autoriai (pvz. Tom Fawcett [14]) dažnai pateikia ir kitus išvestinius rodiklius, kurie padeda geriau įvertinti analizuojamų modelių prognostines savybes:

- Tikslumas (angl. *accuracy*) parodo, kaip dažnai modelis atspėja teisingą reikšmę (tiek teigiamą, tiek neigiamą). Tai santykis tarp teisingai atspėtų reikšmių ir visų spėjimų (3.7):

$$\text{Tikslumas} = \frac{TP + TN}{N} \quad (3.7)$$

- Specifiškumas (angl. *specificity*) parodo, kiek iš prognozuotų neigiamų reikšmių iš tikrųjų buvo neigiamos. Tai santykis tarp teisingai prognozuotų neigiamų reikšmių ir visų prognozuotų reikšmių kiekio. Specifiškumo ir FPR suma visada lygi 1, todėl žinant FPR reikšmę labai lengva paskaičiuoti specifiškumą. Bendra matematinė specifiškumo išraiška pateikiama žemiau (3.8):

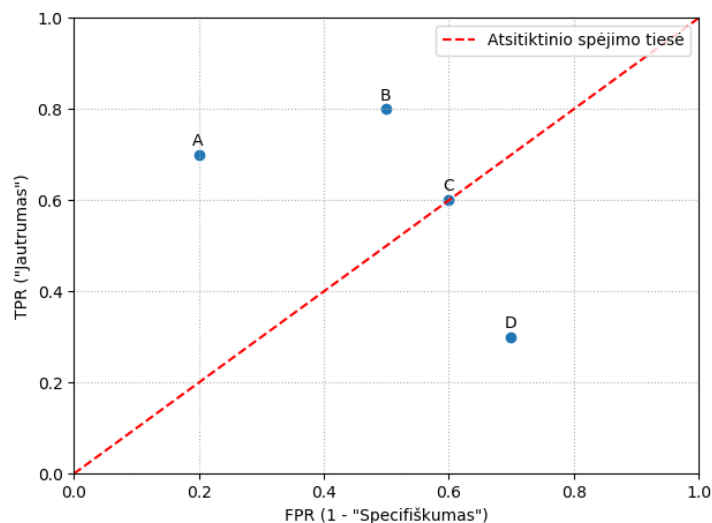
$$\text{Specifiškumas} = \frac{TN}{TN + FP} \quad (3.8)$$

- Preciziškumas (angl. *precision*) parodo, kaip teisingai modelis atspėja teigiamą reikšmę. Šis rodiklis parodo, kiek iš teigiamai prognozuotų elementų iš tikrųjų buvo teigiami. Preciziškumas apskaičiuojamas kaip teisingai prognozuotų teigiamų reikšmių ir visų modelio spėjimų (tiek teisingų tiek neteisingų), kad reikšmė bus teigiama, santykis. Formulė (3.9) pateikiama žemiau:

$$\text{Preciziškumas} = \frac{TP}{TP + FP} \quad (3.9)$$

3.3.2. ROC erdvė

ROC erdvė (angl. *ROC space*) – grafikas skirtas atvaizduoti modelių prognostines savybes t.y. kaip gerai modelis nuspėja teigiamas ir neigiamas reikšmes. Kiekvieną modelį ROC erdvės grafike galima atvaizduoti tašku. Tam naudojami anksčiau minėti teisingai priskirtų teigiamų reikšmių (TPR) bei klaidingai priskirtų teigiamų reikšmių rodikliai (FPR). Įprastai ROC erdvėje TPR reikšmė atvaizduojama *y* ašyje, o FPR – *x* ašyje [14]. Kad būtų paprasčiau suprasti ROC grafiko savybes, jis pateikiamas (8 pav.) bei aptiriamas žemiau.



8 pav. ROC erdvės (angl. *space*) grafikas.

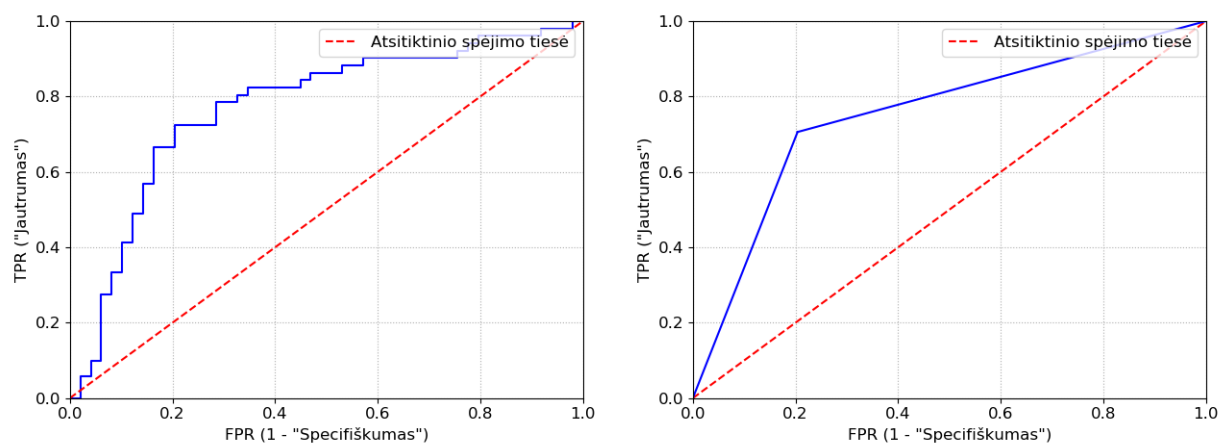
Tobulas modelis, kuris atspėja visas reikšmes (tiek teigiamas, tiek neigiamas) neklysdamas būtų atvaizduojamas taške x (FPR) = 0, y (TPR) = 1. Tokios reikšmės įmanomos tik vieninteliu atveju – kai tiek FN, tiek FP dydžiai lygūs 0. Kairysis žemiausias taškas (kai tiek x , tiek y reikšmės lygios 0) rodo, kad modelis visiškai neatspėja teigiamų reikšmių, bet tuo pačiu nesuklysta prognozuodamas neigiamas reikšmes. Taigi, kintamumo prognozavimo atveju tai būtų modelis, kuris visada prognozuoja tik neigiamą reikšmę (tiek FPR, tiek TPR lygūs 0). Analogiškai, taškas esantis viršutiniame dešiniajame kampe rodo, kad modelis visais atvejais spėja tik teigiamą reikšmę t.y. niekada nesuklysta spėdamas teigiamas reikšmes, bet visada suklysta spėdamas neigiamas reikšmes (tiek TPR, tiek FPR lygūs 1). Per šiuos du taškus (0, 0) ir (1, 1) ROC modelyje yra brėžiama tiesė vadinama atsitiktinio spėjimo (angl. *random guess*) tiesė. Pagrindinė ROC erdvės grafiko savybė – kuo taškas yra labiau nutolęs nuo atsitiktinio spėjimo tiesės į kairę tuo modelio prognostinės savybės geresnės. Pavyzdyje (8 pav.) pateiktame grafike tiek taškas „A“, tiek „B“ yra kairėje pusėje, bet taško „A“ prognostinės savybės geresnės, nes jis nuo tiesės nutolęs labiau nei taškas „B“. Jeigu modelio taškas sutampa su atsitiktinio spėjimo tiesė (taškas „C“), reiškia, kad modelio prognostinės savybės lygios atsitiktiniam spėjimui. Jeigu taškas (šiuo atveju taškas „D“) atsiduria dešinėje pusėje nuo atsitiktinio spėjimo tiesės, reiškia, kad modelio prognozių rezultatai blogesni nei atsitiktinio spėjimo.

3.3.3. ROC kreivė

Analizuojant modelius, kuriuose spėjama ne koks įvykis atsitiks (teigiamas ar neigiamas), tačiau prognozuojama, kokia yra tikimybė tam įvykiui atsitikti, dažniausi atidedami ne taškai, bet brėžiamos ROC kreivės. Vienas iš modelių, prognozuojantis įvykio tikimybę, yra logistinė regresija. Logistinės regresijos modelius patogiau analizuoti ROC kreivės pagalba.

ROC kreivė yra grafikas, kuris parodo klasifikatoriaus jautrumo ir specifiškumo sąryšį. ROC kreivė turi visas savybes kaip ir ROC erdvė (žr. 3.3.2 skyrių). Plotas po ROC kreive (angl. *Area Under the Curve, AUC*) parodo kaip gerai veikia modelis. AUC skaičiuojamas kaip plotas esantis į dešinę nuo ROC kreivės. AUC reikšmė gali svyruoti nuo 0 iki 1. Jeigu plotas po ROC kreive yra artimas 1 reiškia, kad modelio prognozavimo tikslumas labai aukštas, kai plotas mažesnis nei 0.5 galima teigti, kad modelis nepasižymi prognostinėmis savybėmis. AUC reikšmei esant lygiai 0.5 galima teigti, jog modelio prognozavimo tikslumas lygus atsitiktiniam. Įprastai praktikoje daugelio modelių AUC reikšmės svyruoja tarp 0.5 ir 1. Nagrinėjant modelius AUC parametro reikšmę galima vertinti kaip teisingos reikšmės atspėjimo tikimybę.

Analizuojant prognozavimo modelius, kurie prognozuoja ne įvykio tikimybę, o konkretų įvykį („1“ arba „0“) taip pat galima nubrėžti ROC kreivę – tiesiog, kitaip nei nagrinėjant logistinės regresijos modelį, jis bus brėžiama ne per daug taškų, o per tris taškus. Abiejų tipų ROC kreivių pavyzdžiai pateikiami 9 paveikslėlyje.



9 pav. Kairėje: ROC kreivės grafikas, kai analizuojamas logistinės regresijos modelis, kuris prognozuoja įvykio tikimybes. Dešinėje: ROC kreivės grafikas, kai analizuojamas modelis prognozuojantis konkrečius dvinarius įvykius.

Kadangi grafiškai sudėtinga įvertinti nedidelius skirtumus (kai modelių prognostinės savybės skiriasi nežymiai), eksperimentinėje dalyje vietoj grafikų bus pateikiami AUC įverčiai.

4. Kintamumo prognozavimo eksperimentai ir jų vertinimas

4.1. Valiutų kurso duomenys pirminiams eksperimentams

Pirminiams kintamumo modelių prognozavimo skaičiavimams ir eksperimentams atlikti buvo naudojama populiariausios valiutų poros pasaulyje – Euro ir JAV dolerio, sutrumpintai žymimos kaip EUR/USD, duomenys. Buvo surinkti daugiau nei 17 metų dieniniai uždarymo kainų (angl. *closing price*) duomenys nuo 2001 m. sausio 1 d. iki 2018 m. gegužės 4 d. Duomenų šaltinis – internetinis portalas *Investing.com* [5]. Eksperimentams atlikti buvo naudojami ne tiesioginiai EUR/USD kainų duomenys, tačiau remiantis šiais duomenimis apskaičiuotas istorinis metinis kintamumas kiekvieną dieną (iš viso 4503 kintamumo reikšmių sąrašas).


4.2. Pirminis metodų tyrimas naudojant valiutų kurso duomenis

Kadangi, kintamumo dydis, kaip ir kiti finansiniai rodikliai, kinta atsitiktine sunkiai nuspėjama kryptimi, eksperimento metu buvo prognozuojamas 1 žingsnis į priekį t. y. kintamumo reikšmė arba pokytis sekančią dieną. Kiekvienas eksperimentas vyko dviem etapais. Pirmojo etapo metu buvo prognozuojama ir testuojama 100 paskutinių (nuo 2017 m. gruodžio 18 d. iki 2018 m. gegužės 4 d. imtinai) kintamumo reikšmių ir pokyčių. Šiame etape faktinis kintamumas svyravo intervale [4.7787, 8.5485], kintamumo reikšmės didėjo 51 kartą, o mažėjo – 49 kartus. Antrajame etape buvo prognozuojama ir testuojama 100 priešpaskutinių (nuo 2017 m. liepos 31 d. iki 2017 m. gruodžio 17 d. imtinai) reikšmių. Šiame etape kintamumas svyravo intervale [5.8894, 8.3719], kintamumo reikšmės didėjo 45 kartus, mažėjo – 55 kartus. Eksperimento metu buvo testuojami trys metodai: laiko eilučių ARIMA, rekurentinių neuroninių tinklų LSTM bei logistinės regresijos. Visi eksperimentai buvo atliekami naudojant „Python“ 3.6.5 versijos programinį paketą.

4.2.1. ARIMA metodų tyrimas

Iš pradžių buvo atliekami eksperimentai su ARIMA modeliais. ARIMA modelio inicijavimui buvo naudojama „Statsmodels“ biblioteka. Testuoti ARIMA (0,1,0) ir ARIMA (1,1,0) modeliai. ARIMA modelyje įvesties reikšmės buvo istoriniai duomenys su kuriais apmokamas modelis, o išvestis – prognozuojama reikšmė. Iš pradžių parinktas reikšmių sąrašas, kuris buvo naudojamos modelio prognozuotų reikšmių testavimui (100 paskutinių arba 100 priešpaskutinių reikšmių). Modelio apmokymui naudoti šių ilgių sąrašai: 5, 10, 15, 25, 50, 100, 200, 300, 400, 500, 600, 800, 1600, 2400, 3200 ir 4000 reikšmių. Kiekvienas modelio apmokymo sąrašas baigiasi prieš pirmąją testavimo reikšmę (tarp prognozavimo ir testavimo reikšmių sąrašų nėra pertrūkių). Kiekvieną kartą prognozuojant kitą reikšmę iš apmokymo sąrašo buvo išimama seniausia faktinė reikšmė ir modeliui pateikiama naujausia faktinė reikšmė.

Prieš testuojant kiekvieną modelį buvo nagrinėti liekamųjų paklaidų (angl. *residual errors*) bei liekamųjų paklaidų išsibarstymo (angl. *residual errors density*) grafikai, kad būtų galima įsitikinti, kad tarp paklaidų nėra naudingos informacijos, kurios modelis neįtraukė. Kaip pavyzdys, ARIMA (1,1,0) modelio paklaidų grafikas atvaizduotas 10 paveikslėlyje.



10 pav. ARIMA (1,1,0) modelio su 500 apmokymo reikšmių liekamųjų paklaidų (kairėje) ir liekamųjų paklaidų išsibarstymo (dešinėje) grafikai.



Kaip matome iš liekamųjų paklaidų išsibarstymo grafiko (10 pav.) tiesė yra taisyklingos varpo formos, o dažniausiai sutinkamos liekamųjų paklaidų reikšmės telkiasi ties 0. Tai reiškia kad klaidos yra normaliojo skirstinio (angl. *normal distribution*) arba dar vadinamo Gauso skirstinio (angl. *Gaussian distribution*), todėl modelis nepaliko neįtrauktos reikšmingos informacijos. Toliau buvo atliekami kintamumo prognozavimo eksperimentai su ARIMA (0,1,0) ir ARIMA (1,1,0) modeliais bei skaičiuojamos RMSE, MAPE ir AUC metrikos su kiekvienu apmokymų reikšmių ilgiu. Rezultatai pateikti 2 lentelėje.

	Apmokymo reikšmių kiekis	Testavimas su 100 paskutinių reikšmių				Testavimas su 100 priešpaskutinių reikšmių			
		RMSE	MAPE	AUC	Prognozė	RMSE	MAPE	AUC	Prognozė
ARIMA (0,1,0)	5	0.2877	3.1400	0.4438	Įvairi	0.3647	3.0419	0.4495	Įvairi
	10	0.2864	3.0827	0.4536	Įvairi	0.3627	3.0209	0.4111	Įvairi
	15	0.2856	3.0442	0.4438	Įvairi	0.3623	3.0173	0.4566	Įvairi
	25	0.2852	3.0277	0.4924	Įvairi	0.3641	3.1045	0.5000	Didėjanti
	50	0.2844	3.0063	0.5116	Įvairi	0.3609	2.9905	0.5000	Mažėjanti
	100	0.2838	2.9950	0.5288	Įvairi	0.3603	2.9876	0.4111	Įvairi
	200	0.2833	2.9856	0.5096	Įvairi	0.3601	2.9935	0.5000	Didėjanti
	300	0.2831	2.9819	0.4258	Įvairi	0.3596	2.9765	0.5000	Mažėjanti
	400	0.2830	2.9826	0.5000	Mažėjanti	0.3596	2.9774	0.4636	Įvairi
	500	0.2829	2.9795	0.4636	Įvairi	0.3593	2.9719	0.5000	Mažėjanti
	600	0.2830	2.9869	0.5000	Mažėjanti	0.3593	2.9702	0.5000	Mažėjanti
	800	0.2829	2.9778	0.4906	Įvairi	0.3596	2.9847	0.5000	Didėjanti
	1600	0.2828	2.9800	0.5000	Mažėjanti	0.3593	2.9733	0.5000	Mažėjanti
	2400	0.2827	2.9780	0.5000	Mažėjanti	0.3593	2.9760	0.4697	Įvairi
	3200	0.2827	2.9756	0.5000	Mažėjanti	0.3593	2.9760	0.4697	Įvairi
4000	0.2827	2.9754	0.5000	Mažėjanti	0.3593	2.9757	0.4212	Įvairi	
ARIMA (1,1,0)	5	0.2901	3.1486	0.5532	Įvairi	0.3610	3.1238	0.5111	Įvairi
	10	0.2878	3.1050	0.5728	Įvairi	0.3554	3.0686	0.5546	Įvairi
	15	0.2869	3.0860	0.5728	Įvairi	0.3548	3.0673	0.5677	Įvairi
	25	0.2852	3.0438	0.5610	Įvairi	0.3568	3.1364	0.6303	Įvairi
	50	0.2833	3.0125	0.5708	Įvairi	0.3532	2.9842	0.5535	Įvairi
	100	0.2832	3.0324	0.5692	Įvairi	0.3570	2.9612	0.5222	Įvairi
	200	0.2812	2.9533	0.5700	Įvairi	0.3525	2.9716	0.6313	Įvairi
	300	0.2810	2.9602	0.5516	Įvairi	0.3578	2.9440	0.5505	Įvairi
	400	0.2817	2.9540	0.5456	Įvairi	0.3578	2.9447	0.5566	Įvairi
	500	0.2818	2.9563	0.5578	Įvairi	0.3570	2.9378	0.5263	Įvairi
	600	0.2819	2.9586	0.5628	Įvairi	0.3627	3.0266	0.4273	Įvairi
	800	0.2855	3.0400	0.3880	Įvairi	0.3664	3.0927	0.4081	Įvairi
	1600	0.2850	3.0294	0.3958	Įvairi	0.3635	3.0440	0.3687	Įvairi
	2400	0.2837	3.0010	0.4640	Įvairi	0.3620	3.0187	0.3838	Įvairi
	3200	0.2836	2.9991	0.4084	Įvairi	0.3619	3.0179	0.3960	Įvairi
4000	0.2827	2.9746	0.5000	Mažėjanti	0.3594	2.9767	0.4152	Įvairi	

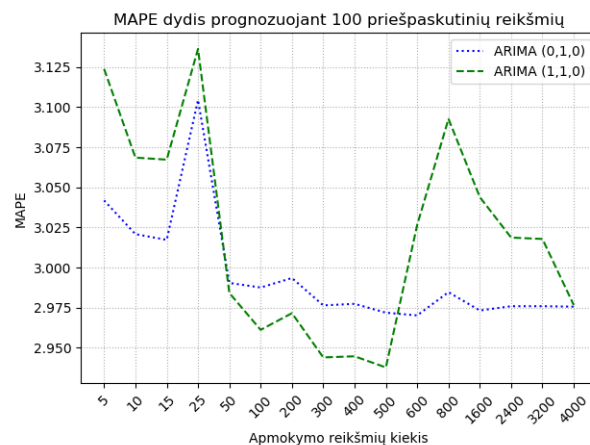
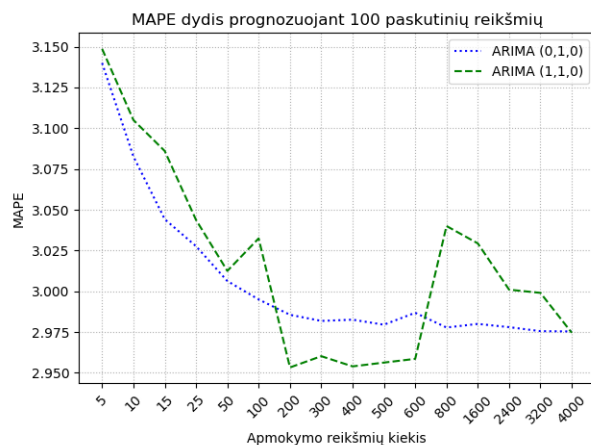
2 lentelė. Tirti ARIMA modelių variantai ir jų RMSE, MAPE, AUC dydžiai bei prognozės kryptis, kai prognozuojamas 100 dienų kintamumas, perskaičiuojant po 1 dieną į priekį.

Prie RMSE, MAPE ir AUC reikšmių buvo įtrauktas papildomas stulpelis „Prognozė“, kuris parodo, kaip modelis prognozavo kintamumą. „Įvairi“ prognozė reiškia, kad modelis lyginant su prieš tai buvusia faktine reikšme prognozuodavo tiek kintamumo mažėjimą, tiek didėjimą, „mažėjanti“ - modelis visada prognozuodavo, kad kintamumas mažės, o „didėjanti“ - modelis prognozavo, kad kintamumas visada tik didės.

Kad būtų lengviau nagrinėti rezultatus eksperimentų duomenys buvo atvaizduoti grafiškai (11, 12 pav.):



11 pav. ARIMA (0,1,0) ir ARIMA (1,1,0) modelių eksperimentų metu gauti RMSE dydžiai apmokant modelį su skirtingais kiekiais reikšmių. Iliustracija kairėje: prognozuojant 100 paskutinių reikšmių. Iliustracija dešinėje: prognozuojant 100 priešpaskutinių reikšmių.




12 pav. ARIMA (0,1,0) ir ARIMA (1,1,0) modelių eksperimentų metu gauti MAPE dydžiai apmokant modelį su skirtingais kiekiais reikšmių. Iliustracija kairėje: prognozuojant 100 paskutinių reikšmių. Iliustracija dešinėje: prognozuojant 100 priešpaskutinių reikšmių.

Kaip galime matyti 11 ir 12 paveikslėliuose abiejų nagrinėtų ARIMA modelių RMSE ir MAPE reikšmės buvo didžiausios kai modeliai apmokyti su nedideliu reikšmių kiekiu (nuo 5 iki 50). Tarp ARIMA (0,1,0) ARIMA (1,1,0) galima pastebėti esminį skirtumą: ARIMA (0,1,0) modelio tiek RMSE, tiek MAPE dydžiai mažėjo didėjant apmokymų reikšmių kiekiui, tuo tarpu ARIMA (1,1,0) RMSE įvertis buvo mažiausias kai modelis apmokytas su ~200 reikšmių, o MAPE - kai modelis apmokomas su apytiksliai 200-600 reikšmių. Toliau didinant ARIMA (1,1,0) apmokymo reikšmių kiekį (600 ir daugiau) abu įverčiai (RMSE ir MAPE) pradėjo didėti. ARIMA (1,1,0) modelio įgyjamos mažiausios RMSE ir MAPE reikšmės buvo mažesnės nei ARIMA (0,1,0) modelio, taigi galima teigti, kad ARIMA (1,1,0) modelio kintamumo reikšmių prognozės, modelį apmokius su apytiksliai 200-400 reikšmių tarp tirtų abiejų ARIMA modelių buvo tiksliausias.

Kaip jau buvo minėta, vertintos ne tik modelių galimybės prognozuoti konkrečią kintamumo reikšmę, bet ir kryptį. Kaip gerai modelis prognozavo kintamumo kryptį nusako AUC įvertis. Iš rezultatų lentelės (2) galima pastebėti, kad ARIMA modelis net 14 kartų iš 32 prognozavo vienakryptį judėjimą t. y. modelis atlikdamas visas 100 kintamumo prognozių spėdavo, kad

kintamumas tik mažės arba tik didės, todėl tai pirmasis signalas, kad ARIMA (0,1,0) modelis netinkamai prognozuoja pokyčio kryptį. Tą pačią tendenciją galima pastebėti ir iš pateiktų AUC įverčių grafikų (13 pav.)



13 pav. ARIMA (0,1,0) ir ARIMA (1,1,0) modelių eksperimentų metu gauti AUC dydžiai apmokant modelį su skirtingais kiekiais reikšmių. Iliustracija kairėje: prognozuojant 100 paskutinių reikšmių. Iliustracija dešinėje: prognozuojant 100 priešpaskutinių reikšmių.

Galima matyti, kad ARIMA (0,1,0) modelis dažnai spėdavo vienakryptį judėjimą, o, kai prognozavo nevienakryptį judėjimą, rezultatai vis tiek dažniausiai būdavo prastesni nei atsitiktinio spėjimo ($AUC < 0.5$). Tuo tarpu nagrinėjant ARIMA (1,1,0) eksperimentų rezultatus matoma aiški tendencija – modelis prognozavo kintamumo judėjimo kryptį geriau nei atsitiktinis spėjimas ($AUC > 0.5$), kai buvo apmokomas su mažiau nei ~ 500 reikšmių. Kai apmokymo reikšmių kiekis viršijo 600, kintamumo judėjimo krypties prognozavimas buvo prastesnis už atsitiktinį ($AUC < 0.5$).

Apibendrinant abiejų ARIMA modelių eksperimentus galima teigti, kad ARIMA (0,1,0) prognozės visų trijų įverčių atžvilgiu (RMSE, MAPE, AUC) buvo geriausios su 800 apmokymo reikšmių ir daugiau, tuo tarpu ARIMA (1,1,0) geriausias rezultatus parodė, kai buvo apmokomas su apytiksliai 200-500 reikšmių. ARIMA (1,1,0) modelio kintamumo prognozių geriausi rezultatai buvo kokybiškesni už ARIMA (0,1,0) geriausias rezultatus.

4.2.2. LSTM metodų tyrimas

LSTM modelio kūrimui buvo naudojama „Keras“ biblioteka su „TensorFlow“ platforma. „TensorFlow“ yra atviro kodo platforma, kurią plėtoja ir prižiūri „Google“ kompanija. Ji daugiausia naudojama įvairioms mašininio mokymosi, tame tarpe ir neuroninių tinklų, užduotims atlikti.

LSTM modelio testavimui naudota panaši metodologija kaip ir ARIMA metodikos eksperimentų metu. Pagrindinis skirtumas – modelio apmokymas testuotas su trumpesniais reikšmių sąrašais, kadangi dėl LSTM modelio hiperbolinio tangento aktyvacijos funkcijos skaičiavimų modelio testavimas su ilgais reikšmių sąrašais užtrunka ilgai. Modelio testavimas su 500 istorinių reikšmių užtrunka apytiksliai 100 minučių. LSTM modelio apmokymui naudotų istorinių reikšmių sąrašai buvo: 3, 5, 10, 15, 25, 50, 100, 200, 300, 400 ir 500 eilučių ilgio. Kintamumo reikšmių sąrašas buvo suskirstytas taip pat kaip ir nagrinėjant ARIMA modelius: į apmokymo ir testavimo sąrašus.

Apmokyti LSTM modelį naudotas apmokymo su mokytoju būdas: apmokymo įvestimis laikytas kintamumo pokyčių reikšmės prieš periodą, o išvestimis esamo periodo pokyčio reikšmė. LSTM modelio apmokymui naudoti reikšmių pokyčiai, o ne tiesioginės reikšmės tam, kad būtų pašalinti trendai.

Kadangi standartinė LSTM modelio aktyvacijos funkcija yra hiperbolinis tangentas, kurio reikšmės kinta intervale $(-1, 1)$ atitinkamai turi būti koreguojamos ir apmokymo reikšmės. Tai gi modelio apmokymui suteikiamos ne tiesioginės kintamumo pokyčio reikšmės, o santykinės. Reikšmių santykiniam perskaičiavimui naudota „Scikit-learn“ bibliotekos funkcija „MinMaxScaler“. Prieš apmokant reikšmės buvo konvertuojamos į intervalą $(-1, 1)$, o prieš grąžinant prognozuotas pokyčių reikšmes tam, kad būtų vėl gautos realios pokyčių reikšmės, o ne santykinės, jos vėl transformuojamos atgal į pradinę skalę. Paskutiniame žingsnyje iš pokyčio reikšmių vėl apskaičiuojamas kintamumas, kuris ir laikomas prognozuojamu kintamumu.

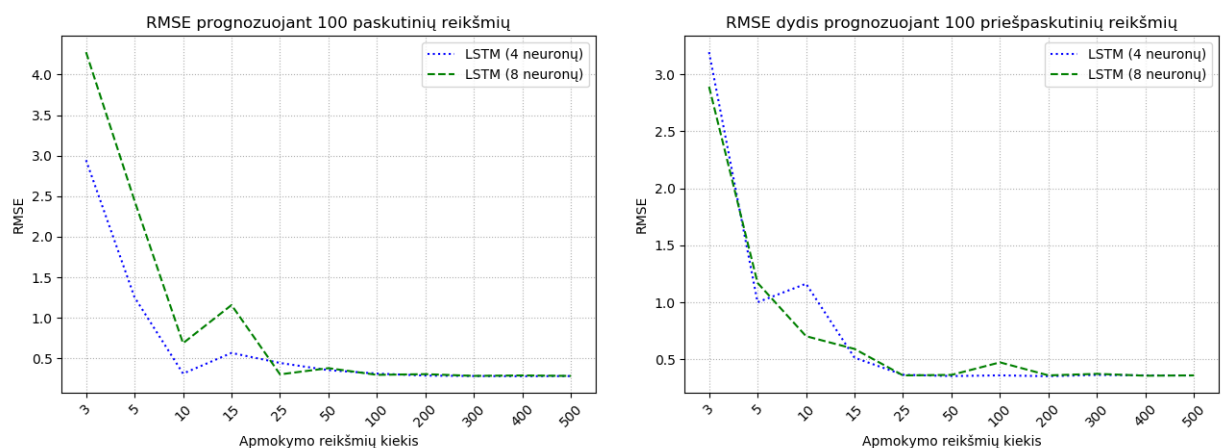
Norint, kad LSTM modelis kiekvienu atveju pats nuspręstų kurios reikšmės modeliui yra reikšmingos „stateful“ argumentas nurodomas kaip „True“. Kitas svarbus parametras – neuronų kiekis. Nagrinėjant nesudėtingas problemas rekomenduojama naudoti nuo 1 iki 5 neuronų, sudėtingesnėms problemoms – gali būti naudojama ir daugiau neuronų. Buvo testuojami du modelio variantai 4 ir 8 neuronų. Dar vienas nustatomas parametras – svorių perskaičiavimų kartų nustatymas. „Keras“ bibliotekoje šiam parametru suteiktas „Epochs“ vardas. Testuose naudojamas 3000 kartų perskaičiavimas. Vienareikšmio atsakymo, koks yra optimalus neuronų kiekis ar kiek kartų turi būti perskaičiuojami svoriai nėra. Visa tai nustatoma eksperimentų pagalba kiekvienam modeliui atskirai.

Abiejų LSTM modelio variantų (4 ir 8 neuronų) eksperimentų rezultatai pateikiami 3 lentelėje.

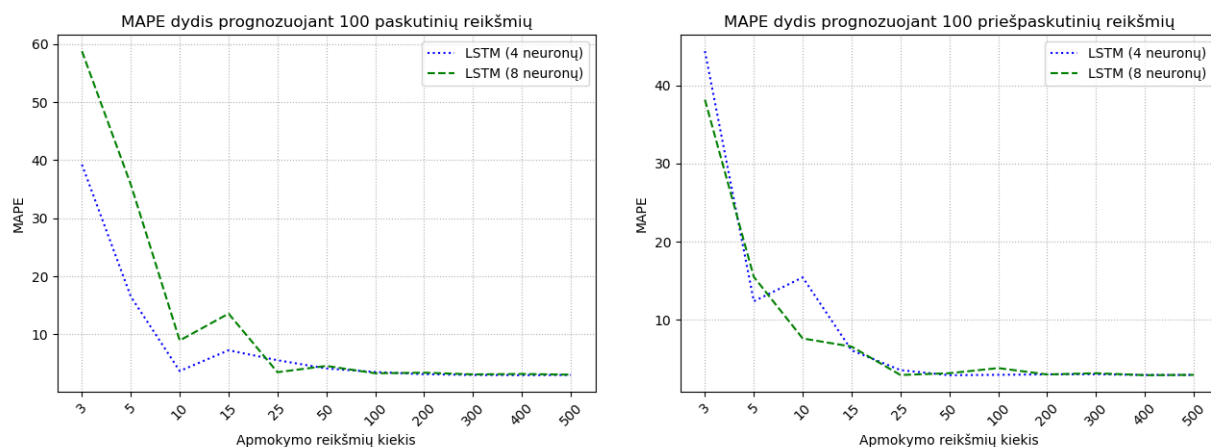
	Apmokymo reikšmių kiekis	Testavimas su 100 paskutinių reikšmių				Testavimas su 100 priešpaskutinių reikšmių			
		RMSE	MAPE	AUC	Prognozė	RMSE	MAPE	AUC	Prognozė
LSTM 4 neuronų	3	2.9440	39.2499	0.5098	Įvairi	3.1927	44.3608	0.5000	Įvairi
	5	1.2541	16.4964	0.5566	Įvairi	1.0004	12.3920	0.4980	Įvairi
	10	0.3132	3.6677	0.5194	Įvairi	1.1628	15.4503	0.5000	Mažėjanti
	15	0.5674	7.2428	0.5098	Įvairi	0.5141	6.1277	0.5505	Įvairi
	25	0.4440	5.5306	0.4782	Įvairi	0.3646	3.5950	0.5444	Įvairi
	50	0.3554	4.1068	0.4856	Įvairi	0.3532	2.9428	0.5616	Įvairi
	100	0.3130	3.4902	0.5280	Įvairi	0.3595	2.9937	0.4818	Įvairi
	200	0.2883	3.1165	0.4990	Įvairi	0.3520	3.0509	0.5444	Įvairi
	300	0.2828	2.9855	0.5000	Mažėjanti	0.3634	3.0670	0.4950	Įvairi
	400	0.2805	2.9420	0.5734	Įvairi	0.3592	2.9734	0.5000	Mažėjanti
500	0.2825	2.9832	0.5774	Įvairi	0.3587	2.9761	0.5475	Įvairi	
LSTM 8 neuronų	3	4.2755	58.7916	0.5000	Mažėjanti	2.8899	38.1560	0.5000	Didėjanti
	5	2.4437	35.8010	0.5102	Įvairi	1.1703	15.5131	0.5111	Įvairi
	10	0.6876	8.9265	0.4838	Įvairi	0.7029	7.6411	0.5040	Įvairi
	15	1.1579	13.5559	0.5350	Įvairi	0.5911	6.6023	0.4859	Įvairi
	25	0.3034	3.4610	0.5000	Mažėjanti	0.3590	2.9691	0.5000	Mažėjanti
	50	0.3800	4.5426	0.5402	Įvairi	0.3636	3.1985	0.5313	Įvairi
	100	0.2973	3.2765	0.5966	Įvairi	0.4734	3.8555	0.4879	Įvairi
	200	0.3060	3.3786	0.5096	Įvairi	0.3593	3.0406	0.6131	Įvairi
	300	0.2846	3.0869	0.5692	Įvairi	0.3727	3.1966	0.5475	Įvairi
	400	0.2902	3.1569	0.5080	Įvairi	0.3566	2.9486	0.6040	Įvairi
500	0.2841	3.0375	0.5876	Įvairi	0.3592	2.9868	0.4939	Įvairi	

3 lentelė. Tirti LSTM modelių variantai ir eksperimentų metu gauti RMSE, MAPE, AUC dydžiai bei prognozės kryptys, kai prognozuojamas 100 dienų kintamumas, perskaičiuojant po 1 dieną į priekį.

RMSE ir MAPE metrikų reikšmės buvo atvaizduotos grafiškai 14 ir 15 paveikslėliuose.



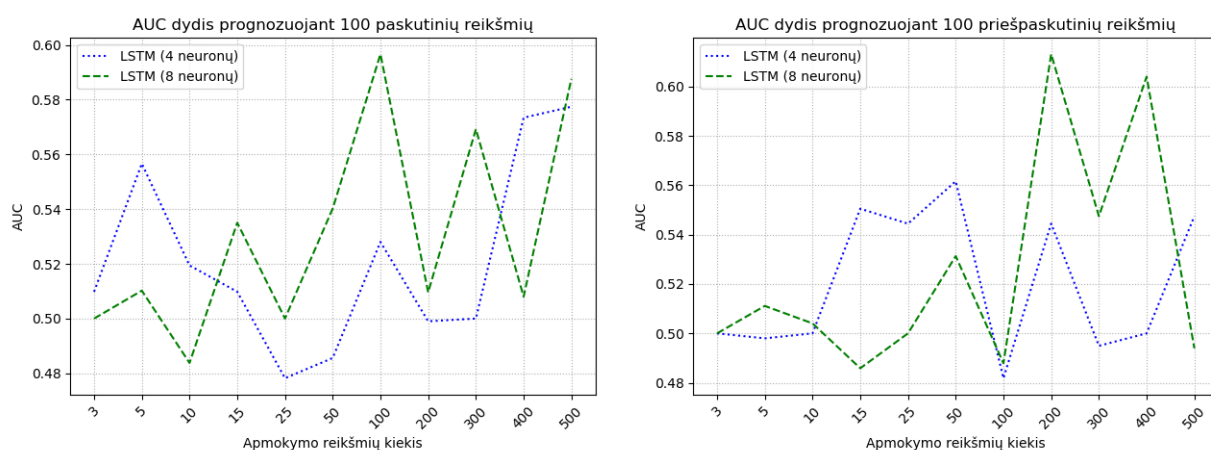
14 pav. LSTM (4 neuronų) ir LSTM (8 neuronų) eksperimentų metu gauti RMSE dydžiai apmokant modelį su skirtingais kiekiais reikšmių. Ilustracija kairėje: prognozuojant 100 paskutinių reikšmių. Ilustracija dešinėje: prognozuojant 100 priešpaskutinių reikšmių.



15 pav. LSTM (4 neuronų) ir LSTM (8 neuronų) eksperimentų metu gauti MAPE dydžiai apmokant modelį su skirtingais kiekiais reikšmių. Iliustracija kairėje: prognozuojant 100 paskutinių reikšmių. Iliustracija dešinėje: prognozuojant 100 priešpaskutinių reikšmių.

Iš pateiktų RMSE ir MAPE gautų eksperimentų metu įverčių grafikų (14, 15 pav.) matoma aiški tendencija: abu įverčiai gerėja (mažėja) didėjant apmokymo reikšmių kiekiui. LSTM 8 neuronų tinklas įgijo mažiausias RMSE ir MAPE reikšmes kai buvo apmokytas su 500 ir 400 apmokymo reikšmių, o LSTM 4 neuronų – atitinkamai su 500 ir 25 reikšmėmis (vis dėlto antras geriausias rezultatas fiksuotas taip pat su 400 apmokymo reikšmių). Taigi, reikšmių kiekio apmokymo didinimas darė tiesioginę teigiamą įtaką modelio RMSE ir MAPE rezultatams. LSTM modelio su 4 neuronais eksperimento RMSE ir MAPE rezultatai buvo tik nežymiai geresni nei LSTM modelio su 8 neuronais. Prognozuojant 100 paskutinių reikšmių LSTM su 4 neuronais mažiausia RMSE fiksuota reikšmė buvo 0.2805, MAPE 2.9420, tuo tarpu LSTM modelio su 8 neuronais nedaug didesni – atitinkamai 0.2841 ir 3.0375. Prognozuojant 100 priešpaskutinių taip pat rezultatai nežymiai geresni buvo LSTM su 4 neuronais modelio – geriausias RMSE rezultatas buvo 0.3520, MAPE – 2.9428, o LSTM su 8 neuronais atitinkamai 0.3566 ir 2.9486.

Toliau buvo analizuojami AUC įverčiai. Rezultatai atvaizduoti 16 paveikslėlyje.



16 pav. LSTM (4 neuronų) ir LSTM (8 neuronų) eksperimentų metu gauti AUC dydžiai apmokant modelį su skirtingais kiekiais reikšmių. Iliustracija kairėje: prognozuojant 100 paskutinių reikšmių. Iliustracija dešinėje: prognozuojant 100 priešpaskutinių reikšmių.

Kaip galima matyti iš grafiko (16 pav.) eksperimento metu prognozuojant kintamumą 100

paskutinių reikšmių daugeliu atvejų geresnius rezultatus rodė LSTM 8 neuronų modelis. Tuo tarpu prognozuojant 100 priešpaskutinių reikšmių, kai modelis buvo apmokytas su mažesniu kiekiu reikšmių (iki 100), didesnės AUC įvertio reikšmės buvo LSTM 4 neuronų modelio, tačiau apmokant modelį su 200, 300 ar 400 reikšmių AUC įvertis buvo didesnis atliekant kintamumo prognozes su 8 neuronų modeliu. Vienareikšmes prognozes daryti sudėtinga, nes bendrų tendencijų iš pateiktų duomenų nėra, vis dėlto, kai modeliai buvo apmokomi su 200 ir daugiau reikšmių, 6 iš 8 kartų AUC įvertis buvo didesnis naudojant LSTM 8 neuronų modelį.

4.2.3. Logistinės regresijos metodo tyrimas

Logistinės regresijos modelio kūrimui ir skaičiavimams buvo naudojama „Scikit-learn“ biblioteka. „Scikit-learn“ yra atviro kodo biblioteka, skirta duomenų gavybai (angl. *data mining*) ir duomenų analizei.

Logistinės regresijos eksperimentui, kitaip nei ARIMA ir LSTM eksperimentų atveju, modelio apmokymui buvo suteikiamos ne tiesioginės kintamumo reikšmės, bet kintamumo pokyčių dvinarės reikšmės t. y. jei kintamumas mažėjo lyginant su prieš tai buvusiu diena, jis buvo pažymėtas „0“, jei didėjo – atitinkamai pažymėtas „1“. Nepriklausomais kintamaisiais laikyti kintamumo pokyčiai prieš tam tikrą dienų skaičių (n), tuo tarpu priklausomu kintamuoju laikytas kintamumo pokytis sekęs po tų dienų skaičiaus ($n + 1$). Pavyzdžiui, kai modelis buvo apmokomas su 5 prieš tai buvusiomis reikšmėmis, buvo sudaroma matrica, kurios kiekvienoje eilutėje buvo 5 nepriklausomi kintamieji (5 dienų pokyčių reikšmės) ir šeštoji reikšmė – priklausomojo kitamojo reikšmė, sekusi po 5 nepriklausomųjų kintamųjų. Konkretus pavyzdys – jei modelį apmokome su 5 prieš tai buvusiomis reikšmėmis, o iš viso turimų reikšmių kiekis yra 8, kurios paeiliui atitinkamai lygios 0, 1, 1, 0, 1, 0, 0, 1, tuomet matrica sudaryta logistinės regresijos apmokymui atrodytų kaip 4 lentelėje.

5 diena prieš pokytį	4 diena prieš pokytį	3 diena prieš pokytį	2 diena prieš pokytį	1 diena prieš pokytį	Pokytis
0	1	1	0	1	0
1	1	0	1	0	0
1	0	1	0	0	1


4 lentelė. Matricos sudarymo pavyzdys logistinės regresijos modelio apmokymui

Kad logistinės regresijos modelis galėtų prognozuoti kintamumo didėjimo tikimybę modeliui analogiškai buvo suteikiamos prieš norimą prognozuoti periodąėjusios kintamumo dvinarės reikšmės (nepriklausomi kintamieji). Kadangi buvo norima palyginti logistinės regresijos modelio rezultatus su ARIMA ir LSTM modelių eksperimentų rezultatais, logistinės regresijos modeliui prognozavus kintamumo didėjimo tikimybę didesnę arba lygią 0.5 buvo laikyta, kad modelis prognozuoja kintamumo didėjimą („1“), prognozavus tikimybę mažesnę nei 0.5 laikyta, kad modelis prognozuoja kintamumo mažėjimą („0“). Eksperimentų metu gauti AUC dydžiai pateikiami 5 lentelėje.

	Modelio apmokymo reikšmių kiekis	AUC testuojant su 100 paskutinių reikšmių	AUC testuojant su 100 priešpaskutinių reikšmių
Logistinė regresija	5	0.4770	0.5051
	10	0.4795	0.6000
	15	0.5186	0.4182
	25	0.5304	0.4727
	50	0.4700	0.4828
	100	0.5398	0.4879
	200	0.4516	0.4990
	300	0.5308	0.5242
	400	0.5504	0.5798
	500	0.4892	0.4535
	600	0.4892	0.5505
	800	0.4900	0.5434
	1600	0.5296	0.4859
	2400	0.5088	0.4970
	3200	0.5402	0.5939
4000	0.4672	0.4808	

5 lentelė. Logistinės regresijos modelio eksperimentų rezultatai (AUC dydis).

Duomenys taip pat buvo atvaizduoti grafiškai 17 paveikslėlyje.



17 pav. Logistinės regresijos eksperimentų metu gauti AUC dydžiai apmokant modelį su skirtingais kiekiais reikšmių.

Kaip galima matyti iš grafiko aiškiau sąryšio tarp apmokymo reikšmių ir AUC įverčio dydžio nėra. Vis dėlto, paskaičiavus AUC įverčio vidurkį su 100 ir daugiau apmokymo reikšmių bei su 50 ir mažiau, galima pastebėti nežymų skirtumą: AUC vidurkis su 100 ir daugiau apmokymo reikšmių yra 0.5129, o su 50 ir mažiau - 0.4954. Skirtumas yra nedidelis ir būtų sudėtinga daryti vienareikšmes išvadas, nes eksperimentų apimtis nėra didelė. Žvelgiant į bendrus rezultatus panašu, kad logistinės regresijos modelis nėra tinkamas kintamumo krypties nustatymui.


4.3. Naudojami duomenys

Norint išplėsti metodų tyrimus buvo surinkti ir įtraukti įvairaus pobūdžio duomenys. Pirmoji duomenų grupė - signalai, turintys kvazi-periodinius svyravimus (svyravimai turi kažkokį

periodą, bet jo griežtai nesilaiko). Tokie duomenys fiksuojami stebint meteorologinius reiškinius, socialinėje-ekonominėje visuomenės veikloje ir panašiose sferose, kur vyrauja periodiškumas. Žemiau pateiktoje 6 lentelėje šie duomenys išrikiuoti nuo 1 iki 11 (imtinai). Buvo surinkti meteorologiniai duomenys – temperatūros, atmosferos slėgio ir drėgnio, santykinės drėgmės, vėjo greičio įvairiuose miestuose bei socialiniai duomenys – areštų skaičius, gimstamumo rodiklis, pervažiavimų dviračiais per tiltą skaičius. Pervažiavimų dviračiais per Fremonto tiltą Portlende, JAV, skaičius, santykinė drėgmė, vėjo greitis bei temperatūra Londone (BPFREMONT, RHLDN, TEMPLDN, WSLDN) buvo fiksuoti intervališkai kiekvieną valandą, o visų likusių šios duomenų grupės fiksavimo intervalas – viena diena.

Antroji duomenų grupė – įvairūs finansiniai duomenys neturintys kvazi-periodinių svyravimų. Jų grafinis palyginimas su pirmąja duomenų grupe pateiktas 18 paveikslėlyje. Kaip galime matyti iš paveikslėlio finansiniai duomenys dažniausiai turi aiškiai išreikštus trendus, tačiau tų trendų trukmė yra sunkiai nuspėjama, signalai yra nestacionarūs. 6 lentelėje šie duomenys išrikiuoti nuo 12 iki 51 imtinai. Tai įvairūs akcijų indeksai (S&P 500, Nikkei ir pan.), valiutų kursų, žaliavų kainų, atskirų kompanijų akcijų dienos pabaigos kainų (angl. *close price*), bei populiariausios kriptovaliutos „Bitcoin“ kainos (JAV dolerio atžvilgiu) duomenys. Visų šių duomenų intervalas – 1 diena.

Taip pat į 52 poziciją buvo įtraukti jau anksčiau nagrinėti Euro ir JAV dolerio kurso duomenys, nes su jais taip pat bus tęsiami tolimesni tyrimai.



18 pav. Iliustracija kairėje: signalų, turinčių kvazi-periodinius svyravimus, pavyzdys. Iliustracija dešinėje: finansinių duomenų, turinčių trendus, pavyzdys.

Visi duomenys buvo surinkti iš internetinių šaltinių. Atmosferos slėgio ir drėgnio Almerijoje duomenys buvo parsųsti iš internetinio portalo *Solargis.com* [6]; areštų skaičiaus, kelionių dviračiais bei temperatūros Kerio mieste duomenys iš *Data.gov* [4]; santykinės drėgmės, temperatūros bei vėjo greičio Londone iš *Urban-Climate.com* [2]; temperatūros Sidnėjuje iš *Bom.gov.au* [1]; gimstamumo JAV iš *Github.com* [7]; vėjo greičio Niujorke – iš *Ncdc.noaa.gov* [3]; visų valiutų kursų bei „Bitcoin“ kainos iš *Investing.com* [5], o visi kiti finansiniai duomenys surinkti iš *finance.yahoo.com* [8] portalo.

Eil. nr.	Aprašymas	Sutrumpinimas	Pradžia	Pabaiga	Eilučių kiekis
1	Atmosferos slėgis (hPa) Almerijoje, Ispanija	APALM	1994-01-01	2016-12-31	8402
2	Areštų skaičius Pitsburge, JAV	ARRSTPGH	2016-08-01	2018-07-31	730
3	Kelionių dviračiais skaičius per Fremonto tiltą Portlende, JAV	BPFREMONT	2017-10-01	2018-09-30	8760
4	Atmosferos drėgnis (kg/m ²) Almerijoje, Ispanija	PWATALM	1994-01-01	2016-12-31	8402
5	Santykinė drėgmė Londone, DB	RHLDN	2016-01-01	2016-12-31	8784
6	Temperatūra Kerio mieste, JAV	TEPCARY	2007-01-01	2018-10-10	4301
7	Temperatūra Londone, DB	TEMPLDN	2016-01-01	2016-12-31	8784
8	Temperatūra Sidnėjuje, Australija	TEMPSYD	2001-01-01	2018-09-29	6481
9	Gimstamumas JAV	USBIRTHS	2000-01-01	2014-12-31	5480
10	Vėjo greitis Londone, DB	WSLDN	2016-01-01	2016-12-31	8784
11	Vėjo greitis Niujorke, JAV	WSNY	2001-01-01	2018-10-07	6444
12	Apple Inc. akcijų kaina	AAPL	2001-01-02	2018-10-10	4472
13	Alaska Air Group Inc. akcijų kaina	ALK	2001-01-02	2018-10-10	4472
14	Bank of America Corporation akcijų kaina	BAC	2001-01-02	2018-10-10	4472
15	Barclays PLC akcijų kaina	BCS	2001-01-02	2018-10-10	4472
16	Berkshire Hathaway Inc. akcijų kaina	BRK-B	2001-01-02	2018-10-10	4472
17	Bitkoino kaina JAV doleriais	BTC	2010-07-16	2018-10-10	3009
18	Citigroup Inc. akcijų kaina	C	2001-01-02	2018-10-10	4472
19	Cisco Systems Inc. akcijų kaina	CSCO	2001-01-02	2018-10-10	4472
20	Chevron Corporation akcijų kaina	CVX	2001-01-02	2018-10-10	4472
21	Dow Jones indeksas	DJI	2001-01-02	2018-10-10	4472
22	Euro - Japonijos jenos kursas	EUR/JPY	2001-01-02	2018-10-10	4655
23	Ford Motor Company akcijų kaina	F	2001-01-02	2018-10-10	4472
24	General Electric Company akcijų kaina	GE	2001-01-02	2018-10-10	4472
25	Aukso (angl. "gold futures") kaina už unciją (USD)	GOLD	2001-01-02	2018-10-10	4472
26	Alphabet Inc. akcijų kaina	GOOG	2004-08-19	2018-10-10	3562
27	The Goldman Sachs Group Inc. akcijų kaina	GS	2001-01-02	2018-10-10	4472
28	International Business Machines Corporation akcijų kaina	IBM	2001-01-02	2018-10-10	4472
29	Intel Corporation akcijų kaina	INTC	2001-01-02	2018-10-10	4472
30	Johnson & Johnson akcijų kaina	JNJ	2001-01-02	2018-10-10	4472
31	JPMorgan Chase & Co. akcijų kaina	JPM	2001-01-02	2018-10-10	4472
32	The Coca-Cola Company akcijų kaina	KO	2001-01-02	2018-10-10	4472
33	Southwest Airlines Co. akcijų kaina	LUV	2001-01-02	2018-10-10	4472
34	Lloyds Banking Group plc akcijų kaina	LYG	2001-01-02	2018-10-10	4472
35	McDonald's Corporation akcijų kaina	MCD	2001-01-02	2018-10-10	4472
36	Nikkei 225 akcijų indeksas	NIKKEI	2001-01-02	2018-10-10	4472
37	Nokia Corporation akcijų kaina	NOK	2001-01-02	2018-10-10	4472
38	Oracle Corporation akcijų kaina	ORCL	2001-01-02	2018-10-10	4472
39	Pfizer Inc. akcijų kaina	PFE	2001-01-02	2018-10-10	4472
40	Rolls-Royce Holdings plc akcijų kaina	RYCEY	2001-01-02	2018-10-10	4472
41	Sony Corporation akcijų kaina	SNE	2001-01-02	2018-10-10	4472
42	S&P 500 akcijų indeksas	SP500	2001-01-02	2018-10-10	4472
43	AT&T Inc. akcijų kaina	T	2001-01-02	2018-10-10	4472
44	Toyota Motor Corporation akcijų kaina	TM	2001-01-02	2018-10-10	4472
45	Tesco PLC akcijų kaina	TSCDY	2001-01-02	2018-10-10	4472
46	JAV dolerio - Šveicarijos franko kursas	USD/CHF	2001-01-02	2018-10-10	4655
47	Volkswagen AG akcijų kaina	VWAGY	2001-01-02	2018-10-10	4472
48	Wells Fargo & Company akcijų kaina	WFC	2001-01-02	2018-10-10	4472
49	Walmart Inc. akcijų kaina	WMT	2001-01-02	2018-10-10	4472
50	Naftos (angl. "Crude Oil WTI Futures") kaina už barelį (USD)	WTI	2001-01-02	2018-10-10	4472
51	Exxon Mobil Corporation akcijų kaina	XOM	2001-01-02	2018-10-10	4472
52	Euro - JAV dolerio kursas	EUR/USD	2001-01-02	2018-05-04	4525

6 lentelė. Duomenų įtrauktų į tolimesnius tyrimus aprašymas.

4.4. Signalų klasifikavimas remiantis Hursto eksponente ir autokoreliacija

Tam, kad geriau suprasti pasirinktų duomenų (signalų) savybes ir prognozuojamumą buvo vertinama kiekvieno signalo Hursto eksponentė bei autokoreliacija.

4.4.1. Hursto eksponentė

Hursto eksponentė (angl. *Hurst exponent*) naudojama matuoti ilgalaikę laiko eilučių atmintį. Hursto eksponentės pagalba galima įvertinti, ar signalas turi ilgalaikę atmintį. Hursto eksponentė yra labai plačiai naudojama laiko eilučių analizei finansų sektoriuje [25].

Hursto eksponentės reikšmė teoriškai gali svyruoti nuo 0 iki 1. Reikšmė artima 0 reiškia, kad laiko eilutės reikšmės svyruoja periodiškai tarp žemų ir aukštų reikšmių t.y. didelės reikšmės keičia mažas reikšmes ir atvirkščiai. Hursto eksponentės reikšmės artimos 1 parodo, kad laiko eilutės turi ilgalaikę teigiamą koreliaciją, t.y. po didelių reikšmių seka didelės, o po mažų reikšmių - mažos. Tuo tarpu Hursto eksponentė artima 0.5 parodo, kad duomenys neturi koreliacijos, reikšmės sekančios po didelių reikšmių skirtingais laiko momentais, gali būti tiek mažos tiek didelės - nėra aiškaus periodiško [19].

Norint įvertinti Hursto eksponentę iš pradžių skaičiuojama logaritminių kainų dispersija, kurios pagalba galima įvertinti signalo judesio tempą. Pasirinktam laiko tarpui τ , dispersija skaičiuojama pagal žemiau pateiktą formulę [29]:

$$\text{Var}(\tau) = \langle |\log(t + \tau) - \log(t)|^2 \rangle \quad (4.1)$$

Kadangi skaičiuojant Hursto eksponentę signalo judesio tempas lyginamas su geometrinium Brauno judesiu (angl. *Geometric Brownian Motion*), galima daryti prielaidą, kad esant didelei τ reikšmei dispersija yra proporcinga τ geometrinio Brauno judesio atveju:

$$\langle |\log(t + \tau) - \log(t)|^2 \rangle \sim \tau \quad (4.2)$$

Svarbiausia prielaida - tai, kad egzistuojant signalo autokoreliacijai, sąryšis pateiktas 4.2 formulėje negalioja, todėl τ galima modifikuoti įtraukiant eksponentės reikšmę $2H$, kur H ir bus Hursto eksponentės reikšmė.


$$\langle |\log(t + \tau) - \log(t)|^2 \rangle \sim \tau^{2H} \quad (4.3)$$

Hursto eksponentės buvo apskaičiuotos visiems duomenims aprašytiems 4.3 skyriuje. Gauti rezultatai pateikti 7 lentelėje.

Eil. nr.	Duomenys	Hursto eksponentė	Autokoreliacija (d)	Eil. nr.	Duomenys	Hursto eksponentė	Autokoreliacija (d)
1	APALM	0.0782	72	27	GS	0.5244	1017
2	ARRSTPGH	0.0157	3	28	IBM	0.4623	1585
3	BPFREMONT	0.0052	4	29	INTC	0.4755	1112
4	PWATALM	0.1416	88	30	JNJ	0.4490	∞
5	RHLDN	0.0996	34	31	JPM	0.4430	∞
6	TEPCARY	0.2501	90	32	KO	0.4299	∞
7	TEMPLDN	0.1845	1691	33	LUV	0.4991	1034
8	TEMPSYD	0.1390	87	34	LYG	0.5209	∞
9	USBIRTHS	0.0209	2	35	MCD	0.4812	∞
10	WSLDN	0.1718	81	36	NIKKEI	0.4906	791
11	WSNY	0.0233	79	37	NOK	0.4786	∞
12	AAPL	0.4898	∞	38	ORCL	0.3949	∞
13	ALK	0.4797	∞	39	PFE	0.4228	900
14	BAC	0.4717	1053	40	RYCEY	0.4746	2177
15	BCS	0.4891	∞	41	SNE	0.5471	1019
16	BRK-B	0.4413	∞	42	SP500	0.4621	∞
17	BTC	0.4902	∞	43	T	0.4234	386
18	C	0.4868	1803	44	TM	0.4850	802
19	CSCO	0.4486	981	45	TSCDY	0.4864	880
20	CVX	0.4164	∞	46	USD/CHF	0.4550	∞
21	DJI	0.4596	∞	47	VWAGY	0.3331	825
22	EUR/JPY	0.5166	540	48	WFC	0.4213	1361
23	F	0.5112	933	49	WMT	0.4678	1627
24	GE	0.4615	906	50	WTI	0.5802	869
25	GOLD	0.4493	1799	51	XOM	0.4017	∞
26	GOOG	0.4200	∞	52	EUR/USD	0.5174	941

7 lentelė. Apskaičiuota Hursto eksponentė ir autokoreliacija (d) kiekvienam duomenų rinkiniui. ∞ ženklas reiškia, kad signalo autokoreliacijos funkcija nepriartėjo prie artimos nuliui ($2/\sqrt{N}$) reikšmės t. y. signalas turi aiškiai išreikštus trendus.

Taip pat Hursto eksponentės įverčiai buvo atvaizduoti grafiškai 19 paveikslėlyje. Remiantis šiuo grafiku Hursto eksponentių pagalba nesunku atskirti signalų grupes. Kvazi-periodinių signalų Hursto eksponentė svyruoja nuo 0.0052 iki 0.2501, o mediana yra 0.0996, tuo tarpu finansinių signalų Hursto eksponentė svyruoja nuo 0.3331 iki 0.5802, o šių signalų mediana - 0.4717, tai tik dar kartą patvirtina, kad kvazi-periodiniuose signaluose didelės reikšmės keičia mažas reikšmes ir atvirkščiai, o finansiniuose signaluose reikšmės sekančios po didelių ar po mažų reikšmių skirtingais laiko momentais, gali būti tiek mažos tiek didelės, todėl šie signalai turėtų būti sunkiau prognozuojami nei kvazi-periodiniai signalai.



19 pav. Tiriamų signalų apskaičiuotų Hursto eksponentėjų grafikas. Tamsiai mėlyna spalva žymimi kvazi-periodiniai signalai, o šviesiai mėlyna – finansiniai.

4.4.2. Autokoreliacija

Autokoreliacija (angl. *autocorrelation*) – tai signalo koreliacijos funkcija su pačiu savimi. Autokoreliacijos pagalba galima įvertinti signalo panašumą į savo paties fragmentus, nutolusiais įvairiais laiko momentais [20]. Taigi, įvertinę autokoreliacijos funkciją galime žinoti, kiek tam tikru laiko momentu signalas atsimesna praeitį.

Autokoreliacijos funkcija, priklausanti nuo argumento d , apibrėžiama žemiau pateikta formule:

$$r(d) = \frac{\sum_{j=0}^{N-d} (f_j - \bar{f})(f_{d+j} - \bar{F})}{\sqrt{\sum_{j=0}^{N-d} (f_j - \bar{f})^2 \sum_{j=0}^{N-d} (f_{d+j} - \bar{F})^2}}, \quad d = 0, 1, \dots, [N/2] \quad (4.4)$$

kur:

$$\bar{f} = \frac{1}{N-d+1} \sum_{i=0}^{N-d} f_i, \quad \bar{F} = \frac{1}{N-d+1} \sum_{i=0}^{N-d} f_{d+i} \quad (4.5)$$

Autokoreliacijos įvertinimui bus ieškoma d reikšmė, su kuria signalo autokoreliacijos funkcija pirmą kartą tampa artima nuliui t.y. jos modulis neviršija $2/\sqrt{N}$ dydžio. d reikšmė parodo kiek laiko signalas išlaiko „atmintį“ su pačiu savimi.

Autokoreliacijos reikšmės d buvo apskaičiuotos visiems duomenų rinkiniams. Rezultatai pateikti 7 lentelėje. Keturiems duomenų rinkiniams (BPFREMONT, RHLDN, TEMPLDN, WSLDN), kurių reikšmės fiksuotos kas valandą, apskaičiuotas autokoreliacijos koeficientas d parodo, kiek valandų signalas išlaikė atmintį su pačiu savimi. Visiems kitiems signalams apskaičiuotas autokoreliacijos koeficientas parodo, kiek dienų signalas išlaikė atmintį su pačiu savimi. Iš gautų įverčių galima pastebėti, kad net 10 iš 11 kvazi-periodinių signalų „atmintis“ (autokoreliacijos įvertis d) yra žymiai trumpesnė nei finansinių signalų ir svyruoja nuo 2 iki 90 imtinai. Vienintelė

išimtis - temperatūros Londone signalo autokoreliacija siekia 1691 ir yra ilgesnė net už kai kurių finansinių signalų.

Tuo tarpu finansinių signalų autokoreliacijos reikšmės yra daug didesnės nei kvazi-periodinių signalų. Net 18 iš 41 tirta finansinio signalo nepriartėjo prie artimos nuliui ($2/\sqrt{N}$) reikšmės. 7 lentelėje šių signalų autokoreliacijos reikšmė žymima „∞“ ženklu. Likusių 23 finansinių signalų autokoreliacijos įverčiai d svyravo nuo 540 iki 2177 imtinai.

Kituose skyriuose vykdomų eksperimentų metu bus tikrinama, ar ilga signalo „atmintis“ turi teigiamą įtaką signalų prognozuojamumui.

4.5. Finansinių ir kvazi-periodinių signalų kintamumų prognozavimo eksperimentai

4.5.1. LSTM metodų tyrimas

Kadangi 4.2.2 ir 4.2.1 skyriuose atlikti eksperimentai parodė, kad tiek LSTM tiek ARIMA modelių prognozių rezultatai buvo geriausi naudojant apytiksliai 400 reikšmių apmokymo sąrašus, eksperimentai bus atliekami būtent su šio ilgio apmokymų sąrašais. Tokio apmokymo sąrašo privalumas ir tai, kad duomenims fiksuotiems kiekvieną dieną, apmokymo sąrašas apima daugiau nei visus metus, o tai turėtų būti aktualu kvazi-periodiniams signalams - modeliai turėtų gebėti išmokti sezoninius kvazi-periodiškumus.


Pirmojo eksperimento metu buvo tiriami LSTM metodai. Iš pradžių kiekvienam duomenų rinkiniui buvo sukurtas naujas LSTM 4 neuronų modelis ir jis apmokomas pasitelkiant atitinkamo duomenų rinkinio 400 kintamumo reikšmių. Testuojama - 100 paskutinių kintamumo reikšmių, tad visas apmokymo sąrašas buvo paimtas prieš testavimo sąrašo reikšmes, kad apmokymo ir testavimo reikšmės tarpusavyje nepersidengtų. Modelis apmokytas taikant analogišką metodiką kaip ir 4.2.2 skyriuje atliktų eksperimentų metu. Apmokymo įvestimi (remiantis 6 pav. x_t) laikytas kintamumo pokytis prieš periodą, o išvestimi (h_t) - po to sekusio periodo pokyčio reikšmė. LSTM modelio apmokymui naudoti reikšmių pokyčiai, o ne tiesioginės reikšmės tam, kad būtų pašalinti trendai. Taigi iš viso buvo sukurtas 51 LSTM 4 neuronų modelis - kiekvienam duomenų rinkiniui po vieną (EUR/USD valiutų kursų eksperimentai jau buvo atlikti 4.2.2 skyriuje). Gauti eksperimentų rezultatai (AUC, MAPE ir RMSE apskaičiuoti įverčiai) pateikiami 8 lentelėje.

Analogiškai tiems patiems duomenų rinkiniams buvo sukurti ir apmokyti LSTM 8 neuronų modeliai. Gauti eksperimentų rezultatai pateikiami toje pačioje 8 lentelėje.

Eil. nr.	Duomenys	LSTM 4 neuronų			LSTM 8 neuronų		
		AUC	MAPE	RMSE	AUC	MAPE	RMSE
1	APALM	0.6093	3.0836	0.2465	0.6036	3.0758	0.2466
2	ARRSTPGH	0.5088	3.3838	29.6041	0.5338	3.3749	29.5659
3	BPFREMONT	0.5137	3.2563	57.9968	0.5535	3.1825	57.3102
4	PWATALM	0.4957	4.0062	26.1131	0.5394	4.0464	26.1886
5	RHLDN	0.6700	8.7712	4.6224	0.7200	8.7842	4.5486
6	TEMPCARY	0.5334	4.3219	6.1876	0.4922	4.3657	6.1686
7	TEMPLDN	0.5649	4.5560	2.7071	0.6234	4.5058	2.7114
8	TEMPSYD	0.5986	3.5020	13.4430	0.6322	3.4888	13.4729
9	USBIRTHS	0.6810	2.6057	14.1192	0.6680	2.5401	13.5952
10	WSLDN	0.5745	9.6424	245.0543	0.5024	10.3259	241.6489
11	WSNY	0.5112	3.2952	52.1882	0.4952	3.2618	52.2533
12	AAPL	0.5601	4.8164	1.7094	0.5224	4.7950	1.7105
13	ALK	0.5452	4.7922	2.5117	0.5134	4.7457	2.5189
14	BAC	0.5040	3.8098	1.2070	0.5362	3.9212	1.2185
15	BCS	0.5000	2.9852	1.1635	0.5000	2.9653	1.1655
16	BRK-B	0.4960	4.7234	1.7077	0.5273	4.8686	1.7253
17	BTC	0.5177	4.3799	3.2852	0.5455	4.3704	3.2803
18	C	0.5561	3.4168	1.1021	0.5090	3.8176	1.1472
19	CSCO	0.5128	4.5366	1.3846	0.5232	4.4665	1.3785
20	CVX	0.4239	4.4866	1.4282	0.4431	4.5172	1.4297
21	DJI	0.5100	4.0594	0.7615	0.5200	4.0634	0.7603
22	EURJPY	0.4892	4.0517	0.4641	0.4928	4.0866	0.4663
23	F	0.4183	3.7237	1.4248	0.4615	3.7539	1.4209
24	GE	0.4984	4.5699	2.7157	0.4872	4.5933	2.7232
25	GOLD	0.5340	4.7572	0.8499	0.5124	4.7319	0.8548
26	GOOG	0.4846	3.8993	1.3208	0.5136	3.8857	1.3176
27	GS	0.5044	3.9294	1.1115	0.4868	3.9388	1.1126
28	IBM	0.5489	3.7625	0.9470	0.4914	3.7903	0.9536
29	INTC	0.4800	4.3357	2.6011	0.4928	4.2950	2.5953
30	JNJ	0.5402	3.3822	0.7716	0.5316	3.3707	0.7708
31	JPM	0.5500	3.9705	1.2701	0.5500	3.9766	1.2714
32	KO	0.4692	3.2331	0.5320	0.5606	3.1471	0.5164
33	LUV	0.5040	3.8607	2.1475	0.4768	3.8715	2.1470
34	LYG	0.5505	3.2607	1.0127	0.5293	3.2633	1.0115
35	MCD	0.4929	4.2171	1.4011	0.4818	4.2305	1.4026
36	NIKKEI	0.5422	3.9066	0.8992	0.5438	3.7964	0.8914
37	NOK	0.5020	3.4102	1.7512	0.4778	3.4005	1.7513
38	ORCL	0.5265	4.4176	2.2880	0.5324	4.4169	2.2873
39	PFE	0.5193	4.4980	0.9945	0.5145	4.4477	0.9892
40	RYCEY	0.6657	5.0505	2.5283	0.6222	5.0423	2.5333
41	SNE	0.4742	4.4277	2.2295	0.4465	4.3207	2.2163
42	SP500	0.4772	3.8532	0.7790	0.4772	3.8219	0.7763
43	T	0.6020	5.0608	2.1785	0.5030	5.1213	2.1853
44	TM	0.5688	3.5071	0.9236	0.5578	3.5038	0.9249
45	TSCDY	0.5268	3.7212	1.7690	0.5374	3.7292	1.7715
46	USDCHF	0.4873	3.7797	0.3055	0.4807	3.7765	0.3056
47	VWAGY	0.4778	3.7252	1.5013	0.4835	3.7273	1.5019
48	WFC	0.4959	4.0777	1.0752	0.5155	4.0398	1.0787
49	WMT	0.5809	5.4253	3.0072	0.6106	5.4874	3.0138
50	WTI	0.5121	3.3073	1.4004	0.5152	3.2963	1.3985
51	XOM	0.4260	3.4301	0.8949	0.4219	3.4739	0.8944
52	EURUSD	0.5734	2.9420	0.2805	0.5080	3.1569	0.2902

8 lentelė. LSTM modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, kintamumo prognozių eksperimentų metu gauti rezultatai.

Kadangi lentelėje pateiktus skaitinius rezultatus interpretuoti sudėtinga dėl didelio jų kiekio, LSTM modelių AUC įverčiai kiekvienam duomenų rinkiniui buvo atvaizduoti grafiškai 20 paveikslėlyje.



20 pav. LSTM 4 neuronų modelio (viršuje) ir LSTM 8 neuronų modelio (apačioje), kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu gauti AUC įverčiai. Punktyrine linija žymima AUC reikšmė lygi 0.5 (atsitiktinis spėjimas). Tamsiai mėlyna spalva žymimi kvazi-periodiniai signalai, o šviesiai mėlyna - finansiniai signalai.

Remiantis 20 pav. pateiktais grafikais galima pastebėti tendenciją, kad tiek LSTM 4 neuronų modelio, tiek LSTM 8 neuronų modelio kvazi-periodinių signalų AUC įverčiai dažniausiai yra didesni nei finansinių signalų.

LSTM 4 neuronų modelio kvazi-periodinių signalų AUC įverčiai svyravo nuo 0.4957 iki 0.6810, vidutinė reikšmė buvo 0.5692, o mediana 0.5649. Tuo tarpu to paties LSTM 4 neuronų modelio finansinių signalų AUC įverčiai kito intervale nuo 0.4183 iki 0.6657, vidutinė reikšmė buvo 0.5158, o mediana 0.51. Remiantis vidurkiu ir mediana galima teigti, kad kvazi-periodinių signalų AUC įverčio prognozuojamumas buvo apie 0.05 AUC punkto (arba apie 10%) geresnis nei finansinių signalų.

LSTM 8 neuronų modelio eksperimentų rezultatai buvo panašūs kaip ir LSTM 4 neuronų. Kvazi-periodinių signalų AUC įverčiai svyravo nuo 0.4922 iki 0.72, vidutinė reikšmė buvo šiek tiek didesnė nei LSTM 4 neuronų ir siekė 0.5785, tačiau mediana mažesnė - 0.5535. Finansinių signalų AUC įverčiai fiksuoti nuo 0.4219 iki 0.6222, vidutinė reikšmė buvo 0.5111, o mediana

0.5134. Tad, kaip ir LSTM 4 neuronų modelio, kvazi-periodinių signalų AUC įverčio prognozuojamumas buvo apie 0.05 AUC punkto (arba apie 10%) geresnis nei finansinių signalų.

Apibendrinant galima teigti, kad esminių skirtumų tarp abiejų LSTM modelių rezultatų nėra, o signalų prognozuojamumas priklauso nuo signalų tipo. Kvazi-periodinių signalų AUC įverčiai buvo apie 10% geresni nei finansinių signalų.

Palyginus apskaičiuotas signalų Hursto eksponentes (7 lentelė), su atitinkamų signalų AUC įverčių rezultatais gautais eksperimentų metu (8 lentelė) stiprios koreliacijos nepastebėta (LSTM 4 neuronų modelio ji buvo apie -0.24, o LSTM 8 neuronų apie -0.48), tačiau galima teigti, kad Hursto eksponentei esant artimai 0, yra didelė tikimybė, kad toks signalas turės geras prognostines savybes ($AUC > 0.5$), o kai Hursto eksponentė nedaug nutolusi nuo 0.5 reikšmės, AUC įvertis tikėtina bus artimas atsitiktiniam spėjimui ($AUC \approx 0.5$).

Nagrinęjant autokoreliacijos įverčius (7 lentelė) atrodytų, kad mažesnis autokoreliacijos dydis d reiškia geresnį signalo prognozuojamumą, tačiau taip teigti negalima, kadangi šiuo atveju pagrindinė savybė lemianti signalų prognozuojamumą yra signalų kvazi-periodiškumas, o ne mažą autokoreliacijos reikšmė. Chaotiniams signalams su žemu autokoreliacijos d įverčiu negalima tikėtis gero prognozuojamumo.

Skirtingų signalų MAPE, o ypač RMSE dydžius sudėtinga lyginti dėl skirtingos signalų kilmės, matavimo amplitudžių, svyravimų amplitudžių ir pan, tačiau tarp tirtų modelių esminių skirtumų nebuvo pastebėta: LSTM 4 neuronų kvazi-periodinių signalų MAPE mediana yra 3.502, o RMSE - 14.1192, LSTM 8 neuronų atitinkamai 3.4888 ir 13.5952. LSTM 4 neuronų modelio finansinių signalų MAPE mediana yra 3.9294, o RMSE - 1.3208, LSTM 8 neuronų atitinkamai 3.9388 ir 1.3176.


4.5.2. ARIMA metodų tyrimas

Naudojant tą patį signalų rinkinį (6 lentelė) buvo tiriami ARIMA (0,1,0) ir ARIMA (1,1,0) modeliai. Modelių apmokymas vyko taikant tą pačią metodiką kaip ir 4.2.1 skyrelyje. Eksperimentų metu buvo testuojama 100 paskutinių kintamumo reikšmių, o modelių apmokymui naudoti 400 faktinių kintamumo reikšmių sąrašai. Kiekvienas modelio apmokymo sąrašas baigiasi prieš pirmąją testavimo reikšmę (tarp prognozavimo ir testavimo reikšmių sąrašų niekada nėra pertrūkių). Kiekvieną kartą prognozuojant kitą reikšmę iš apmokymo sąrašo buvo išimama seniausia faktinė reikšmė ir modeliui pateikiama naujausia faktinė reikšmė. Gauti eksperimentų rezultatai pateikiami 9 lentelėje.

Eil. nr.	Duomenys	ARIMA (0,1,0)			ARIMA (1,1,0)		
		AUC	MAPE	RMSE	AUC	MAPE	RMSE
1	APALM	0.4910	3.1370	0.2470	0.5514	3.0809	0.2464
2	ARRSTPGH	0.3812	3.3617	29.5843	0.4852	3.3616	29.5933
3	BPFREMONT	0.4916	3.1588	57.1625	0.6143	3.0986	56.8983
4	PWATALM	0.4135	3.6299	25.1085	0.4279	3.9813	26.0704
5	RHLDN	0.4900	8.4565	5.0595	0.6100	8.4116	4.7375
6	TEMPCARY	0.5000	4.0327	6.1013	0.5122	4.0266	6.0577
7	TEMPLDN	0.4680	4.7099	2.9173	0.7180	4.3938	2.7054
8	TEMPSYD	0.4936	3.3581	13.4824	0.5857	3.4619	13.4058
9	USBIRTHS	0.4870	3.9425	20.8625	0.5471	3.4011	16.7732
10	WSLDN	0.5000	7.4079	268.9466	0.6338	8.7404	251.8497
11	WSNY	0.4920	3.1606	51.3393	0.5289	3.2477	52.0993
12	AAPL	0.4535	4.7334	1.7247	0.4960	4.7223	1.7106
13	ALK	0.5030	4.5929	2.5135	0.5190	4.7088	2.5185
14	BAC	0.4182	3.7584	1.2002	0.5194	3.7826	1.2010
15	BCS	0.5000	2.9529	1.1646	0.4700	2.9696	1.1663
16	BRK-B	0.4364	4.4279	1.6883	0.4758	4.3361	1.6842
17	BTC	0.5000	4.2895	3.2715	0.5982	4.2891	3.2521
18	C	0.4427	3.3681	1.0887	0.6326	3.3587	1.0833
19	CSCO	0.4856	4.4079	1.3773	0.4623	4.3252	1.3646
20	CVX	0.4151	4.0817	1.3934	0.4191	4.4380	1.4146
21	DJI	0.5200	3.5661	0.7425	0.4800	3.7627	0.7410
22	EURJPY	0.4540	4.0197	0.4624	0.5393	4.0752	0.4624
23	F	0.4287	3.5899	1.3936	0.4223	3.6308	1.3943
24	GE	0.5000	4.2056	2.5240	0.4696	4.3113	2.6411
25	GOLD	0.5000	4.7255	0.8664	0.5278	4.7395	0.8665
26	GOOG	0.5000	3.7635	1.3034	0.4676	3.9769	1.3241
27	GS	0.5000	3.7691	1.0922	0.4701	3.8484	1.1003
28	IBM	0.4491	3.7894	0.9575	0.4869	3.7947	0.9572
29	INTC	0.5000	4.2563	2.5867	0.4920	4.2754	2.5866
30	JNJ	0.4897	3.3815	0.7738	0.5620	3.3719	0.7725
31	JPM	0.4700	3.8899	1.2537	0.5400	3.9471	1.2564
32	KO	0.4564	3.0645	0.5176	0.4912	3.0988	0.5194
33	LUV	0.5182	3.8941	2.1524	0.4768	3.8803	2.1516
34	LYG	0.5000	3.2706	1.0136	0.4919	3.2849	1.0151
35	MCD	0.4758	4.1432	1.4023	0.5040	4.1776	1.4034
36	NIKKEI	0.4432	3.5252	0.8698	0.5901	3.6812	0.8910
37	NOK	0.4778	3.4642	1.7570	0.4818	3.4363	1.7527
38	ORCL	0.5241	4.3870	2.2914	0.5447	4.3986	2.2920
39	PFE	0.4791	4.3151	0.9982	0.4757	4.3097	0.9934
40	RYCEY	0.5687	5.0109	2.5662	0.6101	4.9557	2.5347
41	SNE	0.5234	4.0568	2.1990	0.4267	4.1642	2.2037
42	SP500	0.4446	3.5492	0.7649	0.4818	3.6091	0.7671
43	T	0.4374	4.9255	2.1832	0.5444	5.0351	2.1838
44	TM	0.5350	3.3761	0.9230	0.5586	3.5255	0.9326
45	TSCDY	0.5000	3.7072	1.7497	0.5846	3.7663	1.7920
46	USDCHF	0.4799	3.7339	0.3045	0.4142	3.7533	0.3048
47	VWAGY	0.3582	3.5773	1.4653	0.4841	3.6608	1.4874
48	WFC	0.3545	3.8694	1.0568	0.4859	3.9294	1.0676
49	WMT	0.5216	5.3312	3.0129	0.6090	5.4548	3.0159
50	WTI	0.4657	3.2810	1.4022	0.4828	3.2862	1.4079
51	XOM	0.5229	3.1899	0.8511	0.4213	3.4548	0.9065
52	EURUSD	0.5000	2.9826	0.2830	0.5456	2.9540	0.2817

9 lentelė. ARIMA modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, kintamumo prognozių eksperimentų metu gauti rezultatai.

Kad gautus rezultatus būtų lengviau interpretuoti, AUC įverčiai buvo pavaizduoti grafiškai 9 paveikslėlyje.



21 pav. ARIMA (0,1,0) modelio (viršuje) ir ARIMA (1,1,0) modelio (apačioje), kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu gauti AUC įverčiai. Punktyrine linija žymima AUC reikšmė lygi 0.5 (atsitiktinis spėjimas). Tamsiai mėlyna spalva žymimi kvazi-periodiniai signalai, o šviesiai mėlyna - finansiniai.

Atlikus ARIMA (0,1,0) modelio eksperimentus buvo pastebėta (žr. 21 pav.), kad šio modelio kvazi-periodinių signalų AUC įverčiai ženkliai mažesni nei gauti LSTM modelių eksperimentų metu. AUC įverčiai svyravo nuo 0.3812 iki 0.5000, vidutinė reikšmė buvo 0.4734, o mediana 0.491. Taigi tiek vidurkis, tiek mediana net nesiekė atsitiktinio spėjimo ribos ir tik vieno signalo AUC buvo lygus atsitiktinam spėjimui ($AUC = 0.5$). To paties modelio eksperimentų su finansiniais signalais rezultatai taip pat buvo blogesni nei LSTM modelių. Finansinių signalų AUC įverčiai svyravo nuo 0.3545 iki 0.5687, vidutinė reikšmė buvo 0.4769, o mediana 0.4856, taigi taip pat net nesiekė 0.5. Remiantis gautais rezultatais galima teigti, kad tiek kvazi-periodinių, tiek finansinių signalų prognozuojamumas naudojant ARIMA (0,1,0) yra žemas ir net nesiekia atsitiktinio spėjimo lygio.

Kaip galima matyti 21 paveikslėlyje ARIMA (1,1,0) modelių eksperimentų rezultatai (AUC įverčiai) buvo geresni nei ARIMA (1,1,0). Kvazi-periodinių signalų AUC svyravo nuo 0.4279 iki 0.7180, vidutinė reikšmė fiksuota 0.5649, o mediana - 0.5514. Finansinių signalų AUC įverčiai

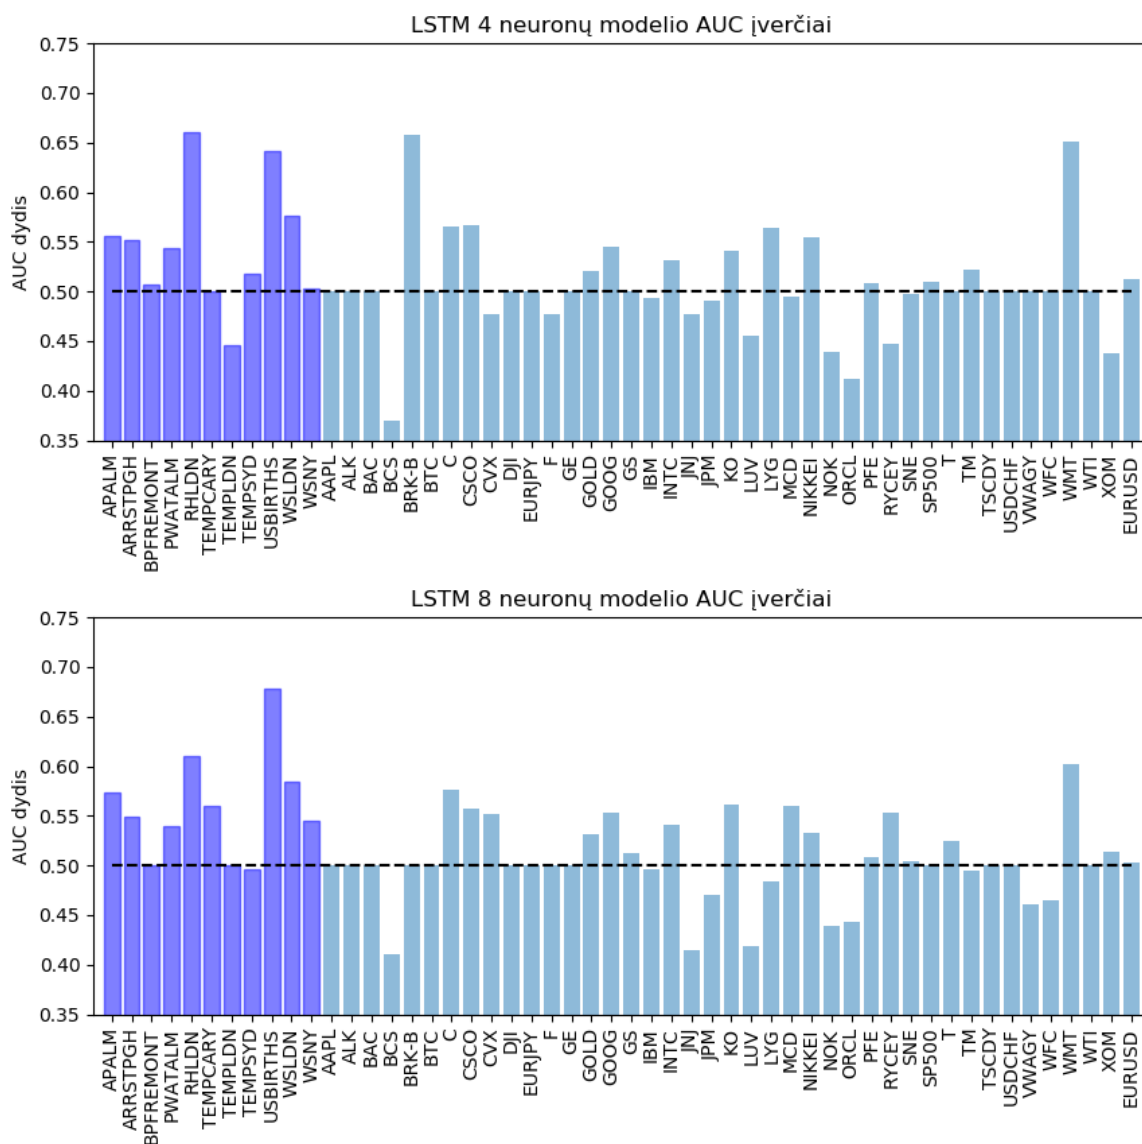
kito nuo 0.4142 iki 0.6326, vidutinė reikšmė buvo 0.5062, mediana – 0.4912. Tad, panašiai, kaip ir prognozėms naudojant LSTM modelius, ARIMA (1,1,0) kvazi-periodinių signalų įverčiai buvo apie 10-12% geresni nei finansinių signalų.

ARIMA (0,1,0) modelio kvazi-periodinių signalų MAPE mediana fiksuota 3.6299, o RMSE – 20.8625, ARIMA (1,1,0) atitinkamai 3.4619 ir 16.7732. Finansinių signalų ARIMA (0,1,0) MAPE mediana yra 3.7894, o RMSE – 1.3034, ARIMA (1,1,0) atitinkamai 4.0266 ir 1.3241. Taigi, prognozuojant kvazi-periodinių signalų reikšmes MAPE ir RMSE įverčiai yra šiek tiek mažesni (geresni) naudojant ARIMA (1,1,0) modelį, tačiau prognozuojant finansinių signalų reikšmes atvirkščiai – MAPE ir RMSE įverčiai mažesni naudojant ARIMA (0,1,0).

Apibendrinant LSTM ir ARIMA metodų eksperimentus atliktus šiame skyriuje galima teigti, kad tiek kvazi-periodinių, tiek finansinių signalų sekančio žingsnio kintamumo kitimo kryptis (AUC) buvo tiksliausiai prognozuota naudojant LSTM modelius. LSTM 4 neuronų modelio – šiek tiek didesnė AUC įverčio mediana, o LSTM 8 neuronų – nežymiai didesnis AUC vidurkis. Kvazi-periodinių signalų MAPE įverčio mediana buvo mažiausia naudojant ARIMA (1,1,0) modelį, RMSE įverčiai (mediana) mažiausi vykdant prognozes su LSTM 8 neuronų modeliu. Finansinių signalų MAPE ir RMSE įverčiai buvo mažiausi naudojant ARIMA (0,1,0) modelį, nors ir buvo tik labai neženkliai nutolę nuo LSTM rezultatų.

4.6. Kintamumų pokyčių prognozavimas remiantis tiesioginėmis signalų reikšmėmis

Naudojant dirbtinius neuroninius tinklus modelio apmokymas galimas ne tik naudojant tiesiogines reikšmes (anksčiau atliktuose eksperimentuose modeliai buvo apmokyti su prieš tai buvusiomis kintamumo reikšmėmis), tačiau galima pasitelkti ir kitas su signalu susijusias reikšmes ar išvestinius dydžius. Tad, prognozuojant kintamumus, buvo atliktas papildomas eksperimentas su LSTM metodu. Modeliai apmokyti tokia pačia logika kaip ir 4.5.1 skyrelyje, tačiau padarytas esminis pakeitimas – įvestimi x_t laikytas tiesioginės signalo reikšmės (pvz. „Apple“ akcijų kainos, bet ne kintamumo) pokytis prieš periodą, o išvestimi (h_t) po to sekęs kintamumo pokytis t. y. kintamumo padidėjimas (žymėtas „1“) arba sumažėjimas (žymėtas „0“). Gauti detalūs rezultatai pateikiami 21 lentelėje ir pavaizduoti grafikuose 22 paveikslėlyje.



22 pav. LSTM 4 neuronų modelio (viršuje) ir LSTM 8 neuronų modelio (apačioje), kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines tiesiogines signalo reikšmes, eksperimentų metu gauti AUC įverčiai. Punktyrine linija žymima AUC reikšmė lygi 0.5 (atsitiktinis spėjimas). Tamsiai mėlyna spalva žymimi kvazi-periodiniai signalai, o šviesiai mėlyna – finansiniai signalai.

Analizuojant pateiktus grafikus (22 pav.) galima pastebėti tendenciją, kad tiek LSTM 4 neuronų, tiek 8 neuronų modelių eksperimentų metu gauti kvazi-periodinių signalų AUC įverčiai yra didesni nei finansinių signalų. Naudojant LSTM 4 neuronų modelių kvazi-periodinių signalų AUC įverčiai fiksuoti intervale nuo 0.4463 iki 0.66 imtinai, vidutinė reikšmė - 0.5457, o mediana - 0.5433. LSTM 8 neuronų modelio rezultatai tiems patiems signalams nežymiai geresni - AUC įverčiai fiksuoti intervale nuo 0.496 iki 0.6778 imtinai, vidutinė reikšmė - 0.5579, o mediana - 0.5496.

LSTM 4 neuronų finansinių signalų AUC įverčiai svyravo nuo 0.37 iki 0.6576, LSTM 8 neuronų nuo 0.41 iki 0.6026, vidurkiai atitinkamai buvo 0.5053 ir 0.5044, o medianos abiem atvejais buvo visiškai lygios atsitiktiniam spėjimui - 0.5.

Taigi, palyginus gautus rezultatus su 4.5.1 skyriuje gautais rezultatais, galima teigti, kad kintamumą prognozavimas, kai modeliai apmokomi remiantis prieš tai buvusiomis kintamumą reikšmėmis, yra tikslesnis nei kintamumą prognozavimas remiantis prieš tai buvusiomis tiesioginėmis

pradinėmis signalų reikšmėmis.


4.7. Kintamųjų prognozavimas keletą žingsnių į priekį

Iki šiol šiame darbe atliktuose eksperimentuose metodų pagalba buvo prognozuojama 1 reikšmė į priekį, tačiau realiame gyvenime būna situacijų, kuomet prognozuoti tik vieną dieną ar vieną intervalą (pvz. kitą valandą) nepakanka arba nėra galimybių atlikti prognozes dažniau. Todėl šių eksperimentų metu buvo daromos keleto žingsnių prognozės, pasitelkus tuos pačius metodus kaip ir 4.5.1 ir 4.5.2 skyreliuose atliktų eksperimentų metu. Eksperimentų metu buvo daromos prognozės kas 2, 4, 5 ir 10 žingsnių. Kaip ir ankstesnių tyrimų metu prognozuoti 100 paskutinių žingsnių. Pavyzdžiui, atliekant dviejų žingsnių eksperimentą iš viso atlikta 50 prognozių po 2 žingsnius, 4 žingsnių – 25 prognozės po 4 žingsnius it t. t.

4.7.1. LSTM metodai

Prieš tai atlikti eksperimentai 4.5.1 ir 4.5.2 skyreliuose parodė, kad kvazi-periodinių ir finansinių signalų prognostinės savybės skiriasi iš esmės, todėl eksperimentų rezultatai šioms dviems duomenų grupėms bus nagrinėjami atskirai. Detalus LSTM metodų eksperimentų rezultatai pateikiami prieduose 13 – 16 lentelėse.

Iš pradžių buvo atvaizduoti LSTM AUC įverčiai 23 paveikslėlyje. Kaip galima matyti iš pateikto grafiko prognozuojant nebe vieną, o du žingsnius ženkliai sumažėjo AUC įvertis. LSTM 4 neuronų modelio kvazi-periodinių signalų AUC įverčio vidurkis sumažėjo nuo 0.5692 iki 0.5201 (mediana nuo 0.5649 iki 0.51), LSTM 8 neuronų modelio AUC vidurkis sumažėjo nuo 0.5785 iki 0.5237 (mediana nuo 0.5535 iki 0.5272). Prognozuojant 4 ir daugiau žingsnių į priekį AUC įverčių vidurkiai ir medianos nė vienu atveju nebeviršijo 0.52 reikšmės, bet svyravo intervale tarp 0.5040 ir 0.5196, taigi visada buvo aukščiau atsitiktinio spėjimo tiesės (AUC > 0.5).




23 pav. LSTM modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant kvazi-periodinių signalų kintamumus, gauti AUC įverčiai. Punktyrine linija žymima AUC reikšmė lygi 0.5 (atsitiktinis spėjimas).

Tam, kad būtų paprasčiau interpretuoti visus eksperimentų metu gautus rezultatus, jie buvo atvaizduoti stačiakampėse diagramose (angl. *box-and-whiskers plot*). Šiose diagramose stačiakampis brėžiamas nuo apatinio (pirmojo) kvartilio (Q_1) iki viršutinio (trečiojo) kvartilio (Q_3) – taigi į stačiakampį patenka 50% visų reikšmių, kurios yra arčiausiai išsidėstę apie medianą (25% iš apačios ir tiek pat iš viršaus). Nuo apatinio kvartilio brėžiami ūsai į apačią yra minimali reikšmė, o į viršų – maksimali reikšmė. Kartais atvaizduojami (viršuje ir/arba apačioje) tuščiaviduriai


apskritimai parodo išskirtis (angl. *outlier*), jei tokių yra. Išskirtys – reikšmės labiausiai nutolę nuo duomenų centro. Šiuo atveju išskirtimis bus laikomos reikšmės, kurios nutolę nuo pirmojo arba trečiojo kvartilio daugiau kaip per 1.5 kvartilinio pločio (KP). Kvartilinis plotis yra skirtumas tarp trečiojo ir pirmojo kvartilio. Taigi išskirtimi bus laikoma reikšmė mažesnė už $Q_1 - 1.5KP$ arba didesnė už $Q_3 + 1.5KP$. Diagramose mažas žalias trikampis nusako vidutinės reikšmės, o oranžinė linija – medianą.

LSTM modelių kvazi-periodinių signalų AUC įverčių stačiakampėse diagramose (24 pav.) galima pastebėti, kad prognozuojant 1 žingsnį į priekį netgi pirmojo kvartilio reikšmė (Q_1) viršijo atsitiktinio spėjimo reikšmę – LSTM 4 neuronų modelio buvo 0.5125, o 8 neuronų 0.5181. Abiejų modelių prognozių daugiau nei 1 žingsnį į priekį AUC įverčių pirmojo kvartilio reikšmė nebesiekė atsitiktinio spėjimo reikšmės. LSTM 4 neuronų modelio 2 ir 3 žingsnių, o su LSTM 8 neuronų 4 ir 5 žingsnių prognozių rezultatuose buvo pastebėtos AUC reikšmių išskirtys, kas nusako netolygų jų pasiskirstymą. Teigiamas rezultatas – net prognozuojant daugiau žingsnių į priekį, tiek AUC įverčių medianos, tiek vidurkiai viršijo atsitiktinio spėjimo reikšmę ($AUC > 0.5$).




24 pav. LSTM modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant kvazi-periodinių signalų kintamumus, gauti AUC įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: LSTM 4 neuronų modelio rezultatai. Iliustracija dešinėje: LSTM 8 neuronų modelio rezultatai.

Kaip galima matyti 25 pav. MAPE įverčių rezultatuose yra didelių išskirčių, kurios daro didelę įtaką vidurkiui, todėl vidurkis ir mediana šiuo atveju nutolę vienas nuo kito ir tikslingiau nagrinėti medianą. LSTM 4 ir 8 neuronų modelio MAPE įverčių medianos prognozuojant 1 žingsnį į priekį buvo labai panašios ir sudarė apie 3.5, tačiau padidinus prognozuojamų žingsnių kiekį MAPE mediana išaugo apie 6 kartus ir svyravo tarp apytiksliai 20 ir 22.




25 pav. LSTM modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu prognozuojant kvazi-periodinių signalų kintamumus gauti MAPE įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: LSTM 4 neuronų modelio rezultatai. Iliustracija dešinėje: LSTM 8 neuronų modelio rezultatai.

Kvazi-periodinių signalų RMSE įverčiai (25 pav.) kaip ir MAPE turi didelių išskirčių, todėl tikslingiau nagrinėti medianas. RMSE įverčių mediana prognozuojant 1 žingsnį į priekį sudarė 14.1192 (LSTM 4 neuronų) ir 13.5952 (LSTM 8 neuronų). Atliekant 2 žingsnių prognozę RMSE dydis išaugo daugiau nei 6 kartus (iki 98.7388 ir 101.0177 atitinkamai), o didžiausias buvo LSTM 8 neuronų modeliu atliekant 5 žingsnių prognozes – 108.6835.




26 pav. LSTM modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant kvazi-periodinių signalų kintamumus, gauti MAPE įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: LSTM 4 neuronų modelio rezultatai. Iliustracija dešinėje: LSTM 8 neuronų modelio rezultatai.

Toliau apžvelgiami eksperimentų su *finansiniais signalais* rezultatai. 4.5.1 skyrelyje paaiškėjo, kad finansinių signalų AUC reikšmės prognozuojant 1 žingsnį į priekį yra tik nedaug didesnės už atsitiktinį spėjimą ir abiejų LSTM modelių AUC įverčių medianos ir vidurkiai siekia šiek tiek daugiau nei 0.51. Eksperimentų metu didinant prognozuojamų žingsnių kiekį AUC įvertis praktiškai nesikeitė ir išliko stabilus (žr. 27 pav.) ir nei vidurkis, nei mediana nenukrito žemiau 0.51.




27 pav. LSTM modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant finansinių signalų kintamumus, gauti AUC įverčiai. Punktyrine linija žymima AUC reikšmė lygi 0.5 (atsitiktinis spėjimas).

Finansinių signalų stačiakampės AUC įverčių diagramos (28 pav.) dar kartą patvirtina, kad AUC įverčiai (ne tik vidurkiai ar medianos, bet ir minimalios bei maksimalios reikšmės) išlieka ganėtinai stabilios didinant prognozuojamų žingsnių kiekį.




28 pav. LSTM modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant finansinių signalų kintamumus, gauti AUC įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: LSTM 4 neuronų modelio rezultatai. Iliustracija dešinėje: LSTM 8 neuronų modelio rezultatai.

Finansinių signalų MAPE įverčių diagramos (29 pav.) parodo, kad prognozuojant daugiau nei vieną žingsnį į priekį MAPE įvertis ženkliai išaugo bei atsirado išskirčių. Prognozuojant vieną žingsnį LSTM 4 neuronų modelio MAPE įverčių mediana buvo 3.9294, LSTM 8 neuronų - 3.9388, o prognozuojant du žingsnius ir daugiau MAPE mediana išaugo daugiau nei 12 kartų. Didžiausia MAPE įverčių mediana fiksuota LSTM 8 neuronų modeliu prognozuojant 10 žingsnių į priekį ir siekė 51.5909.



29 pav. LSTM modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant finansinių signalų kintamumus, gauti MAPE įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: LSTM 4 neuronų modelio rezultatai. Iliustracija dešinėje: LSTM 8 neuronų modelio rezultatai.


RMSE įverčių diagramos (29 pav.) atskleidžia ganėtinai panašią situaciją kaip ir nagrinėjant MAPE įverčius. Jau prognozuojant 2 žingsnius RMSE įverčiai ženkliai išaugo – apie 8 kartus. Prognozuojant vieną žingsnį RMSE įverčių mediana siekė apie 1.3, o prognozuojant 2 arba daugiau žingsnių RMSE įverčių mediana buvo ~ 10.3 .




30 pav. LSTM modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant finansinių signalų kintamumus, gauti RMSE įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: LSTM 4 neuronų modelio rezultatai. Iliustracija dešinėje: LSTM 8 neuronų modelio rezultatai.

4.7.2. ARIMA metodai

Analogiškai tirti ir ARIMA modelių rezultatai. Kaip jau buvo minėta 4.5.2 skyrelyje ARIMA (0,1,0) modelio kvazi-periodinių signalų kintamumo kitimo krypties prognozės buvo mažesnės už atsitiktinio spėjimo. Tą patvirtina ir 31 bei 32 paveikslėliai – visais atvejais tiek AUC įverčių vidurkis, tiek mediana (su retomis išimtimis atskiriems signalams) visada buvo mažesni nei atsitiktinis spėjimas ($AUC < 0.5$). Tuo tarpu ARIMA (1,1,0) modelio gauti kvazi-periodinių signalų AUC įverčiai buvo geresni. Prognozuojant 1 ir 2 žingsnius AUC įverčių vidurkiai ir medianos viršijo 0.5 reikšmę (medianos atitinkamai buvo 0.5514 ir 0.5301). Tačiau 4 žingsnių ir daugiau ARIMA (1,1,0) modelio prognozių AUC įverčiai buvo mažesni nei atsitiktinio spėjimo.




31 pav. ARIMA modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant kvazi-periodinių signalų kintamumus, gauti AUC įverčiai. Punktyrine linija žymima AUC reikšmė lygi 0.5 (atsitiktinis spėjimas).




32 pav. ARIMA modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant kvazi-periodinių signalų kintamumus, gauti AUC įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: ARIMA (0,1,0) modelio rezultatai. Iliustracija dešinėje: ARIMA (1,1,0) modelio rezultatai.

Kvazi-periodinių signalų MAPE įverčių stačiakampėse diagramose (33 pav.) atsiskleidžia MAPE įverčių augimas didinant prognozuojamų žingsnių kiekį. Kadangi diagramose galima matyti, kad vidurkiai yra paveikti išskirčių, tikslingiau tarpusavyje lyginti medianas. ARIMA (0,1,0) modelio MAPE mediana prognozuojant 1 žingsnį buvo 3.6299, o 10 žingsnių beveik 3 kartus didesnė – 10.6689, tačiau augimas buvo gan tolygus ir pvz. prognozuojant 2 žingsnius MAPE mediana buvo apie 20% didesnė nei prognozuojant 1 žingsnį. ARIMA (1,1,0) modelio pagalba prognozuojant 1 žingsnį MAPE mediana buvo 3.4619, o 10 žingsnių – taip pat beveik 3 kartus didesnė – 10.4585.




33 pav. ARIMA modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant kvazi-periodinių signalų kintamumus, gauti MAPE įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: ARIMA (0,1,0) modelio rezultatai. Iliustracija dešinėje: ARIMA (1,1,0) modelio rezultatai.

Gautos RMSE reikšmės (34 pav.), panašiai kaip ir MAPE įverčiai, augo didinant prognozuojamų žingsnių kiekį. Kaip ir MAPE, RMSE vidurkiai yra paveikti išskirčių, todėl lyginamos medianos. Abiejų ARIMA modelių RMSE įverčių medianos augo tolygiai, bet lėčiau nei MAPE medianos. ARIMA (0,1,0) modelio RMSE įverčių medianos augo šiek tiek mažiau nei 1.5 karto - nuo 20.8625, atliekant vieno žingsnio prognozes, iki 31.2738, prognozuojant 10 žingsnių. ARIMA (1,1,0) modelio mažiau nei du kartus - nuo 16.7732 iki 30.6762 atitinkamai.




34 pav. ARIMA modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant kvazi-periodinių signalų kintamumus, gauti RMSE įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: ARIMA (0,1,0) modelio rezultatai. Iliustracija dešinėje: ARIMA (1,1,0) modelio rezultatai

Toliau apžvelgiami ARIMA modelių eksperimentų su *finansiniais signalais* rezultatai. Kaip galima matyti 35 ir 36 pav. tik ARIMA (1,1,0) modelio vidutinė AUC reikšmė prognozuojant 1 žingsnį į priekį buvo nedaug didesnė už atsitiktinio spėjimo reikšmę, visais kitais atvejais tiek AUC įverčių medianos tiek vidurkiai buvo mažesni už 0.5, tad galima teigti, kad abu ARIMA modeliai finansinių signalų kintamumo pokytį (didėjimą ar mažėjimą) prognozuoja prasčiau nei tai būtų daroma atsitiktinio spėjimo būdu.




35 pav. ARIMA modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant finansinių signalų kintamumus, gauti AUC įverčiai. Punktyrine linija žymima AUC reikšmė lygi 0.5 (atsitiktinis spėjimas).




36 pav. ARIMA modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant finansinių signalų kintamumus, gauti AUC įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: ARIMA (0,1,0) modelio rezultatai. Iliustracija dešinėje: ARIMA (1,1,0) modelio rezultatai.

Finansinių signalų MAPE įverčiai (37 pav.) turėjo tokia pačią tendenciją kaip ir kvazi-periodinių signalų – tolygiai augo didinant prognozuojamų žingsnių kiekį. Nors ir nedaug, bet vis dėlto vidurkiai buvo paveikti išskirčių, todėl nagrinėtos medianos. ARIMA (0,1,0) modelio MAPE mediana prognozuojant 1 žingsnį buvo 3.7894, o, prognozuojant 10 žingsnių, beveik 3 kartus didesnė – 11.2297. MAPE medianos augimas buvo gan tolygus ir pvz. prognozuojant 2 žingsnius MAPE mediana buvo apie 30% didesnė nei prognozuojant 1 žingsnį. ARIMA (1,1,0) modelio 1 žingsnio prognozių MAPE įverčių mediana buvo 3.8803, o 10 žingsnių – taip pat beveik 3 kartus didesnė – 11.2264.



37 pav. ARIMA modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant finansinių signalų kintamumus, gauti MAPE įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: ARIMA (0,1,0) modelio rezultatai. Iliustracija dešinėje: ARIMA (1,1,0) modelio rezultatai.

Gautos finansinių signalų RMSE reikšmės (34 pav.), panašiai kaip ir MAPE įverčiai, augo didinant prognozuojamų žingsnių kiekį. Kaip ir MAPE, RMSE vidurkiai paveikti išskirčių, todėl lyginamos medianos. Abiejų ARIMA modelių RMSE įverčių medianos augo tolygiai, bet lėčiau nei MAPE medianos. Abiejų modelių RMSE medianos augo šiek tiek daugiau nei du kartus nuo ~ 1.3 atliekant prognozes vieną žingsnį į priekį iki ~ 2.9 prognozuojant 10 žingsnių.



38 pav. ARIMA modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu, prognozuojant finansinių signalų kintamumus, gauti RMSE įverčiai atvaizduoti stačiakampėse diagramose. Iliustracija kairėje: ARIMA (0,1,0) modelio rezultatai. Iliustracija dešinėje: ARIMA (1,1,0) modelio rezultatai.

Apibendrinant LSTM ir ARIMA modelių rezultatus, kuomet buvo prognozuojama kelias žingsnių į priekį, galima teigti, kad LSTM modelių kintamumo pokyčio prognozių rezultatai (AUC įverčiai), buvo daug pranašesni nei ARIMA modelių ir abiejų signalų grupių (kvazi-periodinių ir finansinių) AUC įverčių medianos bei vidurkiai išliko didesni nei atsitiktinio spėjimo reikšmė ($AUC > 0.5$). Nagrinėjant ARIMA modelius tik ARIMA (1,1,0) modelio 1 ir 2 žingsnių prognozių AUC įverčių medianos ir vidurkiai buvo didesni nei atsitiktinio spėjimo, visais kitais atvejais – mažesni. Analizuojant MAPE ir RMSE įverčių kitimą didinant prognozuojamų žingsnių kiekį, pastebėta, kad abu dydžiai, atliekant prognozes LSTM modelių pagalba, išaugdavo daug greičiau lyginant su ARIMA modeliais, kuomet MAPE ir RMSE įverčiai didėdavo tolygiau ir lėčiau.

4.8. Ilgalaikės kintamumo krypties prognozavimas naudojant LSTM metodus

Ilgalaikiam planavimui, ypač finansų srityje, svarbu ne tik kitos dienos ar kelių dienų prognozė, bet ir ilgalaikė krypties prognozė t.y. kokia kryptimi ateityje ilguoju laikotarpiu kis kintamumas ar kainos: didės ar mažės. Tam, kad nustatyti, ar ilguoju laikotarpiu kintamumas mažėja ar didėja, buvo pasitelktas mažiausių kvadratų metodas.

4.8.1. Mažiausių kvadratų metodas

Mažiausių kvadratų (angl. *least squares*) metodo pagalba randama tokia tiesinė funkcija $f(x, \beta) = \beta_0 + \beta_1 x$, kurios pagalba nubrėžta tiesė geriausiai atitinka išsibarsčiusias duomenų reikšmes.

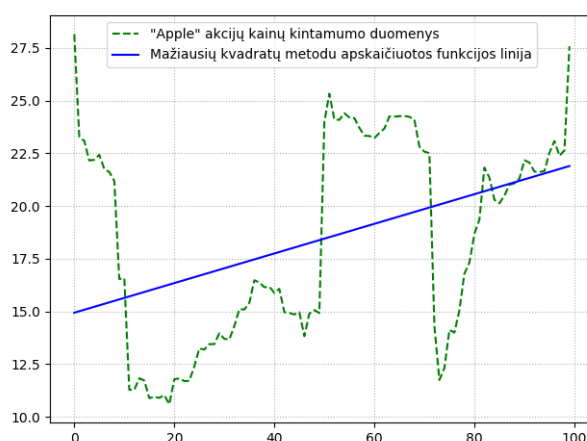
Kaip modelis atitinka laiko eilutės taškus nusako skirtumas tarp tikrų reikšmių ir tarp mažiausių kvadratų metodo pagalba apskaičiuotų reikšmių. Tuos skirtumas galima išreikšti šia formule:

$$r_i = y_i - f(x_i, \beta). \quad (4.6)$$

Mažiausių kvadratų metodo pagalba funkcija optimizuojama tol, kol gaunami tokie parametrai, su kuriais kvadratinių liekanų (angl. *squared residuals*) suma yra minimali:

$$S = \sum_{i=1}^n r_i^2. \quad (4.7)$$

Pavyzdžiui, „Apple“ paskutinio 100 dienų kintamumo reikšmių mažiausiu kvadratų metodu apskaičiuota funkcija yra $f(x, \beta) = 14.9415 + 0.0702x$, kadangi β_1 reikšmė yra didesnė už 0, galima teigti, kad per paskutines šimtą dienų „Apple“ akcijų kintamumas didėjo. Ir atvirkščiai - jeigu β_1 reikšmė būtų mažesnė už 0, būtų galima teigti, jog 100 dienų kintamumas mažėjo. Žemiau (39 pav.) pavaizduotas 100 paskutinių „Apple“ kintamumo reikšmių grafikas ir funkcija apskaičiuota mažiausių kvadratų metodu:



39 pav. „Apple“ akcijų kainų paskutinio 100 dienų kintamumo ir funkcijos, apskaičiuotos mažiausių kvadratų metodu, grafikas.

Kaip galima matyti, mažiausių kvadratų metodu apskaičiuota funkcija yra didėjanti - tai lemia teigiama β_1 reikšmė. Jei ilgalaikis kintamumas mažėtų, β_1 būtų neigiama, o funkcijos grafikas mažėjantis.

4.8.2. Ilgalaikės kintamumo krypties prognozavimas remiantis kintamumo reikšmėmis

Pirmojo ilgalaikės kintamumo krypties prognozavimo eksperimento metu, analogiškai kaip ir 4.5.1 skyriuje aprašytų eksperimentų metu, kiekvienai duomenų grupei buvo sukuriama atskiras LSTM 4 neuronų ir LSTM 8 neuronų modelis. Norint, kad modeliai gebėtų prognozuoti ilgalaikę (100 reikšmių) kintamumo judėjimo kryptį, kiekvienas iš modelių buvo apmokomas apmokymo įvestimi (remiantis 6 pav. x_t) laikant kintamumo pokytį prieš periodą, o išvestimi (h_t) – po to pokyčio sekusių 100 kintamumo reikšmių judėjimo kryptį (100 reikšmių didėjimą arba mažėjimą), apskaičiuotą mažiausių kvadratų metodu. Jeigu mažiausių kvadratų metodu apskaičiuotos funkcijos β_1 reikšmė yra teigiama, laikyta, kad kintamumas per 100 dienų didėjo ir žymėta „1“, o jeigu neigiama – laikyta kad kintamumas mažėjo ir žymėta „0“. Apmokymo sąrašo ilgį sudarė 400 reikšmių. Testuojama buvo 100 paskutinių kintamumo reikšmių judėjimo kryptis, tad jos į apmokymo sąrašą nebuvo įtraukiamos. Pasitelkus apmokytą modelį buvo prognozuojama kiekvieno duomenų rinkinio 100 paskutinių kintamumo reikšmių judėjimo kryptis ir prognozė lyginama su faktine judėjimo kryptimi, apskaičiuota mažiausių kvadratų metodu. Iš gautų rezultatų apskaičiuotas AUC įvertis pagal metodiką pateiktą 3.3.2 skyriuje. Detalūs rezultatai pateikti prieduose 22 lentelėje, o rezultatų suvestinė 10 lentelėje žemiau:

Rezultatai	LSTM 4 neuronų prognozė	LSTM 8 neuronų prognozė
AUC (kvazi-period.)	0.7167	0.8000
AUC (finans.)	0.6066	0.6360

10 lentelė. Kintamumo krypties prognozių, LSTM modelius apmokus kintamumo reikšmėmis ir po jų sekančiomis 100 kintamumo reikšmių judėjimo kryptimis, eksperimentų metu gauti AUC įverčiai.

Kaip galima matyti iš gautų rezultatų, ilgalaikio kintamumo krypties prognozių eksperimentų metu gauti AUC įverčiai tiek kvazi-periodinių tiek finansinių signalų buvo didesni nei atsitiktino spėjimo ($AUC > 0.5$). Taip pat jie geresni ir už rezultatus gautus prognozuojant tik sekančios kintamumo reikšmės pokytį (žr. 4.5.1 skyrelį). LSTM 4 neuronų modelio kvazi-periodinių signalų AUC įvertis buvo apie 25% didesnis nei prognozuojant tik sekančios kintamumo reikšmės pokytį, o to paties modelio finansinių signalų – apie 18%. LSTM 8 neuronų kvazi-periodinių signalų AUC įvertis net apie 40% didesnis nei prognozuojant tik sekančios kintamumo reikšmės pokytį, o finansinių signalų apie 23%. Tad galima teigti, kad LSTM modelių ilgalaikio kintamumo krypties prognostinės savybės yra geresnės nei atsitiktinio spėjimo ir tikslesnės nei tik sekančios kintamumo reikšmės pokyčio.

4.8.3. Ilgalaikės kintamumo krypties prognozavimas remiantis tiesioginėmis reikšmėmis

Šio eksperimento metu taikyta ta pati metodika kaip ir 4.8.2 skyrelyje, bet padarytas vienas esminis pakeitimas – įvestimi (x_t) buvo laikoma tiesioginės signalo reikšmės (pvz. akcijų kainos) pokytis prieš periodą. Gauti rezultatai pateikti prieduose 23 lentelėje. Rezultatų suvestinė pateikiama žemiau 11 lentelėje:

Rezultatai	LSTM 4 neuronų	LSTM 8 neuronų
	progozė	progozė
AUC (kvazi-period.)	0.2667	0.6500
AUC (finans.)	0.4694	0.4069

11 lentelė. Kintamumo krypties prognozių, LSTM modelius apmokius tiesioginėmis pradinėmis signalo reikšmėmis ir po jų sekančiomis 100 kintamumo reikšmių judėjimo kryptimis, eksperimentų metu gauti AUC įverčiai.

Kaip galima matyti iš pateiktų rezultatų, AUC įvertis vieninteliu atveju buvo didesnis nei atsitiktinio spėjimo – pasitelkus LSTM 8 neuronų modelį kvazi-periodinių signalų prognozėms. Visais kitais atvejais AUC įvertis buvo mažesnis už 0.5, tad panašu, kad šis metodas nėra tinkamas ilgalaikės kintamumo krypties prognozėms.

4.8.4. Ilgalaikės kintamumo krypties prognozavimas remiantis Hursto eksponentėmis

Šio eksperimento metu taip pat buvo taikyta analogiška metodika kaip ir 4.8.2 skyrelyje, tačiau šįkart įvestimi (x_t) laikytos Hursto eksponentės apskaičiuotos iš reikšmių sąrašo prieš periodą, o išvestimi, (h_t) kaip ir 4.8.2 skyrelyje, po to sekusių 100 kintamumo reikšmių judėjimo kryptis. Norint suprasti, kokio ilgio sąrašas Hursto eksponentių apskaičiavimui yra optimalus, buvo atliekami eksperimentai su įvairiais reikšmių sąrašų ilgiais. Hursto eksponentės buvo skaičiuojamos iš 120, 150, 200, 250 ir 300 reikšmių. Gauti detalūs eksperimentų rezultatai pateikiami prieduose 24 ir 25 lentelėse. Rezultatų santrauka pateikiama žemiau 12 lentelėje:

Hursto eksponentės sąrašo ilgis	LSTM 4 neuronų prognozė		LSTM 8 neuronų prognozė	
	AUC (kvazi-period.)	AUC (finans.)	AUC (kvazi-period.)	AUC (finans.)
120 reikšmių	0.3667	0.6152	0.5333	0.4853
150 reikšmių	0.8333	0.5221	0.7333	0.5980
200 reikšmių	0.7167	0.6446	0.4333	0.5735
250 reikšmių	0.4500	0.5025	0.3667	0.3934
300 reikšmių	0.4500	0.4559	0.7333	0.3811

12 lentelė. Kintamumo krypties prognozių eksperimentų metu gauti AUC įverčiai LSTM modelius apmokius Hursto eksponentėmis ir po jų sekančiomis 100 kintamumo reikšmių judėjimo kryptimis.

Kaip galima matyti iš pateiktos lentelės, rezultatai pakeitus Hursto eksponentės apskaičiavimo reikšmių ilgį skyrėsi ženkliai. Pavyzdžiui, Hursto eksponentę skaičiuojant iš 120 reikšmių LSTM 4 neuronų kvazi-periodinių signalų AUC įvertis buvo vos 0.3667, tačiau Hursto eksponentę skaičiuojant iš 150 reikšmių AUC įvertis išaugo net daugiau nei du kartus – iki 0.8333. Nors vienareikšmiškas išvadas iš gautų rezultatų sudėtinga daryti, tačiau panašu, kad LSTM modelių apmokymas Hursto eksponentėmis galėtų duoti teigiamų rezultatų, tačiau reikėtų gilesnių ir platesnių tyrimų. Iš pateiktos 12 lentelės matyti, kad geriausiai LSTM modeliai atlikdavo kintamumo reikšmių judėjimo krypties prognozes, kai buvo apmokomi su Hursto eksponentėmis apskaičiuotomis iš 150 ir 200 reikšmių.

Atlikus skirtingus eksperimentus, prognozuojant 100 kintamumo reikšmių judėjimo kryptį, galima teigti, kad geriausi rezultatai buvo pasiekti, kuomet LSTM modeliai buvo apmokomi pasitelkiant kintamumo reikšmių pokyčius ir po jų sekančias ilgalaikes kintamumo reikšmių judėjimo kryptis. Prasčiausi rezultatai stebėti, kai modelio įvestimi buvo laikytos tiesioginės reikšmės. Ilgalaikės kintamumo krypties prognozės, pasitelkiant Hursto eksponentę, irgi davė teigiamų, tačiau nevienareikšmiškų rezultatų. Norint įsitikinti tokius metodikos efektyvumą, reikėtų atlikti platesnio masto tyrimus.

Išvados ir rekomendacijos

Šiame darbe, remiantis rekurentiniais neuroniniais tinklais (LSTM) bei laiko eilučių metodais (ARIMA), buvo siekiama, panaudojant įvairius modelius bei jų parametrus, surasti metodus, kurie gebėtų tiksliausiai prognozuoti finansinių signalų kintamumą. Atlikti eksperimentai atskleidė, kad geriausias finansinių signalų kintamumo prognozuojamumas fiksuotas naudojant rekurentinių neuroninių tinklų LSTM modelius, tačiau jis buvo tik nežymiai didesnis už atsitiktinio spėjimo lygį. Eksperimentų metu gautas AUC įvertis siekė apie 0.51, o atsitiktiniu spėjimu laikoma, kai AUC reikšmė lygi 0.5. Vis dėlto žinant, kad finansiniai signalai pasižymi dideliu neapibrėžtumu ir dažniausiai kinta atsitiktine nenuspėjama kryptimi, tai gali būti laikoma teigiamu rezultatu. Paraleliai tirtų kvazi-periodinių signalų eksperimentai atskleidė, kad šie signalai yra lengviau prognozuojami.

Susijusių darbų analizė 2 skyriuje atskleidė, kad populiariausios metodikos, šiuo metu naudojamos kintamumo prognozavimui apima ARMA šeimos modelius, GARCH, neuroninių tinklų modelius bei jų junginius (hibridinius modelius). Taip pat literatūros analizė parodė, kad geriausi rezultatai paprastai stebimi kintamumo prognozavimui naudojant hibridinius ir neuroninių tinklų modelius.

Eksperimentų rezultatų vertinimo metodika apžvelgta 3 skyriuje. Buvo nustatyta, kad dažniausiai naudojamos ir patikimiausios vertinimo metrikos yra šaknis iš vidutinės kvadratinės paklaidos (RMSE) bei vidutinė absoliuti procentinė paklaida (MAPE). Kadangi buvo vertinama ne tik metodų prognozuojama kintamumo reikšmė, bet ir jos pokytis (didėjimas arba mažėjimas), papildomai pasitelkta ROC analizė (skaičiuotas AUC įvertis).

Eksperimentų rezultatai 4.2 skyriuje parodė, kad tiek LSTM tiek ARIMA modelių prognozių rezultatai buvo geriausi naudojant apytikriai 400 reikšmių apmokymo sąrašą. Tokio apmokymo sąrašo privalumas ir tai, kad duomenims fiksuotiems kiekvieną dieną, apmokymo sąrašas apima daugiau nei visus metus.

4.5 skyriuje atliktų eksperimentų metu paaiškėjo, kad signalų kintamumo krypties prognozuojamumas priklauso nuo signalų kilmės. Kvazi-periodinių signalų AUC įverčių medianos ir vidurkiai naudojant LSTM metodus svyravo tarp 0.55–0.58, o finansinių signalų buvo tik nedaug didesni už atsitiktinį spėjimą. AUC įverčiai buvo didesni naudojant LSTM metodus. Tuo tarpu MAPE ir RMSE įverčiai daugeliu atveju, išskyrus kvazi-periodinių signalų RMSE, fiksuoti geresni naudojant ARIMA metodus. Taip pat buvo nustatyta, kad signalų, kurių Hursto eksponentė yra artima 0, kintamumo pokytis (didėjimas ar mažėjimas) yra lengviau prognozuojamas nei signalų, kurių Hursto eksponentė artima 0.5.

LSTM kintamumų pokyčių prognozavimo eksperimentai, remiantis tiesioginėmis signalų reikšmėmis (4.6 skyrius), taip pat davė teigiamų rezultatų tiriant kvazi-periodinius signalus. Vis dėlto gauti AUC įverčiai buvo mažesni nei apmokymams naudojant buvusias faktines kintamumo reikšmes.

4.7 skyriuje atlikti eksperimentai atskleidė, kad kvazi-periodinių signalų AUC įvertis prognozuojant nebe 1, o du žingsnius nukrito iki 0.52–0.53. Toliau didinant žingsnių skaičių tapo artimas, bet išliko šiek tiek didesnis nei atsitiktinio spėjimo įvertis ($AUC \approx 0.5$). Naudojant ARIMA metodus pastebėta, kad tik ARIMA (1,1,0) modelio kvazi-periodinių signalų AUC įverčiai viršijo atsitiktinio spėjimo ribą prognozuojant 1 ir 2 žingsnius, visais kitais atvejais ARIMA metodų AUC įverčiai buvo mažesni nei atsitiktinio spėjimo. MAPE ir RMSE įverčiai, naudojant LSTM metodiką, jau antrame žingsnyje labai išaugo, tuo tarpu, naudojant ARIMA metodiką, augimas nebuvo toks staigus – MAPE ir RMSE įverčiai augo tolygiau ir buvo mažesni.

Atliekant ilgalaikės kintamumo krypties prognozavimo eksperimentus 4.8 skyriuje, geriausi rezultatai stebėti, kuomet modelis buvo apmokomas pasitelkus buvusias faktines kintamumo reikšmes. AUC įverčiai fiksuoti didesni nei prognozuojant tik 1 žingsnį: kvazi-periodiniams signalams siekė 0.7-0.8, o finansiniams, kaip ir anksčiau darbe atliktų eksperimentų metu, buvo mažesni bei siekė ~ 0.6 . Teigiamų rezultatų nepastebėta, kai modelio įvestimi buvo laikytos tiesioginės pradinės signalo reikšmės. Modelių apmokymas išvestiniu dydžiu - Hursto eksponentėmis davė teigiamų rezultatų, kai Hursto eksponentė buvo skaičiuojama iš 150 ir 200 reikšmių, tačiau, norint įsitikinti jo patikimumu, reikėtų atlikti platesnio masto tyrimus.

Apibendrinus rezultatus galima daryti išvadą, kad signalų kintamumo prognozuojamumas priklauso nuo signalų kilmės. Kintamumo judėjimo kryptis, kuriai įvertinti naudojamas AUC įvertis, geriau prognozuojama naudojant LSTM metodus, kai modeliai apmokomi prieš tai buvusiomis kintamumo reikšmėmis. Nors ir nežymiai, dažniausiai MAPE ir RMSE įverčiai buvo mažesni (geresni) naudojant ARIMA metodus.

Tikėtina, kad apjungus abu metodus (LSTM ir ARIMA) t. y. suformavus hibridinį modelį, kas buvo pastebėta ir susijusių darbų analizėje, būtų galima pasiekti geresnių kintamumo prognozavimo rezultatų.

Ateities tyrimų gairės

- Skaičiuoti kitus rodiklius, kaip Liapunovo rodiklis ar koreliacinė dimensija, kuriuos pasitelkus galėtų būti apmokomas LSTM modelis.
- Panaudoti ARIMA įvairesnius/didesnių eilių modelius.
- Modifikuoti LSTM metodus didinant neuronų kiekį ir perskaičiavimų skaičių (tam reikia didelių skaičiavimo pajėgumų).
- Apjungti ARIMA ir LSTM metodiką.
- Įtraukti kitus rekurentinius neuroninius tinklus.
- Panaudoti GARCH metodiką.

Literatūros šaltiniai

- [1] Bureau of meteorology: Australia's official weather forecasts & weather. Bom.gov.au.
<http://www.bom.gov.au/>. Tikrinta 2018-10-13.
- [2] Data - urban climate. Urban-climate.com.
<http://www.urban-climate.net/content/data/9-data>. Tikrinta 2018-10-14.
- [3] Datasets | climate data online (cdo) | national climatic data center. Ncdc.noaa.gov/cdo-web/datasets.
<https://www.ncdc.noaa.gov/cdo-web/datasets>. Tikrinta 2018-10-15.
- [4] The home of the u.s. government's open data. Data.gov.
<https://www.data.gov/>. Tikrinta 2018-10-12.
- [5] Investing.com - stock market quotes & financial news. Investing.com.
<https://www.investing.com/>. Tikrinta 2018-10-11.
- [6] Solargis global solar radiation data. Solargis.com.
<https://solargis.com/products/time-series-and-tmy-data/useful-resources/>. Tikrinta 2018-10-14.
- [7] U.s. births data for the years 2000 to 2014, as provided by the social security administration. Github.com.
<https://github.com/fivethirtyeight/data/tree/master/births>. Tikrinta 2018-10-13.
- [8] Yahoo finance - business finance, stock market, quotes, news. Finance.yahoo.com.
<https://finance.yahoo.com>. Tikrinta 2018-10-11.
- [9] Ratnadip Adhikari and R. K. Agrawal. An introductory study on time series modeling and forecasting. Cornell University Library, 2013.
<https://arxiv.org/ftp/arxiv/papers/1302/1302.6613.pdf>. Tikrinta 2018-03-28.
- [10] Danko Brezak, Tomislav Bacek, Dubravko Majetic, Josip Kasac, and Branko Novakovic. A comparison of feed-forward and recurrent neural networks in time series forecasting. IEEE Xplore, 2012.
<https://pdfs.semanticscholar.org/2259/564042359cf6a90e676b18dbc93a683cd73d.pdf>.
Tikrinta 2018-04-24.
- [11] Ricardo de A. Araújo. Swarm-based translation-invariant morphological prediction method for financial time series forecasting. Information Sciences, 2010.
<https://www.sciencedirect.com/science/article/pii/S002002551000410X> Tikrinta. 2018-03-24.
- [12] Christian L. Dunis and Xuehuan Huang. Forecasting and trading currency volatility: An application of recurrent neural regression and model combination. Wiley Online Library, 2001.
<https://onlinelibrary.wiley.com/doi/abs/10.1002/for.833>. Tikrinta 2018-03-20.

- [13] Audrius Džikevičius. Užsienio valiutų kursų nepastovumo ir kovariacijų prognozavimas. EKONOMIKA 2003, 2003.
http://www.manoinvesticijos.lt/pics/file/Ekonomikai%20Nr_%2063.pdf. Tikrinta 2018-03-26.
- [14] Tom Fawcett. An introduction to roc analysis. ScienceDirect, 2005.
<http://people.inf.elte.hu/kiss/12dwhdm/roc.pdf>. Tikrinta 2018-05-23.
- [15] Klaus Greff, Rupesh K. Srivastava, Jan Koutník, Bas R. Steunebrink, and Jurgen Schmidhuber. Lstm: A search space odyssey. arXiv, 2017.
<https://arxiv.org/pdf/1503.04069.pdf>. Tikrinta 2018-04-25.
- [16] Caglar Gulcehre, Marcin Moczulski, Misha Denil, Yoshua BengioXingyuan Pan, and Vivek Srikumar. Noisy activation functions. arXiv, 2016.
<https://arxiv.org/pdf/1603.00391.pdf>. Tikrinta 2018-04-24.
- [17] Bekir Karlik and A. Vehbi Olgac. Performance analysis of various activation functions in generalized mlp architectures of neural networks. International Journal of Artificial Intelligence And Expert Systems, 2011.
<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.740.9413&rep=rep1&type=pdf>. Tikrinta 2018-05-21.
- [18] Andrej Krenker¹, Janez Bešter², and Andrej Kos. Introduction to the artificial neural networks. InTech, 2013.
<http://cdn.intechweb.org/pdfs/14881.pdf>. Tikrinta 2018-04-14.
- [19] Subir Mansukhani. The hurst exponent: Predictability of time series. Analytics Magazine, 2012.
<http://analytics-magazine.org/the-hurst-exponent-predictability-of-time-series> Tikrinta. 2018-10-15.
- [20] Tadas Meškauskas. Signalų analizė ir apdorojimas. Vilniaus universitetas, 2017.
https://klevas.mif.vu.lt/~meska/SAA/Tadas_Meskauskas_-_Signalu_Analize_Ir_Apdorojimas_-_Mokymo_Priemone.pdf. Tikrinta 2018-11-01.
- [21] Hemanth Kumar P. and S. Basavaraj Patil. Estimation & forecasting of volatility using arima, arfima and neural network based techniques. IEEE Xplore Digital Library, 2015.
<https://ieeexplore.ieee.org/document/7154853/>. Tikrinta 2018-04-08.
- [22] Xingyuan Pan and Vivek Srikumar. Expressiveness of rectifier networks. arXiv, 2016.
<https://arxiv.org/pdf/1511.05678.pdf>. Tikrinta 2018-04-24.
- [23] Dabal Pedamonti. Comparison of non-linear activation functions for deep neural networks on mnist classification task. arXiv, 2018.
<https://arxiv.org/pdf/1804.02763.pdf>. Tikrinta 2018-05-18.
- [24] Keith Pilbeam and Kjell Noralf Langeland. Forecasting exchange rate volatility: Garch models versus implied volatility forecasts. Springer Link, 2014.
<https://link.springer.com/article/10.1007/s10368-014-0289-4>. Tikrinta 2018-04-03.

- [25] B L Qian and Khaled Rasheed. Hurst exponent and financial market predictability. Semantic Scholar, 2005.
<https://pdfs.semanticscholar.org/0816/a5a989c8d2431a6d20076d27c4295c00fb77.pdf>.
 Tikrinta 2018-11-04.
- [26] Prajit Ramachandran, Barret Zoph, and Quoc V. Le. Searching for activation functions. arXiv, 2017.
<https://arxiv.org/pdf/1710.05941.pdf>. Tikrinta 2018-05-24.
- [27] R. Sathya and Annamma Abraham. Comparison of supervised and unsupervised learning algorithms for pattern classification. International Journal of Advanced Research in Artificial Intelligence, 2013.
https://thesai.org/Downloads/IJARAI/Volume2No2/Paper_6-Comparison_of_Supervised_and_Unsupervised_Learning_Algorithms_for_Pattern_Classification.pdf.
 Tikrinta 2018-04-16.
- [28] Emad A. M. Andrews Shenouda. A quantitative comparison of different mlp activation functions in classification. Springer, 2006.
<http://individual.utoronto.ca/emad/downloads/39710849.pdf>. Tikrinta 2018-05-12.
- [29] Tom Starke. Basics of statistical mean reversion testing. Quant Start, 2013.
<https://www.quantstart.com/articles/Basics-of-Statistical-Mean-Reversion-Testing> Tikrinta. 2018-10-15.
- [30] Anupam Tarsauliya, Rahul Kala, Ritu Tiwari, and Anupam Shukla. Financial time series volatility forecast using evolutionary hybrid artificial neural network. Springer Link, 2011.
https://link.springer.com/content/pdf/10.1007/978-3-642-22540-6_44.pdf. Tikrinta 2018-03-24.
- [31] Fang-Mei Tsenga, Gwo-Hshiung Tzengb, Hsiao-Cheng Yua, and Benjamin JC Yuana. Fuzzy arima model for forecasting the foreign exchange market. Elsevier, 2013.
<https://pdfs.semanticscholar.org/90ac/a78b7c653350ce0d7dd2f9ad0d0dc01391d7.pdf>.
 Tikrinta 2018-03-24.
- [32] Yi Xiao, Jin Xiao, John Liu, and Shouyang Wang. A multiscale modeling approach incorporating ARIMA and ANNs for financial market volatility forecasting. Springer Link, 2014.
<https://link.springer.com/article/10.1007/s11424-014-3305-4>. Tikrinta 2018-04-10.
- [33] Mao Xin. The vix volatility index. Uppsala Universitet, 2011.
<https://uu.diva-portal.org/smash/get/diva2:417612/FULLTEXT01.pdf>. Tikrinta 2018-02-24.

Priedai

Dokumentą sudaro keturi priedai: A priede pateikiama LSTM metodų keleto žingsnių prognozių eksperimentų metu gauti rezultatai, B priede – ARIMA metodų keleto žingsnių prognozių eksperimentų metu gauti rezultatai, C priede – LSTM metodų eksperimentų, kai buvo remiamasi tiesioginėmis pradinėmis signalo reikšmėmis, metu gauti rezultatai, o D priede – kintamumo krypties prognozavimo eksperimentų metu gauti rezultatai.

A. LSTM metodų keletu žingsnių prognozių eksperimentų rezultatai

Eil. nr.	Duomenys	LSTM (4 neuronai) 2 žingsniai			LSTM (4 neuronai) 4 žingsniai		
		AUC	MAPE	RMSE	AUC	MAPE	RMSE
1	APALM	0.5414	47.2575	2.8532	0.5414	47.0452	2.8185
2	ARRSTPGH	0.6222	21.8501	148.6947	0.6329	21.6097	146.9427
3	BPFREMONTE	0.4923	16.9157	242.4262	0.4662	18.5509	240.4509
4	PWATALM	0.5120	17.7003	98.7388	0.4816	17.8626	100.3729
5	RHLDN	0.5100	283.9830	58.0933	0.5200	288.4581	59.3752
6	TEMPCARY	0.4690	92.4417	103.5508	0.4992	95.4179	107.4810
7	TEMPLDN	0.5011	46.8069	25.3697	0.4503	47.7119	25.4686
8	TEMPSYD	0.5272	21.4437	82.4384	0.4968	21.2095	82.3008
9	USBIRTHS	0.5065	7.1764	36.1964	0.5698	7.2843	37.2370
10	WSLDN	0.5545	69.5861	2347.0584	0.5136	66.3066	2341.9584
11	WSNY	0.4848	17.2081	176.8173	0.5264	18.0179	185.1016
12	AAPL	0.6114	50.9224	10.1660	0.5914	50.3362	10.0493
13	ALK	0.5158	61.5599	17.0123	0.4962	62.0803	17.0155
14	BAC	0.5442	63.2966	12.0319	0.5650	62.4330	11.8062
15	BCS	0.4300	27.1165	6.6400	0.4500	28.7245	6.8993
16	BRK-B	0.5323	82.9610	12.3893	0.5323	83.6186	12.5182
17	BTC	0.5089	41.6404	19.9837	0.5475	39.8863	19.2935
18	C	0.5080	36.4095	7.8562	0.5167	37.1327	7.9635
19	CSCO	0.5889	75.7830	13.2333	0.5593	77.0097	13.3566
20	CVX	0.4864	35.3109	7.9542	0.4864	36.4445	8.1663
21	DJI	0.4600	121.4389	11.9819	0.4600	122.6355	12.1337
22	EURJPY	0.5397	34.4281	2.4928	0.5680	34.1414	2.4864
23	F	0.5641	55.1181	12.0030	0.5537	54.8155	12.0622
24	GE	0.5369	32.0957	10.5619	0.5673	33.0978	10.8740
25	GOLD	0.5440	25.8771	2.6218	0.5440	27.6024	2.7465
26	GOOG	0.5256	61.6953	12.4713	0.5256	61.6921	12.5033
27	GS	0.5143	59.2985	11.5264	0.5249	60.1198	11.6885
28	IBM	0.4926	93.2657	13.6709	0.4721	90.5996	13.3969
29	INTC	0.5024	55.8323	15.6651	0.5329	54.0346	15.3364
30	JNJ	0.4466	64.3237	10.0730	0.4466	64.3669	10.0440
31	JPM	0.5300	64.9160	11.0731	0.5500	65.8063	11.2024
32	KO	0.5046	46.1369	6.2158	0.5046	47.3443	6.3890
33	LUV	0.5788	43.3177	10.1889	0.5384	43.5432	10.1931
34	LYG	0.5404	25.0995	5.7202	0.5647	26.1174	5.9393
35	MCD	0.5263	64.8890	11.0812	0.5354	63.7163	11.0475
36	NIKKEI	0.4383	50.0318	7.6151	0.4586	50.4883	7.5993
37	NOK	0.5707	41.2559	13.8186	0.5434	38.7539	13.2920
38	ORCL	0.4408	92.5885	16.3963	0.4641	90.3863	16.0119
39	PFE	0.4998	95.0104	12.2395	0.4868	95.1304	12.3384
40	RYCEY	0.5727	24.9750	7.7631	0.5525	21.8417	6.8448
41	SNE	0.5270	37.9171	11.7009	0.4960	38.2572	11.9291
42	SP500	0.4954	124.8159	11.0159	0.4954	126.6798	11.1793
43	T	0.5384	38.0019	7.7758	0.5384	38.5153	7.8796
44	TM	0.4716	37.4310	7.7235	0.5010	37.4974	7.7733
45	TSCDY	0.4820	50.9201	9.7286	0.5118	49.9970	9.4980
46	USDCHF	0.4302	41.9851	2.3209	0.4421	43.3480	2.3910
47	VWAGY	0.5165	29.3443	8.7323	0.5137	29.1715	8.8385
48	WFC	0.5550	67.7268	12.7426	0.5624	70.0067	13.1777
49	WMT	0.4800	88.1772	16.1495	0.4800	85.1314	15.7147
50	WTI	0.4717	25.7299	7.4178	0.4717	26.7758	7.6309
51	XOM	0.4686	57.0976	10.1697	0.4686	57.3699	10.2259
52	EURUSD	0.5406	15.4335	1.1759	0.5206	15.7228	1.1795

13 lentelė. LSTM 4 neuronų modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu gauti AUC, MAPE ir RMSE įverčiai.

Eil. nr.	Duomenys	LSTM (4 neuronai) 5 žingsniai			LSTM (4 neuronai) 10 žingsniai		
		AUC	MAPE	RMSE	AUC	MAPE	RMSE
1	APALM	0.5502	47.3362	2.8364	0.5502	44.2297	2.7040
2	ARRSTPGH	0.6210	20.1189	141.9498	0.5939	18.4122	135.6564
3	BPFREMONT	0.4444	18.0078	235.5289	0.4694	19.5141	258.4391
4	PWATALM	0.4944	18.7875	106.7573	0.4936	18.3836	107.2485
5	RHLDN	0.5000	290.2219	59.1612	0.5100	297.4765	60.6744
6	TEMPCARY	0.5094	96.5207	106.9577	0.4784	97.5189	108.4580
7	TEMPLDN	0.4688	47.6910	25.4118	0.4672	48.5318	24.7295
8	TEMPSYD	0.4976	20.9256	81.1726	0.4880	20.0053	80.3859
9	USBIRTHS	0.5584	6.5225	31.9590	0.5341	7.0448	33.4565
10	WSLDN	0.5441	66.4655	2342.4107	0.5321	64.4725	2327.7686
11	WSNY	0.5272	18.6552	191.4044	0.5497	19.7573	197.1205
12	AAPL	0.5914	50.4437	10.0383	0.5513	53.0275	10.3437
13	ALK	0.5256	61.1695	16.9315	0.5150	56.7736	16.0769
14	BAC	0.5740	63.7019	12.1279	0.5752	59.9619	11.6144
15	BCS	0.4200	28.3702	6.8562	0.4200	27.2678	6.6065
16	BRK-B	0.5414	80.0415	11.9250	0.5414	83.5140	11.8977
17	BTC	0.5089	41.6359	20.0732	0.5230	42.9589	20.4296
18	C	0.5400	35.0962	7.5929	0.5343	33.6956	7.1990
19	CSCO	0.5593	75.3735	13.0507	0.5481	78.4338	13.2018
20	CVX	0.4768	36.5959	7.9602	0.4680	39.8771	8.3625
21	DJI	0.4800	119.1448	11.7027	0.4800	126.7007	11.9435
22	EURJPY	0.5586	32.5812	2.4122	0.5964	33.5898	2.4502
23	F	0.5617	56.2564	12.0608	0.5705	48.1322	10.8962
24	GE	0.5481	31.4847	10.2643	0.5192	34.0867	11.0618
25	GOLD	0.5040	24.4179	2.4780	0.4950	24.3088	2.6947
26	GOOG	0.5460	60.0458	12.1548	0.5460	59.4199	11.9586
27	GS	0.5450	58.2260	11.2584	0.5118	59.0633	10.9887
28	IBM	0.4873	88.2485	13.2066	0.5099	87.8227	13.2326
29	INTC	0.5329	54.0697	15.3840	0.4808	51.4997	15.1283
30	JNJ	0.4466	61.9078	9.6540	0.4466	61.2839	9.5234
31	JPM	0.5800	65.4539	11.1017	0.5700	65.1498	10.9996
32	KO	0.5148	44.9087	6.0862	0.5254	45.3210	6.2033
33	LUV	0.5677	43.5082	10.2538	0.5525	42.8646	10.0153
34	LYG	0.5535	24.6500	5.5636	0.5828	24.3435	5.7542
35	MCD	0.5131	64.5409	11.1743	0.5091	65.5706	11.6708
36	NIKKEI	0.4675	50.5761	7.8426	0.4927	58.3315	8.5575
37	NOK	0.5758	37.1237	12.7797	0.5606	35.7269	12.2536
38	ORCL	0.4641	90.5739	16.1142	0.4641	94.5926	16.5292
39	PFE	0.5092	90.3436	11.8942	0.5482	85.9662	11.5896
40	RYCEY	0.5414	24.4987	7.4865	0.5303	24.0159	7.9464
41	SNE	0.4960	37.6118	11.5927	0.4791	36.3392	11.2801
42	SP500	0.4958	122.0198	10.7293	0.5060	128.6558	10.8757
43	T	0.5657	37.9749	7.8719	0.5323	34.0787	7.1997
44	TM	0.4818	37.8890	7.9291	0.4610	39.8874	8.0626
45	TSCDY	0.4820	48.5891	9.0737	0.4730	45.7143	8.2994
46	USDCHF	0.4302	41.7842	2.3029	0.4302	43.0236	2.3322
47	VWAGY	0.4904	27.9948	8.3188	0.5108	28.6967	8.5546
48	WFC	0.5258	66.9941	12.6233	0.5502	64.7829	12.1611
49	WMT	0.5120	262.5049	42.6451	0.4631	99.4724	19.2239
50	WTI	0.4828	27.3952	7.6661	0.4828	28.6541	7.9055
51	XOM	0.4649	57.8358	10.2423	0.4649	58.4805	10.2576
52	EURUSD	0.5010	16.9141	1.2597	0.5108	15.4968	1.1556

14 lentelė. LSTM 4 neuronų modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu gauti AUC, MAPE ir RMSE įverčiai.

Eil. nr.	Duomenys	LSTM (8 neuronai) 2 žingsniai			LSTM (8 neuronai) 4 žingsniai		
		AUC	MAPE	RMSE	AUC	MAPE	RMSE
1	APALM	0.5414	47.1443	2.8495	0.5414	47.1361	2.8217
2	ARRSTPGH	0.6222	21.8405	148.6451	0.6234	21.7112	147.3352
3	BPFREMONT	0.5297	18.2407	234.3042	0.4738	18.4436	241.6073
4	PWATALM	0.5120	17.9029	101.0177	0.5032	18.3223	102.2196
5	RHLDN	0.5100	283.8431	58.0765	0.5200	288.5244	59.3856
6	TEMPCARY	0.4690	92.5871	103.6508	0.4992	95.8376	107.7918
7	TEMPLDN	0.4511	46.8117	25.3951	0.4407	47.5815	25.4032
8	TEMPSYD	0.5272	21.4427	82.2812	0.4968	21.2186	82.4311
9	USBIRTHS	0.5586	7.8116	37.9613	0.5244	7.3176	37.5687
10	WSLDN	0.5545	69.5993	2351.6911	0.5136	66.4152	2339.5581
11	WSNY	0.4848	17.2799	177.2022	0.5264	18.2001	186.9063
12	AAPL	0.6114	51.0559	10.1930	0.5914	50.2552	10.0424
13	ALK	0.5260	61.3776	16.9884	0.4962	62.1824	17.0313
14	BAC	0.5442	63.1088	11.9509	0.5650	62.8378	11.9479
15	BCS	0.4300	27.1620	6.6471	0.4500	28.6785	6.8899
16	BRK-B	0.5323	83.3976	12.4555	0.5323	83.7346	12.5175
17	BTC	0.5197	41.7075	20.0198	0.5382	40.3162	19.3716
18	C	0.5080	35.9298	7.7343	0.5167	38.9888	8.3089
19	CSCO	0.5889	75.7827	13.2308	0.5593	76.9916	13.3360
20	CVX	0.4864	35.1535	7.9209	0.4864	36.7167	8.2317
21	DJI	0.4600	122.3347	12.0336	0.4600	123.3739	12.1672
22	EURJPY	0.5480	32.8229	2.3810	0.5775	33.8826	2.4643
23	F	0.5641	55.1797	12.0085	0.5537	54.8426	12.0525
24	GE	0.5369	32.0342	10.5413	0.5577	33.1662	10.8791
25	GOLD	0.5440	25.7558	2.6139	0.5338	27.6375	2.7495
26	GOOG	0.5256	61.6974	12.4760	0.5256	61.6681	12.5025
27	GS	0.5249	58.8697	11.4072	0.5167	61.2553	11.7932
28	IBM	0.4926	93.2584	13.6708	0.4721	90.7177	13.4105
29	INTC	0.5016	55.7192	15.6464	0.5232	54.1048	15.3732
30	JNJ	0.4466	63.8259	9.9913	0.4466	63.9088	9.9397
31	JPM	0.5200	65.0627	11.0592	0.5500	65.6857	11.1785
32	KO	0.5046	46.1610	6.2119	0.5046	47.2856	6.3704
33	LUV	0.5788	43.2976	10.1831	0.5384	43.5098	10.1848
34	LYG	0.5606	25.0753	5.7253	0.5535	25.7600	5.8810
35	MCD	0.5263	64.8876	11.0777	0.5354	63.6987	11.0447
36	NIKKEI	0.4383	49.8581	7.6063	0.4586	50.0713	7.5733
37	NOK	0.5707	41.2115	13.8056	0.5434	38.7184	13.2783
38	ORCL	0.4408	92.6041	16.3936	0.4641	90.1403	15.9648
39	PFE	0.4998	95.0013	12.2351	0.4761	95.0205	12.3089
40	RYCEY	0.5727	25.1363	7.8362	0.5525	21.7445	6.8148
41	SNE	0.5270	37.9104	11.7142	0.4960	38.1681	11.8851
42	SP500	0.4954	124.4985	10.9920	0.4954	126.7563	11.1794
43	T	0.5384	37.9861	7.7720	0.5384	38.4389	7.8561
44	TM	0.4328	44.3652	8.5572	0.5104	37.3365	7.6305
45	TSCDY	0.4820	50.8509	9.6951	0.5118	50.0646	9.5094
46	USDCHF	0.4302	41.9893	2.3205	0.4421	43.3279	2.3909
47	VWAGY	0.5165	29.3614	8.7347	0.5137	29.4841	9.0034
48	WFC	0.5550	67.8576	12.7776	0.5624	69.9517	13.1653
49	WMT	0.4800	88.1007	16.1167	0.4912	433.4865	74.1432
50	WTI	0.4717	25.7046	7.4106	0.4717	26.7271	7.6242
51	XOM	0.4686	73.0687	12.2496	0.4686	59.3592	10.4573
52	EURUSD	0.5406	15.4429	1.1767	0.5104	15.7683	1.1818

15 lentelė. LSTM 8 neuronų modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu gauti AUC, MAPE ir RMSE įverčiai.

Eil. nr.	Duomenys	LSTM (8 neuronai) 5 žingsniai			LSTM (8 neuronai) 10 žingsniai		
		AUC	MAPE	RMSE	AUC	MAPE	RMSE
1	APALM	0.5502	47.3032	2.8360	0.5502	43.2377	2.6480
2	ARRSTPGH	0.6293	21.2150	147.8631	0.6034	19.2227	139.3489
3	BPFREMONT	0.4106	17.9784	237.0315	0.4601	18.6920	247.4352
4	PWATALM	0.5032	18.0989	104.5942	0.5040	18.3399	109.0317
5	RHLDN	0.4900	289.8214	59.0833	0.5000	299.9902	61.8598
6	TEMPCARY	0.5094	96.4180	106.9001	0.4886	97.6922	108.6835
7	TEMPLDN	0.4688	47.5278	25.3522	0.4672	48.2268	24.6387
8	TEMPSYD	0.4976	21.0026	81.8356	0.4784	19.9124	79.5287
9	USBIRTHS	0.5195	6.8032	34.6337	0.5430	7.2074	34.3457
10	WSLDN	0.5441	66.5419	2343.2775	0.5112	64.5101	2325.7533
11	WSNY	0.5272	18.5788	191.3631	0.5497	19.9444	199.6885
12	AAPL	0.5914	50.5010	10.0624	0.5513	53.0077	10.3710
13	ALK	0.5256	61.2670	16.9586	0.5150	56.6970	16.0317
14	BAC	0.5740	62.6686	11.8172	0.5752	62.1633	12.0918
15	BCS	0.4200	28.3626	6.8534	0.4200	26.9739	6.5680
16	BRK-B	0.5414	79.9097	11.8817	0.5414	84.2979	12.0184
17	BTC	0.4996	41.4764	20.0178	0.5230	42.9050	20.4037
18	C	0.5400	36.3557	7.7802	0.5343	36.0182	7.8695
19	CSCO	0.5593	75.3362	13.0334	0.5481	78.4491	13.2133
20	CVX	0.4768	36.1178	7.9403	0.4680	40.6440	8.3708
21	DJI	0.4800	119.7784	11.7790	0.4800	127.2948	12.0013
22	EURJPY	0.5586	32.5953	2.4147	0.5964	33.0485	2.4173
23	F	0.5617	56.3432	12.0676	0.5705	48.3786	10.9748
24	GE	0.5481	31.6345	10.3231	0.5192	37.0268	12.3567
25	GOLD	0.5040	24.3840	2.4674	0.4856	24.5626	2.7055
26	GOOG	0.5460	60.0398	12.1505	0.5460	59.2007	11.8914
27	GS	0.5450	58.8702	11.3078	0.5118	58.6135	10.9763
28	IBM	0.4873	88.2629	13.2094	0.5099	87.7983	13.2290
29	INTC	0.5224	53.8720	15.3628	0.4808	51.5909	15.1559
30	JNJ	0.4466	61.0890	9.5454	0.4466	60.5379	9.4169
31	JPM	0.5700	65.5962	11.0867	0.5700	65.2476	10.9998
32	KO	0.5148	44.6590	6.0582	0.5254	45.2058	6.1801
33	LUV	0.5677	43.3167	10.2064	0.5525	42.8301	10.0016
34	LYG	0.5535	24.5755	5.5578	0.5647	24.7690	5.8142
35	MCD	0.5131	64.5731	11.1795	0.5091	65.5927	11.6729
36	NIKKEI	0.4675	50.5086	7.8414	0.4927	58.4124	8.5809
37	NOK	0.5869	37.0606	12.7513	0.5606	35.7521	12.2589
38	ORCL	0.4641	90.4427	16.1062	0.4641	94.7455	16.5498
39	PFE	0.4986	90.5659	11.8899	0.5482	85.6008	11.5630
40	RYCEY	0.5414	24.6374	7.5301	0.5303	24.4170	7.9975
41	SNE	0.4960	37.5914	11.5783	0.4791	36.3305	11.2761
42	SP500	0.4958	122.1150	10.7324	0.5060	128.4590	10.8552
43	T	0.5657	37.9844	7.8881	0.5343	33.9818	7.1648
44	TM	0.5006	38.0332	7.9567	0.4198	64.0246	13.7032
45	TSCDY	0.4820	48.5297	9.0653	0.4730	45.5468	8.3069
46	USDCHF	0.4302	41.7308	2.3030	0.4302	42.7142	2.3172
47	VWAGY	0.4904	27.9555	8.2918	0.5108	29.0379	8.5886
48	WFC	0.5258	66.7899	12.5427	0.5502	64.7511	12.1055
49	WMT	0.5497	117.3456	25.4599	0.4375	135.6587	28.2529
50	WTI	0.4828	27.0424	7.6120	0.4828	28.5305	7.8823
51	XOM	0.4649	57.2668	10.1644	0.4649	59.1551	10.3487
52	EURUSD	0.5010	16.9150	1.2603	0.5108	15.6695	1.1692

16 lentelė. LSTM 8 neuronų modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu gauti AUC, MAPE ir RMSE įverčiai.

B. ARIMA metodų keletu žingsnių prognozių eksperimentų rezultatai

Eil. nr.	Duomenys	ARIMA (0,1,0) 2 žingsniai			ARIMA (0,1,0) 4 žingsniai		
		AUC	MAPE	RMSE	AUC	MAPE	RMSE
1	APALM	0.4845	4.1668	0.3211	0.4143	5.4623	0.3866
2	ARRSTPGH	0.4663	4.2173	37.6036	0.4334	6.0146	52.2990
3	BPFREMONTE	0.4207	3.8433	64.0433	0.4799	4.7217	81.8720
4	PWATALM	0.4832	4.2177	28.4532	0.5297	6.1649	37.9583
5	RHLDN	0.3800	12.6244	7.2882	0.3400	19.4253	10.4787
6	TE MPCARY	0.4330	5.9892	8.1742	0.3557	9.4242	11.9059
7	TE MPLDN	0.3582	6.9910	4.2397	0.3686	9.9199	5.9048
8	TE MP SYD	0.5224	4.1772	16.9074	0.4543	5.6108	21.4512
9	US BIRTHS	0.5081	3.6383	19.3437	0.4724	4.6443	24.3791
10	WSLDN	0.4744	11.5552	368.2253	0.4095	20.4933	576.5766
11	WSNY	0.5000	3.9195	56.3638	0.5136	5.7718	76.3789
12	AAPL	0.4279	6.6775	2.3890	0.4335	10.4605	3.1992
13	ALK	0.5214	7.2072	3.5539	0.5108	9.8776	4.5088
14	BAC	0.4696	5.2486	1.4884	0.4606	7.8847	2.0513
15	BCS	0.5100	3.5924	1.2690	0.5100	5.3915	1.8831
16	BRK-B	0.5202	6.1185	2.2139	0.5030	8.6088	2.7574
17	BTC	0.4775	5.7244	4.0362	0.4610	8.3741	5.3421
18	C	0.4778	4.4146	1.2875	0.4196	6.7979	1.8880
19	CSCO	0.5537	5.2176	1.6202	0.5433	7.6860	2.2317
20	CVX	0.4431	5.4994	1.6683	0.5024	7.3069	1.9876
21	DJI	0.5300	4.6201	0.8054	0.5000	6.0047	0.9710
22	EURJPY	0.3764	6.0401	0.6304	0.4332	8.8322	0.8074
23	F	0.5657	5.2590	1.9037	0.5689	6.5930	2.2618
24	GE	0.4623	5.2160	2.9055	0.4752	6.7447	3.1864
25	GOLD	0.4368	7.1939	1.1548	0.5148	8.1661	1.0976
26	GOOG	0.5354	4.9801	1.4909	0.6080	6.0601	1.6824
27	GS	0.5281	4.9823	1.2918	0.5221	7.0545	1.6604
28	IBM	0.4881	5.1057	1.1915	0.4860	7.8305	1.6168
29	INTC	0.4912	4.5653	2.3766	0.5737	7.7037	3.4371
30	JNJ	0.4852	4.1225	0.8814	0.4852	5.6209	1.1792
31	JPM	0.4700	5.3514	1.4916	0.4400	8.6662	2.2025
32	KO	0.4630	3.7837	0.6006	0.4830	5.2538	0.7813
33	LUV	0.4677	5.7858	3.1100	0.5061	8.1303	3.8197
34	LYG	0.4889	3.9918	1.0916	0.5222	5.9211	1.5702
35	MCD	0.4434	5.7177	1.7347	0.4525	8.4070	2.2884
36	NIKKEI	0.4440	4.9985	1.1934	0.4797	7.3652	1.4828
37	NOK	0.4546	5.0899	2.5161	0.4051	7.5155	3.2588
38	ORCL	0.4515	4.8289	2.3266	0.4515	7.8666	3.1422
39	PFE	0.5761	5.9021	1.2416	0.4675	9.2099	1.7656
40	RYCEY	0.4899	6.0735	2.9771	0.4152	9.4591	4.5304
41	SNE	0.5318	5.6599	2.9896	0.4875	6.8694	3.1847
42	SP500	0.4924	4.2781	0.8032	0.5120	5.7711	0.9110
43	T	0.4606	6.5741	2.7894	0.5020	10.4385	3.9271
44	TM	0.5276	4.2539	1.1687	0.4880	5.5186	1.4349
45	TS CDY	0.4862	5.3153	2.4168	0.5144	6.4218	2.3605
46	USDCHF	0.5333	4.8694	0.3808	0.5365	6.7065	0.4832
47	VWAGY	0.3817	4.2081	1.5945	0.4198	5.9233	2.0449
48	WFC	0.4277	4.7804	1.2327	0.4849	6.5643	1.6368
49	WMT	0.4207	6.2161	3.0945	0.4103	8.9796	4.4423
50	WTI	0.4475	3.9931	1.5790	0.3768	6.3674	2.1841
51	XOM	0.5649	3.6356	0.9123	0.5252	4.7277	1.1534
52	EURUSD	0.5346	3.7577	0.3303	0.5170	4.7954	0.4157

17 lentelė. ARIMA (0,1,0) modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu gauti AUC, MAPE ir RMSE įverčiai.

Eil. nr.	Duomenys	ARIMA (0,1,0) 5 žingsniai			ARIMA (0,1,0) 10 žingsniai		
		AUC	MAPE	RMSE	AUC	MAPE	RMSE
1	APALM	0.4229	6.3990	0.4503	0.3584	10.8202	0.7199
2	ARRSTPGH	0.5088	6.1107	53.6002	0.4827	8.7589	73.4259
3	BPFREMONT	0.4195	6.1603	102.9783	0.4767	10.6686	164.6879
4	PWATALM	0.4343	6.8893	40.7852	0.4712	7.8766	45.5941
5	RHLDN	0.3500	27.1884	11.8612	0.3000	56.8884	22.2285
6	TEMPCARY	0.4162	9.4817	12.3690	0.4288	14.4264	16.8693
7	TEMPLDN	0.3766	11.7326	6.6595	0.3478	22.1519	12.6437
8	TEMPSYD	0.4800	6.9929	26.2411	0.4808	9.5414	31.2738
9	USBIRTHS	0.5942	4.3064	21.9539	0.5430	5.1045	27.6766
10	WSLDN	0.3902	16.4697	638.5978	0.3750	57.0885	1273.6917
11	WSNY	0.4335	6.8851	106.5444	0.4768	8.2382	113.4048
12	AAPL	0.4103	12.8890	3.6393	0.4487	22.5940	5.1947
13	ALK	0.4410	10.9388	4.5829	0.4794	14.8356	6.5651
14	BAC	0.4312	8.4360	2.2930	0.4822	12.0330	3.0095
15	BCS	0.4500	6.8276	2.4162	0.5100	8.3946	2.7781
16	BRK-B	0.4606	11.0679	3.2166	0.4849	17.5634	4.4100
17	BTC	0.4843	9.2410	5.8221	0.4815	13.3201	7.6460
18	C	0.4867	6.5235	1.8316	0.4841	8.6880	2.2706
19	CSCO	0.4319	9.1930	2.3990	0.5577	10.3876	2.2150
20	CVX	0.5016	8.8978	2.1861	0.5409	11.2297	2.6976
21	DJI	0.5000	8.2483	1.1585	0.4800	9.1551	1.1680
22	EURJPY	0.4757	9.8098	0.9230	0.4781	15.4390	1.3302
23	F	0.5345	8.0575	2.7244	0.5128	11.5424	3.4148
24	GE	0.5465	8.4180	4.1822	0.5441	9.8695	4.3980
25	GOLD	0.4626	11.6039	1.5778	0.4622	18.1083	2.0305
26	GOOG	0.5362	6.6667	1.9379	0.4970	9.5171	2.4195
27	GS	0.6140	7.5848	1.8818	0.5879	8.3603	1.6995
28	IBM	0.4495	7.5905	1.6741	0.4819	13.6329	2.6153
29	INTC	0.5136	6.7783	3.1890	0.4904	9.2284	3.4359
30	JNJ	0.5316	6.4912	1.3670	0.4893	9.0060	1.8305
31	JPM	0.4500	9.2061	2.5154	0.4700	13.3137	3.0308
32	KO	0.5120	5.7751	0.8784	0.5418	7.4582	1.2300
33	LUV	0.5647	8.1722	3.8060	0.5647	9.4458	4.1094
34	LYG	0.4657	6.6139	1.9567	0.4737	8.1629	2.2622
35	MCD	0.4626	8.8250	2.5179	0.4808	13.2756	3.3794
36	NIKKEI	0.5146	7.8283	1.5613	0.4732	11.2643	1.9813
37	NOK	0.4283	7.8143	3.3239	0.4283	10.1591	4.1824
38	ORCL	0.4545	10.4320	3.7375	0.4049	19.7214	6.0931
39	PFE	0.5006	8.6555	1.6340	0.4793	13.2015	2.4593
40	RYCEY	0.3899	10.8635	4.9287	0.4172	17.1941	6.7572
41	SNE	0.5399	9.2244	4.2088	0.5403	11.9394	4.5451
42	SP500	0.4508	7.0141	0.9862	0.5582	7.5783	0.9921
43	T	0.4414	13.4770	4.3784	0.4455	13.8063	4.2293
44	TM	0.4096	7.0550	1.7029	0.4700	10.7903	2.4410
45	TSCDY	0.4842	7.9406	2.1534	0.4650	11.9054	4.1539
46	USDCHF	0.4934	7.5532	0.5238	0.4688	10.6516	0.7093
47	VWAGY	0.5012	7.1566	2.2903	0.4867	10.5184	3.2359
48	WFC	0.4473	9.3971	2.0596	0.4510	13.0024	2.9124
49	WMT	0.4567	11.7737	5.3914	0.4415	27.1003	8.9955
50	WTI	0.4303	7.2658	2.6004	0.4687	11.1978	3.8921
51	XOM	0.4802	4.9458	1.2560	0.4859	5.8191	1.2441
52	EURUSD	0.4872	5.5503	0.4725	0.4880	6.6637	0.5778

18 lentelė. ARIMA (0,1,0) modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu gauti AUC, MAPE ir RMSE įverčiai.

Eil. nr.	Duomenys	ARIMA (1,1,0) 2 žingsniai			ARIMA (1,1,0) 4 žingsniai		
		AUC	MAPE	RMSE	AUC	MAPE	RMSE
1	APALM	0.5481	4.1652	0.3246	0.4608	5.3965	0.3855
2	ARRSTPGH	0.5301	4.2927	38.0348	0.4689	6.1494	53.2712
3	BPFREMONT	0.4658	3.7747	62.7278	0.5326	4.5891	79.7432
4	PWATALM	0.4391	4.5996	29.3235	0.4736	6.1079	37.6611
5	RHLDN	0.4800	12.1273	6.9966	0.3800	17.9086	10.2271
6	TE MPCARY	0.4538	5.9500	8.1225	0.3864	9.4064	11.9028
7	TE MPLDN	0.5385	6.7814	4.0400	0.4800		5.7077
8	TE MP SYD	0.5801	4.2592	16.7070	0.5264	5.8531	21.7010
9	US BIRTHS	0.5698	3.4191	16.7287	0.5430	4.0302	19.8034
10	WSLDN	0.5833	11.1012	281.0349	0.4407	18.2428	444.8684
11	WSNY	0.5176	4.0649	58.1199	0.5080	5.8292	76.9733
12	AAPL	0.4247	6.7348	2.3839	0.4535	10.4820	3.1900
13	ALK	0.4590	7.3222	3.5724	0.4794	10.0664	4.5283
14	BAC	0.5210	5.1844	1.4813	0.4614	7.8580	2.0612
15	BCS	0.4800	3.6213	1.2726	0.4900	5.4270	1.8874
16	BRK-B	0.4798	6.0062	2.2043	0.4748	8.4056	2.7523
17	BTC	0.4980	5.7061	4.0305	0.4614	8.5048	5.3903
18	C	0.5394	4.3126	1.2806	0.4345	6.9234	1.9031
19	CSCO	0.5633	5.0771	1.6139	0.5232	7.6668	2.2392
20	CVX	0.4191	5.7687	1.7011	0.5513	7.4476	1.9779
21	DJI	0.5000	4.7258	0.8077	0.5000	6.0694	0.9831
22	EURJPY	0.3328	6.1686	0.6341	0.3954	8.8527	0.8083
23	F	0.5873	5.2612	1.9024	0.5785	6.6089	2.2640
24	GE	0.4287	5.3125	2.9964	0.4511	6.8577	3.2339
25	GOLD	0.4960	7.2098	1.1565	0.5344	8.2214	1.1042
26	GOOG	0.5002	5.1359	1.4972	0.5696	6.3044	1.6820
27	GS	0.5185	5.0209	1.3019	0.5173	7.1990	1.6853
28	IBM	0.4967	5.0976	1.1892	0.4980	7.7866	1.6115
29	INTC	0.4776	4.5883	2.3767	0.5409	7.6703	3.4373
30	JNJ	0.4906	4.1096	0.8784	0.4614	5.5885	1.1748
31	JPM	0.5300	5.2183	1.4650	0.4600	8.5907	2.1939
32	KO	0.4708	3.8363	0.6006	0.4912	5.2507	0.7794
33	LUV	0.4505	5.7931	3.1148	0.5242	8.1470	3.8204
34	LYG	0.4828	4.0115	1.0942	0.5313	5.9050	1.5697
35	MCD	0.4939	5.6405	1.7275	0.4778	8.2607	2.2827
36	NIKKEI	0.4619	5.2481	1.2222	0.5390	7.4510	1.4980
37	NOK	0.4647	5.0715	2.5167	0.4414	7.4914	3.2634
38	ORCL	0.4486	4.8253	2.3265	0.4339	7.8426	3.1388
39	PFE	0.4888	5.7831	1.2183	0.4900	8.8497	1.7224
40	RYCEY	0.4950	6.0316	2.8430	0.4131	9.0993	4.4337
41	SNE	0.4718	5.6850	2.9873	0.4336	6.8914	3.1828
42	SP500	0.5312	4.2386	0.8017	0.5206	5.7183	0.9012
43	T	0.4889	6.6993	2.7984	0.4737	10.4432	3.9306
44	TM	0.5500	4.3360	1.1616	0.4994	5.4840	1.4152
45	TSCDY	0.5540	5.1640	2.4408	0.5340	6.4543	2.3715
46	USDCHF	0.5021	4.8827	0.3809	0.5246	6.7152	0.4831
47	VWAGY	0.4608	4.4026	1.6418	0.4784	6.1373	2.1196
48	WFC	0.4944	4.8370	1.2441	0.4642	6.6460	1.6461
49	WMT	0.4880	6.2394	3.0937	0.4399	8.8264	4.4388
50	WTI	0.4828	3.9942	1.5834	0.4010	6.3870	2.1904
51	XOM	0.5358	3.9269	0.9520	0.4961	5.1787	1.2117
52	EURUSD	0.5574	3.7327	0.3291	0.5182	4.8344	0.4184

19 lentelė. ARIMA (1,1,0) modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu gauti AUC, MAPE ir RMSE įverčiai.

Eil. nr.	Duomenys	ARIMA (1,1,0) 5 žingsniai			ARIMA (1,1,0) 10 žingsniai		
		AUC	MAPE	RMSE	AUC	MAPE	RMSE
1	APALM	0.4490	6.3092	0.4493	0.3933	10.6448	0.7110
2	ARRSTPGH	0.5395	6.1100	53.5704	0.4757	8.7570	73.2851
3	BPFREMONT	0.4738	6.0405	101.5012	0.5093	10.4585	162.7297
4	PWATALM	0.5337	6.7498	39.3486	0.4607	7.9768	44.1922
5	RHLDN	0.4500	25.8433	11.3694	0.3300	55.2197	22.0193
6	TEMPCARY	0.4068	9.5072	12.3522	0.4194	14.4210	16.8655
7	TEMPLDN	0.4255	10.6388	6.1876	0.3982	21.7225	12.2824
8	TEMPSYD	0.5056	7.3172	26.4803	0.4639	9.6307	30.6762
9	USBIRTHS	0.5925	4.1505	20.8582	0.5998	4.6973	25.4720
10	WSLDN	0.4968	31.6298	708.9409	0.4447	61.8950	1206.0116
11	WSNY	0.4375	7.1669	106.9884	0.4591	8.8892	115.3080
12	AAPL	0.4191	12.7568	3.6139	0.4375	22.2978	5.1547
13	ALK	0.4402	10.8875	4.5154	0.4790	14.7750	6.5613
14	BAC	0.5010	8.3688	2.2901	0.4920	12.0346	3.0113
15	BCS	0.4400	6.8419	2.4168	0.5000	8.4015	2.7777
16	BRK-B	0.4748	10.8740	3.2203	0.4737	17.3495	4.4130
17	BTC	0.4891	9.3559	5.8530	0.4831	13.4842	7.7387
18	C	0.5016	6.4822	1.8165	0.4317	8.6197	2.2294
19	CSCO	0.4407	9.2173	2.4273	0.5849	10.4578	2.2528
20	CVX	0.4928	8.8454	2.2052	0.5329	11.3174	2.7145
21	DJI	0.4900	8.0779	1.1546	0.5100	8.9194	1.1567
22	EURJPY	0.4687	9.8937	0.9256	0.4605	15.5345	1.3354
23	F	0.4960	8.0876	2.7234	0.5032	11.5407	3.4172
24	GE	0.5008	8.8221	4.4319	0.5433	10.0287	4.4134
25	GOLD	0.4626	11.6226	1.5797	0.4724	18.1480	2.0359
26	GOOG	0.5178	6.8822	1.9781	0.5080	9.6125	2.4464
27	GS	0.5584	7.6720	1.8998	0.5666	8.3990	1.7061
28	IBM	0.4581	7.5155	1.6669	0.4819	13.5873	2.6105
29	INTC	0.5136	6.9097	3.1932	0.4808	9.4494	3.4423
30	JNJ	0.5283	6.4829	1.3653	0.4741	8.9769	1.8253
31	JPM	0.5100	9.2181	2.5184	0.4800	13.4293	3.0217
32	KO	0.5010	5.7992	0.8826	0.5214	7.4721	1.2304
33	LUV	0.5717	8.1641	3.7988	0.5737	9.4752	4.1152
34	LYG	0.4929	6.5840	1.9524	0.5010	8.1235	2.2541
35	MCD	0.4313	8.9406	2.5169	0.4515	13.3231	3.3872
36	NIKKEI	0.5520	7.6810	1.5435	0.4878	10.9294	1.9334
37	NOK	0.4354	7.8202	3.3273	0.4283	10.2006	4.1849
38	ORCL	0.4370	10.4298	3.7339	0.3962	19.7075	6.0841
39	PFE	0.4534	8.6400	1.5899	0.4298	12.7230	2.3721
40	RYCEY	0.3990	10.7280	4.8609	0.4394	16.7799	6.6089
41	SNE	0.5306	9.2148	4.2069	0.5217	11.9507	4.5434
42	SP500	0.5406	6.7691	0.9799	0.5790	7.2422	0.9808
43	T	0.4576	13.4987	4.3746	0.4636	13.8752	4.2385
44	TM	0.3908	7.3057	1.7187	0.4508	10.8375	2.4574
45	TSCDY	0.5026	7.9971	2.1736	0.4842	11.9670	4.1391
46	USDCHF	0.4709	7.5500	0.5239	0.4548	10.6707	0.7100
47	VWAGY	0.4955	7.3261	2.3386	0.4927	10.8660	3.3197
48	WFC	0.5130	9.2744	2.0612	0.4669	12.7988	2.9100
49	WMT	0.4960	11.6706	5.3906	0.4511	27.0702	9.0005
50	WTI	0.4212	7.2732	2.6070	0.4687	11.2264	3.8997
51	XOM	0.4764	5.2594	1.3273	0.4785	6.2218	1.3040
52	EURUSD	0.5088	5.5358	0.4717	0.5288	6.6812	0.5797

20 lentelė. ARIMA (1,1,0) modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumo reikšmes, eksperimentų metu gauti AUC, MAPE ir RMSE įverčiai.

C. LSTM metodų eksperimentų rezultatai remiantis tiesioginėmis signalo reikšmėmis

Eil. nr.	Duomenys	LSTM 4 neuronų	LSTM 8 neuronų
		AUC	AUC
1	APALM	0.5563	0.5736
2	ARRSTPGH	0.5514	0.5496
3	BPFREMONT	0.5077	0.5000
4	PWATALM	0.5433	0.5401
5	RHLDN	0.6600	0.6100
6	TE MPCARY	0.5000	0.5602
7	TEMPLDN	0.4463	0.5000
8	TEMPSYD	0.5176	0.4960
9	USBIRTHS	0.6412	0.6778
10	WSLDN	0.5761	0.5841
11	WSNY	0.5032	0.5457
12	AAPL	0.5000	0.5000
13	ALK	0.5000	0.5000
14	BAC	0.5000	0.5000
15	BCS	0.3700	0.4100
16	BRK-B	0.6576	0.5000
17	BTC	0.5000	0.5000
18	C	0.5649	0.5767
19	CSCO	0.5673	0.5569
20	CVX	0.4768	0.5513
21	DJI	0.5000	0.5000
22	EURJPY	0.5000	0.5000
23	F	0.4768	0.5000
24	GE	0.5000	0.5000
25	GOLD	0.5210	0.5312
26	GOOG	0.5456	0.5534
27	GS	0.5000	0.5129
28	IBM	0.4934	0.4967
29	INTC	0.5313	0.5409
30	JNJ	0.4766	0.4146
31	JPM	0.4900	0.4700
32	KO	0.5410	0.5610
33	LUV	0.4556	0.4182
34	LYG	0.5647	0.4838
35	MCD	0.4950	0.5596
36	NIKKEI	0.5552	0.5325
37	NOK	0.4384	0.4394
38	ORCL	0.4117	0.4437
39	PFE	0.5078	0.5078
40	RYCEY	0.4475	0.5525
41	SNE	0.4980	0.5040
42	SP500	0.5098	0.4996
43	T	0.5000	0.5253
44	TM	0.5220	0.4950
45	TSCDY	0.5000	0.5000
46	USDCHF	0.5000	0.5000
47	VWAGY	0.5000	0.4610
48	WFC	0.5000	0.4651
49	WMT	0.6514	0.6026
50	WTI	0.5000	0.5000
51	XOM	0.4374	0.5136
52	EURUSD	0.5126	0.5024

21 lentelė. LSTM modelių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines tiesiogines signalų reikšmes, eksperimentų metu gauti AUC įverčiai.

D. Ilgalaikės kintamumo krypties prognozavimo eksperimentų rezultatai

Eil. nr.	Duomenys	Faktinės reikšmės	LSTM 4 neuronų prognozė	LSTM 8 neuronų prognozė
1	APALM	1	1	1
2	ARRSTPGH	0	0	0
3	BPFREMONT	0	0	0
4	PWATALM	1	1	1
5	RHLDN	0	0	0
6	TE MPCARY	0	1	0
7	TE MPLDN	0	0	0
8	TE MP SYD	1	1	1
9	USBIRTHS	1	0	0
10	WSLDN	0	0	0
11	WSNY	1	0	0
12	AAPL	1	0	0
13	ALK	1	0	0
14	BAC	0	0	1
15	BCS	0	1	1
16	BRK-B	0	0	0
17	BTC	0	1	1
18	C	0	0	0
19	CSCO	0	0	0
20	CVX	0	1	1
21	DJI	0	0	0
22	EURJPY	0	0	0
23	F	1	0	0
24	GE	0	1	1
25	GOLD	1	1	1
26	GOOG	0	0	1
27	GS	1	1	1
28	IBM	1	1	1
29	INTC	1	1	1
30	JNJ	0	0	0
31	JPM	0	1	0
32	KO	0	0	0
33	LUV	0	1	1
34	LYG	1	1	0
35	MCD	0	0	0
36	NIKKEI	1	1	1
37	NOK	1	0	0
38	ORCL	0	0	0
39	PFE	1	1	1
40	RYCEY	1	1	1
41	SNE	0	0	0
42	SP500	0	0	0
43	T	0	1	1
44	TM	0	1	1
45	TSCDY	1	1	1
46	USDCHF	1	1	1
47	VWAGY	1	0	1
48	WFC	0	0	0
49	WMT	1	0	1
50	WTI	0	1	0
51	XOM	0	0	0
52	EURUSD	1	0	0
AUC (kvazi-period.)			0.7167	0.8000
AUC (finans.)			0.6066	0.6360

22 lentelė. LSTM modelių paskutinio 100 kintamumo reikšmių krypties prognozių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines kintamumų reikšmes, eksperimentų metu gauti rezultatai.

Eil. nr.	Duomenys	Faktinės reikšmės	LSTM 4 neuronų prognozė	LSTM 8 neuronų prognozė
1	APALM	1	1	1
2	ARRSTPGH	0	1	0
3	BPFREMONT	0	0	1
4	PWATALM	1	0	1
5	RHLDN	0	1	1
6	TE MPCARY	0	1	1
7	TEMPLDN	0	1	0
8	TEMPSYD	1	0	1
9	USBIRTHS	1	0	0
10	WSLDN	0	0	0
11	WSNY	1	0	1
12	AAPL	1	1	1
13	ALK	1	0	0
14	BAC	0	1	1
15	BCS	0	1	1
16	BRK-B	0	0	1
17	BTC	0	0	1
18	C	0	1	1
19	CSCO	0	1	1
20	CVX	0	1	1
21	DJI	0	1	1
22	EURJPY	0	0	0
23	F	1	0	0
24	GE	0	1	1
25	GOLD	1	1	1
26	GOOG	0	1	1
27	GS	1	1	1
28	IBM	1	0	0
29	INTC	1	1	1
30	JNJ	0	1	1
31	JPM	0	1	1
32	KO	0	0	0
33	LUV	0	0	1
34	LYG	1	0	0
35	MCD	0	1	1
36	NIKKEI	1	1	1
37	NOK	1	0	0
38	ORCL	0	1	1
39	PFE	1	1	1
40	RYCEY	1	1	1
41	SNE	0	1	1
42	SP500	0	1	1
43	T	0	1	1
44	TM	0	1	1
45	TSCDY	1	1	1
46	USDCHF	1	1	1
47	VWAGY	1	1	1
48	WFC	0	0	0
49	WMT	1	1	1
50	WTI	0	1	1
51	XOM	0	0	0
52	EURUSD	1	0	0
AUC (kvazi-period.)			0.2667	0.6500
AUC (finans.)			0.4694	0.4069

23 lentelė. LSTM modelių paskutinio 100 kintamumo reikšmių krypties prognozių, kai modeliai buvo apmokyti pasitelkus prieš tai buvusias faktines tiesiogines signalų reikšmes, eksperimentų metu gauti rezultatai.

Eil. nr.	Duomenys	Faktinės reikšmės	LSTM 4 neur. prognozės apmokant su Hursto skponente, apskaičiuota				
			iš 120 reikšmių	iš 150 reikšmių	iš 200 reikšmių	iš 250 reikšmių	iš 300 reikšmių
1	APALM	1	1	1	1	0	0
2	ARRSTPGH	0	0	0	0	0	1
3	BPFREMONT	0	1	1	1	1	0
4	PWATALM	1	1	1	1	1	0
5	RHLDN	0	1	1	0	0	1
6	TE MPCARY	0	0	0	0	0	0
7	TE MPLDN	0	1	0	0	1	1
8	TE MP SYD	1	0	1	0	1	1
9	USBIRTHS	1	0	1	0	0	0
10	WSLDN	0	1	0	0	1	0
11	WSNY	1	0	1	1	0	1
12	AAPL	1	1	0	1	1	1
13	ALK	1	0	0	0	0	0
14	BAC	0	1	0	0	0	1
15	BCS	0	0	0	1	0	0
16	BRK-B	0	0	0	0	0	0
17	BTC	0	1	0	0	1	0
18	C	0	1	0	0	0	1
19	CSCO	0	1	0	0	0	1
20	CVX	0	1	1	1	1	1
21	DJI	0	0	0	0	0	0
22	EURJPY	0	0	0	0	0	0
23	F	1	1	0	1	1	1
24	GE	0	1	1	1	1	1
25	GOLD	1	0	0	1	0	1
26	GOOG	0	1	0	0	1	0
27	GS	1	0	0	1	1	0
28	IBM	1	1	1	1	0	0
29	INTC	1	1	1	1	0	1
30	JNJ	0	0	1	1	0	1
31	JPM	0	1	0	1	1	1
32	KO	0	0	0	1	1	1
33	LUV	0	0	1	0	1	0
34	LYG	1	0	0	0	1	0
35	MCD	0	0	0	1	1	0
36	NIKKEI	1	1	0	1	1	0
37	NOK	1	1	0	0	0	0
38	ORCL	0	0	0	0	0	1
39	PFE	1	1	1	1	1	1
40	RYCEY	1	0	0	1	1	1
41	SNE	0	1	1	1	1	0
42	SP500	0	0	0	1	1	0
43	T	0	0	0	1	1	0
44	TM	0	0	0	0	1	1
45	TSCDY	1	1	1	1	1	0
46	USDCHF	1	1	1	1	0	0
47	VWAGY	1	1	0	1	1	0
48	WFC	0	1	0	0	0	0
49	WMT	1	1	0	0	1	1
50	WTI	0	0	1	0	1	1
51	XOM	0	0	0	0	1	1
52	EURUSD	1	0	0	0	0	0
AUC (kvazi-period.)			0.3667	0.8333	0.7167	0.4500	0.4500
AUC (finans.)			0.6152	0.5221	0.6446	0.5025	0.4559

24 lentelė. LSTM 4 neuronų modelių paskutinio 100 kintamumo reikšmių krypties prognozių, kai modeliai buvo apmokomi su apskaičiuotomis Hursto eksponentėmis ir po jų einančiomis 100 kintamumo reikšmių judėjimo kryptimis, eksperimentų metu gauti rezultatai.

Eil. nr.	Duomenys	Faktinės reikšmės	LSTM 8 neur. prognozės apmokant su Hursto skponente, apskaičiuota				
			iš 120 reikšmių	iš 150 reikšmių	iš 200 reikšmių	iš 250 reikšmių	iš 300 reikšmių
1	APALM	1	1	0	0	0	0
2	ARRSTPGH	0	0	0	0	0	0
3	BPFREMONT	0	0	0	1	1	0
4	PWATALM	1	1	1	1	0	1
5	RHLDN	0	1	1	0	1	1
6	TE MPCARY	0	0	0	0	0	0
7	TEMPLDN	0	0	1	1	1	1
8	TEMPSYD	1	0	1	0	1	1
9	USBIRTHS	1	0	1	0	1	1
10	WSLDN	0	1	0	0	1	0
11	WSNY	1	0	1	0	0	1
12	AAPL	1	1	0	1	1	1
13	ALK	1	0	0	0	0	0
14	BAC	0	0	0	0	0	0
15	BCS	0	0	0	1	0	1
16	BRK-B	0	0	0	0	0	0
17	BTC	0	1	1	0	1	1
18	C	0	1	0	0	0	1
19	CSCO	0	1	0	0	1	1
20	CVX	0	0	1	1	1	1
21	DJI	0	0	1	0	0	0
22	EURJPY	0	0	0	0	0	1
23	F	1	1	1	1	1	1
24	GE	0	1	1	1	1	1
25	GOLD	1	0	0	1	0	1
26	GOOG	0	1	1	0	1	0
27	GS	1	0	1	1	0	0
28	IBM	1	1	1	1	0	0
29	INTC	1	1	1	1	0	1
30	JNJ	0	1	1	1	0	1
31	JPM	0	1	0	1	1	1
32	KO	0	1	0	1	1	1
33	LUV	0	0	0	0	1	1
34	LYG	1	0	0	0	0	0
35	MCD	0	0	0	1	1	1
36	NIKKEI	1	0	0	1	1	0
37	NOK	1	1	1	0	0	0
38	ORCL	0	0	0	1	1	1
39	PFE	1	1	1	1	1	1
40	RYCEY	1	0	0	1	1	1
41	SNE	0	1	1	1	1	0
42	SP500	0	0	0	1	1	0
43	T	0	0	0	1	1	0
44	TM	0	1	0	0	1	1
45	TSCDY	1	0	1	1	1	0
46	USDCHF	1	0	1	0	1	1
47	VWAGY	1	1	0	1	0	0
48	WFC	0	1	0	0	0	1
49	WMT	1	1	1	0	0	1
50	WTI	0	0	1	0	1	1
51	XOM	0	1	0	1	0	1
52	EURUSD	1	0	0	0	0	0
AUC (kvazi-period.)			0.5333	0.7333	0.4333	0.3667	0.7333
AUC (finans.)			0.4853	0.5980	0.5735	0.3934	0.3811

25 lentelė. LSTM 4 neuronų modelių paskutinio 100 kintamumo reikšmių krypties prognozių, kai modeliai buvo apmokomi su apskaičiuotomis Hursto eksponentėmis ir po jų einančiomis 100 kintamumo reikšmių judėjimo kryptimis, eksperimentų metu gauti rezultatai.