



VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

VERSLO VADYBOS FAKULTETAS

FINANSŲ INŽINERIJOS KATEDRA

Kristina Miškinytė

**INVESTAVIMO SKAITMENINIŲ VALIUTŲ RINKOJE NAUDOJANT
GILIOJO MOKYMOSI ALGORITMUS TYRIMAS**

**INVESTIGATION OF INVESTMENT IN DIGITAL CURRENCY
MARKET BY USING DEEP LEARNING ALGORITHMS**

Baigiamasis magistro darbas

Finansų inžinerija studijų programa, valstybinis kodas 6211LX060

Finansinių technologijų (FinTech) specializacija

Finansų studijų kryptis

Vilnius, 2021

VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

VERSLO VADYBOS FAKULTETAS

FINANSŲ INŽINERIJOS KATEDRA

TVIRTINU
Katedros vedėjas

(Parašas)

doc. dr. Algita Miečinskienė

(Vardas, pavardė)

2021-01-04

(Data)

Kristina Miškinytė

**INVESTAVIMO SKAITMENINIŲ VALIUTŲ RINKOJE NAUDOJANT
GILIOJO MOKYMOŠI ALGORITMUS TYRIMAS**

**INVESTIGATION OF INVESTMENT IN DIGITAL CURRENCY
MARKET BY USING DEEP LEARNING ALGORITHMS**

Baigiamasis magistro darbas

Finansų inžinerija studijų programa, valstybinis kodas 6211LX060

Finansinių technologijų (FinTech) specializacija

Finansų studijų kryptis

Vadovas

dr. Algita Miečinskienė 2020-12-29
(Moksl. laipsnis/pedag. vardas, vardas, pavardė) (Parašas) (Data)

Konsultantas

(Moksl. laipsnis/pedag. vardas, vardas, pavardė) (Parašas) (Data)

Konsultantas

(Moksl. laipsnis/pedag. vardas, vardas, pavardė) (Parašas) (Data)

Lietuvių kalbos konsultantas doc. dr. Rasuolė Vladarskienė

(Moksl. laipsnis/pedag. vardas, vardas, pavardė)

(Parašas)

(Data)

Vilnius, 2021

VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS
VERSLO VADYBOS FAKULTETAS
FINANSŲ INŽINERIJOS KATEDRA

Finansų studijų kryptis

Finansų inžinerijos studijų programa, valstybinis kodas 6211LX060

Finansinių technologijų (FinTech) specializacija

TVIRTINU
Katedros vedėjas

(Parašas)

doc. dr. Algita Miečinskienė

(Vardas, pavardė)

(Data)

**BAIGIAMOJO MAGISTRO DARBO
UŽDUOTIS**

2019-11-04 Nr.

Vilnius

Studentui (ei) Kristina Miškinytė.....
(Vardas, pavardė)

Baigiamojo darbo tema: investavimo skaitmeninių valiutų rinkoje naudojant giliojo mokymosi algoritmus tyrimas

patvirtinta 2019 m. spalio 31..... d. dekanų potvarkiu Nr. 243vv....

Baigiamojo darbo užbaigimo terminas 2021 m. sausio 4 d.

BAIGIAMOJO DARBO UŽDUOTIS:

1. Apžvelgti teorinius skaitmeninių valiutų aspektus, investavimo skaitmeninių valiutų rinkoje galimybes ir sprendimų paramos sistemų taikymą;
2. Išanalizuoti mokslinius tyrimus susijusius su skaitmeninių valiutų vertinimo ir prognozavimo metodais;
3. Atlikti skaitmeninių valiutų vertinimo tyrimą;
4. Atlikti skaitmeninių valiutų vertės prognozavimo tyrimą;
5. Įvertinti siūlomą investavimo sprendimų paramos sistemą;

Baigiamojo darbo rengimo konsultantai:

.....
(Moksl. laipsnis/pedag. vardas, vardas, pavardė)

Vadovas

.....
(Paraša)

dr. Nijolė Maknickienė
(Moksl. laipsnis/pedag. vardas, vardas, pavardė)

Užduotį gavau

.....
(Parašas)

Kristina Miškinytė

(Vardas, pavardė)

2019 m. lapkričio 4 d.
(Data)

Vilniaus Gedimino technikos universitetas
Verslo vadybos fakultetas
Finansų inžinerijos katedra

ISBN ISSN
Egz. sk.
Data

Antrosios pakopos studijų **Finansų inžinerijos** programos magistro baigiamasis darbas

Pavadinimas **Investavimo skaitmeninių valiutų rinkoje naudojant giliojo mokymosi algoritmus tyrimas**

Autorius **Kristina Miškinytė**

Vadovas **Nijolė Maknickienė**



Kalba: lietuvių

Anotacija

Baigiamajame magistro darbe nagrinėjama sprendimo priėmimo, investuojant skaitmeninių valiutų rinkoje, problema. Darbo tikslas – pasiūlyti investavimo skaitmeninių valiutų rinkoje paramos sistemą, pritaikant giliojo mokymosi algoritmą. Pirmoje dalyje analizuojamas skaitmeninių valiutų apibrėžimas, rinkos raidos aspektai, mokslinė literatūra, susijusi su skaitmeninių valiutų vertinimu, prognozavimu ir investavimo sprendimų priėmimu. Metodinėje tyrimo dalyje pateikiama tyrimo struktūra, TOPSIS metodo ir LSTM algoritmo žingsniai ir pagrindinės formulės ir skaitinės charakteristikos reikalingos sudaryti ir įvertinti investicijų portfelį. Praktinėje dalyje atliekamas daugiakriteris skaitmeninių valiutų vertinimas, istorinių duomenų prognozavimas, sudaromi vienodų svorių portfeliai, įvertinami taikomi metodai, kuriais remiantis sudaromas investavimo paramos sistemos modelis. Gauti rezultatai apibendrinami, pateikiamos išvados ir pasiūlymai.

Darbą sudaro: įvadas, trys pagrindinės darbo dalys: skaitmeninių valiutų, kaip investavimo objekto teorinė analizė, investavimo skaitmeninių valiutų rinkoje tyrimo metodika ir skaitmeninių valiutų vertės nustatymo ir kainų prognozavimo tyrimas, išvados ir siūlymai, literatūros sąrašas.

Darbo apimtis – 66 p. teksto be priedų, 14 iliustr., 10 lent., 79 bibliografiniai šaltiniai.

Atskirai pridedami darbo priedai.

Prasminiai žodžiai: sprendimų paramos sistema, dirbtinis intelektas, gilusis mokymasis, LSTM, prognozavimas, skaitmeninės valiutos, TOPSIS, daugiakriteris metodas, vienodų svorių portfelis, graža, rizika, Šarpo rodiklis, koreliacija.

Vilnius Gediminas Technical University
Faculty of Business Management
Department of Financial Engineering

ISBN ISSN
Copies No.
Date

Master Degree Studies **Financial Engineering** study programme Master Graduation Thesis

Title **Investigation of Investment in Digital Currency Market by Using Deep Learning Algorithms**

Author **Kristina Miškinytė**

Academic supervisor **Nijolė Maknickienė**

atlikt

Thesis language: Lithuanian

Annotation

The main problem analysed in the master's thesis is improvement of investment decision process in the digital currency market. The aim of the work is to suggest decision support system for investing in digital currency market which would be based on deep learning algorithm. In the first part of the work analysis the definition of digital currency, market development aspects, scientific literature related to digital currency valuation, forecasting and investment decision making. Methodological part of the research presents the structure of the research, main steps of TOPSIS method and LSTM algorithm and the main formulas to form and evaluate investment portfolio. In the practical part the multi-criteria valuation method is used to rank digital currencies. Secondly forecasting of historical prices with LSTM algorithm is performed and equal weight portfolios computed. Lastly evaluation of proposed methods for the decision support system is presented. Obtained results are summarized, conclusions and suggestions are presented.

Structure: introduction, three main parts of the work: theoretical analysis of digital currencies as an investment object, research methodology of investment in the digital currency market and the research of digital currency valuation and price forecasting, conclusions and suggestions, references.

Thesis consist of: 66 p. text without appendixes, 14 pictures, 10 tables, 79 bibliographical entries.
Appendixes included.

Keywords: decision support system, artificial intelligence, deep learning, LSTM, forecasting, digital currencies, TOPSIS, multicriteria decision method, equal weight portfolio, return, risk, Sharpe ratio, correlation.

(Baigiamojo darbo sąžiningumo deklaracijos forma)

VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

Kristina Miškinytė, 20153107

(Studento vardas ir pavardė, studento pažymėjimo Nr.)

Verslo vadybos fakultetas

(Fakultetas)

Finansų inžinerija, FTfm-19

(Studijų programa, akademinė grupė)

BAIGIAMOJO DARBO (PROJEKTO)


SĄŽININGUMO DEKLARACIJA

2021 m. sausio 04 d.

Patvirtinu, kad mano baigiamasis darbas tema „Investavimo skaitmeninių valiutų rinkoje naudojant giliojo mokymosi algoritmus tyrimas“ patvirtintas 2019 m. spalio 31 d. dekanų potvarkiu Nr. 243vv, yra savarankiškai parašytas. Šiame darbe pateikta medžiaga nėra plagijuota. Tiesiogiai ar netiesiogiai panaudotos kitų šaltinių citatos pažymėtos literatūros nuorodose.

Mano darbo vadovas docentas daktaras Nijolė Maknickienė.

Kitų asmenų indėlio į parengtą baigiamąjį darbą nėra. Jokių įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs (-usi).


(Parašas)

Kristina Miškinytė
(Vardas ir pavardė)

SUTIKIMAS DĖL ASMENS DUOMENŲ NAUDOJIMO

2021-01-04

(Data)

Šiuo sutikimu aš, Kristina Miškinytė (toliau – Duomenų subjektas) sutinku, kad Vilniaus Gedimino technikos universitetas, juridinio asmens kodas 111950243, adresas Saulėtekio al. 11, LT-10223 Vilnius (toliau – Duomenų valdytojas), tvarkytų mano asmens duomenis kitų studentų mokymosi tikslu. T. y. tvarkytų (*pažymėkite tinkamą*):

- ☐ vardą, pavardę, bakalauro baigiamąjį darbą;
- ☐ bakalauro baigiamąjį darbą, nenurodant vardo, pavardės;
- ☐ vardą, pavardę, magistro baigiamąjį darbą;
- ☒ magistro baigiamąjį darbą nenurodant vardo, pavardės.

Šiuo tikslu tvarkomų asmens duomenų Duomenų valdytojas neperduos jokiems tretiesiems asmenims, studentams su baigiamaisiais darbais bus leidžiama susipažinti vidinėje informacinėje sistemoje. Duomenų subjekto asmens duomenys šiuo tikslu bus naudojami ne ilgiau nei 5 metai.

Šiuo sutikimu Duomenų subjektas patvirtina, kad yra supažindintas su šiomis teisėmis:

- Susipažinti su savo duomenimis ir kaip jie yra tvarkomi (teisė susipažinti);
- Reikalauti ištaisyti arba, atsižvelgiant į asmens duomenų tvarkymo tikslus papildyti asmens neišsamius asmens duomenis (teisė ištaisyti);
- Savo duomenis sunaikinti arba sustabdyti savo duomenų tvarkymo veiksmus (išskyrus saugojimą) (teisė sunaikinti ir teisė „būti pamirštam“);
- Reikalauti, kad asmens duomenų valdytojas apribotų asmens duomenų tvarkymą (teisė apriboti);
- Teisė į duomenų perkėlimą (teisė perkelti);
- Nesutikti, kad būtų tvarkomi asmens duomenys, kai šie duomenys tvarkomi ar ketinami tvarkyti kitais tikslais;
- Pateikti skundą Valstybinei duomenų apsaugos inspekcijai;

Duomenų subjektas turi teisę bet kuriuo metu atšaukti savo sutikimą.

Kristina Miškinytė _____

[Duomenų subjekto vardas, pavardė, parašas]

Duomenų valdytojo rekvizitai:

Vilniaus Gedimino technikos universitetas

Juridinio asmens kodas: 111950243

Adresas: Saulėtekio al. 11, LT-10223 Vilnius

Tel. (8 5) 274 5030

Faks. (8 5) 270 0112

El. paštas: vgtu@vgtu.lt

PVM mokėtojo kodas: LT119502413

Duomenų apsaugos pareigūno tel. (8 5) 251 2191, el. paštas: dap@vgtu.lt

TURINYS

IVADAS.....	12
1. SKAITMENINIŲ VALIUTŲ, KAIP INVESTAVIMO OBJEKTO, TEORINĖ ANALIZĖ.....	15
1.1. Skaitmeninės valiutos ir skaitmeninių valiutų rinkos teoriniai aspektai	16
1.2. Skaitmeninių valiutų rinkos tendencijų apžvalga.....	19
1.3. Skaitmeninių valiutų vertinimas ir prognozavimas.....	22
1.4. Investavimas skaitmeninių valiutų rinkoje.....	26
1.5. Investavimo sprendimo priėmimo modelis.....	29
2. INVESTAVIMO SKAITMENINIŲ VALIUTŲ RINKOJE TYRIMO METODIKA	32
2.1. Kuriamasis mokslas.....	32
2.2. Skaitmeninių valiutų vertės nustatymas	33
2.3. Kainų prognozavimas naudojant giliojo mokymosi algoritmą metodika	36
2.4. Investavimo skaitmeninių valiutų rinkoje vertinimas.....	41
3. SKAITMENINIŲ VALIUTŲ VERTĖS NUSTATYMO IR KAINŲ PROGNOZAVIMO TYRIMAS.....	45
3.1. TOPSIS metodas.....	45
3.2. Giliojo mokymosi algoritmo taikymo skaitmeninių valiutų kainų prognozavimui tyrimas.....	49
3.3. Portfelio sudarymas.....	55
IŠVADOS	60
PASIŪLYMAI	62
LITERATŪROS SĄRAŠAS.....	63

PAVEIKSLŲ SĄRAŠAS

1 pav. Bendra skaitmeninių valiutų rinkos kapitalizacija (JAV doleriais) 2017–2020 m.....	19
2 pav. Skaitmeninių valiutų rinkos kapitalizacijos paskirstymas 2014–2020 m. kapitalizacija 2014–2020 m.	20
3 pav. Skaitmeninių valiutų ir S&P 500 indekso kainos (JAV doleriai).....	22
4 pav. Neuronų tinklo veiklos struktūra	36
5 pav. Sigmoido funkcija.....	37
6 pav. Duomenų kiekio įtaka dirbtinio intelekto metodų rezultatų tikslumui	38
7 pav. Ilgalaiškės trumpalaikės atminties neuronų tinklo struktūra.....	39
8 pav. BTC skaitmeninė valiutos LSTM algoritmo prognozės 2017-08-01 – 2020-07-31 mokymosi laikotarpiui.....	52
9 pav. LTC skaitmeninės valiutos LSTM algoritmo prognozės 2020-04-01 – 2020-07-31 mokymosi laikotarpiui.....	53
10 pav. LTC skaitmeninės valiutos LSTM algoritmo prognozės 2017-08-01 – 2020-07-31 mokymosi laikotarpiui.....	53
11 pav. XRP skaitmeninės valiutos LSTM algoritmo prognozės 2017-08-01 – 2020-07-31 mokymosi laikotarpiui.....	54
12 pav. Prognozių nuokrypių sklaida XRP skaitmeninei valiutai 2017-08-01 – 2020-07-31 mokymosi laikotarpiui.....	54
13 pav. Gražos ir rizikos.....	57
14 pav. Skaitmeninių valiutų gražų koreliacijos stiprumas.....	58

LENTELIŲ SĄRAŠAS

1 lentelė. Skaitmeninių valiutų rinkos kapitalizacijos procentinis pokytis (RKP) rugsėjo 1 d. 2013–2019 m. periodu,.....	21
2 lentelė. Sprendimų matrica	46
3 lentelė. TOPSIS normalizuota sprendimų matrica	47
4 lentelė. TOPSIS alternatyvų modeliai	47
5 lentelė. TOPSIS alternatyvų atstumai.....	48
6 lentelė. Prognozuojamo laikotarpio reikšmių RMSE	50
7 lentelė. Vidutinė kaina (USD) prognozuojamam periodui	50
8 lentelė. RMSE ir skaitmeninės valiutos vidutinės kainos prognozuojamo periodo laikotarpiui santykis	51
9 lentelė. Prognozuojamo laikotarpio reikšmių MAPE.....	51
11 lentelė. Gražos, rizikos, Šarpo rodikliai	56
10 lentelė. Mėnesinių gražų koreliacijos koeficientai 2017–2020 m.	57

PRIEDŲ SĄRAŠAS

1 PRIEDAS. LSTM giliojo mokymosi algoritmas.....	70
2 PRIEDAS. BCH skaitmeninės valiutos LSTM algoritmo prognozės 2017-08-01 – 2020-07-31 mokymosi laikotarpiui.....	72
3 PRIEDAS. BNB skaitmeninės valiutos LSTM algoritmo prognozės 2017-08-01 – 2020-07-31 mokymosi laikotarpiui.....	72
4 PRIEDAS. XRP skaitmeninės valiutos LSTM algoritmo prognozės 2019-08-01 – 2020-07-31 mokymosi laikotarpiui.....	72
5 PRIEDAS. BTC skaitmeninės valiutos LSTM algoritmo prognozės 2019-08-01 – 2020-07-31 mokymosi laikotarpiui.....	73
6 PRIEDAS. BCH skaitmeninės valiutos LSTM algoritmo prognozės 2019-08-01 – 2020-07-31 mokymosi laikotarpiui.....	73
7 PRIEDAS. BNB skaitmeninės valiutos LSTM algoritmo prognozės 2019-08-01 – 2020-07-31 mokymosi laikotarpiui.....	73
8 PRIEDAS. LTC skaitmeninės valiutos LSTM algoritmo prognozės 2019-08-01 – 2020-07-31 mokymosi laikotarpiui.....	74
9 PRIEDAS. BTC skaitmeninės valiutos LSTM algoritmo prognozės 2020-04-01 – 2020-07-31 mokymosi laikotarpiui.....	74
10 Priedas. BNB skaitmeninės valiutos LSTM algoritmo prognozės 2020-04-01 – 2020-07-31 mokymosi laikotarpiui.....	74
11 PRIEDAS. XRP skaitmeninės valiutos LSTM algoritmo prognozės 2020-04-01 – 2020-07-31 mokymosi laikotarpiui.....	75
12 PRIEDAS. BCH skaitmeninės valiutos LSTM algoritmo prognozės 2020-04-01 – 2020-07-31 mokymosi laikotarpiui.....	75
13 PRIEDAS. Portfelio sudarymas „RStudio“ programoje	75
14 PRIEDAS. Maknickienė ir Miškinytės (2020) straipsnis „Skaitmeninių valiutų kainų prognozavimas naudojant giliojo mokymosi algoritmą“	79

IVADAS

Skaitmeninės valiutos nėra naujiena tiek finansų rinkai, tiek jos dalyviams. Skaitmeninimui įgaunant vis didesnę pagreitį, vis labiau yra domimasi investavimo galimybėmis skaitmeninių valiutų rinkoje. Vertės išlaikymas ir padidėjimas globalios pandemijos periodu parodė, kad investuotojai ieškodami saugios investavimo alternatyvos vis labiau linksta rinktis skaitmenines valiutas. Kadangi skaitmeninių valiutų rinka vis dar yra besivystanti ir kelia didelį neapibrėžtumą, investavimo galimybės lydi įvairios rizikos, tokios kaip iki galo neužtikrintas likvidumas, didelis vertės svyravimas, kainų manipuliavimas, kibernetinio saugumo, o kartu ir investicinio turto pažeidžiamumas (Angerer, Hoffmann, Neitzert ir Kraus, 2020; Wei, 2018). Nepaisant to yra pastebimas rinkos efektyvumo augimas ko pasekoje rinka tampa tvirtesnė, stabilesnė ir saugesnė renkantis skaitmenines valiutas, kaip investavimo alternatyvą (Kristoufek ir Vosvrda, 2019; Tran ir Leirvik, 2020). Didelis informacijos kiekis, lengvas jos pasiekiamumas sudaro itin sunkias sąlygas investuotojams greitai ir efektyviai atsirinkti ir vertinti teisingą informaciją ir atitinkamai į ją reaguoti. Investavimo rizikai mažinti vis dažniau pasitelkiamas dirbtinis intelektas, kuris automatizuoja ne tik fizinį, bet ir protinį darbą, šiuo atveju – strateginių sprendimų priėmimą išanalizuojant tūkstančius duomenų sekundžių greičiu. Atlikta literatūros analizė parodė, kad yra tik keli moksliniai darbai, skirti analizuoti skaitmeninių valiutų kainų prognozavimui taikant giliojo mokymosi algoritmus. Mokslinių tyrimų stoka skatina nagrinėti šią tyrimo sritį nuodugniau. Tam, kad investavimo sprendimai būtų atlikti remiantis mokslškai pagrįsta informacija ir inovatyviomis technologijomis, kyla poreikis turėti pagalbinę priemonę, kuri paremtų sprendimų priėmimus. Šiam tikslui dažnai yra pasitelkiamos sprendimų paramos sistemos. Apžvelgus mokslinę literatūrą buvo pastebėtas mokslinių darbų trūkumas, kuriuose būtų siūlomos investavimo paramos sistemos orientuotos į skaitmeninių valiutų rinkos investavimo gerinimą. Taigi kyla poreikis pasiūlyti investavimo skaitmeninių valiutų rinkoje paramos sistemą, palengvinančią investavimo skaitmeninių valiutų rinkoje procesą. Remiantis tuo, baigiamajame magistro darbe, iškelta problema – investavimo proceso skaitmeninių valiutų rinkoje palengvinimas, pasiūlant sprendimų paramos sistemą, kuri remiasi giliojo mokymosi algoritmu. Problemos tyrimas pridės mokslinės vertės paramos sistemų, skirtų investavimui skaitmeninių valiutų rinkoje, analizavimui ir tolesniam plėtojimui. Apžvelgus literatūrą buvo nustatyta, kad sprendimų paramos sistemoms, susijusioms su investavimu, yra būdingi šie žingsniai: duomenų rinkimas, duomenų apdorojimas, prognozavimas, strategijos pasirinkimas ir portfelio sudarymas (Kekytė ir Stasytė, 2017). Magistro darbo tyrimui atlikti buvo analizuojamos šešios skaitmeninės valiutos pagal didžiausią kapitalizacijos dydį. Skaitmeninių

valiutų analizavimui ir vertinimui buvo pasirinkta naudoti TOPSIS daugiakriterį vertinimo metodą, kuriuo buvo nustatyta, kad bitkoinas, riplas ir litkoinas yra arčiausios idealiajam sprendimui pagal pasirinktus kriterijus. Įvertinus skaitmenines valiutas pagal vidinius jų veiksnius, svarbu įvertinti kainų pokyčius. Tikslus prognozavimas yra ypač svarbus tam, kad būtų galima sudaryti investavimo strategijas. Vienas iš patikimiausių, didelį informacijos kiekį apdoroti galinčių prietaisų – giliojo mokymosi algoritmas, kurio veikimo pagrindas paremtas neuroniniais tinklais. Kainų prognozavimui buvo pasitelktas ilgalaikės-trumpalaikės atminties algoritmas. Palyginus prognozuojamas reikšmes su realiais istoriniais duomenimis, kainų prognozių nuokrypis gautas palyginti mažas – ne didesnis kaip 3 % didžiausią kapitalizaciją turinčiomis skaitmeninėms valiutomis algoritmą apmokant su trejų metų duomenimis į kuriuos įeina pandemijos laikotarpis, tad galima teigti, kad LSTM modelis tiksliai pavaizduoja kainos kitimo tendenciją. Viena vertus, tai rodo, kad skaitmeninių valiutų rinka yra nuspėjama ir juda ne pagal atsitiktinio pasivaikščiojimo teoriją, kita vertus, tokie rezultatai leidžia teigti, kad giliojo mokymosi algoritmas yra saugus prietaisas norint įsivertinti galimas skaitmeninių valiutų kainų vertes. Tai itin svarbu sudarant investicijų portfelį, vertinant galimus investicinius scenarijus ir su jais susijusias rizikas.

Temos aktualumas. Finansų rinkos dalyviams yra svarbu efektyviai reaguoti į besikeičiančią rinką ir jos naujoves. Sparčiai auganti skaitmeninių valiutų rinka tampa vis patrauklesnė investuotojams, ieškantiems rizikos diversifikavimo alternatyvų ir naujų investavimo galimybių. Vis sparčiau integruojant kompiuterines technologijas į finansų rinkas atsiveria galimybės atlikti sudėtingesnes ir analizes, apdorojant didesnius duomenų kiekius. Kadangi skaitmeninės valiutos vis dar yra iki galo neištirta finansų rinkos dalis, mokslinės literatūros trūkumas skatina plačiau analizuoti investavimo galimybes skaitmeninių valiutų rinkoje, pasiūlyti investavimo sprendimus remiančius ir lengvinančius metodus.

Problema – kaip palengvinti investavimo skaitmeninių valiutų rinkoje procesą pritaikant giliojo mokymosi algoritmus.

Objektas – skaitmeninių valiutų rinka;

Apribojimai – tyrimas yra ribojamas pasirinktų kriterijų, istorinių duomenų laikotarpiu ir tiriamų skaitmeninių valiutų imtimi;

Tikslas – pasiūlyti investavimo skaitmeninių valiutų rinkoje paramos sistemą, pritaikant giliojo mokymosi algoritmą;

Uždaviniai:

1. Apžvelgti teorinius skaitmeninių valiutų aspektus, investavimo skaitmeninių valiutų rinkoje galimybes ir sprendimų paramos sistemų taikymą;

2. Išanalizuoti mokslinius tyrimus, susijusiu su skaitmeninių valiutų vertinimo ir prognozavimo metodais;
3. Atlikti skaitmeninių valiutų vertinimo tyrimą;
4. Atlikti skaitmeninių valiutų vertės prognozavimo tyrimą;
5. Įvertinti siūlomą investavimo sprendimų paramos sistemą;

Tyrimo metodai: literatūros analizė, sprendimų paramos sistema, kuriamasis mokslas, daugiakriteris vertinimas, TOPSIS, gilusis algoritmas, neuroniniai tinklai, LSTM, statistinė analizė; investicijų portfelio analizė;

Baigiamojo darbo struktūra: baigiamąjį magistro darbą sudaro įvadas, trys skyriai, išvados, pasiūlymai, literatūros šaltinių sąrašas ir priedai. Pirmoje darbo dalyje pateikiama skaitmeninių valiutų, investavimo ir sprendimų priėmimų teorinė analizė. Šioje dalyje analizuojamas skaitmeninių valiutų apibrėžimas ir rinkos raidos aspektai, mokslinė literatūra, susijusi su skaitmeninių valiutų vertinimu, prognozavimu ir investavimo sprendimų priėmimu. Antroje dalyje pateikiama magistro darbe naudojama tyrimo metodika. Apibrėžiama tyrimo atlikimo struktūra, TOPSIS metodo ir LSTM algoritmo žingsniai ir pagrindinės formulės ir skaitinės charakteristikos, reikalingos investicijų portfeliui sudaryti ir įvertinti. Trečioje darbo dalyje pateikiami tyrimų rezultatai. Visų pirma surenkami duomenys ir atliekamas daugiakriteris skaitmeninių valiutų vertinimas. Tolesniu žingsniu vertinami giliojo mokymosi algoritmo prognozių rezultatai. Galiausiai remiantis atliktais tyrimais, sudaromi vienuodų svorių skaitmeninių valiutų portfeliai, kurių rezultatai lyginami su akcijų rinkos indeksu, siekiant įvertinti siūlomų sprendimų paramos sistemos metodų rinkinio efektyvumą, investavimo sprendimų priėmimui. Remiantis tyrimo rezultatais pateikiamos išvados ir pasiūlymai.

Teorinis indėlis ir praktinė nauda. Panašių modelių trūkumas riboja darbą siekiant nurodyto siūlomo investavimo sprendimų paramos sistemos modelio teisingumo ir efektyvumo. Nepaisant to tyrimas atneša pridėtinės vertės į mokslinių darbų sritį, susijusią su skaitmeninėmis valiutomis ir joms skirtomis sprendimų paramos sistemomis. Darbe siūlomi metodai yra pritaikomi praktiškai, integruojant juos į finansines technologijas, tokias kaip investavimo mobiliosios programėlės, internetinės investavimo platformos ar konsultavimo vykdomose paslaugose, tokiose kaip – investicijų prognozavimas ir vertinimas.

1. SKAITMENINIŲ VALIUTŲ, KAIP INVESTAVIMO OBJEKTO, TEORINĖ ANALIZĖ

Akcijų rinka yra rinkų ir biržų rinkinys, kuriame prekiaujama, parduodama ar mainomasi vertybiniais popieriais, išvestinėmis finansinėmis priemonėmis, opcionais, akcijomis ir kitomis prekėmis. Akcijų biržos svyravimas priklauso nuo paklausos, investuotojų nusiteikimo ir lūkesčių ateičiai. Būdama sudėtinga netiesinė dinaminė sistema, akcijų birža sulaukia nemažai tyrimų skirtų, veiksmingo prognozavimo modelio kūrimui, siekiant pagerinti ir padėti investuotojams priimti tinkamus sprendimus (Indera *ir kt.*, 2018). Skaitmeninių valiutų rinka yra panaši į akcijų rinką. Vienas iš aktualiausių investuotojams skirtumų yra rizikos ir nepastovumo lygis. Akcijų rinka yra griežtai reguliuojama, tad rinkos tyčinis veikimas yra retas reiškiny, atvirkščiai nei skaitmeninių valiutų rinkoje, kuri yra nereguluojama, todėl yra jautresnė išoriniams veiksniams ir taikiny kainų manipuliacijai. Rinkos pokyčio krypties prognozavimas nėra lengvas procesas, ypač kai tenka apdoroti masiškai didelį kiekį duomenų. Didelio kiekio informacijos ir ateities numatymo reikmė, žadina norą investuotojams turėti mechanizmą ar prognozavimo modelį, kuris tai atliktų už juos ir garantuotų lengvą ir greitą pelną su mažiausia rizika (Adebiyi ir Adewumi, 2014). Esant technologijų ir giliojo mokymosi, kitaip tariant, automatizavimo augimo amžiuje, tai yra neišvengiama ateitis, tiek akcijų, tiek visoms kitoms rinkoms. Noras būti pirmiems, skatina mokslininkus vystyti ir plėtoti naujus prognozavimo modelius ir algoritmus. Sudėtingas skaitmeninių valiutų rinkos pobūdis reikalauja plataus profilio duomenų kiekio, kuriam apdoroti naudojami įvairūs metodai, tokie kaip statistinė, techninė, sentimentų, sprendimų ir kita analizė (Indera *ir kt.*, 2018).

Viena iš artimiausių ir dažniausiai investuotojų naudojama analizės rūšių – sprendimų analizė. Sprendimų teisingumo pagrindimui, prognozuojant finansų rinkos pokyčius, ji apima tiek finansinių naujienų, tiek socialinių erdvių, tokių kaip „Twitter“ turinio analizę. Kaip teigia Feuerriegel ir Fehrer (2016), jau egzistuojančių prognozavimo modelių struktūra beveik visuomet taiko tradicinius mašininio mokymosi metodus, kurie atliktų tyrimų duomenimis, nėra efektyvūs ir pakankamai tinkami duomenų analizei, kurios galutiniame produkte būtų atrinktos tinkamos savybės ir užfiksuotas ir įsimintas netiesinis sudėtingų užduočių pobūdis. Tačiau, derėtų pabrėžti, kad integruojant mašininį mokymąsi į investavimo sprendimų priėmimą, didėja ne tik efektyvumas, analizuojant naujausią prieinamą informaciją, bet ir sprendimų priėmimo kokybė. Žinoma, kokybę stipriai nulemia tiek analizuojamų duomenų kiekis, pobūdis ir analizės metodas, tiek pačių analizuojamų duomenų kokybė ir pagrįstumas.

1.1. Skaitmeninės valiutos ir skaitmeninių valiutų rinkos teoriniai aspektai

Skaitmeninių valiutų atsiradimas finansų rinkoje sukėlė nemažą ažiotažą pasaulinėje ekonomikoje. Skaitmeninės valiutos nėra faktiniai pinigai, tai visiškai skaitmeninis eksperimentinės rūšies vertės perdavimo matas, kurių naudojimo ir ateities galimybių aspektai yra vis dar tiriami ir vystomi. Skaitmeninių valiutų pradžia laikomi 2009 metai, kai buvo pristatytas bitkoinas (angl. bitcoin), tačiau intensyvus susidomėjimas ir naudojimas investavimui yra ganėtinai naujas reiškinys, kuris stokoja detalių tyrimų tiek ties skaitmeninių valiutų rinka ir jos kainų kitimu, tiek ties investavimo ir prognozavimu. Skaitmeninių valiutų apibrėžimas dažnai yra tapatinamas su virtualių pinigų sąvoka, kas neatspindi pilnos jų prigimties. Virtualūs pinigai dažnai yra tapatinami su elektroniniais pinigais, kas yra du skirtingi finansiniai instrumentai. Elektroniniai pinigai yra mokėjimo priemonė, kurios piniginė vertė saugoma elektroninėse laikmenose. Ši vertė atitinkamai keičiasi atliekant pirkimo, pardavimo, pakrovimo ar iškrovimo operacijas. Skiriamasi šių pinigų bruožas yra tai, kad pinigų vertė išreiškiama kaip pretenzija emitentui, todėl banko sąskaitos nurodymas nėra būtinas (Lansky, 2018).

Skaitmeninė valiuta, arba kriptografinė valiuta, yra elektroniniu būdu išleidžiama valiuta, kurios pakeitimas į realios vertės pinigus nėra garantuotas valstybės. Dauguma mokslininkų skaitmenines valiutas apibūdina, kaip virtualų turtą, kurio paskirtis yra veikti kaip mainų priemonė ar terpė, kuriai sukurti naudojama sudėtinga kriptografijos technologija, užtikrinanti finansinių operacijų srauto saugumą ir papildomų skaitmeninių valiutų generavimą (Chohan, 2018; Schueffel, 2017). Būtent dėl šios technologijos, skaitmeninės valiutos pasižymi finansinių institucijų ir kitų trečiųjų šalių išvengimu. Andriantas (2017) apibūdina skaitmenines valiutas kaip sparčiai besiplečiančią mokėjimo sistemą, priklausančią nuo skaitmeninės blokų grandinės sistemos. Dourado ir Brito (2014) įvardina virtualias valiutas kaip sistemą, kuri naudoja kriptografiją, kad užtikrintų saugų skaitmeninių žetonų pardavimą ar keitimąsi decentralizuotu būdu. Houbenas ir Snyersas (2018) skaitmenines valiutas įvardina kaip virtualia vertės išraiškas, kas yra alternatyva pinigams. Dabrowskis ir Janikowskis (2018) formuoja mainų priemonės įvaizdį, kuri veikia perduodama, saugodama ir mainydamą skaitmenines valiutas elektroniniu būdu. Platanakis ir Urquhartas (2019) pabrėžia, kad tai yra ne tik mainų priemonė ar matavimo matas, bet ir kaupimo būdas. Audito, apskaitos, turto vertinimo ir nemokumo valdymo tarnybos (2018) išleistose skaitmeninių valiutų ir žetonų apskaitos rekomendacijose pagrindiniai skiriamieji bruožai:

1. Vertės nustatymas – įprastai nustato paklausa ir pasiūla;

2. Struktūra – decentralizuota, veikimo ir funkcionavimo principai priklauso nuo skaitmenine valiuta besinaudojančios bendruomenės;
3. Anonimiškumas – sandorių sudarymui nėra reikalinga konfidenciali informacija, tačiau kiekvienas sandoris yra viešai registruojamas, dėl ko sandoriai išlaiko anonimiškumą, tačiau yra galima jų identifikacija;
4. Skaidrumas – sandorių registras yra viešai prieinamas kiekvienam vartotojui;
5. Sandorio vykdymas – sandorių valdymas priklauso nuo skaitmeninių valiutų bendruomenės, dėl ko yra labai maža tikimybė, kad skaitmeninės valiutos naudotojai sutiks su siūlymu keisti blokų grandinės struktūrą;

Remiantis Lanske (2018) skaitmeninė valiuta turi atitikti šias šešias sąlygas:

1. Sistemos palaikymui nėra reikalinga centrinė valdžia, nes tai yra užtikrinama per paskirstymo kanalus;
2. Sistema kaupia informaciją ir apžvalgą apie skaitmeninių valiutų vienetų ir jų savininkus;
3. Sistema nustato tai, ar yra galimas naujų skaitmeninių valiutų vienetų sukūrimas. Tuo atveju, kai nauja skaitmeninė valiuta gali būti sukurta, sistema nustato jų atsiradimo aplinkybes ir savininką;
4. Nuosavybės teisės gali būti nustatytos tik naudojant kriptografiją;
5. Sistema leidžia operacijų metu, keisti nuosavybės teises. Sandorio išrašą suteikti gali tik tas subjektas, kuris pateikia skaitmeninės valiutos nuosavybės įrodymą;
6. Jei tuo pačiu metu sistema gauna du skirtingus kriptografinių vienetų nuosavybės teisės pakeitimus, tik vienas iš jų yra įvykdomas.

Tad apibrėžiant skaitmenines valiutas tai – mokėjimų terpės sistema, naudojanti kriptografijos technologiją, kad sukurtų virtualaus turto vertę.

Skaitmeninių valiutų rinkos augimo ir raidos sparta gniaužia kvapą, todėl jų analizė domina ne tik mokslininkus, bet įvairias institucijas, kurios reguliuoja finansų rinkas. Tam, kad geltų kurti atitinkamus įstatymus ir nutarimus, visų pirma reikalingas skaitmeninių valiutų apibrėžimas, kuris skiriasi nuo mokslininkų siūlomų apibrėžimų. Europos centrinis bankas skaitmenines valiutas priskyrė, kaip virtualios valiutos pogrupį ir apibūdino ją, kaip nereguliuojamų skaitmeninių pinigų tipą, kuris yra kontroliuojamas jų kūrėjų, naudojamas ir priimamas konkrečios virtualios bendruomenės narių. Vėliau apibrėžimas buvo papildytas skaitmenines valiutas aiškinant, kaip virtualią vertės išraišką, kuri nėra išleista centrinio banko, kredito ar elektroninių pinigų įstaigos ir kuri, tam tikromis aplinkybėmis, gali būti naudojama, kaip pinigų alternatyva (Houben ir Snyers, 2018). Europos bankininkystės institucija pateikia panašų apibrėžimą: skaitmeninė vertės perdavimo priemonė, kuri nėra išleista nei centrinio

banko, nei valdžios institucijos, nei būtinai susiejama su įprastine valiuta, tačiau yra pripažįstama fizinių ar juridinių asmenų, kaip mainų priemonė, gali būti perduodama, saugoma ir mainoma elektroniniu būdu (Dabrowski ir Janikowski, 2018). Mokėjimų ir rinkos infrastruktūros komitetas (tarptautinių atsiskaitymų banko įstaiga), skaitmenines valiutas pripažino skaitmeninėmis valiutomis arba skaitmeninių valiutų schemomis. Pagal juos, ši schema turi sekančias ypatybes:

1. Tai turtas, kurio vertę lemia pasiūla ir paklausa, panašiai kaip aukso, tik su nuline tikrąja verte;
2. Naudojami paskirstymo srautais tam, kad sudarytų sąlygas nuotoliniu būdu keistis elektronine skaitmeninių valiutų verte, tuo atveju kai nėra pasitikėjimo tarp šalių, tačiau be tarpininko dalyvavimo būtinybės;
3. Jos nėra valdomos konkretaus asmens ar institucijos.

Taigi, iš aukščiau išdėstytų apibrėžimų, galime pastebėti, kad nėra vieno bendro skaitmeninės valiutos termino apibrėžimo. Galima išskirti tai, kad mokslinėje literatūroje, terminas yra gretinamas, su sistema, kuri kriptografijos būdu sukuria mainų terpę, taip atskleidžiant pagrindinį skaitmeninės valiutos veikimo principą. Įstatymu ir reguliaciniame kontekste, skaitmeninė valiuta yra apibrėžiama, kaip skaitmeninė vertės perdavimo priemonė, kuris naudojamas, kaip piniginio vieneto alternatyva sukurta kriptografijos pagalba.


Analizuojant mokslinę literatūrą, buvo pastebėtas ir trečias, skaitmeninių valiutų apibrėžimas. Skaitmenines valiutas apibrėžia, ir kaip investavimo priemonę (Baur, Hong ir Lee, 2018). Mokslininkai teigia, kad virtuali valiuta nėra tik mokėjimų sistema, tačiau ir ypač sparčiai populiarėjanti investavimo priemonė. Saksonova ir Kuzmina-Merlinova (2019) taip pat išskyrė pagrindinius skaitmeninių valiutų bruožus dėl kurių, jos gali būti laikomos investavimo instrumentu. Visų pirma, autorės nurodė, kad skaitmeninė valiuta gali veikti, kaip mainų priemonė. Sekantis svarbus bruožas yra tai, kad blokų grandinės technologija užtikrina informacijos patikimumą ir dvigubo skaitmeninės valiutos išleidimo grėsmės nebuvimą. Autoriai taip pat pabrėžia, kad skaitmeninės valiutos gali veikti kaip matavimo matas ir kaip vertės saugojimo ir kaupimo instrumentas. Šie bruožai verčia skaitmenines valiutas laikyti daugiau investavimo priemone, nei pinigais.

Vertėtų paminėti, kad vienas didžiausių skaitmeninių valiutų privalumas yra moderni mokėjimų sistema, kuri išsiskiria mažesnėmis kainomis, greitu pasiekiamumu pasauliniu mastu ir mokėtojo anonimiškumu. Tai pagrindiniai bruožai skatinantys skaitmeninių valiutų rinkos augimą. Augantis susidomėjimas investavimo srityje išbalansuoja skaitmeninių valiutų kainas, sukeldamos vertės nepastovumą, kas atbaido potencialius valiutos naudotojus. Stabili pusiausvyra, tarp investuotojų ir vartotojų yra ypač svarbi, siekiant išlaikyti skaitmeninių

valiutų, kaip mainų priemonės, matavimo mato ir kaupimo būdo sėkmę (Platanakis ir Urquhart, 2019).

1.2. Skaitmeninių valiutų rinkos tendencijų apžvalga

Skaitmeninės valiutos yra viena iš žinomiausių ir populiariausių skaitmeninė finansinė tendencija XXI amžiuje. Skaitmeninių valiutų atsiradimas sukėlė susidomėjimą, ne tik mokslininkams, ekonomistams ir finansų specialistams, bet ir įvairių reguliavimo institucijų darbuotojams. Vertės išlaikymas ir spartus augimas parodė, kad visuomenei, šiame technologinio augimo amžiuje, trūksta valiutos, pagrįstos visiškai kitokių taisyklių nei įprasti pinigai. Tas lėmė atsiradimą skaitmeninių valiutų šalininkų, teigiančių kad sparti virtualių valiutų evoliucija galiausiai pavers jas grynujų pinigų mainų priemone, galinčia pakeisti visą pasaulį (Corbet *ir kt.*, 2019).




1 pav. Bendra skaitmeninių valiutų rinkos kapitalizacija (JAV doleriais) 2017–2020 m.

Šaltinis: coingecko.com (2020)

Jau dešimtimis praėjo, nuo pirmosios skaitmeninės valiutos, sukėlusios chaosą valiutų rinkoje – bitkoino, išleidimo. Bitkoinas yra laikomas visų kitų virtualių valiutų pradininku, kuriuo ypač buvo susidomėta per 2017 m. (žr. pav. 1) įvykusią skaitmeninių valiutų karštligę. Investuotojai smarkiai susidomėjo bitkoinu, eteriu (angl. etherumu), litkoinu (angl. litecoin) ir visomis kitomis skaitmeninėmis valiutomis, gyvavusioms jau kurį laiką kaip investavimo instrumentu. Išaugęs populiarumas lėmė milijonų žmonių įsitraukimą į virtualių valiutų rinką. Jau 2018 m. gegužės mėnesį dviejų didžiausių skaitmeninių valiutų (bitkoino ir eterio) bendra rinkos vertė siekė 160,9 milijardus JAV dolerių, iš kurios vien tik bitkoinas sudarė 115 milijardų

dolerių. Smarkiai kintančią ir svyruojančią skaitmeninių valiutų vertę varomą padidėjusios paklausos veikė tiek įgaunamas ir stiprėjantis faktinės valiutos įvaizdis, tiek kaip investavimo alternatyva (Abraham, Higdon ir Nelson, 2018). Būdamas ganėtinai naujas fenomenas, skaitmeninių valiutų svyravimas kelia neužtikrintumą tiek tiems, kurie mato ir naudoja skaitmenines valiutas kaip vertės perdavimo matą, atsiskaitydami už prekes ar paslaugas, tiek finansų rinkos dalyviams, siekiantiems diversifikuoti savo portfelį ir padidinti pelningumą.



2 pav. Skaitmeninių valiutų rinkos kapitalizacijos paskirstymas 2014–2020 m. kapitalizacija 2014–2020 m.

Šaltinis: sukurta autoriaus, remiantis coinmarketcap.com (2020) duomenimis

Pirmas paveikslas vaizduoja bendrą skaitmeninių valiutų kapitalizaciją nuo 2016 m. iki 2020 m. balandžio mėnesio. Kapitalizacijos dydis ir kitimas yra vertės rodiklis suinteresuotam vartotojui ar investuotojui. Ji yra gaunama padauginus esamų rinkoje žetonų skaičių iš tuometinės jų kainos, taip išreiškiant investicijos dydį. Kaip jau minėta, skaitmeninių valiutų aukso amžius prasidėjo 2017 m., tuometinė skaitmeninių valiutų rinkos kapitalizacija sausio mėnesį siekė 17,000 milijonų JAV dolerių, o jau birželį buvo pašokusi iki 90,000 milijonų JAV dolerių. Tokį didelį kapitalizacijos pokytį daugiausia lėmė staigus bitkoino kainų pakilimas. Todėl ir kitų, tuometinių skaitmeninių valiutų kainos, nuo padidėjusios paklausos, taip pat pradėjo kilti. Iš 2 paveikslo, matome, kad labiausiai 2017 m. be bitkoino išsiskyrė riplas (žr. pav. 2, XRP) (1,27 %) ir eteris (3,90 %) skaitmeninės valiutos, kurios vertę ir poziciją pagal rinkos dominavimą yra išlaikiusios iki dabar. Analizuojant skaitmeninių valiutų rinkos sudėtį – bitkoinas sudaro daugiau negu pusę visos rinkos vertės (žr. 2 pav.). Tai daugiausia lėmė unikali blokų grandinės sistema. Antroje pagal dydį vietoje yra eteris, kurio sėkmę lėmė išmaniosios sutarys. XRP arba daugumai geriau žinoma kaip riplas buvo ir yra trečia pagal kapitalizacijos dydį valiuta. Jis išsiskyrė savo mokėjimų sistema, kuri yra orientuota į bankinių paslaugų įmones ir pavedimų greitį. Dėl staiga susidomėjimo skaitmeninių valiutų rinka

pasiekė rekordinę vertę – jau 2018 m. sausio mėnesį siekė 612 mlrd. JAV dolerių, kas yra 595 mlrd. JAV dolerių daugiau, lyginat su 2017 m. sausio mėnesiu (žr. 1 lentelę). Nuo šio taško, skaitmeninių valiutų kainos, gana sparčiai pradėjo mažėti ir jau 2018 m. gale, 2019 m. pradžioje skaitmeninių valiutų rinkos vertė nukrito beveik 79 % (žr. 1 lentelę). Šios krizės priežastimi yra laikomas Kinijos sprendimas drausti prekybą skaitmeninėmis valiutomis ir blokuoti prieigą prie valiutų keitimo platformos. Toks sprendimas turėjo stiprią įtaką visai rinkai, nes Kinijai priklausė apie 70 % bitkoino gavybos ir 90 % prekybos. Kinijos sprendimas buvo paremtas noru išvengti ir apsaugoti šalį nuo spekuliacinių burbulų, sukčiavimo ir elektros energijos suvartojimo (Bloomberg.com, 2019).


1 lentelė. Skaitmeninių valiutų rinkos kapitalizacijos procentinis pokytis (RKP) rugsėjo 1 d. 2013 – 2019 m. periodu

Metai	2014	2015	2016	2017	2018	2019	2020
JAV dol. Mln,	10 587	5 486	7 091	17 716	612 925	125 708	190 906
RKP	572,12 %	-48,18 %	29,25 %	149,86 %	3359,65 %	-79,49 %	51,86 %

Šaltinis: sukurta autorės, remiantis coinmarketcap.com (2020) duomenimis

Apžvelgiant skaitmeninių valiutų vertės pokyčius globalios pandemijos COVID-19 laikotarpiu, prasidėjusiu 2019 m. lapkričio pabaigoje, galima pastebėti, kad virusui pasiekus Europą rinkos vertės kritimas buvo didesnis, negu virusui neišplitus iš Kinijos (žr. 1 pav.). Lyginant bitkoino (BTC) ir bitkoino kešo (angl. Bitcoin cash, BCH) kainų kitimą su S&P 500 akcijų rinkos indeksu, taip pat pastebima, kad Europoje įsisiautusi pandemija paveikė tiek skaitmeninių valiutų tiek akcijų rinkos indekso vertę (žr. 3 pav., 2020 m. kovo mėn.). Kainos kritimą galima pagrįsti baime ir nerimu pasklidusiu tarp žmonių ir investuotojų. Išplitęs virusas sukėlė daug pokyčių visame pasaulyje, pradedant nuo judėjimo ribojimų tarptautiniu mastu, komercinių veiklų stabdymu, sveikatos sistemos prieinamumu, darbo ir edukacijos vystymo namuose ir žemiausių profesijų, tokių kaip kasininkų, kurjerių, mokytojų, slaugytojų būtinumų. Pandemija smogė tiek sveikatos sistemai tiek darbo rinkai. Nežinia ir neužtikrintumas skatina susilaikyti nuo naujų investicijų ir atsiimti esamas. Tai ypač akivaizdu per pirmąją pandemijos bangą 2020 m. kovo mėnesį – skaitmeninių valiutų rinkos kapitalizacija nukrito iki 150 mlrd. JAV dolerių. Nepaisant to, jau balandį bendra skaitmeninių valiutų kapitalizacija perkopė 200 mlrd. JAV dolerių, o liepą pasiekė ir 300 mlrd. JAV dolerių (Coinmarketcap.com, 2020). Analizuojant atliktus mokslininkų darbus, kuriuose buvo tiriamas COVID-19 viruso protrūkio poveikis skaitmeninių valiutų grąžai buvo pastebėta, kad prieš pandemiją efektyviausia

skaitmeninė valiuta buvo bitkoinas, o po ligos pasklidimo pasaulyje didžiausią efektyvumą demonstravo eteris. Taip pat mokslininkų tyrimų rezultatai parodė, kad išplitus pandemijai padidėjo tirtų skaitmeninių valiutų efektyvumas (Iqbal, Fareed, Guangcai ir Shahzad, 2020; Mnif, Jarboui ir Mouakhar, 2020). Tai rodo, kad tiek vartotojų tiek investuotojų nuotaikos buvo optimistinės ir sustiprino pasitikėjimą vertės stabilumu ir augimu.



3 pav. Skaitmeninių valiutų ir S&P 500 indekso kainos (JAV doleriai)

Šaltinis: sudaryta autorės remiantis finance.yahoo.com (2020) duomenimis

Vertinant kainų judėjimo tendencijas, pastebima, kad akcijų rinkos ir skaitmeninių valiutų kainos kažikuriais periodais sutampa. Ryškus skirtumas matomas 2018 m., kur skaitmeninių valiutų kainos turi mažėjantį trendą, o S&P 500 indeksas didėjanti (žr. 3 pav.). Panaši situacija matoma ir 2018 m. gegužės – 2019 m. sausio mėnesio laikotarpiu. Kitais periodais, tokiais kaip 2018 m. lapkričio – 2019 m. sausio ar 2020 m. vasario – gegužės mėnesiais matomas labai panašus kainų kitimo trendas. Taigi, galima įžvelgti silpną ryšį tarp skaitmeninių valiutų ir akcijų rinkų. Lyginant kainų atsistatymą pandemijos laikotarpiu, remiantis 3 paveiksle pateiktu grafiku, galima teigti, kad skaitmeninės valiutos pranoko akcijų rinką, kadangi kainos gegužio mėnesį pakilo virš vasario mėnesio vertės. Vertės išlaikymas ir netgi padidėjimas pandemijos laikotarpiu parodė, kad investuotojai ieškodami saugios investavimo alternatyvos rinkosi skaitmenines valiutas.

1.3. Skaitmeninių valiutų vertinimas ir prognozavimas

Siekiant atlikti kokybiškus ir užtikrintus investavimo sprendimus, tinkamas skaitmeninių valiutų vertinimas ir lyginimas yra itin svarbus. Apžvelgus mokslinę literatūrą,

buvo pastebėta, kad siekiant išrikiuoti skaitmenines valiutas ir įsivertinti pasirinkimo sprendimą lyginant su pasirinkimo alternatyvomis yra naudojami daugiakriteriai sprendimų metodai. Tang, Shi ir Dong (2019) atliko tyrimą, kur autorių tikslas buvo atlikti išsamų blokų grandinės vertinimą apžvelgiant ir išskiriant vertę lemiančius kriterijus. Straipsnyje buvo naudojamas daugiakriteris artumo idealiajam taškui metodas (TOPSIS), kaip pagrindinis įrankis įvertinti ir išrikiuoti skaitmenines valiutas. Metodo naudojimo tikslas moksliniame darbe – paremti sprendimų priėmimo procesą. Verkleijas, Jansenas ir Cubillas (2018) atliko tyrimą, kuriame pasirinkimą tarp skirtingų blokų grandinių platformų įvertino kaip daugiakriterį sprendimų problemą ir to pagrindu sudarė blokų grandinės platformos pasirinkimo paramos modelį. Mačekas ir Alagicas (2017) bitkoino sistemos lyginimo tyrime naudojo daugiakriterį AHP modelį tam, kad galėtų prioretizuoti ir įvertinti skirtingas sistemas. Autoriai darbe mini, kad kaip alternatyvą jų pasirinktam metodui, laiko TOPSIS. Parvena, Arora ir Alama (2020) atliko tyrimą apie blokų grandinės sistemos lyginimą, kur taip pat naudojo daugiakriterį TOPSIS modelį. Autoriai darbe siekė išrinkti kritiškiausią mokėjimo sistemas, jas išrangavus su artumu idealiajam taškui metodu. Apžvelgus susijusius tyrimus, buvo nuspręsta tyrimui naudoti TOPSIS metodą, dėl to, kad jis labiausiai atitiko nagrinėjamą daugiakriterę problemą – išranguoti skaitmenines valiutas nustatant geriausią alternatyvą.

Rinkos pokyčio krypties prognozavimas yra ypač sudėtingas ir tuo pat įdomus mokslininkams siekiantiems pagerinti jau egzistuojančius prognozavimo modelius. Kiekvieno investuotojo tikslas, renkantis investavimo strategiją, remiantis modeliais, medija ir naujausia informacija, ekonomikos prognozėmis ir panašiai, yra atlikti sprendimus, kurie sumažintų riziką ir padidintų pelną. Kainų kintamumas yra pagrindinis veiksnys veikiantis kainų nuspėjamumo tikslumą. Skaitmeninės valiutos ypač pasižymi savo kainų nepastovumu, ypač aiškiai tai įrodė 2018 metais. Kainos kintamumas rodo, kiek yra rizikingas turto laikymas tam tikru metu ar laikotarpiu. Kuo didesni procentas, tuo didesnė tikimybė, kad vertė gali arba smarkiai pakilti arba taip pačiai nukristi. Tai sudaro ganėtinai didelę riziką, tačiau tuo pat metu padidina šansus patirti didelį pelną per trumpą laiko tarpą. Theblockcrypto.com (2019) birželį atlikta kainų kitimo analizė parodė, kad bitkoinas buvo pati nestabiliausia valiuta – kainos pokytis siekė 102 %. Nepaisant to, bitkoinas išliko pelningiausia skaitmeninė valiuta, kurios vertė netgi pakilo 30 %. Litekoino kainų svyravimas siekė 98 %, riplo – 82 %. Bitkoino kainos augimas sukėlė rinkos dalyviams vilčių, kad tai numatoma rinkos augimo kryptis. Vertės išlaikymas COVID-19 pandemijos laikotarpiu verčia daugumą investuotojų vėl koncentruotis į skaitmeninių valiutų rinkos galimybes. Coinmarketcap.com duomenimis 2020 m. spalio mėnesį rinkoje buvo 3,7 tūkstančiai skaitmeninių valiutų, kurių kapitalizacija, perkamumas ir cirkuliavimas rinkoje yra labai skirtingas. Atsižvelgiant į tai, kad investavimo pasirinkimas ir

rizika yra didelė, ypač aktualus ir svarbus yra tikslingas skaitmeninių valiutų rinkos prognozavimas.

Nors ir klasikinis sprendimų priėmimo požiūris yra grindžiamas laiko patikrintomis sprendimų priėmimo taisyklėmis, šiuolaikinis sprendimų palaikymas daugiausia grindžiamas statistiniais įrodymais, kurie gaunami analizuojant patikimus duomenis (Feuerriegel ir Fehrer, 2016). Ši, duomenų pagrįstumu palaikomą sprendimų priėmimo būdą paskatino suvokimas, kad žmonės ir jų kompiuteriai generuoja daug ir įvairių duomenų, kuriuos yra įmanoma analizuoti. Šis atotrūkis ir bandymas fiksuoti ir naudoti pusiau struktūruotų ir nestrukūruotų duomenų vadinamas – didžiųjų duomenų era. Šis terminas apima nuolat didėjančių duomenų kiekį ir sparčiai besivystančios kompiuterinės technikos tobulinimą tam, kad sprendimų priėmimas būtų grindžiamas sudėtingų duomenų analize. Nuolatinį duomenų kitimą lemia, kiekvieną dieną generuojami duomenys. Žmonės siunčia laiškus, apsipirkinėja internetu, reiškia savo nuomones socialiniuose tinkluose, naršo įvairiose svetainėse ir kitaip naudojami internetiniu ryšiu, kuris yra pagrindinis duomenų perdavimo šaltinis. Kadangi visi veiklos duomenys yra įrašomi, toks duomenų srautas pateikia masišką duomenų kiekį, kurį apibūdina keturi žodžiai: kiekis, įvairovė, patikimumas ir greitis (Power, 2014). Norint tikslingai, greitai ir efektyviai analizuoti gaunamą informaciją, yra pasitelkiama algoritmų pagalba. Algoritmas yra taisyklių rinkinys arba procedūra, kurios reikia laikytis sprendžiant matematinę problemą (Schueffel, 2017).

Taip kaip ir akcijų rinkos prognozavime, taip ir skaitmeninių valiutų rinkoje, kyla klausimas – ar yra įmanoma nuspėti skaitmeninių valiutų elgesį, kai šis yra toks dinamiškas, kas iš esmės prieštarauja efektyvios rinkos hipotezei, pagal kurią kainų kitimas yra atsitiktinis (Sun, Liu, & Sima, 2019). Ankstesni tyrimai virtualių valiutų kainas numatė dviem būdais: empirine analize ir mašinų mokymosi algoritmų analize. Šioje dalyje bus apžvelgiama giliojo mokymosi algoritmų metodų taikymas literatūroje, skaitmeninių valiutų kainų prognozavimui.

Sun, Liu ir Sima (2019) atliko kainų prognozavimą naudojant tris skirtingus metodus: „LightGBM“, Atraminų vektorių klasifikavimo algoritmas (angl. Support Vector Machines) ir atsitiktinio miško (angl. Random Forests). Tyrimui buvo naudojamos 42 valiutos, pasirinktos pagal aktyvumą. Gauti rezultatai parodė, kad modeliai geriausiai veikia naudojant dviejų savaitių prognozavimo laikotarpį. Atlikus tą patį tyrimą pasirinkus 10 stipriausių valiutų, prognozavimas buvo šiek tiek tikslesnis. To pasekoje, autoriai priėjo išvada, kad prognozavimo tikslumas koreliuoja su skaitmeninių valiutų stiprumu ir prognozavimo laikotarpiu. Lyginant tris modelius, LightGBM parodė geresnius rezultatus lyginant su likusiais dviem.

Lahmiri ir Bekirosa (2019) skaitmeninių valiutų kainų prognozavimui pasirinko siauresnę imtį – tris pačias aktyviausias skaitmenines valiutas. Kainų prognozavimui buvo

pasirinkti du algoritmai – ilgosios trumposios atminties (angl. long-short term memory neural network, toliau LSTM) ir apibendrintos regresijos neuroninių tinklų (angl. generalized regression neural networks, toliau GRNN). Autoriai taip pat šiek tiek patobulino LTSM modelį, pertaikydami jam kontroliuojančius vartus, kurių galutinis tikslas yra filtruoti reikšmingą informaciją, kuri galiausiai pataptų prognoze. Tyrimo rezultatai parodė, kad LSTM giliojo mokymosi sistema, geriau sugebėjo išmokyti trejų pasirinktų valiutų kitimo dinamiką ir pateikti tikslesnei prognozes, lyginant su GRNN. Autoriai taip pat pabrėžė, kad giliojo mokymosi sistemos sugeba įsisavinti tiek trumpalaikę tiek ilgalaikę informaciją tuo pat metu, kas suteikia pranašumo siekiant atskleisti kitimo seką.

Madana, Saluja ir Zhao, (2015) taip pat naudojo giliojo mokymosi algoritmus Bitcoin kainų prognozavimui. Tyrimui naudota 25 bruožai, susijusę su skaitmeninių valiutų spekuliacijomis. Pasitelkiant atsitiktinio miško (angl. random forest) ir apibendrintas tiesines (angl. generalized linear model) laiko eilučių modelius, duomenų jautrumas buvo nustatomas, siekiant nustatyti, labiausiai tinkančius duomenų kitimo intervalus. Tyrimo rezultatai buvo sėkmingi - autorių algoritmas 98,7 % tikslumu numatė bitkoino dienos kainas. Bitkoino kainą taip pat prognozavo ir Chena, Li ir Suna (2020). Autoriai naudojo tiek statistinius metodus tiek mašininio mokymosi metodus. Dienos kainos prognozavime, statistiniai metodai pasiekė 66 % tikslumą, kur giliojo mokymosi algoritmų rezultatai pasiekė 65 % tikslumą. Tačiau lyginant su aukšto dažnio kainų prognozavimu, mokymosi modeliai: atsitiktinio miško, atraminių vektorių, ilgalaikės trumpalaikės atminties tinklo ir kvadratinės diskriminacijos analizė parodė pranašumą prognozavimo rezultatuose - pasiekė 67,2 % tikslumą, kur statistinio prognozavimo tikslumo vidurkis buvo 53%. Rebane ir Karlssonas (2018), Torresas ir Qiunas, (2018) savo darbuose, taip pat lygino giliojo mokymosi prognozavimo rezultatus su laiko eilučių analizės modelio rezultatais. Abu darbai patvirtino, kad algoritmo pateiktos prognozės yra tikslesnės negu laiko eilučių statistinio prognozavimo metodo.

Kim *ir kt.* (2016) skaitmeninių valiutų kainos vertinimui naudojo virtualių valiutų svetainių naudotojų išreiškiamus komentarus Naudojant sentimentų analizę, kaip veikiantį jų kainos svyravimo ir naudojimo faktorių, mokslininkai pritaikė šį paprastą, tačiau efektyvų būdą, trejų populiariausių skaitmeninių valiutų kainų ir operacijų prognozavimui. Autoriams pavyko pasiekti 79,57 % prognozavimo tikslumą naudojant Granger priežastingumo modelį. Tyrimas parodė, kad tiek kainų kitimas tiek operacijų apimtis yra stipriai susiję su teigiamomis temomis, komentarais ir atsakymais. Mai *ir kt.* (2018) atliko tyrimą, ties bitkoino kainos kitimo ir socialinių tinklų sąsaja. Autoriai tyrimas parodė, kad socialiniuose tinklai sudaryti iš 95 % pasyvių naudotojų, kas palieka 5 % aktyvių vartotojų, kurie paskelbia didžiąją dalį komentarų

ir diskusijų, veikiančių skaitmeninių valiutų kainų svyravimus. Tyrimo rezultatai leido teigti, kad sentimentų analizė yra svarbus kainų prognozavimo būdas.

Apžvelgus šiuos ir panašius empirinius tyrimus, nėra aiškus giliojo mokymosi algoritmų naudojimo privalumas, skaitmeninių valiutų kainų prognozavime. Kai kurie mokslininkų darbai parodė, kad naudojant paprastus, statistinius metodus prognozavimui, galimas netgi tikslesnis prognozavimas. Žinoma, rezultatų gavimui yra ypač svarbus duomenų dažnumo pasirinkimas, dėl ypač greitai kintančios skaitmeninių valiutų kainos ir prognozavimo laikotarpio pasirinkimas.

1.4. Investavimas skaitmeninių valiutų rinkoje

Augant susidomėjimui alternatyviomis investavimo galimybėmis vis didesnis dėmesys skiriamas skaitmeninės valiutos dėl išskirtinių jų savybių. Vienas iš jų yra nepriklausymas nuo finansinių įstaigų, tokių kaip bankai, brokeriai ar pan. Sekantis bruožas – vertės svyravimas, kuris sukelia galimybes gauti didelę grąžą. Viena vertus, didelė kainų vertės kaita neša atitinkamai didelę riziką, kita vertus yra sudaromos galimybės pasidaryti greitą pelną. Tai ypač vilioja investuotojus, siekiančius greitai užsitikrinti papildomą pajamų srautą. Taigi, kyla klausimas ar investavimas į skaitmenines valiutas gali užtikrinti esamą ir būsimą finansinį saugumą ir pajamas, kitaip tariant kiek efektyvus yra investavimas skaitmeninių valiutų rinkoje? Taigi, visų pirma reikia apžvelgti kokie yra svarbiausi skaitmeninių valiutų investavimo privalumai ir trūkumai.

Pagrindinės ir dažniausiai nurodomos rizikos yra susijusios su vertės nestabilumu ir likvidumu, kibernetiniais nusikaltimais, pinigų plovimu ir nusikalstamų veiklų finansavimu. Analizuojant mokslinę literatūrą taip pat buvo pastebėta, kad skaitmeninės valiutos pasižymi priklausomybe nuo tam tikros skaitmeninės valiutos – mažesnės skaitmeninės valiutos yra priklausomos nuo didesnių, tokių kaip bitkoino. Tai vienas iš signalų apie skaitmeninių valiutų rinkos neefektyvumą (Angerer, Hoffmann, Neitzert ir Kraus, 2020). Kita vertus, galima teigti, kad rinka reaguoja į naują informaciją, todėl kintant stipresnių, rinkoje ilgiau egzistuojančių skaitmeninių valiutų kainai, atitinkamai kinta ir mažesnės skaitmeninės valiutos, kadangi informacija mažiau ar daugiau yra susijusi su visa rinka. Sekantis svarbus aspektas yra likvidumas. Tai viena iš būtiniausių savybių investuojant į finansinius aktyvus. Finansinio turto likvidumas yra svarbus norint įsivertinti, kaip greitai investicija gali būti išgryninta, kitaip tariant – paversta į pinigus. Skaitmeninės valiutos pasižymi žemu likvidumais, dėl tokių veiksnių kaip kainų manipuliacijos galimybės, skaitmeninių valiutų keityklų kursų svyravimai ir mokestinių ir teisinių įstatymų neapibrėžtumu (Angerer et al., 2020). Wei (2018) atliktame

skaitmeninių valiutų likvidumo vertinimo tyrime, buvo nustatytas, kad gražos nuspėjamumas mažėja, didėjant likvidumui. Taip pat buvo pabrėžta, kad didesnė sandorių atlikimo sąnaudos mažina rinkos efektyvumą, kadangi rinkos dalyviai reaguoja lėčiau į vykstančius pokyčius. Mokslininkai pastebėjo, kad nors ir bitkoinas rodo efektyvios gražos ženklus, daugumas rinkoje esančių skaitmeninių valiutų pasižymi priklausomybe ir koreliacija didesnėms valiutoms. Tai ypač būdinga naujoms skaitmeninėms valiutoms, kurių likvidumas yra ribotas, dėl jų nežinomumo ir užgožimo kitų, didesnių, rinkoje stabiliai cirkuliuojančių skaitmeninių valiutų, kurių efektyvumas rinkos atžvilgiu gerėja.

Vertinant skaitmeninių valiutų rizikas ir privalumus, taip pat yra svarbu paminėti ir operacines skaitmeninių valiutų savybes. Skaitmeninių valiutų operacijos yra užšifruotos specialiais kodais ir nustatyti jų siuntėją ar gavėją yra ypatingai sunku. Tuo tarpu, pati skaitmeninė valiuta, pavyzdžiui, bitkoinas, savyje laiko visą reikalingą informaciją apie transakciją. Taigi iš vienos pusės žvelgiant kriptografijos technologija užtikrina greitą ir anonimišką operacijų vykdymą, kita vertus – atlikus pavedimą į neteisingą gavėjo sąskaitą ar skaitmeninių valiutų piniginę, operacijos atsekimas ir atšaukimas nebus galimas. Taip pat išlieka vartotojo vardo ar slaptažodžio praradimo rizika ar internetinių sukčių įsilaužimas į asmeninį kompiuterį, kuriame saugomos skaitmeninės valiutos, ko pasekoje – duomenų atstatymas ar prarastų valiutų atgavimas nėra galimas. Taip pat verta paminėti, kad norint išsigryninti dideles sumas, susiduriama su keblumais, kai finansinės institucijos reikalauja pateikti turto kilmės įrodymus (Angerer et al., 2020). Teisinis reguliavimas apimantis skaitmenines valiutas nėra išvystytas tarptautiniu mastu, taip pat nėra ir jokių tarptautinių susitarimų, kurie užkirstų kelią stambaus masto sukčiavimui ar teroristinių organizacijų finansavimui. Lietuvos Respublikos mokesčių inspekcija 2018-ais metais išleido išaiškinimą, „Dėl virtualiųjų valiutų ir pirminio virtualiųjų žetonų platinimo veiklos mokestinių nuostatų paaiškinimo“, kuriame buvo detalieji pateikti išaiškinimai apie skaitmeninių valiutų procesus ir pirminius žetonų siūlymus. Dokumente taip pat apibrėžtos ribos, nuo kurių pradedamas mokėti GPM (gyventojų pajamų mokestis), PVM (pridėtinės vertės mokestis) ir kiti privalomi mokesčiai pagal pasirinktą veiklos formą (VMI, 2018). Lietuva ne vienintelė šalis siekianti užtikrinti teisinį reguliavimą skaitmeninėms valiutoms, Bulgarija buvo viena iš pirmųjų šalių, pripažinusi bitkoiną, kaip valiutą. Valstybės intencijos buvo gana rimtos šiuo klausimu – lyginant pagal vertę, šiuo metu šalis turi daugiau šios skaitmeninės valiutos negu turimu aukso rezervų – šalis įsigijusi apie 213 tūkst. bitkoino monetų, kurių vertė siekia apie 2,1 milijardo JAV dolerių, o jos turimo aukso vertė 1,8 milijardo JAV dolerių (Coindesk.com, 2017). Šalies vyriausybė aktyviai kuria teisinę bazę skaitmeninėms valiutoms ir siekia apibrėžti aiškų jų reguliavimą. Bitkoino valiutai panašių perspektyvų mato ir Naujoji Zelandija, kuri patapo

pirmoji šalimi pasaulyje, leidusi įmonėms algas mokėti bitkoino skaitmenine valiuta, taip pripažindamas šios valiutos piniginę vertę (Markets.businessinsider.com, 2019). Šie ir kiti panašūs įvykiai pabrėžia, jog valstybės mato skaitmenines valiutas kaip stabilų pagrindą ateityje tiek kaip atsiskaitymo priemonės kontekste, tiek kaip investicine alternatyva ir aktyviai tam ruošiasi. Kadangi skaitmeninių valiutų rinka, turi unikalių savybių, tokių kaip kasimo išlaidos, investuotojų dėmesys, bloko grąžą ir kt., dėl ko skaitmeninių valiutų rinka yra atspari akcijų rinkos veiksniams (Liu ir Tsyvinski, 2018). Šis bruožas iškelia skaitmenines valiutas, kaip alternatyvą renkantis investicijų instrumentus tam, kad diversifikuoti investicijų portfelį ir sumažinti jo riziką. Stebint skaitmeninių valiutų rinkos augimą ir vystymąsi iš investuotojo pusės, ankstyvas įsitraukimas į rinkos investavimą gali patapti puikia investicija ilguoju laikotarpiu, tačiau tam užtikrinti reikia stebėti ne tik skaitmeninių valiutų kapitalizacijos pokyčius tačiau ir aplink šią rinką brėžiamus reguliavimus.

Taip pat yra svarbu apžvelgti mokslinius darbus tiriančiu skaitmeninių valiutų rinkos efektyvumą. Rinkos efektyvumas parodo, kiek rinkos kainos atitinka visą prieinamą informaciją. Taigi, jei skaitmeninių valiutų kainą laikytume efektyvia, tai reikštų, kad rinkoje cirkuliuojančių skaitmeninių valiutų kainos atspindi, visą prieinamą informaciją, todėl nėra pervertintų ar nuvertintų skaitmeninių valiutų. Taip pat jei rinka yra efektyvi, ateities kainos nėra numatomos, o kainų svyravimai yra atsitiktiniai, dėl atsitiktinių ir nenusipėjusių įvykių. Tokie požymiai leistų teigti, kad kainos kitimas yra nepriklausomas ir seka atsitiktinį pasivaikščiojimą (angl. random walk) (Urquhart, 2016). Latifa, Mohdas, Aminos ir Mohamadas (2017) atliko tyrimą vertinant silpnos formos efektyvios rinkos požymius skaitmeninių valiutų rinkoje. Tyrimo rezultatai parodė, kad istoriniai duomenys gali būti naudojami kainų prognozavimui ir tai, kad skaitmeninės valiutos akimirksniu reaguoja į naujai pasirodžiusią informaciją. Viena iš to priežasčių yra tai, kad atvirkščia nei akcijų rinkoje, virtualios valiutos nėra paremtos jokių produktu ar paslauga, kuri taip pat suteiktų informaciją apie vertės kitimą, dėl to informacijos poveikis skaitmeninėms valiutomis yra stipresnis. Didelis jautrumas į naujai atsiradusią informaciją suteikia galimybes kainų manipuliavimui ir spekuliacinio burbulų atsiradimui, ko pasekoje investuotojai neteisingai įvertina skaitmeninių valiutų vertę, taip paveikdami rinkoje atsispindinčią kainą. Šie bruožai remia tyrimus, kurie nustatė, kad daugumą atvejų skaitmeninių valiutų rinka yra neefektyvi (Bartis, 2015); (Wei, 2018); (Urquhart, 2016). Tokių rezultatų pagrindimas yra susijęs su neracionaliu investuotojų elgesiu ir pagrįsto kainų nustatymo mechanizmo nebuvimu. Tačiau žvelgiant į vėliau atliktus tyrimus, kuriuose analizuojami naujesni duomenys, po minėto skaitmeninių valiutų iškilimo laikotarpio, kuris sužadino didelį susidomėjimą skaitmeninėmis valiutomis, yra pastebimas rinkos efektyvumas (Kristoufek ir Vosvrda, 2019); (V. Le Tran & Leirvik, 2020). Tyrimų rezultatai rodo, kad

bitkoinas ypač rodo efektyvumo pokytį po 2017 m. (Tran ir Leirvik, 2020). Tokie rezultatai rodo, kad skaitmeninių valiutų rinka stiprėja ir įgauna efektyvios rinkos požymius. Tai galimai lemia tiek sutvirtėjusi skaitmeninių valiutų vertė ir susidomėjimas tiek įmonių, siekiančių integruoti kriptografinės sistemas į įmonės operacines sistemas, tiek iš investuotojų matančių potencialas galimybes užsitikrinti investicinę naudą.

Apibendrinant, skaitmeninių valiutų rinka vis dar yra besivystanti, tad investavimo galimybės yra supamos įvairiomis rizikomis, tokiomis kaip pilnai neužtikrinta likvidumas, didelis vertės svyravimas, kainų manipuliavimas, kibernetinio saugumo, o kartu ir investicinio turto pažeidžiamumas. Nepaisant to, yra pastebimas rinkos efektyvumo augimas dėl ko rinka tampa tvirtesnė, stabilesnė ir saugesnė renkantis ją, kaip investavimo alternatyvą. Taigi galima teigti, kad turint pakankamai lėšų, nusimanyti ir nesibaiminant rizikos, galima investuoti į skaitmenines valiutas, tačiau nevertėtų į skaitmenines valiutas nukreipti visas savo investicijas, o labiau vertinti, tai kaip investicijų portfelio diversifikavimo galimybę, kadangi kaip jau buvo aptarta, skaitmeninių valiutų rinka pasižymi išskirtiniais bruožais, kurie nėra veikiami akcijų rinkos veiksmų. Renkantis investavimo alternatyvas – svarbu įvertinti, koks yra investavimo tikslas. Nusibrėžus tikslus yra galimas rizikos ir finansinių galimybių vertinimas. Tam, kad sprendimai būtų atlikti remiantis mokslškai pagrįsta informacija ir inovatyviomis technologijomis, kyla poreikis turėti tai atliekančią priemonę. Dėl to yra svarbu apžvelgti investavimo sprendimų paramos sistemas.

1.5. Investavimo sprendimo priėmimo modelis

Tinkamas portfelio sudarymas, lemia generuojamos investicinės grąžos dydį, kuri yra kiekvieno investuotojo pagrindinis interesas. Sparčiai skaitmeninių valiutų rinkos plėtra kelia poreikį turėti inovatyvias ir mokslškai pagrįstas investicijų portfelio sudarymo ir valdymo priemones. Tai skatina mokslo sritį nagrinėti ir kurti pagrįstas žinias ir technologiniais sprendimai aprūpintas investavimo sprendimų sistemas.

Sprendimų paramos sistema (toliau SPS) literatūroje yra aiškinamos, kaip kompiuterinės sistemos, padedančios priimti sprendimą, remiantis supaprastinta informacija, kuri yra gaunama iš sudėtingų duomenų analizės. Po SPS veikimu slypi integruotos teorijos, modeliai ir algoritmai, pritaikyti pateikti supaprastintą informaciją vartotojams (Chiang, Enke, Wu, & Wang, 2016). Taigi sprendimų paramos sistemos tikslas – pateikti būtiną informaciją tam, kad sprendimas būtų atliktas remiantis patikima ir lengvai suvokiama informacija.

Kompiuterinėms technologijoms sparčiai populiarėjant, dėl greitų ir sudėtingų skaičiavimų atlikimo galimybių, naudojant didelius duomenų kiekius, paramos sistemos tampa

išmanesnės ir sugeba apdoroti duomenis sekundžių greitumu. Kainų prognozavimas turi itin svarbią reikšmę formuojant strategijas ir atliekant sprendimus, todėl labai svarbu, kad prognozuojamos reikšmės būtų tikslios tam, kad būtų sumažintas neapibrėžtumas. Prieš išskylant giliojo mokymosi algoritmams, dauguma mokslinių darbų naudojo statistinę analizę, tam, kad išgauti prognozes remiantis istoriniais duomenimis. Tačiau didėjant susidomėjimui patikimu ir greitu duomenų analizavimu ir prognozavimu, vis daugiau dėmesio yra skiriama dirbtiniam intelektui, pagrįstam neuroniniams tinklams (Chiang, Enke, Wu ir Wang, 2016).

Kekytė ir Stasytė (2017) atliko investavimo sprendimų priėmimo modelių ir sistemų lyginamąjį tyrimą, siekiant išanalizuoti, palyginti ir įvertinti literatūroje siūlomus sprendimų modelius taikomus akcijų rinkoje. Vienas iš mokslinio tyrimo uždavinių buvo įvertinti SPS privalumus, trūkumus ir galimybes pritaikyti realioje rinkoje. Autorės pastebėjo, kad dauguma SPS remiasi daugiakriteriu vertinimu, taip pat auga ir dirbtinių neuronų tinklų įtraukimas į sistemas. Atliktas tyrimas parodė, kad dauguma sprendimų priėmimo modelių siekia nustatyti kainos prognozę, judėjimo kryptį, prekybos taškus, tinkamiausią investavimo struktūrą ir portfelio sudėtį.

Analizuojant mokslinę literatūrą buvo pastebėta, kad yra labai mažai mokslinių darbų susijusių su sprendimų paramos sistemų pritaikymu investavimui skaitmeninių valiutų rinkoje. Li ir Wangas (2017) atliko tyrimą apie techninius ir ekonominius veiksnius lemiančius bitkoino vertę, naudodami autoregresinį modelį su pasiskirsčiusiais ankstiniais (angl. ARDL, autoregressive distributed lags model) ir nustatė, kad efektyvinant kasimo technologijas, kasimo išlaidų poveikis kainos vertei ilguoju periodu mažėja. Taip autoriai pastebėjo, kad rinkos tampa atsparesnė spekuliacinėms investicijoms ir vis labiau seka ekonominių veiksnių, tokių kaip infliacija, palūkanų norma ir USD cirkuliacija, pokyčius. Autoriai išvadose teigia, kad skaitmeninių valiutų savybių įvertinimas yra itin svarbus sprendimų paramos sistemos dalis.

Abdo ir Zeadalis (2020) atliko tyrimą apie blokų grandinės sistemos pasirinkimą ir pateikė sprendimų paramos sistemą tam atlikti. Dėl išaugusio susidomėjimo blokų grandinės siūloma, decentralizuotos infrastruktūros, sandorių vykdymo sistema, pritaikoma įvairiems verslo ir asmeniniams poreikiams, iškilio poreikis turėti sistemą galinčią padėti atrinkti tinkamą technologiją. Tam autoriai pasiūlė neuroniniais tinklais paremtą sprendimų schemą, kuri nurodo svarbius charakteristikoms, kurių nėra jokioje kitoje blokų grandinės tipo sprendimų schemoje ir išsprendžia esamų sistemų trūkumus. Autorių pasiūlyta SPS modelis sudaromas atliekant tris pagrindinius žingsnius: duomenų rinkimas, neuroninio tinklo mokymas, rezultatų pateikimas.

Farshidas ir kt., (2020) atliko tyrimą apie blokų grandinės pasirinkimo sistemą pagrįstą neuroniniais tinklais. Autoriai pabrėžė, kad sprendimų priėmimo procesas tampa vis

sudėtingesnis daugėjant sprendimo priėmėjų, alternatyvų ir kriterijų skaičiui. Taigi norint palengvinti šį procesą, yra reikalingi sprendimo priėmimo medeliai, kurie surinktų ir sudėliotų informaciją reikalingą blokų grandinės pasirinkimui. SPS tikslas – parinkti tinkamą blokų grandinės platformą, pagal pasirinkus vartotojo pageidavimus. Autorių pasiūlyta SPS modelis sudaromas taip pat ta pačia seka, kaip prieš tai aptartas – renkant duomenis, apmokant neuroninį tinklą ir pateikiant rezultatus.

Analizuojant mokslinę literatūrą, pastebėtas mokslinių darbų trūkumas, kuriuose būtų siūloma paramos sistemos orientuotos į skaitmeninių valiutų rinkos investavimo proceso gerinimą. Remiantis apžvelgtais tyrimais galima teigti, kad sprendimų paramos sistemoms susijusiomis su investavimu yra būdingi šie žingsniai: duomenų rinkimas, duomenų apdorojimas, prognozavimas, strategijos pasirinkimas ir investicijų portfelio sudarymas. Taip pat, ieškant atliktų mokslinių darbų susijusių su sprendimų paramos sistemomis investuojant skaitmeninių valiutų rinkoje, pastebėta, kad dauguma mokslinių darbų yra orientuoti į blokų grandinės sistemą arba į vienos skaitmeninės valiutos – bitkoino analizavimą. Atsižvelgiant į mokslinių tyrimų trūkumą susijusių su sprendimų paramos sistemomis investavimui skaitmeninių valiutų rinkoje, galima manyti, kad moksliniai tyrimai vis dar yra orientuoti į kapitalo rinkos investavimo sritį, todėl yra svarbu tirti ir plėsti naują požiūrį į investavimą ir jo metodus, susijusius su skaitmeninėmis valiutomis.

Skaitmeninimui įgaunant vis didesnę pagreitį, investavimo operacijos ir sandoriai susiję su jomis tampa vis efektyvesni. Didelis informacijos kiekis, lengvas jos pasiekiamumas sudaro itin sunkias sąlygas investuotojams greitai ir efektyviai atsirinkti ir vertinti teisingą informaciją tam, kad atitinkamai į ją reaguojant būtų priimti teisingi sprendimai. Dėl to yra svarbu moksliai analizuoti skaitmeninių valiutų rinką, kuri itin reaguoja į naujai pasirodžiusią informaciją. Atsižvelgiant į tai, kad skaitmeninių valiutų rinka ir investavimas į ją vis dar kelia didelį neapibrėžtumą, dėl ko investuotojams yra sunku atlikti tinkamus sprendimus investuojant. Taigi kyla poreikis pasiūlyti investavimo skaitmeninių valiutų rinkoje paramos sistemą, palengvinančią investavimo skaitmeninių valiutų rinkoje sprendimą.

2. INVESTAVIMO SKAITMENINIŲ VALIUTŲ RINKOJE TYRIMO METODIKA

2.1. Kuriamasis mokslas

Siekiant pasiūlyti pagalbinę investavimo sprendimo priėmimo sistemą yra remiamasi kuriamojo mokslo metodu. Šis modelis tyrimuose naudojamas kuriant ir vertinant artefaktus siekiant patenkinti nustatytus poreikius (Farshidi ir *kt.*, 2018). (Baskervillis, Storeisas ir Kaulas, 2015) teigia, kad šis metodas taikomas sprendžiant problemas naudojant įgytas žinias, kuriant pokyčius ar tobulinant esamus sprendimus, kartu kaupiant naujas žinias ir įžvelgiant teorinius paaiškinimus. Eggert (2014) apžvelgiant šį metodą, teigia, kad tyrimo rezultatas yra sudaromas iš konstrukto, modelio, metodo ir pritaikomumo. Pasak autoriaus, konstruktas gali būti apibūdinamas, kaip tam tikros idėja ar problemos aiškinimas. Modelis – tai pasiūlymų ar teiginių rinkinys aiškinantis konstruktą. Metodas yra sudarytas iš žingsnių skirtų atlikti tam tikrą užduotį. Žingsniai sudaromi naudojant konstrukto ir modelius. Pritaikomumas tai vieno ar daugiau artefakto pritaikymas kaip specifinio prietaiso ar informacinės sistemos principu. Peffersas, Tuunanenas, Rothenbergeras ir Chatterje (2007) tyrime apie kuriamąjį mokslą pateikė fazes, pagal kurias yra atliekamas tyrimas:

1. Problemos identifikavimas. Šioje priminėje fazėje yra nustatoma problema ir jos sprendimo vertė. Magistro baigiamajame darbe, iškelta problema – investavimo proceso skaitmeninių valiutų rinkoje palengvinimas, pasiūlant sprendimų paramos sistemą, kuri remiasi giliojo mokymosi algoritmu. Problemos tyrimas pridės mokslinės vertės paramos sistemų, skirtų investavimui skaitmeninių valiutų rinkoje, analizavimui ir tolesniam plėtojimui.
2. Sprendimo tikslų nustatymas. Šioje fazėje pateikiamas tikslas nusakantis rezultatą, kurį norima pasiekti. Taigi darbo tikslas – pasiūlyti investavimo skaitmeninių valiutų rinkoje paramos sistemą, pritaikant giliojo mokymosi algoritmą;
3. Modeliavimas ir vystymas – artefaktų modeliavimas, kurie sudarys nagrinėjamos problemos sprendimą. Šioje fazėje nustatomi žingsniai, kuriais bus pasiektas nagrinėjamos problemos tikslas, pateikiami metodai žingsniams vykdyti. Visų pirma magistro darbe buvo išnagrinėtos skaitmeninių valiutų rinkos tendencijos, vidinius ir išorinius rinkos veiksnius. Toliau buvo teoriškai išanalizuoti skaitmeninių valiutų vertinimo ir prognozavimo metodai, investavimo skaitmeninių valiutų rinkoje galimybės ir sprendimų paramos sistemos. Atlikus literatūrinę analizę, remiantis atviros prieigos puslapio coinmarketcap.com skelbiamais duomenimis bus atrenkamos šešios didžiausią kapitalizaciją turinčios skaitmeninės valiutos. Surinkus duomenis, bus

atliktas skaitmeninių valiutų vertės nustatymo ir vertės prognozavimo tyrimus, kurį seka investavimo skaitmeninių valiutų rinkoje įvertinimas;

4. Demonstracija – įrodymas, kad pateikta problemos sprendimo idėja veikia. Šioje fazėje bus testuojama sprendimų paramos sistema sudarant investicijų portfelį;
5. Vertinimas – nustatymas kaip efektyviai veikia suformuoti artefaktai problemos sprendime. Šioje fazėje bus vertinamas sudarytas investicijų portfelis, rezultatus lyginant su akcijų rinkos indeksu. Investiciniai aktyvai pasirenkami remiantis daugiakriterio vertinimo rezultatais ir apžvelgtomis prognozėmis.
6. Komunikacija – tai tyrimo žinių, tiriamos problemos ir rezultatų dalinimasis. Šioje dalyje bus pateikiamos išvados, pastebėjimai ir tyrimo pritaikymo praktikoje galimybės.

Remiantis kuriamojo mokslo metodu, magistro darbe bus siekiama pasiūlyti metodu skirtus palengvinti investavimo sprendimą skaitmeninių valiutų rinkoje. Atlikus nustatytus uždavinius, bus pasiūlytas sprendimų paramos sistemos modelis ir jo pritaikomumas praktikoje. Toliau bus aptariami metodai, naudojami sprendimų paramos sistemos modeliavime.

2.2. Skaitmeninių valiutų vertės nustatymas

Daugiakriteris sprendimų priėmimo metodai (toliau DSPM) yra plačiai naudojami siekiant padėti priimti tinkamą sprendimą, pasirinkant tinkamas alternatyvas arba gauti jų reitingą pagal kelis, tiek kokybinius tiek kiekybinius, kriterijus. Vienas iš dažniausių sutinkamų ir tyrimuose naudojamų DSPM yra TOPSIS – tai reitingą pagal panašų į idealiausią sprendimą ir tolimiausiu atstumu nuo neigiamo idealaus sprendimo suteikiantis metodas. Įvertinus atstumą iki idealiausio sprendimo randamas optimaliausias pasirinkimas (Liang & Xu, 2017). Metodas buvo pristatytas, kaip idėja, kad geriausia pasirenkama alternatyva, turėtų turėti trumpiausią atstumą nuo teigiamo idealaus sprendimo ir tolimiausią nuo neigiamo idealaus sprendimo (Hwang ir Yoon, 1981). Taigi, TOPSIS metodas grindžiamas paprasta idėja – geriausias sprendimas yra gaunamas pasirinkus geriausią alternatyvą, kuri yra toliausiai nuo turinčios mažiausią naudą. Reikėtų paminėti, kad DSPM metodai turi tam tikrų trūkumų, vienas iš jų yra rangų pakeitimo reiškinys (angl. rank reversal), kuris sutinkamas naudojant ir TOPSIS metodą. Airesas ir Ferreiras (2019) pabrėžia, kad problema iškyla, kai yra pridėamos arba šalinamos problemos sprendimo alternatyvos, dėl ko gali kisti pirmenybinė alternatyvų tvarka. Šis fenomenas taip pat gali atsirasti keičiant naudojamą metodą. Kai kuriais atvejais yra galimas visiškasis rango pakeitimas, kai rango tvarkas yra visiškai apversta. Kitaip tariant, pašalinus ar pridėjus alternatyvą, prieš tai buvęs geriausias sprendimas, tampa blogiausias, dėl šio DSPM trūkumo, tyrimas yra ribojamas pasirinktų kriterijų.

TOPSIS modelis sudarytas iš žemiau pateiktų žingsnių (Hwang ir Yoon, 1981, Ginevičius ir Podvezko, 2008):

Pirmas žingsnis: apibrėžiami pradiniai duomenys

$$X = x_{ij} , \quad (1)$$

čia:

X – sprendimų matrica;

x_{ij} – sprendimų matricos elementai – i -tosios alternatyvos j -tojo rodiklio reikšmė;

$x_{ij} \in \mathbb{R}$

$$W = [w_1, w_2, \dots, w_n], \quad (2)$$

čia:

W – reikšmingumo vektorius (svoris);

$w_j \in \mathbb{R}$;

$$w_1 + w_2 + \dots + w_n = 1 , \quad (3)$$

Antras žingsnis: sudarytos matricos elementų normalizavimas pagal formulę:

$$n_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}}, \quad (4)$$

Trečias žingsnis: sudaroma svertinė normalizuota matrica pagal formulę:

$$v_{ij} = w_j n_{ij} , \quad (5)$$

čia $i = 1, \dots, m; j = 1, \dots, n$.

Ketvirtas žingsnis: sudaromi geriausios įmanomos (V^+) ir blogiausios įmanomos (V^-) alternatyvų modeliai:

$$V^+ = (v_1^+, v_2^+, \dots, v_n^+) = \left(\left(\max_i v_{ij} \mid j \in I \right), \left(\min_i v_{ij} \mid j \in J \right) \right), \quad (6)$$

$$V^- = (v_1^-, v_2^-, \dots, v_n^-) = \left(\left(\min_i v_{ij} \mid j \in I \right), \left(\max_i v_{ij} \mid j \in J \right) \right), \quad (7)$$

Penktas žingsnis: Skaičiuojami atstumai iki geriausios (S^+) ir blogiausios alternatyvos (S^-):

$$S_i^+ = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^+)^2}, \quad i = 1, 2, \dots, m, \quad (8)$$

$$S_i^- = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^-)^2}, \quad i = 1, 2, \dots, m, \quad (9)$$

Šeštasis žingsnis: nustatomas kiekvienos alternatyvos santykinis atstumas iki blogiausios alternatyvos:

$$P_i = \frac{S_i^-}{S_i^- + S_i^+}, \quad (10)$$

kur:

$$0 \leq P_i \leq 1,$$


$$i = 1, 2, \dots, m.$$

Septintasis žingsnis: Alternatyvos vertinamos remiantis mažėjančia P_i reikšme. Šiuo žingsniu bus pateikiami skaitmeninių valiutų rangai, taip nustatant patraukliausias sprendimo alternatyvas.

Remiantis šiuo metodu, baigiamojo darbo tiriamojoje dalyje bus atliekamas skaitmeninių valiutų vertinimas tam, kad įvertinti ir išrikiuoti investavimo aktyvus. Šis vertinimo žingsnis yra svarbus, siekiant nustatyti geriausias investavimo alternatyvas. Esant dideliame skaitmeninių valiutų kiekiui, metodas padeda atrinkti tinkamiausias alternatyvas pagal pasirinkus kriterijus. Atsirinkus investavimo aktyvus, sekantis žingsnis yra kainų tendencijų apžvalga ir prognozavimas naudojant giliojo mokymosi algoritmą.

2.3. Kainų prognozavimas naudojant giliojo mokymosi algoritmą metodika

Gilusis mokymasis tai mašininio mokymosi metodas. Gilusis mokymasis yra paremtas neuroninių tinklų struktūra, kurio pagrindu tame pačiame tinkle sujungiami keli procesų lygiai taip, kad įvedus į sistemą duomenis jie pereitų per kiekvieną iš jų. Ši algoritmo struktūra buvo sukurta remiantis žmogaus biologine smegenų struktūra ir jos neuroninio tinklo funkcijomis. Neuronų tinklas yra programavimo sistema, sudaryta iš sujungtų neuronų, kuriais yra perduodami signalai. Ši sistema leidžia kompiuteriui mokytis iš stebėjimo duomenų, taip palaipsniui tobulindama veiksmų atlikimą signalų perdavimo metu (Talo, Baloglu, Yıldırım ir Acharya, 2019). Vieno neurono signalo išvestis (angl. output) veikia kaip kito neurono įvestis (angl. input). Algoritmo veikimo principas yra daugkartinis informacijos apdorojimas, kas suteikia gilesnį ir naudingesnį mokymąsi. Neuronų tinklai dažniausiai yra sudaryti iš sluoksnių, kurių kiekvieną sudaro daugybė neuronų. Tokia struktūra leidžia kompiuteriui rinkti apdorotus duomenis, kurie moko, kaip turėtų būti pakeisti vidiniai parametrai, kad būtų pavaizduotas kiekvieno sluoksnio rezultatas. Rezultatai ar atpažinti pasikartojantys veiksmai yra skaitiniai ir išreikšti vektoriuose, kurie vartotojui pateikiami kaip vaizdai, tekstas, laiko eilutės ir pan. (Zhong, Ling ir Wang, 2018).




4 pav. Neurono tinklo veiklos struktūra

Šaltinis: Love, 2007

Sluoksniai yra surišti mazgais (sinapsėmis), kuriuose vyksta skaičiavimai. Mazgas derina duomenų įvestį su koeficientų arba svorių rinkiniu, kurie tą įvestį arba sustiprina, arba sumažina, taip priskirdami įvesties reikšmę užduočiai, kurią bando išmokyti algoritmas. Sinapsių

ir neuronų sandaugų suma sudaro aktyvavimo funkciją, kuri apriboja neurono išvesties amplitudę. Naudojant aktyvavimo funkciją yra nustatoma, ar ir koku mastu išvesties signalas toliau turėtų būti siunčiamas per tinklą. Jei signalas praeina, neuronas tampa „aktyvuotas“ (Selman, 2012; Mahdavifar ir Ghorbani, 2019). 4 paveikslas vaizduoja neurono tinklo veiklos struktūrą.

Visų pirma yra sudedamos neuronų reikšmės, kurios buvo prieš tai prijungtuose stulpeliuose. Paveiksle vaizduojami keturi signalai (X_1 , X_2 , X_3 , X_4), taigi turime keturis neuronus besijungiančius prie vieno. Kiekvienas signalas yra sudauginamas iš atitinkamo svorio (w_1 , w_2 , w_3 , w_4). Kiekviena neuronų jungtis turi savo svorius reikšmes, kurios yra vienintelės kintančios mokymosi proceso metu. Trečiu žingsniu yra gaunama sandaugų suma. Suma keliauja į aktyvacijos funkciją, kuri dažniausiai yra pakeičiama į reikšmę nuo 0 iki 1. Tam dažniausiai naudojama Sigmoido funkcija, dar vadinama logistine funkcija (žr. 5 pav.). Gauta reikšmė, siunčiama toliau, kaip signalas kitam neuronui (Selman, 2012; Mahdavifar ir Ghorbani, 2019). Pagrindinė neuronų tinklo užduotis yra sugeneruoti išvesties rezultatą kiekvienam signalui. Iš pradžių algoritmas bando nustatyti ir suderinti teisingų atsakymų skaičių, taip kartais tiesiog atspėjant atsakymus. Spėjimai lyginami su realiai duomenimis, pagal ką keičiami parametrai, kol gaunamas rezultatas, taptų panašesnis į pateiktus „tikruosius“ duomenis. Taigi, kol algoritmas „mokosi“ jis tūkstančius kartų spėlioja, lygina, priskiria svorius ir vėl lygina rezultatus, kol spėlionės nustoja tikslėti arba tikslumas tampa per mažas tolesniam tikslinimui (Tang et al., 2018).




5 pav. Sigmoido funkcija

Šaltinis: Chang et al., 2012

Pagrindinis giliojo mokymosi skiriamasis bruožas nuo kitų mašininio mokymosi metodų yra, tai, kad giliojo mokymosi algoritmas klasifikuoja ir mokosi daugiau pagal sutapimus ir tam tikrus aptinkamus duomenų bruožus, negu specifinių užduočių algoritmus. Tai yra naudinga skaitmeninių valiutų prognozavimui, kai pateikus didelį duomenų kiekį, algoritmas surenka


panašius kainų pokyčius. Taip pat algoritmo klasifikatoriai mokosi su įvairiu duomenų kiekiu, kurio rezultato tikslumas gerėja didėjant duomenų kiekiui (žr. 6 pav.) (Tang et al., 2018).



6 pav. Duomenų kiekio įtaka dirbtinio intelekto metodų rezultatų tikslumui

Šaltinis: Tang et al., 2018

Ilgalaikės trumpalaikės atminties tinklas (LSTM) yra besikartojančių neuronų tinklo (angl. recurrent neural network, toliau RNN) algoritmo tęsinys (Hochreiter ir Schmidhuber, 1997). RNN algoritmas geba aptikti stebimų duomenų sekas ir jas tiksliai suklasifikuoti pagal koreliacijos stiprumą. Siekiant pašalinti RNN algoritmo netikslumus besimokant iš laiko eilučių duomenų, buvo sukurta patobulinta jo versija, kuri geba apdoroti ir mokytis iš ilgesnių laiko eilučių – LSTM (Nakisa, Rastgoo, Rakotonirainy, Maire ir Chandran, 2018). Būtent dėl šios priežasties LSTM yra tinkamas metodas skaitmeninių valiutų kainų prognozavimui. Straipsnio tikslui pasiekti bus taikomas sekos eilės mokymosi regresinis modelis (angl. sequence to sequence learning). Šiame ilgalaikės trumpalaikės atminties modelio mokymo būde gauti atsakymai yra mokymosi seka, kurios reikšmės keičiasi per vieną periodą. To pasėkoje, kiekvienos įvesties laiko žingsnyje, LSTM tinklas mokosi numatyti kito laiko žingsnio reikšmę. Taikant šį prognozavimo metodą, LSTM algoritmas mokosi prognozuoti. Tam, kad būtų vykdomi pateikti modelio mokymosi žingsniai taikomas algoritmo kodas (žr. 1 priedą). 7 paveikslas grafiškai pateikia mokymosi žingsniu naudojamus algoritme.



7 pav. Ilgalaikės trumpalaikės atminties neuronų tinklo struktūra

Šaltinis: Le et al., 2019

LSTM tinklas yra sudarytas iš atminties blokų, kurie vadinami ląstelėmis (angl. cells). Duomenų srauto judėjimą sudaro būsenų perdavimas iš vienos ląstelės į kitą: ląstelės būsenos (C_{t-1}), kuri siunčia paskutinio LSTM vieneto atminties informaciją ir paslėptos būsenos (h_{t-1}) – paskutinė LSTM vieneto išvesties. Paslėptoji būseną veikia, kaip neuronų tinklo atmintis – saugo informaciją iš apdorotų duomenų prieš tai. Ši būseną gaunama sudarant vektorius iš esamos ir buvusių įvesčių, taip saugant informaciją apie ne tik esamą bet ir visas buvusias įvestis. Vektorius toliau keliauja per aktyvacijos funkciją (σ), kurios gautas rezultatas yra nauja paslėpta būseną (h_t), kuri toliau keliauja link naujos įvesties (X_t) (Le et al., 2019).

Duomenys iš ląstelės gali būti pašalinti arba pridėti per sigmoido vartus, kartais dar vadinamus reguliatoriais (angl. sigmoid gate). Vartai yra sudaryti iš svorių. LSTM dažniausiai turi tris vartus: įvesties (σ_i), išvesties (σ_o) ir pamiršimo (σ_f). Jų paskirtis yra skirstyti ir reguliuoti duomenų srautus. Išvesties vartai atskiria, kuri informacija turėtų būti palikta, o kuri išmesta. Čia, jei iš sigmoido funkcijos gauta reikšmė yra arti 0, vadinasi, turi būti pamiršta, jei, kuo arčiau 1 – išsaugota. Įvesties vartai skirti ląstelės būsenos atnaujinimui. Čia pirmiausia paskutinė paslėpta būseną ir nauja įvesties suma yra paverčiami į reikšmę, nuo 0 iki 1, naudojant sigmoido funkciją. Suma neuroniniais tinklais keliauja ir į tanh funkciją, kur priskiriama reikšmė nuo -1 iki 1 tam, kad tinklas būtų sureguliuotas. Abiejų funkcijų išskirtys yra sudauginamos ir keliauja į sigmoido funkciją, kur vėl yra sprendžiama ar rezultatas turėtų būti atsimintas ar pamirštas. Apdorota informacija keliauja link prieš tai buvusios ląstelės būsenos (C_{t-1}), kurios reikšmė yra

sudauginama su pamiršimo vartų išvestimi. Gauta sandauga yra susumuojama su įvesties ir tanth funkcijų sandauga. Ši išvestis keliauja toliau, kaip atnaujinta ląstelės funkcija – Ct (Tran et al., 2018).

Išvesties vartai skirti paslėptos ląstelės būsenos atnaujinimui. Tam prieš tai esanti paslėpta ląstelės būsenos reikšmė siunčiama į sigmoido funkciją, kartu su nauja įvestimi. Tuomet gauta reikšmė sudauginama su reikšme gauta siunčiant atnaujintą ląstelę (Ca) į tanth funkciją. Sandauga yra nauja paslėpta išvestis (ht). Apibendrinant, vartai mokosi, kuriuos duomenis reikia palikti, kuriuos išmolti ir saugoti. Tokiu būdu informacija perduodama ilgoje sekų grandinėje (Tran et al., 2018).

Tyrimo praktinėje dalyje ilgalaikės trumpalaikės atminties modelio algoritmas mokomas prognozuoti skaitmeninių valiutų kainas. Žemiau pateikti, duomenų prognozavimo žingsniai:

- Algoritmas mokosi nuspėti reikšmes naudojant prieš tai buvusią laiko eilutės reikšmę iš eilės pagal seką, taip paslenkant kiekvieną buvusią vertę per vieną laiko žingsnį. Mokymuisi bus testuojama ir mokomasi iš 90 % pateiktų duomenų, likusius 10 % prognozuojant ir vertinant nuokrypį nuo gautų reikšmių ir realių duomenų.
- Tam, kad algoritmo mokymasis būtų tikslesnis ir neiškryptų, duomenys standartizuojami, taip kad vidurkio ir vieneto dispersija būtų lygi nuliui.
- Duomenų prognozavimui algoritmas mokomas su kiekviena nauja įvestimi numatyti būsimą reikšmę. Taigi algoritmas mokysis iš numatytų reikšmių sekos principu.
- Numatytos reikšmės lyginamos su mokymosi duomenimis skaičiuojant kvadratų vidurkio kvadratinės šaknies nuokrypį (angl. root mean square error, toliau RMSE) pagal formulę žemiau (Wang ir Lu, 2018):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}, \quad (11)$$

čia:

$\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n$ – prognozuojamos reikšmės;

$y_1, y_2, \dots, y_n$ – realios reikšmės;

n – imties skaičius.

- Naudojant realius duomenis, LSTM tinklas bus atnaujintas tam, kad prognozuojant sekančią laiko žingsnio reikšmę, būtų naudojami realūs duomenys, vietoj prieš tai išprognozuoto, taip tikslinant algoritmo mokymasi ir prognozių rezultatus.
- Vertinamas prognozavimo tikslumas, skaičiuojant kvadratų vidurkio kvadratinės šaknies nuokrypi ir vidutinę absoliutinę procentinę paklaidą (angl. Mean absolute

percentage error, toliau MAPE) . MAPE parodo kiek klaidingos prognozės lyginant su realia reikšme. Paklaida apskaičiuojamas pagal formulę žemiau (Khair, Fahmi, Hakim, & Rahim, 2017):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|, \quad (12)$$

Tam, kad investavimas skaitmeninių valiutų rinkoje būtų efektyvus ir pelningas, itin svarbu turėti tikslias kainų prognozes. Skaitmeninės valiutos pasižymi dažnu kainų kitimu, todėl analizuojant ilgo periodo duomenis ir prognozuojant vertes yra svarbus tinkamas duomenų apdorojimas. Gilusiojo mokymasi algoritmai sugeba išspręsti sudėtingus užduotis naudojant įvairius duomenis ar jų rinkinius, būtent dėl to giliojo mokymosi metodai rodo daug perspektyvos opdorojant laiko eilučių duomenis ir nustanat duomenų tendencijas ir sezoniškumą. Kadangi neuroniniai tinklai leidžia saugoti jau apdorotą informaciją ir lyginti ją su naujai gaunama, taip mokantis kainų kitimą - gauti rezultatai yra tikslūs ir nuodugnai išanalizuoti. Turint kainų prognozes ir įvertinus jų patikimumą, galimas trečias žingsnis – investavimas skaitmeninių valiutų rinkoje.

2.4. Investavimo skaitmeninių valiutų rinkoje vertinimas

Šioje dalyje bus pateikiamos pagrindinės formulės ir skaitinės charakteristikos, kurios bus reikalingos tam, kad patikrinti siūlomo investicijų portfelio efektyvumą.

Ryšio tarp dviejų kintamųjų įvertinimui yra naudojamas koreliacijos koeficientas. Koreliacijos analizė parodo tiesinio ryšio stiprumą. Ryšio stiprumas gali svyruoti nuo -1 iki +1. Kuo koreliacijos reikšmė yra arčiau 1, tuo teigiamas ryšys yra stipresnis. Teigiama koreliacija rodo, kad didėjant vienam kintamajam didėja ir kitas, tuo tarpu, neigiama koreliacija reiškia, kad vienam kintamajam didėjant, kitas mažėja. 0 koreliacijos reikšmė rodo, kad tiesinio ryšio, tarp kintamųjų nėra, taigi kuo reikšmė arčiau nulio, tuo ryšys tarp dviejų kintamųjų yra silpnesnis. Koreliacijos koeficientas yra apskaičiuojamas pagal žemiau pateiktą formulę (Česnulevičiūtė, 2015):

$$r_{x,y} = \frac{\frac{1}{n-1} \sum (x_i - \bar{x})(y_i - \bar{y})}{s_x s_y}, \quad (13)$$

čia:

$\bar{x}$ – kintamojo x vidurkis;

$\bar{y}$ – kintamojo y vidurkis;

S_x ir S_y – standartinis nuokrypis;

n – imties dydis.

Siekiant sumažinti investicijos riziką yra svarbu diversifikuoti portfelio sudėtį. Tai galima atlikti įtraukiant aktyvus, turinčius kuo silpnesnę tiesinę ryšį. Esant neigiamai koreliacijai tarp kintamųjų yra tikslingiausiai išnaudojamas diversifikacijos privalumas.

Norint įvertinti ir palyginti skaitmeninių valiutų pelningumą bus skaičiuojama pelno norma. Literatūroje šis rodiklis dažnai vadinama paprastąja grąža ir yra apskaičiuojama pagal formulę žemiau (Kumar, 2016):

$$x_{ij} = \frac{K_t}{K_{t-1}} - 1, \quad (14)$$

čia:

K_t – j -ojo indekso kaina i -ajį mėnesį;

Magistro darbe yra pasirinkta tirti mėnesinę grąžą. Kadangi portfelio formavime bus naudojamas daugiau negu viena skaitmeninė valiuta, todėl sudaryto portfelio grąža bus skaičiuojama, kaip svartinis grąžos vidurkis:

$$P_i = \sum_{j=1}^n w_j x_{ij}, \quad (15)$$

čia:

x_{ij} – j -ojo indekso i -ojo mėnesio grąža;

w_j – j -ojo indekso svoris portfelyje;

n – imties dydis. Baigiamojo darbo tyrime yra naudojamos keturių skaitmeninių valiutų duomenys, todėl $n=4$.

Tam, kad įvertinti vidutinę portfelio P grąžą, bus apskaičiuota vidutinė laikotarpio grąža:

$$P = \sum_{j=1}^n w_j \bar{x}_j, \quad (16)$$

čia:

$\bar{x}_j$ – j -tojo indekso grąžos vidurkis tyrimo laikotarpiui;

Investicijos rizikos įvertinimui – naudojamas standartinis nuokrypis. Kad paskaičiuoti portfelio standartinį nuokrypį, reikia apskaičiuoti kovariacijos rodiklį. Kovariacija yra apskaičiuojama pagal pateiktą formulę (Klein, Pham Thu, & Walther, 2018):

$$k_{ij} = \frac{(x_i - \bar{x}_i)(x_j - \bar{x}_j)}{n-1}, \quad (17)$$

Kovariacija išreiškia, kiek du atsitiktiniai kintamieji keičiasi kartu. Teigiama kovariacija rodo, kad kintamųjų reikšmės juda ta pačia linkme. Esant neigiamai kovariacijai – kintamųjų pelningumai juda priešingomis kryptimis. Jei kovariacija k_{ij} yra teigiama, tai finansinių aktyvų i ir j pelningumai tuo pačiu metu juda ta pačia kryptimi.

Toliau, kad paskaičiuoti portfelio riziką, reikia apskaičiuoti portfelio grąžos dispersiją pagal formulę žemiau (Klein et al., 2018):

$$D = \sum_{j=1}^n \sum_{i=1}^n k_{ij} w_i w_j, \quad (18)$$

Tuomet portfelio standartinis nuokrypis (rizika) apskaičiuojama pagal formulę žemiau:

$$sd = \sqrt{D}, \quad (19)$$

Vertinant grąžos ir rizikos santykį, dažnai naudojamas Šarpo rodiklis. Šis rodiklis investuotojams padeda įvertinti, kas lemia portfelio grąžą – tinkamai diversifikuotas portfelio valdymas ar didelė prisiimta rizika, kadangi šis rodiklis parodo papildomos investavimo grąžos dydį, tenkantį vienam rizikos vienetui (Sharpe, 1966). Šarpo rodiklis apskaičiuojamas pagal formulę žemiau:

$$SR = \frac{P - r_f}{sd}, \quad (20)$$

čia:

r_f – nerizikinga palūkanų norma yra lygi 0;

P – portfelio grąža;

Šarpo rodikliui esant aukščiau už vienetą, rodo, kad portfelis generuoja didesnę grąžą už prisiimtą riziką.

Baigiamojo magistro darbo portfelio konstravimo tiriamojoje dalyje konstruojamas tolygusis vienodų svorių portfelis. Vienodų svorių apskaičiavimui naudojama formulė žemiau:

$$w = \frac{1}{n}, \quad (21)$$

Vienodų svorių portfelis yra paprasčiausias metodas siekiant sudaryti investicijų portfelį. Šis portfelis dažnai naudojamas, kaip kontrolinis portfelis, su kuriuo yra lyginamos kiti įvairūs portfeliai. Taljaardas ir Maresas (2020) analizavo vienodų svorių portfelių našumą ir pabrėžė, kad portfelis geriau pasirodo ilguoju periodu, lyginant su kitais portfeliais. Atsižvelgiant į tai bus sudaromi kelis skirtingų laikotarpių portfeliai, kad tiksliau įvertinti skaitmeninių valiutų portfelio investicijų portfelio grąžos ir rizikos santykį ir palyginti jį su alternatyvaus investicinio sprendimo - akcijų rinkos indekso, rezultatais,

Apibendrinat investavimo skaitmeninių valiutų rinkoje metodiką, galima teigti, kad vertinant investicines aktyvas yra svarbu išanalizuoti tiek jų vidines, tiek statistines charakteristika. Tinkamas investicinių priemonių diversifikavimas padeda ne tik kontroliuoti riziką, bet ir užsitikrinti stabilesnį pelną, todėl yra svarbu įsivertinti tiesinį ryšį tarp kintamųjų. Įsivertinus investicines alternatyvas sekantis svarbus žingsnis yra tikslų kainų prognozių turėjimas, tam, kad investavimas skaitmeninių valiutų rinkoje būtų apgalvotas ir parinkta tinkama investavimo strategija. Apžvelgus praeities ir prognozuojamas ateities kainų tendencijas ir įsivertinus rinkoje vyraujančias nuotaikas galimas investicijų portfelio sudarymas. Įvertinus ir palyginus sudaryto portfelio grąžą ir riziką galimas tolesnis investicinių portfelių modeliavimas pagal investuotojo pelningumo lūkesčius, toleravimą rizikai ir tolimesnę investicijos valdymo strategija.

3. SKAITMENINIŲ VALIUTŲ VERTĖS NUSTATYMO IR KAINŲ PROGNOZAVIMO TYRIMAS

Šioje dalyje bus siekiama įvertinti skaitmeninių valiutų vidines charakteristikas tam, kad būtų galima nustatyti geriausius investavimo aktyvus. Vertės nustatymui bus naudojamas daugiakriteris artumo idealiajam taškui metodas. Pasirinktos tyrimo skaitmeninės valiutos bus suranguotos ir pagal geriausias alternatyvas pasirinktiems kriterijams. Remiantis skaitmeninėms valiutoms priskirtais rangais ir kainų judėjimo prognozėmis gautomis naudojant giliojo mokymosi algoritmą, bus sudaromas vienodų svorių portfelis, vertinamas jo efektyvumas ir lyginamas su akcijų rinkos indeksu.

3.1. TOPSIS metodas

Tyrimui buvo pasirinktos šešios skaitmeninės valiutos, pagal didžiausią kapitalizaciją rinkoje, remiantis coinmarketcap.com duomenimis: bitkoinas (angl. bitcoin), riplas (agl. ripple arba XRP), eteris (angl. ethereum), litkoinas (angl. litecoin), binanckoinas (angl. Binance Coin) ir bitkoin grynieji (angl. bitcoin cash).

Tyrimo naudojami kriterijai pasirinkti remiantis Hayeso (2017) skaitmeninės valiutos vertės formavimo tyrimu ir Sovbetovo (2018) tyrimu apie skaitmeninių valiutų kainą lemiančius veiksniai. Abiem tyrimams naudoti vidinius veiksniai:

- Likutis – tai santykis tarp šiuo metu rinkoje spekuliuojančių skaitmeninių valiutų ir maksimalaus jų skaičiaus. Kuo mažesnis yra likęs neatrastų blokų kiekis, tuo skaitmeninė valiuta yra vertingesnė. Todėl šis kriterijus yra maksimizuojantis.
- Spekuliavimo laikas – skaitmeninės valiutos egzistavimo laikas, nuo jos išleidimo iki dabar, išreikštas metais. Kuo ilgiau skaitmeninė valiuta egzistuoja, tuo ji yra patrauklesnė. Tai rodo, kad skaitmeninė valiuta yra atsparesnė rinkos veiksniams ir patikimesnė, nei naujai atsiradusios skaitmeninės valiutos. Dėl šios charakteristikos, kriterijus yra maksimizuojantis.
- Kaina – rinkos kaina, išreikšta JAV doleriais. Kuo kaina didesnė, tuo patrauklesnė ji yra vartotojams, tad šis kriterijus taip pat yra maksimizuojantis.
- Bloko laikas (min) – parodo, laiką, per kurį bus kasant surastas skaitmeninės valiutos blokas. Kadangi, kai kurios valiutos duomenų imtyje nėra minuojamos, jų grąža ir laikas lygus nuliui, todėl skaitinė vertė bus suteikta reikšmėms patenkančioms į priskirtų reikšmių intervalus. Kuo ilgesnis kasimo laikas, lyginant

su gautinu blokų skaičiumi, tuo mažiau patraukli yra skaitmeninė valiuta, todėl šis rodiklis yra minimizuojantis.

- Bloko grąža – tai skaitmeninės valiutos vienetų skaičius, kuris gaunamas išminuojant bloką. Šiam kriterijui, taip pat bus suteikiama skaitinė reikšmė. Kuo didesnė grąža, tuo patrauklesnė yra valiuta – todėl kriterijus maksimizuojantis.
- Sudėtingumas – parodo, kaip sunku (skaičiuojant galią) rasti naują bloką. Šiam kriterijui, taip pat bus suteikiama skaitinė reikšmė. Kuo sudėtingesnė yra gavyba tuo mažiau patraukli kasėjams yra skaitmeninė valiuta, todėl kriterijus yra minimizuojantis.
- Algoritmo tipas – bloko minavimo procese yra naudojamas tam tikra sistema. *Script*, buvo pradėta naudoti, siekiant patobulinti prieš tai buvusią *SHA-256* sistemą. Skaitmeninė valiuta, naudojanti *Script* sistemą, yra patrauklesnė, kitiems faktoriams esant lygiems, todėl kriterijus yra maksimizuojantis. Šiam kriterijui, taip pat bus suteikiama skaitinė reikšmė.

Duomenys tyrimui surinkti iš coinmarketcap.com, blockchain.com, etherscan.io, coinbase.com atviros prieigos puslapių pateiktų duomenų. Surinkus ir apdorojus duomenis yra sudaroma septynių atributų reikšmių – rodiklių, pagal visas šešias alternatyvas sprendimų matrica (žr. 2 lentelę). Tyrimo metu, yra daroma prielaida, kad visų kriterijų svoriai yra vienodai lygūs. Skaitmeninės valiutos žymimos trumpiniais: bitkoinas – BTC, riplas – XRP, eteris – ETC, litkoinas – LTC, binanckoinas – BNB ir bitkoin gryniesi – BCH.

2 lentelė. Sprendimų matrica

	max	max	max	min	max	min	max
	Likutis	Spekuliavimo laikas (metais)	Kaina USD	Bloko laikas (min) *	Bloko grąža **	Sudėtingu mas ***	Algoritmo tipas****
BTC	0,857	10	7975,640	3	3	3	2
XRP	43,243	6	0,295	1	1	1	1
BCH	0,860	2	212,690	3	3	2	2
LTC	0,756	8	53,420	2	3	1	1
BNB	1,555	2	18,130	1	1	1	1
ETC	1,000	4	174,220	1	2	4	1

Šaltinis: sudaryta autorės

- * $[0; 2,5) - 1; [2,5; 5) - 2; [5; 10) - 3;$
 ** $[0; 2) - 1; [2; 5) - 2; [5; \infty) - 3;$
 *** $[0; 300) - 1; [300; 9000) - 2; [900; \infty) - 3;$
 **** Scrypt = 2 ; kitos – 1;

Sudarius sprendimų matricą antras žingsnis link alternatyvų prioritetiškumo nustatymo yra pradinių duomenų normalizavimas. TOPSIS metodu duomenys yra normalizuojami bendrai. Duomenų normalizavimas atliekamas kiekvieną veiksnį dalinant iš visų veiksmių kvadratų sumos šaknies (žr. 3 lentelę).

3 lentelė. TOPSIS normalizuota sprendimų matrica

	max	max	max	min	max	min	max
valiuta / kriterijus	Likutis	Spekuliavimo laikas	Kaina USD	Bloko laikas (min)	Bloko grąža	Sudėtingumas	Algoritmo tipas
BTC	0,020	0,668	0,999	0,600	0,522	0,530	0,577
XRP	0,999	0,401	0,000	0,200	0,174	0,177	0,289
BCH	0,020	0,134	0,027	0,600	0,522	0,354	0,577
LTC	0,017	0,535	0,007	0,400	0,522	0,177	0,289
BNB	0,036	0,134	0,002	0,200	0,174	0,177	0,289
ETC	0,023	0,267	0,022	0,200	0,348	0,707	0,289

Šaltinis: sudaryta autorės

Tyrimo metu yra laikomasi prielaidos, kad visų kriterijų svoriai yra vienodi, todėl svertinė normalizuota matrica atitinka 3-ioje lentelėje pateiktus duomenis. Toliau, reikia sudaryti geriausios įmanomos V^+ ir blogiausios įmanomos V^- alternatyvų modelius (žr. 4 lentelę). Čia geriausiai alternatyvai minimizuojančiam kriterijui, ieškome mažiausios reikšmės, maksimizuojančiam – pačios didžiausios. Blogiausios įmanomos alternatyvos modelis sudaromas maksimizuojančios reikšmės ieškant mažiausios imties reikšmės, minimizuojančios – aukščiausios.

4 lentelė. TOPSIS alternatyvų modeliai

Alternatyva / kriterijus	Likutis	Spekuliavimo laikas	Kaina USD	Bloko laikas (min)	Bloko grąža	Sudėtingu- mas	Algoritmo tipas
V+	0,9985	0,6682	0,9994	0,2000	0,5222	0,1768	0,5774
V-	0,0175	0,1336	0,0000	0,6000	0,1741	0,7071	0,2887

Šaltinis: sudaryta autorės

Sudarius alternatyvų modelius, sekančiu žingsniu yra skaičiuojami atstumai atitinkamai i -ajai alternatyvai iki geriausios įmanomos ir blogiausios įmanomos alternatyvų. Gavus rezultatus, galutinis TOPSIS metodo žingsniu nustatomas kiekvienos i -osios alternatyvos santykinis atstumas P_i iki blogiausios įmanomos alternatyvos. P_i turi patekti į intervalą $0 \leq P_i \leq 1$. Pagal gautus alternatyvos santykio atstumus, bus vertinamos skaitmeninės valiutos (žr. 5 lentelę). Racionalus variantas bus tas, kurio reikšmė yra didžiausia. S^+ atstumai kiekvienai alternatyvai gaunami ištraukus šaknį iš kriterijų ir atitinkamai geriausios alternatyvos skirtumų kvadratų sumos. Atitinkamai, S^- kiekvienai skaitmeninei valiutai gaunami, skaičiuojant šaknį iš kriterijų ir atitinkamai blogiausios alternatyvos skirtumų kvadratų sumos (žr. 5 lentelę). Apskaičiuoti atstumai iki alternatyvų, gaunamas santykinis atstumas P_i iki blogiausios įmanomos alternatyvos pagal kurį yra vertinamos alternatyvos (žr. 5 lentelę):

5 lentelė. TOPSIS alternatyvų atstumai

Skaitmeninė valiuta	S_i^+	S_i^-	P_i	Vieta
BTC	1,115	1,233	0,525	1
XRP	1,129	1,215	0,518	2
BCH	1,543	0,575	0,271	5
LTC	1,445	0,777	0,350	3
BNB	1,553	0,665	0,300	4
ETC	1,569	0,457	0,225	6

Šaltinis: sudaryta autorės

Daugiakriteris TOPSIS metodas pirmoje vietoje, geriausią alternatyvą nustato bitkoino skaitmeninę valiutą. Išanalizavus kriterijus, pastebima, kad lyginant su alternatyvomis, bitkoinas turi didžiausią atstumą nuo blogiausios alternatyvos. Rezultatą lemia aukšta skaitmeninės valiutos kaina, ganėtinai mažas likutis neatrastų blokų ir blokų grąžą, lyginant su kitomis imties valiutomis. Antroje vietoje yra riplas, kuriam panašiai kaip bitkoinui, didelę persvarą suteikia neatrastų blokų likutis. Persvarą taip pat teikia didelis atstumas, tarp spekuliacinio ir bloko minavimo laiko. Žemas minavimo sudėtingumas taip pat pakelia skaitmeninės valiutos rangą. Remiantis gautais rezultatais galime teigti, kad geriausia investavimo pasirinkimo alternatyva yra bitkoino skaitmeninė valiuta, kadangi ji turi mažiausią atstumą nuo idealaus sprendimo ir didžiausią atstumą nuo blogiausio sprendimo. Taip pat, galima teigti, kad ilgas spekuliacinio laikas, rodantis, kad skaitmeninė valiuta yra tvirta ir atspari rinkos veiksniams ir didelė blokų grąžą gaunama išminavus skaitmeninę valiutą indikuoja tvarios ir vertingos skaitmeninės valiutos bruožus.

Įvertinus skaitmenines valiutas pagal vidinius jų veiksnis, svarbu apžvelgti ir įvertinti kainų pokyčių tendencijas skaitmeninių valiutų rinkoje. Tikslus prognozavimas yra ypač

svarbus, norint sudaryti investavimo strategijas. Siekiant generuoti investicines pajamas svarbu ne tik prognozuoti, tačiau ir turėti prietaisą, kuris greitai apdorotų didelį kiekį duomenų, nuolat atnaujinant informaciją ir prognozes pagal rinkoje vykstančius pokyčius. Vienas iš patikimiausių tam atlikti prietaisų – giliojo mokymosi algoritmas, kurio veikimo pagrindas paremtas neuroniniais tinklais.

3.2. Giliojo mokymosi algoritmo taikymo skaitmeninių valiutų kainų prognozavimui tyrimas

Kainų prognozavimo tiriamojoje dalyje pasirinktos penkios, aukščiausią įvertinimą gavusios skaitmeninės valiutos, pagal TOPSIS daugiakriterį vertinimą: BTC, XRP, LTC, BCH, BNB. Algoritmo mokymui ir skaitmeninių kainų prognozavimui yra pasirinktos kasdieninės uždarymo kainos. Duomenys surinkti iš atviros prieigos svetainės finance.yahoo.com. Kainos prognozuojamos algoritmą mokant iš trejų skirtingų laikotarpių: 2017-08-01 – 2020-07-31, 2019-08-01 – 2020-07-31 ir 2017-04-01 – 2020-07-31, siekiant palyginti algoritmo prognozavimo tikslumą esant skirtingiems duomenų kiekiams.

Skaitmeninių valiutų kainų prognozavimas atliekamas naudojant „Matlab“ programinę terpę, kuri yra skirta įvairiems matematiniams veiksams atlikti, vienos iš jų – operacijos matricomis. Ši programa pasirinkta dėl savo neuroninių tinklų funkcijų rinkinio, kuris skirtas neuroninių tinklų kūrimui. Toliau pateikti duomenų prognozavimo žingsniai:

Visų pirma, kainoms prognozuoti visiems duomenims naudojami vienodi parametrai. Tai yra svarbu, norint, kad duomenys mokymosi proceso metu neiškryptų ir būtų tinkami neuronų tinklui formuoti, taigi nustatomi nulinio vidurkio ir vienetinio dispersijos standartizavimo reikšmės. Šiame žingsnyje, algoritmas standartizuoja mokymosi duomenis, t. y. 90 % analizuojamo periodo. Kadangi duomenų kiekis didelis, nustatoma, kad LSTM sluoksnis turės 200 paslėptųjų jungčių, taip sukuriant LSTM regresijos tinklą. Prognozavimas vyks sekos principu, todėl algoritme nurodoma, kad mokymasis vyktų iš išvesties, t. y. su kiekviena įvestimi, LSTM numatys tolesnį žingsnį, jo atsakymas bus naudojamas kitam žingsniui numatyti ir t. t., dėl ko mokymasis neturi galutinės mokymosi įvesties. Siekiant kuo tikslesnių rezultatų, duomenims atnaujinti nurodoma 300 epochų. Šios epochos reprezentuoja, kiek kartų visi mokymo vektoriai bus naudojami svoriams atnaujinti. Nustačius būtinus parametrus algoritmo veikimui, galimas antras žingsnis – prognozavimas.

Parinkus mokymosi parametrus, LSTM algoritmas mokomas naudojant „trainNetwork“ funkciją „Matlab“ programinėje terpėje. Šiame etape 90 % testuojamų duomenų yra naudojami mokymuisi, kur likę 10 % duomenų yra prognozuojami ir vertinamas jų tikslumas. Kainų

prognozavimui algoritmas mokomas su kiekviena nauja įvestimi numatyti būsimą reikšmę. Taigi algoritmas mokysis iš numatytų reikšmių sekos principu. Toliau išprognuozuotos reikšmės lyginamos su tikrosiomis reikšmėmis skaičiuojant kvadratų vidurkio kvadratinės šaknies nuokrypį. Kadangi tyrime naudojami istoriniai duomenys, LSTM tinklas pakartotinai atnaujinamas naudojant realius duomenis. Šioje dalyje prognozuojant sekančią laiko žingsnio reikšmę, algoritme yra naudojami realūs duomenys, vietoj prieš tai išprognuozuoto, taip tikslinant algoritmo prognozavimą. Gavus galutines prognozes trečiuoju žingsniu yra vertinamas prognozavimo tikslumas. Čia skaičiuojant kvadratų vidurkio kvadratinės šaknies nuokrypi (RMSE), kuris parodo nuokrypių sklaidą, tad kuo didesnis RMSE, tuo didesni prognozių nuokrypiai nuo realių reikšmių. Taip pat skaičiuojama vidutinė absoliutinė procentinę paklaidą (MAPE), kuri parodo prognozių tikslumą. Visų pirma apžvelgiame prognozuojamų reikšmių sklaidą, nuo tikrųjų reikšmių. Apskaičiuotos RMSE reikšmės, naudojant atnaujintą LSTM tinklą pateikiamos 6-oje lentelėje. Kadangi RMSE parodo nuokrypių sklaidą, todėl kuo didesnis RMSE rezultatas, tuo didesni prognozių nuokrypiai nuo realių reikšmių.

6 lentelė. Prognozuojamo laikotarpio reikšmių RMSE

Laikotarpis	BTC	XRP	BCH	LTC	BNB
2017-08-01 – 2020-07-31	313,5959	0,0086	8,0616	1,8107	0,4638
2019-08-01 – 2020-07-31	1 232,9634	0,0136	11,3460	3,8263	0,8261
2020-04-01 – 2020-07-31	1 152,4316	0,0168	28,3337	10,4937	3,1674

Šaltinis: sudaryta autorės

Analizuojant RMSE rezultatus pastebėta, kad esant didesnei duomenų imčiai, gaunama mažesnė prognozuojamų kainų paklaidą. Taip pat lyginat vidutines prognozuojamo periodo skaitmeninių valiutų kainas (žr. 7 lentelę) ir prognozių sklaidos dydį, galima teigti, kad esant didesnei kainai, sklaidą yra didesnė, vadinasi rizika, patirti didesnę prognozuojamų ir gautų rezultatų skirtumą, yra didesnė.

7 lentelė. Vidutinė kaina (USD) prognozuojamam periodui

Laikotarpis	BTC	XRP	BCH	LTC	BNB
2017-08-01 – 2020-07-31	9 132,4605	0,1995	240,3961	44,8835	16,8507
2019-08-01 – 2020-07-31	9 526,8786	0,1994	238,6308	45,582493	17,4846
2020-04-01 – 2020-07-31	10 183,6310	0,2199	258,1224	51,5384	19,2322

Šaltinis: sudaryta autorės

Remiantis gautais rezultatais, pateiktais 8-oje lentelėje, galima teigti, kad nepaisant skaitmeninių valiutų kainų skirtumų, RMSE ir vidutinės kainos santykis prognozuojamaisiais periodais yra panašus – 2017–2020 m. laikotarpiu neviršija 0,04. 2018–2020 m. laikotarpius svyruoja tarp 0,05 ir 0,1, o esant mokymuisi tik iš trejų mėnesių yra tarp 0,08 ir 0,2. Lyginant kainų nuokrypių sklaidą su vidutine skaitmeninės valiutos kaina, pastebėta, kad didėjant algoritmo mokymosi laikotarpiui gaunama santykinai mažesnė sklaida (žr. 8 lentelę).

8 lentelė. RMSE ir skaitmeninės valiutos vidutinės kainos prognozuojamo periodo laikotarpiui santykis

Laikotarpis	BTC	XRP	BCH	LTC	BNB
2017-08-01 – 2020-07-31	0,03	0,04	0,03	0,04	0,03
2019-08-01 – 2020-07-31	0,13	0,07	0,05	0,08	0,05
2020-04-01 – 2020-07-31	0,11	0,08	0,11	0,20	0,16

Šaltinis: sudaryta autorės


9 lentelėje pateikiami vidutinė absoliutinės procentinės paklaidos skaičiavimai pirmoms dviem prognozių savaitėms. Apskaičiuotas MAPE reprezentuoja prognozavimo tikslumą – paklaidos dydį procentais nuo tikrųjų reikšmių. Gauti MAPE rezultatai leidžia teigti, kad esant trumpesniui mokymosi laikotarpiui gaunama didesnė prognozių paklaida (žr. 9 lentelę). Algoritmui mokantis iš trejų metų duomenų, kainų prognozių procentinė paklaida svyruoja tarp 2 – 3 %, kur mokantis iš vienerių metų kainų duomenų, MAPE padidėja, išskyrus dviem skaitmeninėms valiutoms – BCH ir BNB. Analizuojant vidutinės absoliutinės procentinės paklaidos rezultatus, mokymosi laikotarpiui esant tik 3 mėnesiams, pastebėta, kad prognozių tikslumas mažėja, t. y. MAPE didėja. Vertinant MAPE rezultatus, galima teigti, kad esant ilgesniui duomenų mokymosi laikotarpiui, gaunama mažesnė prognozių paklaida. Gauti MAPE skaičiavimai taip pat patvirtina teiginį, kad algoritmo rezultato tikslumas gerėja didėjant duomenų kiekiui (žr. 5 pav.).

9 lentelė. Prognozuojamo laikotarpio reikšmių MAPE

Laikotarpis	BTC	XRP	BCH	LTC	BNB
2017-08-01 – 2020-07-31	2,0186%	3,1466%	3,2883%	2,7368%	2,9582%
2019-08-01 – 2020-07-31	4,0361%	4,4297%	1,8485%	3,5866%	2,7492%
2020-04-01 – 2020-07-31	7,8732%	5,3244%	9,0192%	16,3688%	13,7643%

Šaltinis: sudaryta autorės


9-oje lentelėje pateikti duomenys rodo, kad didžiausias RMSE nuokrypis yra bitkoino skaitmeninės valiutos duomenims. Šie rezultatai buvo tikėtini, kadangi bitkoinas turi didžiausią kainą (žr. 7 lentelę) lyginant su kitomis tiriamomis skaitmeninėmis valiutomis. Taip pat, ši skaitmeninė valiuta turi didžiausią kapitalizaciją skaitmeninių valiutų rinkoje ir sulaukia didžiausio investuotojų susidomėjimo, kas lemia akivaizdų RMSE reikšmės atotrūkį, nuo likusių rezultatų. Kadangi bitkoino kainos pokyčiai taip pat jautresni tiek ekonomikos svyravimams, tiek socialinėse erdvėse vyraujantiems vartotojų lūkesčiams, algoritmui yra sunkiau mokytis ir tiksliau prognozuoti kainos pokyčius, ko pasėkoje paklaida didėja, ypač algoritmui mokantis iš trumpesnio laikotarpio duomenų. Apibendrinant MAPE rezultatus, algoritmui mokantis iš trejų metų duomenų, gaunamas mažiausias procentinis paklaidos dydis nuo tikrųjų reikšmių. Derėtų pabrėžti, kad analizuojami skaitmeninių valiutų duomenys ir prognozės apima globalios pandemijos laikotarpį. COVID-19 pandemija ir tarptautinis atsakas į ją akivaizdžiai pastūmėjo pasaulį link internetinės ekosistemos, įskaitant skaitmenines finansines operacijas. Susirūpinimas dėl viruso plitimo esant artimam kontaktui tiek su žmonėmis tiek su daiktais, tokiais kaip monetos, čekiai, dokumentai ir pan. skatino ieškoti ir naudotis grynųjų pinigų ar tiesioginio kontakto nereikalaujančios atsiskaitymo ir sandorių sudarymo alternatyvų. Operacijų vykdymo delsimai, su jomis susiję mokesčiai ir asmeninių duomenų rinkimas sulaukė vis didesnio dėmesio. Tvyrant tiek politiškai tie socialiai įtemptai situacijai visame pasaulyje, grafiškai pateikus prognozuojamas kainas (žr. 8 pav.), matome, kad kainos kitimo prognozuojam reikšmių tendencija vizualiai atitinka realius duomenis, ypač augantį kainos kitimo trendą. Pastebima, kad LSTM algoritmas prognozavo mažesnes, negu realias kainas – raudona grafiko linija reprezentuojanti prognozuotas kainas yra žemiau mėlynos, kurioje pavaizduotos tikrosios reikšmės.



8 pav. BTC skaitmeninė valiutos LSTM algoritmo prognozės 2017-08-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės


Santykinai didžiausia nuokrypių sklaida yra litkoino skaitmeninė valiuta, algoritmą mokant iš trejų mėnesių uždarymo kainų judėjimo duomenų. 9-ame paveiksle grafiškai vaizduojamas realios ir prognozuojamos uždarymo kainos. Analizuojant pateiktus duomenis pastebima, kad algoritmo mokymosi rezultatai pateikė mažesnes, negu realias skaitmeninių valiutų kainas. Didžiausias kainų atotrūkis yra penktą prognozavimo dieną, kur reali skaitmeninės valiutos kaina pakilo nuo 52,95 iki 55,58 JAV dolerių, o prognozių rezultatai pateikė atvirkščiai – kainos sumažėjimą nuo 43,00 iki 41,46 JAV dolerių (žr. 9 pav.).



9 pav. LTC skaitmeninės valiutos LSTM algoritmo prognozės 2020-04-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės


Lyginat litkoino skaitmeninės valiutos prognozių duomenis, kai LSTM algoritmas mokomas iš trejų metų duomenų, pastebima, kad atvirkščiai nei bitkoino prognozės, čia kainos yra aukštesnės nei realios prognozuojamam laikotarpiui. Taip pat galima pastebėti, kad prognozuojamos kainos yra tarsi pasislinkusios viena laiko eilute į priekį. Analizuojant 10-ame paveiksle vaizduojamas kainas, stebina tai kad modelis išprogozavo didelį kainos kritimą 18–21 dienomis, staigų kilimą nuo 70 dienos tiek visą kainos kitimo tendenciją (žr. 10 pav.). Tam įtakos galima turi žemesnė skaitmeninės valiutos kaina, dėl ko yra gaunama mažesnė paklaidos sklaida ir tikslesnės prognozės.



10 pav. LTC skaitmeninės valiutos LSTM algoritmo prognozės 2017-08-01 – 2020-07-31 mokymosi laikotarpiui


Šaltinis: sudaryta autorės

XRP skaitmeninė valiuta pasižymi itin stabiliais tiek MAPE tiek RMSE pokyčiais skirtingais duomenų imties periodais. Paklaidos dydis procentais nuo tikrųjų reikšmių yra didžiausias būtent šiai skaitmeninei valiutai esant ilgiausiam algoritmo mokymosi periodui (žr. 3 lentelę). Analizuojant 11-ame paveiksle grafiškai pateiktų duomenų, pastebėta, kad nors ir kainos tendencija atitinka realų XRP kainos judėjimą, tačiau pačios prognozės yra chaotiškesnės – raudona linija, reprezentuojanti prognozuotas kainas, dažnai tai pakyla, tai nusileidžia po mėlyna – realių realių kainų linija (žr. 11 pav.). 12-ame paveiksle grafiškai pateita nuokrypių sklaida. Iš paveikslo aiškiai matosi, kad kainos prognozės yra nepastovios. Tam įtakos turi itin maža skaitmeninės valiutos kaina – vidutiniškai nesiekiantis 0,20 JAV dolerių.



11 pav. XRP skaitmeninės valiutos LSTM algoritmo prognozės 2017-08-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės



12 pav. Prognozių nuokrypių sklaida XRP skaitmeninei valiutai 2017-08-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės

Apibendrinant prognozių rezultatus (žr. 2–12 priedus) galima teigti, kad LSTM modelis pateikia tikslesnes prognozes mokant iš ilgesnio duomenų kiekio. Taip pat, galima teigti kad algoritmas visoms penkioms skaitmeninėms valiutoms prognozavo realius duomenis atitinkančias kainų kitimo tendencijas. Analizuojamų skaitmeninių valiutų kainų prognozių,

nuokrypis yra palyginti mažas – neperkopia 3 % didžiausią kapitalizaciją turinčiomis skaitmeninėms valiutoms algoritmą apmokant su trejų metų duomenimis į kuriuos įeina pandemijos laikotarpis, tad LSTM modelis tiksliai pavaizduoja kainos kitimo tendenciją. Viena vertus tai rodo, kad skaitmeninių valiutų rinka yra nuspėjama ir juda ne pagal atsitiktinio pasivaikščiojimo teoriją, kita vertus, tokie rezultatai leidžia teigti, kad giliojo mokymosi algoritmas yra saugus prietaisas norint įsivertinti galimas skaitmeninių valiutų kainų vertes ateityje pagal istorinius kainų duomenis. Tai itin svarbu konstruojant investicijų portfelį ir vertinant galimus investicinius scenarijus ir su jais susijusia riziką.

3.3. Portfelio sudarymas

Šioje tyrimo dalyje bus demonstruojamas siūlomo modelio efektyvumas. Remiantis TOPSIS rezultatais pasirenkamos keturios aukščiausios įvertinto skaitmeninės valiutos: BTC, XRP, LTC ir BNB. Portfelio duomenų laikotarpis – 2017–2020 m. Iš pasirinktų skaitmeninių valiutų bus sudaromas vienodų svorių portfelis. Siekiant palyginti skaitmeninių valiutų kainų pokyčius prieš ir po pandemijos, skaitmeninių valiutų kainų duomenys dalinami į du intervalus: 2017–2018 m. ir 2019–2020 m. Sudaromi vienodų svorių portfeliai – visiems aktyvams priskiriami vienodus svorius: 0,25. Sudaromi vienodų svorių skaitmeninių valiutų portfeliai:

- Eqw_t1 – 2017–2018 m. kainų duomenys;
- Eqw_t2 – 2019–2020 m. kainų duomenys;
- Eqw – 2017–2020 m. kainų duomenys.

Taip pat, rezultatų lyginimui su akcijų rinkos indeksu, atitinkamai padalinami ir S&P 500 kainų duomenys:

- S&P 500 t1 – 2017–2018 m. kainų duomenys;
- S&P 500 t2 – 2019–2020 m. kainų duomenys;
- S&P 500 – 2017–2020 m. kainų duomenys.

Siekiant įvertinti sudarytų portfelių efektyvumą, paskaičiuojamos paprastosios grąžos, standartinis nuokrypis, parodantis riziką ir Šarpo rodikliai. S&P 500 akcijų rinkos indeksas reprezentuoja 500 didžiausių Jungtinės Amerikos Valstijų įmonių akcijų našumą, todėl siekiant palyginti skaitmeninių valiutų grąžą ir riziką su akcijų rinka, atitinkamai paskaičiuojami rodikliai ir indekso duomenims. Skaičiavimai buvo atliekami naudojant „RStudio“ programą. Portfelių sudarymo ir skaičiavimo kodas pridėtas 13-ane priede. Gauti rezultatai pateikti 11-oje lentelėje. Remiantis pateiktais rezultatais galime teigti, kad skaitmeninių valiutų portfelis generuoja didesnę grąžą lyginant su rinkos akcijų indeksu visais periodais. Skaitmeninių valiutų portfelis generuoja didesnę grąžą prieš COVID-19 pandemiją (žr. 11 lentelę, eqw_t1). Lyginant

su akcijų rinkos indeksu, didesnė grąža yra generuojama periode nuo 2019 m. Žvelgiant į standartinio nuokrypio skaičiavimus, skaitmeninių valiutų portfeliai visais periodais turi didesnę riziką, lyginant su SP 500 indeksu. Taigi galima teigti, kad didesnė skaitmeninių valiutų grąža yra gaunama su atitinkamai didesne rizika.


10 lentelė. Grąžos, rizikos, Šarpo rodikliai

	Grąža	Rizika	Šarpo rodiklis
Eqw_t1	6,1428	5,3646	1,1451
Eqw_t2	0,8370	0,8398	0,9966
Eqw	3,5558	3,7738	0,9422
S&P 500 t1	0,0171	0,1325	0,1294
S&P 500 t2	0,1837	0,2003	0,9170
S&P 500	0,1050	0,1710	0,6141
BTC	0,8681	0,9420	0,9215
LTC	0,8100	1,3963	0,5801
BNB	8,8287	12,258	0,7202
XRP	2,5571	4,8254	0,5299

Šaltinis: sudaryta autorės

Vertinant grąžos ir rizikos santykį išreikštą Šarpo rodikliu (žr. 11 lentelę), matome, kad tik vienas portfelis generuoja didesnę grąžą už prisiimtą riziką – eqw_t1. Lyginant Šarpo rodiklius pilnam periodui, skaitmeninių valiutų portfelio rodiklis yra didesnis, negu S&P 500 indekso, vadinasi, investuojant į skaitmeninių valiutų portfelį santykinė grąža prisiimtai rizikai yra didesnė negu akcijų rinkos indekso.

Portfelio suderinamumą tarp grąžos ir rizikos galima pateikti grafiškai, plokštumoje atidedant investicijų portfelio standartinį nuokrypį ir grąžos vidurkį. 13-ame paveiksle galima matyti skaitmeninių valiutų, sudarytų vienodų svorių portfelių ir rinkos indekso grąžą ir riziką pateiktą grafiškai. Iš pateikto grafiko matome, kad S&P 500 indeksas turi žemiausią riziką ir grąžą negu skaitmeninių valiutų portfeliai. Taip pat pastebėta, kad itin didelį grąžos rodiklį turi BNB skaitmeninė valiuta, tačiau ji taip pat turi ir didžiausią riziką. Sudarant portfelį, siekiant geresnių rezultatų, vertėtų įsivertinti portfelio našumą ir Šarpo rodiklį be jos. Toliau analizuojant gautus rezultatus, galima teigti, kad Eqw_t1 portfelis turi didžiausią grąžą ir yra labiausiai nutolęs nuo eqt ir eqt_t2 portfelių. Eqt_t1 portfelis yra ties didžiausiu kampu, kuriam didėjant, reiškia kad prisiimama vis daugiau rizikos didinant grąžos vienetą.



13 pav. Grąžos ir rizikos

Šaltinis: sudaryta autorės

Iš 13-ojo paveikslo pastebima, kad tiek S&P 500 indekso, tiek sudarytų skaitmeninių valiutų portfelių išsidėstymas grąžos ir rizikos santykiu yra nevienodas, tad vertėtų įsivertinti ryšį tarp grąžų. Šis žingsnis padės suprasti, kaip glaudžiai finansiniai aktyvai ir jų generuojamos grąžos yra susiję vienos nuo kitų. Siekiant įvertinti ryšį tarp kintamųjų, apskaičiuojamas mėnesinių grąžų koreliacijos koeficientas, gauti rezultatai pateikiami 10-oje lentelėje.


11 lentelė. Mėnesinių grąžų koreliacijos koeficientai 2017 – 2020 m.

	BTC	XRP	BNB	LTC	GSPC
BTC	1,0000	0,3273	0,4826	0,7471	0,1683
XRP	0,3273	1,0000	0,1855	0,7571	0,0159
BNB	0,4826	0,1855	1,0000	0,3899	-0,0238
LTC	0,7471	0,7571	0,3899	1,0000	0,1061
GSPC	0,1683	0,0159	-0,0238	0,1061	1,0000

Šaltinis: sudaryta autorės

Gauti rezultatai rodo, kad LTC ir BTC skaitmeninės valiutos turi stiprų tiesinį ryšį 0,75 (žr. 13 pav.). LTC ir CRP taip pat rodo stiprų ryšį – 0,76. Taigi didėjant bitkoino grąžai, didėja ir litkoino skaitmeninės valiutos grąža. Taip pat didėjant litkoinui, auga ir riplo grąža. Esant tokiems rezultatams tikėtasi, kad stiprus teigiamas ryšys bus ir tarp riplo ir bitkoino

skaitmeninių valiutų, tačiau šių dviejų aktyvų koreliacijos koeficientas yra tik 0,33 (žr. 10 lentelę), kas patenka į silpno teigiamo teisinio ryšio intervalą (žr. 13 pav.). Iš 10-os lentelės pateiktų duomenų galima pastebėti, kad BNB turi labai silpną ryšį su XRP skaitmenine valiuta ir silpną neigiamą ryšį su S&P 500 indeksu (žr. 10 lentelę, GSPC), vadinasi, didėjant akcijų indekso grąžai, skaitmeninės valiutos grąža mažėja. Taip pat pastebima, kad akcijų rinkos indeksas turi silpną teigiamą koreliaciją su BTC ir LTC ir beveik nekoreliuoja su XRP skaitmeninės valiutos kainų grąžą. Apibendrinant skaitmeninių valiutų ir akcijų rinkos gražų tiesinį ryšį, galima teigti, kad jis yra labai silpnas – neviršija 0,17, tad naudojant skaitmenines valiutas ir akcijas investicijų portfelyje būtų užtikrintas rizikos diversifikavimas.



14 pav. Skaitmeninių valiutų gražų koreliacijos stiprumas

Šaltinis: sudaryta autorės

Apibendrinant rezultatus, galima teigti, kad sudarytas skaitmeninių valiutų portfelis Eqt iš esmės atitiko lūkesčius – jis pralenkė S&P 500 indeksą generuojama grąža, kas leidžia teigti, kad siūlomas portfelio sudarymo metodas padeda atrinkti tinkamus aktyvus investavimui. Kita vertus, gauti rezultatai leidžia manyti, kad skaitmeninės valiutos yra rizikingesnė investicija, lyginat su akcijų rinka. Tai rodo, kad investuojant į skaitmenines valiutas galima tikėtis didesnės grąžos, tačiau ji gaunama su didesne rizika. Vertinant tiesinio ryšio rezultatus tarp gražų, rezultatai leidžia teigti, kad skaitmeninių valiutų aktyvų įtraukimas į investicijų portfelį padėtų padidinti diversifikaciją ir sumažintų investicinę riziką.

Apibendrinant atliktus tyrimus, galima pasiūlyti investavimo skaitmeninių valiutų rinkoje sprendimų paramos sistemą, kuri remtųsi daugiakriteriu TOPSIS modeliu aktyvų rangavimui, taip pat LSTM neuroninių tinklų giliuoju algoritmu, kuris prognozuotų kainas.

Tikslus skaitmeninių valiutų kainų prognozavimas suteikia sprendimas reikalingos ir svarbos informacijos, kuri lemia investicinių strategijų ir portfelio sudarymą. Siūlomi metodai investavimo sprendimui priimti pagerintų ir palengvintų investicijų portfelio sudarymo procesą ir sprendimų priėmimo procesą analizuojant rinkoje esančias skaitmenines valiutas ir jų kainų pokyčius.

Panašių modelių trūkumas riboja darbą siekiant nurodyto modelio teisingumo ir efektyvumo. Nepaisant to, tyrimas atneša pridėtinės vertės į mokslinių darbų sritį, susijusią su skaitmeninėmis valiutomis ir joms skirtomis SPS. Siūlomi metodai sistemoje yra tolimesnio tyrimo objektas tam, kad būtų tikslingai pritaikytas praktikoje, tokiose srityse, kaip investavimo platformos, programėlės ar atitinkamai suderinta konsultantų sprendimo priėmimo atraminė sistema.

IŠVADOS

1. Sparčiai plečiantis skaitmeninimui, vis labiau yra domimasi investavimo galimybėmis skaitmeninių valiutų rinkoje. Kadangi skaitmeninių valiutų rinka yra besivystanti, investavimo galimybės supa įvairios rizikos. Nepaisant to, yra pastebimas rinkos efektyvumo augimas, dėl ko rinka tampa tvirtesnė, stabilesnė ir saugesnė investavimui. Renkantis investicijų alternatyvas svarbu įvertinti investavimo tikslus, rizikas ir finansines galimybes. Atsižvelgiant į tai, kad investavimas skaitmeninių valiutų rinkoje kelia didelį neapibrėžtumą, dėl ko investuotojams yra sunku atlikti tinkamus sprendimus investuojant, kyla poreikis turėti investavimo skaitmeninių valiutų rinkoje paramos sistemą, palengvinančią investavimo skaitmeninių valiutų rinkoje sprendimą. Analizuojant literatūrą pastebėtas trūkumas mokslinių darbų, kuriuose būtų siūlomos investavimo paramos sistemos, orientuotos į skaitmeninių valiutų rinkos investavimo gerinimą. Taip pat atlikta literatūros analizė parodė, kad yra tik keli moksliniai darbai, skirti analizuoti skaitmeninių valiutų kainų prognozavimui taikant giliojo mokymosi algoritmus. Analizuota literatūra parodė, kad SPS, susijusioms su investavimu, yra būdingi šie žingsniai: duomenų rinkimas, apdorojimas, prognozavimas, strategijos pasirinkimas ir portfelio sudarymas.
2. Tyrimai, susiję su skaitmeninių valiutų vertinimu ir rangavimu (Tang, Shi ir Dong, 2019; Cubillo, 2018; Maček ir Alagić, 2017; Parveen, Arora ir Alam, 2020), parodė, kad dažniausiai yra naudojami daugiakriteriai vertinimo metodai. Vienas iš dažniausiai naudojamų – TOPSIS. Remiantis anksčiau atliktais darbais, magistro darbo tyrimui buvo pasirinkti vidiniai skaitmeninių valiutų rodikliai, pagal kuriuos buvo vertinamos alternatyvos. Šį sprendimą lėmė, tai kad išoriniai rodikliai, tokie kaip palūkanos, populiarumas, rinkos raida yra per daug kintantys, o vidiniai, tokie kaip minavimo sudėtingumas, laikas, grąža, yra mažai kintantys, tačiau turintys didelę reikšmę skaitmeninės valiutos vertei. Apžvelgus kainų prognozavimo tyrimus (Madan ir kt., 2015; Chen ir kt., 2020; Kim ir kt., 2016; Mai ir kt., 2018), pastebėta, kad tyrimui naudojant dažną kainos kitimą, giliojo mokymosi algoritmų rezultatai yra tikslesni. Mokslinės literatūros apžvalgos parodė, kad yra keli dirbtinio intelekto naudojimo modeliai, kurie gali būti pritaikyti skaitmeninių valiutų kainų prognozavimui. Vieni iš dažniausiai naudojamų modelių buvo ilgalaikės trumpalaikės atminties algoritmas ir atsitiktinio miško. Tyrimui pasirinktas LTSM algoritmas, dėl laiko eilučių duomenų apdorojimo pritaikomumo.

3. TOPSIS metodas aukščiausiai įvertino bitkoino skaitmeninę valiutą rodant, kadangi ji labiausiai nutolusi nuo blogiausios alternatyvos. Rezultatą daugiausia lemia ypač aukšta bitkoino kaina, mažas likutis neatrastų blokų likutis ir generuojama blokų grąža, lyginant su kitomis imties valiutomis. Antroje vietoje, kaip geriausia alternatyva, įvertintas riplas, kuri taip pat turi ilgą spekuliacinio laiką rinkoje ir mažą neatrastų blokų likutį. Gauti rezultatai leidžia teigti, kad ilgas skaitmeninės valiutos spekuliacinio laikas, rodantis, kad skaitmeninė valiuta yra tvirta ir atspari rinkos veiksniams ir didelė blokų grąža gaunama išminavus skaitmeninę valiutą, indikuoja tvarios ir vertingos skaitmeninės valiutos bruožus. Įvertinus skaitmenines valiutas pagal vidinius jų veiksnius, svarbu išanalizuoti ir įvertinti kainų pokyčių tendencijas skaitmeninių valiutų rinkoje tam, kad būtų galima sudaryti tinkamas investavimo strategijas.
4. Vidutinė absoliutinė procentinė paklaida analizuotoms skaitmeninėms valiutomis trejų metų duomenų prognozavimo laikotarpiui neviršijo 3 %, ką galima laikyti geru prognozavimo rezultatu. Taigi galima teigti, kad LSTM modelis yra tinkamas skaitmeninių valiutų kainų prognozavimui. Tikslios prognozės gali padėti skaitmeninių valiutų investuotojams priimti teisingus investavimo sprendimus ir padidinti potencialų pelną. Remiantis šiais rezultatais, giliojo mokymosi algoritmai ir kriptografijos technologija gali būti pritaikyta sudarant investicijų portfelius ir jų rizikos valdymui. Šių technologijų pritaikymas finansų rinkoje užtikrintų finansinių pavedimų saugumą, greitį ir anonimiškumą. Plečiantis skaitmeninių valiutų naudojimui ir dvipusiškumui, auga finansinių technologijų paslaugų paklausa ir reguliacinė reikmė, užtikrinanti finansinį makroekonomikos stabilumą.
5. Siūlomos sprendimų paramos sistemos vertinimas atliktas sudarant vienodų svorių portfelius iš aukščiausiai įvertintų skaitmeninių valiutų. Lyginant sudarytus portfelius su akcijų rinkos indeksu, gauti rezultatai parodė, kad skaitmeninių valiutų portfelis generuoja didesnę grąžą. Analizuojant grąžų standartinį nuokrypį, skaitmeninių valiutų portfeliai visais analizuotais periodais turi didesnę riziką, lyginant su akcijų rinkos indeksu. Taigi galima teigti, kad didesnė skaitmeninių valiutų grąža gaunama su atitinkamai didesne rizika. Įvertinus skaitmeninių valiutų ir akcijų rinkos grąžų tiesinį ryšį gauti rezultatai neviršija 0,17, kuo remiantis galima teigti, kad naudojant skaitmenines valiutas ir akcijas investicijų portfelyje bus užtikrintas rizikos diversifikavimas. Skaitmeninių valiutų perdavimo ir vertės kitimo stebėjimo ir investavimo realiuoju laiku poreikis skatina paklausą ir galimybes finansinių technologijų produktams, kurie leistų vartotojui saugiai, greitai ir patogiai dalyvauti

skaitmeninių valiutų rinkoje ir integruoti kriptografijos ir giliojo mokymosi technologijas į verslo modelius.

PASIŪLYMAI

Atlikus investavimo skaitmeninių valiutų rinkoje naudojant giliojo mokymosi algoritmą tyrimą, buvo pastebėtas investavimo skaitmeninių valiutų rinkoje sprendimų paramos priemonių trūkumas. Atsižvelgiant į tai, buvo pasiūlytas metodų rinkinys, kaip sprendimų paramos sistemos modelis. Prognozuojant skaitmeninių valiutų kainas su LSTM algoritmu, buvo gauti tiek tendencijas atitinkantys, tiek mažą prognozuojamų reikšmių paklaidą turintys rezultatai. Tokie rezultatai leidžia manyti, kad dirbtinio intelekto technologijos bus sparčiai integruojamos į finansų rinką, taip plečiant finansinių paslaugų šaką elektroninėje erdvėje tiek privatiems asmenims, tiek įmonėms. Giliojo mokymosi algoritmų pritaikymas investavimo procese, tiek pačios skaitmeninių valiutų rinkos vystymasis rodydamas daug potencialo, neslepia ir galimų rizikų. Visos šios technologinės galimybės kelia nuodugnesnio tyrimo reikalaujančią problemą: kaip išlaikyti finansinį stabilumą, kai finansų dalyviai vis labiau remiasi kompiuterio sprendimais ir renkasi necentralizuotas ir nereguliuojamas investavimo priemones. Tai verčia svarstyti, kas bus jei visi finansų rinkos dalyviai žinos, kaip uždirbti su maža rizika? Taigi, kaip ir minėta, skaitmeninių valiutų rinka, vis dar yra pasižymi neapibrėžtumu, tad tolimesnės diskusijos ir tyrimai apie skaitmeninių valiutų vertinimą, prognozavimą, pelningumą ir efektyvumą vis dar yra tik pradinėje stadijoje ir reikalauja tolimesnių mokslinių tyrimų.

Kristina Miškinytė 

LITERATŪROS SĄRAŠAS

Abdo, J. B., & Zeadally, S. (2020). Neural network-based blockchain decision scheme. *Information Security Journal: A Global Perspective*, 1–15. <https://doi.org/10.1080/19393555.2020.1831658>

Abraham, J., Higdon, D., & Nelson, J. (2018). Cryptocurrency price prediction using tweet volumes and sentiment analysis. *SMU Data Science Review*, 1(3). Retrieved from <https://scholar.smu.edu/datasciencereview/vol1/iss3/1>

Adebiyi, A. A., & Adewumi, A. O. (2014). Stock Price Prediction Using the ARIMA Model. *2014 UKSim-AMSS 16th International Conference on Computer Modelling and Simulation*, 16, 105–111. <https://doi.org/10.1109>

Aires, R. F. de F., & Ferreira, L. (2019). A new approach to avoid rank reversal cases in the TOPSIS method. *Computers & Industrial Engineering*, 132, 84–97. <https://doi.org/10.1016/j.cie.2019.04.023>

Andrianto, Y. (2017). The Effect of Cryptocurrency on Investment Portfolio Effectiveness. *Journal of Finance and Accounting*, 5(6), 229. <https://doi.org/10.11648/j.jfa.20170506.14>

Angerer, M., Hoffmann, C. H., Neitzert, F., & Kraus, S. (2020). Objective and subjective risks of investing into cryptocurrencies. *Finance Research Letters*, 101737. <https://doi.org/10.1016/j.frl.2020.101737>

Audito, apskaitos, turto vertinimo ir nemokumo valdymo tarnyba. *Kripto valiutos ir žetonų apskaitos rekomendacijos.*, (2018).

Bartis, J. (2015). Does Bitcoin follow the hypothesis of efficient market? *International Journal of Economic Sciences*, IV(2), 10–23. <https://doi.org/10.20472/es.2015.4.2.002>

Baskerville, L. R., Storey, V., & Kaul, M. (2015). Genres of Inquiry in Design-Science Research: Justification and Evaluation of Knowledge Production. *MIS Quarterly*, 39(3), 541–564. Retrieved from <https://www.scribd.com/document/373652485/Baskerville-Et-al-2015>

Baur, D. G., Hong, K. H., & Lee, A. D. (2018). Bitcoin: Medium of exchange or speculative assets? *Journal of International Financial Markets, Institutions and Money*, 54, 177–189. <https://doi.org/10.1016/j.intfin.2017.12.004>

Bloomberg.com. (2019). China Plans to Ban Cryptocurrency Mining in Renewed Clampdown - Bloomberg. Retrieved September 25, 2019, from <https://www.bloomberg.com/news/articles/2019-04-09/china-plans-to-ban->

cryptocurrency-mining-in-renewed-clampdown

Česnulevičiūtė, R. (2015). *Vertybinių popierių optimalaus portfelio konstravimas ir vertinimas*. 1–105.

Chang, J., Arbeláez, P., Switz, N., Reber, C., Tapley, A., Davis, J. L., ... Malik, J. (2012). Automated tuberculosis diagnosis using fluorescence images from a mobile microscope. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7512 LNCS, 345–352. https://doi.org/10.1007/978-3-642-33454-2_43

Chen, Z., Li, C., & Sun, W. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365, 112395. <https://doi.org/10.1016/j.cam.2019.112395>

Chiang, W. C., Enke, D., Wu, T., & Wang, R. (2016). An adaptive stock index trading decision support system. *Expert Systems with Applications*, 59, 195–207. <https://doi.org/10.1016/j.eswa.2016.04.025>

Chohan, U. (2018). Cryptocurrencies: A Brief Thematic Review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3024330>

CoinDesk.com. (2017). The Bulgarian Government Is Sitting on \$3 Billion in Bitcoin - CoinDesk. Retrieved September 25, 2019, from <https://www.coindesk.com/bulgarian-government-sitting-3-billion-bitcoin>

coingecko.com. (2020). Retrieved December 28, 2020, from <https://www.coingecko.com/en>

Coinmarketcap.com. (2020). CoinMarketCap. Retrieved September 24, 2019, from <https://coinmarketcap.com/charts/>

Corbet, S., Lucey, B., Urquhart, A., & Yarovaya, L. (2019). Cryptocurrencies as a financial asset: A systematic analysis. *International Review of Financial Analysis*, 62, 182–199. <https://doi.org/10.1016/j.irfa.2018.09.003>

Dabrowski, M., & Janikowski, L. (2018). *Virtual currencies and central banks monetary policy: challenges ahead Monetary Dialogue July 2018 Policy Department for Economic, Scientific and Quality of Life Policies*. (July). Retrieved from http://www.europarl.europa.eu/cmsdata/149900/CASE_FINAL_publication.pdf

Dourado, E., & Brito, J. (2014). Cryptocurrency. *The New Palgrave Dictionary of Economics*, 50(1), 1–10. <https://doi.org/https://doi.org/10.1016/j.jempfin.2018.11.002>

Eggert, M. (2014). *Compliance Management in Financial Industries: A Model-based Business Process and Reporting Perspective*. Retrieved from <https://www.google.com/books?hl=en&lr=&id=qdqGAgAAQBAJ&oi=fnd&pg=PR6&dq>

=Compliance+Management+in+Financial+Industries:+A+Model-
based+Business+Process+and+Reporting+Perspective&ots=xMOaWtmRTl&sig=pW_x6
9A5_AyzUe58K3oK5IJNnb0

Farshidi, S., Jansen, S., Espana, S., & Verkleij, J. (2020). Decision Support for Blockchain Platform Selection: Three Industry Case Studies. *IEEE Transactions on Engineering Management*, 67(4), 1109–1128. <https://doi.org/10.1109/TEM.2019.2956897>

Feuerriegel, S., & Fehrer, R. (2016). Improving decision analytics with deep learning: The case of financial disclosures. *24th European Conference on Information Systems, ECIS 2016*.

Ginevičius, R., & Podvezko, V. (2008). *Daugiakriterinio Vertinimo Bûdø Suderinamumas the Problem of Compatibility of Various Multiple Criteria Evaluation Methods*. 9(1).

Hayes, A. S. (2017). Cryptocurrency value formation: An empirical study leading to a cost of production model for valuing bitcoin. *Telematics and Informatics*, 34(7), 1308–1321. <https://doi.org/10.1016/j.tele.2016.05.005>

Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

Houben, R., & Snyers, A. (2018). *Cryptocurrencies and blockchain. Legal context and implications for financial crime, money laundering and tax evasion STUDY Requested by the TAX3 committee Policy Department for Economic, Scientific and Quality of Life Policies*. (July).

Hwang, C.-L., & Yoon, K. (1981). *Methods for Multiple Attribute Decision Making*. https://doi.org/10.1007/978-3-642-48318-9_3

Indera, N. I., Yassin, I. M., Zabidi, A., & Rizman, Z. I. (2018). Non-linear Autoregressive with Exogeneous input (narx) bitcoin price prediction model using PSO-optimized parameters and moving average technical indicators. *Journal of Fundamental and Applied Sciences*, 9(3S), 791. <https://doi.org/10.4314/jfas.v9i3s.61>

Iqbal, N., Fareed, Z., Guangcai, W., & Shahzad, F. (2020). Asymmetric nexus between COVID-19 outbreak in the world and cryptocurrency market. *International Review of Financial Analysis*, 101613. <https://doi.org/10.1016/j.irfa.2020.101613>

Kekytė, I., & Stasytė, V. (2017). Investavimo sprendimų priėmimo modelių lyginamoji analizė. *Mokslas - Lietuvos Ateitis*, 9(2), 197–208. Retrieved from <http://journals.vgtu.lt/index.php/MLA/article/view/550>

Khair, U., Fahmi, H., Hakim, S. Al, & Rahim, R. (2017). Forecasting Error Calculation with Mean Absolute Deviation and Mean Absolute Percentage Error. *Journal*

of Physics: Conference Series, 930(1), 012002. <https://doi.org/10.1088/1742-6596/930/1/012002>

Kim, Y. Bin, Kim, J. G., Kim, W., Im, J. H., Kim, T. H., Kang, S. J., & Kim, C. H. (2016). Predicting fluctuations in cryptocurrency transactions based on user comments and replies. *PLoS ONE*, 11(8). <https://doi.org/10.1371/journal.pone.0161197>

Klein, T., Pham Thu, H., & Walther, T. (2018). Bitcoin is not the New Gold – A comparison of volatility, correlation, and portfolio performance. *International Review of Financial Analysis*, 59, 105–116. <https://doi.org/10.1016/j.irfa.2018.07.010>

Kristoufek, L., & Vosvrda, M. (2019). Cryptocurrencies market efficiency ranking: Not so straightforward. *Physica A: Statistical Mechanics and Its Applications*, 531, 120853. <https://doi.org/10.1016/j.physa.2019.04.089>

Kumar, R. (2016). *Valuation: Theories and Concepts*. Retrieved from <https://www.sciencedirect.com/book/9780128023037/valuation>

Lahmiri, S., & Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons and Fractals*, 118, 35–40. <https://doi.org/10.1016/j.chaos.2018.11.014>

Lansky, J. (2018). Possible State Approaches to Cryptocurrencies. *Journal of Systems Integration*, 9(1), 19–31. <https://doi.org/10.20470/jsi.v9i1.335>

Latif, S. R., Mohd, M. A., Amin, M. M., & Mohamad, A. I. (2017). Testing the weak form of efficient market in cryptocurrency Insurance modeling View project Saiful Reeza. *Journal of Engineering and Applied Science*, 12(9), 2285–2288. Retrieved from <https://www.researchgate.net/publication/341536510>

Le, X. H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of Long Short-Term Memory (LSTM) neural network for flood forecasting. *Water (Switzerland)*, 11(7). <https://doi.org/10.3390/w11071387>

Li, X., & Wang, C. A. (2017). The technology and economic determinants of cryptocurrency exchange rates: The case of Bitcoin. *Decision Support Systems*, 95, 49–60. <https://doi.org/10.1016/j.dss.2016.12.001>

Liang, D., & Xu, Z. (2017). The new extension of TOPSIS method for multiple criteria decision making with hesitant Pythagorean fuzzy sets. *Applied Soft Computing Journal*, 60, 167–179. <https://doi.org/10.1016/j.asoc.2017.06.034>

Liu, Y., & Tsyvinski, A. (2020). Risks and Returns of Cryptocurrency. *The Review of Financial Studies*, (24877), 1–68. <https://doi.org/10.1093/rfs/hhaa113>

Love, J. (2007). Artificial Neural Networks. In: Process Automation Handbook. In *Process Automation Handbook* (pp. 929–943). <https://doi.org/10.1007/978-1-84628-282->

Maček, D., & Alagić, D. (2017). Comparisons of bitcoin cryptosystem with other common internet transaction systems by AHP technique. *Journal of Information and Organizational Sciences*, 41(1), 69–87. <https://doi.org/10.31341/jios.41.1.5>

Madan, I., Saluja, S., & Zhao, A. (2015). Automated Bitcoin Trading via Machine Learning Algorithms. URL: <Http://Cs229.Stanford.Edu/Proj2014/Isaac%20Madan,20,1-5>. Retrieved from http://cs229.stanford.edu/proj2014/Isaac_Madan,Shaurya_Saluja,Aojia_Zhao,AutomatedBitcoinTradingviaMachineLearningAlgorithms.pdf

Mahdavifar, S., & Ghorbani, A. A. (2019). Application of deep learning to cybersecurity: A survey. *Neurocomputing*, 347, 149–176. <https://doi.org/10.1016/j.neucom.2019.02.056>

Mai, F., Shan, Z., Bai, Q., Wang, X. (Shane), & Chiang, R. H. L. (2018). How Does Social Media Impact Bitcoin Value? A Test of the Silent Majority Hypothesis. *Journal of Management Information Systems*, 35(1), 19–52. <https://doi.org/10.1080/07421222.2018.1440774>

Markets.businessinsider.com. (2019). New Zealand just became the first country to legalize salary payments in cryptocurrencies (BTC) | Markets Insider. Retrieved September 25, 2019, from <https://markets.businessinsider.com/news/stocks/new-zealand-legalizes-cryptocurrency-salaries-including-bitcoin-2019-8-1028442320>

Mnif, E., Jarboui, A., & Mouakhar, K. (2020). How the cryptocurrency market has performed during COVID 19? A multifractal analysis. *Finance Research Letters*, 36, 101647. <https://doi.org/10.1016/j.frl.2020.101647>

Nakisa, B., Rastgoo, M. N., Rakotonirainy, A., Maire, F., & Chandran, V. (2018). Long short term memory hyperparameter optimization for a neural network based emotion recognition framework. *IEEE Access*, 6, 49325–49338. <https://doi.org/10.1109/ACCESS.2018.2868361>

Parveen, T., Arora, H. D., & Alam, M. (2020). *Intuitionistic Fuzzy Shannon Entropy Weight Based Multi-criteria Decision Model with TOPSIS to Analyze Security Risks and Select Online Transaction Method*. https://doi.org/10.1007/978-981-15-0222-4_1

Peffer, K., Tuunanen, T., Rothenberger, M. A., & Chatterjee, S. (2007). A Design Science Research Methodology for Information Systems Research. *Journal of Management Information Systems*, 24(3), 45–77. <https://doi.org/10.2753/MIS0742-1222240302>

Platanakis, E., & Urquhart, A. (2019). Portfolio management with cryptocurrencies: The role of estimation risk. *Economics Letters*, 177, 76–80. <https://doi.org/10.1016/j.econlet.2019.01.019>

Power, D. J. (2014). Using 'Big Data' for analytics and decision support. *Journal of Decision Systems*, 23(2), 222–228. <https://doi.org/10.1080/12460125.2014.888848>

Rebane, J., & Karlsson, I. (2018). *Seq2Seq RNNs and ARIMA models for Cryptocurrency Prediction : A Comparative Study*. (August), 2–6.

Saksonova, S., & Kuzmina-Merlino, I. (2019). Cryptocurrency as an Investment Instrument in a Modern Financial Market. *St Petersburg University Journal of Economic Studies*, 35(2), 269–282. <https://doi.org/10.21638/spbu05.2019.205>

Schueffel, P. (2017). *The Consise Fintech Compendium*. Retrieved from [http://www.heg-fr.ch/FR/HEG-FR/Communication-et-evenements/evenements/SiteAssets/Pages/patrick-schuffel/Schueffel \(2017\) The Concise FINTECH COMPENDIUM.PDF](http://www.heg-fr.ch/FR/HEG-FR/Communication-et-evenements/evenements/SiteAssets/Pages/patrick-schuffel/Schueffel%20(2017)%20The%20Concise%20FINTECH%20COMPENDIUM.PDF)

Selman, S. (2012). Distinction of The Authors of Texts Using Multilayered Feedforward Neural Networks. *Southeast Europe Journal of Soft Computing*, 1(1). <https://doi.org/10.21533/scjournal.v1i1.82>

Sharpe, W. F. (1966). Mutual Fund Performance on JSTOR. *The Journal of Business*, 39(1), 119–138. <https://doi.org/10.1086/294846>

Sovbetov, Y. (2018, February 17). *Factors Influencing Cryptocurrency Prices: Evidence from Bitcoin, Ethereum, Dash, Litecoin, and Monero*.

Sun, X., Liu, M., & Sima, Z. (2019). A novel cryptocurrency price trend forecasting model based on LightGBM. *Finance Research Letters*. <https://doi.org/10.1016/j.frl.2018.12.032>

Taljaard, B., & Mare, E. (2020). Why Has the Equal Weight Portfolio Underperformed and What Can We Do About It? *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3608632>

Talo, M., Baloglu, U. B., Yıldırım, Ö., & Acharya, U. R. (2019). Application of deep transfer learning for automated brain abnormality classification using MR images. *Cognitive Systems Research*, 54, 176–188. <https://doi.org/10.1016/j.cogsys.2018.12.007>

Tang, A., Tam, R., Cadrin-Chênevert, A., Guest, W., Chong, J., Barfett, J., ... Shabana, W. (2018, May 1). Canadian Association of Radiologists White Paper on Artificial Intelligence in Radiology. *Canadian Association of Radiologists Journal*, Vol. 69, pp. 120–135. <https://doi.org/10.1016/j.carj.2018.02.002>

Tang, H., Shi, Y., & Dong, P. (2019). Public blockchain evaluation using entropy and TOPSIS. *Expert Systems with Applications*, 117, 204–210. <https://doi.org/10.1016/j.eswa.2018.09.048>

Theblockcrypto.com. (2019). Bitcoin has been the most volatile and best

performing major cryptocurrency in June - The Block. Retrieved September 25, 2019, from <https://www.theblockcrypto.com/linkedin/29595/bitcoin-has-been-the-most-volatile-and-best-performing-major-cryptocurrency-in-june>

Torres, G. D., & Qiu, H. (2018). *Applying Recurrent Neural Networks for Multivariate Time Series Forecasting of Volatile Financial Data*. 1–10.

Tran, D., Mac, H., Tong, V., Tran, H. A., & Nguyen, L. G. (2018). A LSTM based framework for handling multiclass imbalance in DGA botnet detection. *Neurocomputing*, 275, 2401–2413. <https://doi.org/10.1016/j.neucom.2017.11.018>

Tran, V. Le, & Leirvik, T. (2020). Efficiency in the markets of crypto-currencies. *Finance Research Letters*, 35, 101382. <https://doi.org/10.1016/j.frl.2019.101382>

Urquhart, A. (2016). The inefficiency of Bitcoin. *Economics Letters*, 148, 80–82. <https://doi.org/10.1016/j.econlet.2016.09.019>

Verkleij, J. R. Q. ., Jansen, S., & Cubillo, E. (2018). *A Decision Support System for Blockchain Platform Selection*. Retrieved from <https://www.scribd.com/document/431040146/Jr-Qver-Kle-i-j-Master-Thesis-Final>

VMI. (2018). Dėl virtualiųjų valiutų ir pirminio virtualiųjų žetonų platinimo veiklos mokestinių nuostatų paaiškinimo - Mokesčių naujienos - VMI. Retrieved September 25, 2019, from http://www.vmi.lt/cms/mokesciu-naujienos/-/asset_publisher/DkY4/content/del-virtualiuju-valiutu-ir-pirminio-virtualiuju-zetonu-platinimo-veiklos-mokestiniu-nuostatu-paaiskinimo

Wang, W., & Lu, Y. (2018). Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model. *IOP Conference Series: Materials Science and Engineering*, 324(1). <https://doi.org/10.1088/1757-899X/324/1/012049>

Wei, W. C. (2018). Liquidity and market efficiency in cryptocurrencies. *Economics Letters*, 168, 21–24. <https://doi.org/10.1016/j.econlet.2018.04.003>

Yahoo Finance. (2020). Retrieved December 28, 2020, from <https://finance.yahoo.com/>


Zhong, G., Ling, X., & Wang, L. (2018). From shallow feature learning to deep learning: Benefits from the width and depth of deep architectures. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(1). <https://doi.org/10.1002/widm.1255>

1 PRIEDAS. LSTM giliojo mokymosi algoritmas

```
mydata = readtable('data.txt');
data = table2array(mydata(:, 5));
figure
plot(data)
xlabel("Dienos")
ylabel("Kaina")
title("BTC")
numTimeStepsTrain = floor(0.9*numel(data));
dataTrain = data(1:numTimeStepsTrain+1)';
dataTest = data(numTimeStepsTrain+1:end)';
mu = mean(dataTrain);
sig = std(dataTrain);
dataTrainStandardized = (dataTrain - mu) / sig;
XTrain = dataTrainStandardized(1:end-1);
YTrain = dataTrainStandardized(2:end);
numFeatures = 1;
numResponses = 1;
numHiddenUnits = 200;
layers = [ ...
    sequenceInputLayer(numFeatures)
    lstmLayer(numHiddenUnits)
    fullyConnectedLayer(numResponses)
    regressionLayer];
options = trainingOptions('adam', ...
    'MaxEpochs',300, ...
    'GradientThreshold',1, ...
    'InitialLearnRate',0.005, ...
    'LearnRateSchedule','piecewise', ...
    'LearnRateDropPeriod',125, ...
    'LearnRateDropFactor',0.2, ...
    'Verbose',0, ...
    'Plots','training-progress');
net = trainNetwork(XTrain,YTrain,layers,options);
dataTestStandardized = (dataTest - mu) / sig;
XTest = dataTestStandardized(1:end-1);
net = predictAndUpdateState(net,XTrain);
[net,YPred] = predictAndUpdateState(net,YTrain(end));
numTimeStepsTest = numel(XTest);
for i = 2:numTimeStepsTest
    [net,YPred(:,i)] = predictAndUpdateState(net,YPred(:,i-1),'ExecutionEnvironment','cpu');
end
YPred = sig*YPred + mu;
YTest = dataTest(2:end);
rmse = sqrt(mean((YPred-YTest).^2))
figure
plot(dataTrain(1:end-1))
hold on
idx = numTimeStepsTrain:(numTimeStepsTrain+numTimeStepsTest);
plot(idx,[data(numTimeStepsTrain) YPred],'.-')
hold off
```


1 PRIEDAS (tęsinys). LSTM giliojo mokymosi algoritmas

```
xlabel("Dienos")
ylabel("Kaina")
title("Forecast")
legend(["Observed" "Forecast"])
figure
subplot(2,1,1)
plot(YTest)
hold on
plot(YPred,'.-')
hold off
legend(["Observed" "Forecast"])
ylabel("Cases")
title("Forecast")
subplot(2,1,2)
stem(YPred - YTest)
xlabel("Dienos")
ylabel("Error")
title("RMSE = " + rmse)
net = resetState(net);
net = predictAndUpdateState(net,XTrain);
YPred = [];
numTimeStepsTest = numel(XTest);
for i = 1:numTimeStepsTest
    [net,YPred(:,i)] = predictAndUpdateState(net,XTest(:,i),'ExecutionEnvironment','cpu');
end
YPred = sig*YPred + mu;
rmse = sqrt(mean((YPred-YTest).^2))
figure
subplot(2,1,1)
plot(YTest)
hold on
plot(YPred,'.-')
hold off
legend(["Observed" "Predicted"])
ylabel("Kaina")
title("Forecast with Updates")
subplot(2,1,2)
stem(YPred - YTest)
xlabel("Dienos")
ylabel("Error")
title("RMSE = " + rmse)
```




2 PRIEDAS. BCH skaitmeninės valiutos LSTM algoritmo prognozės 2017-08-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės




3 PRIEDAS. BNB skaitmeninės valiutos LSTM algoritmo prognozės 2017-08-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės




4 PRIEDAS. XRP skaitmeninės valiutos LSTM algoritmo prognozės 2019-08-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės




5 PRIEDAS. BTC skaitmeninės valiutos LSTM algoritmo prognozės 2019-08-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės




6 PRIEDAS. BCH skaitmeninės valiutos LSTM algoritmo prognozės 2019-08-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės




7 PRIEDAS. BNB skaitmeninės valiutos LSTM algoritmo prognozės 2019-08-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės




8 PRIEDAS. LTC skaitmeninės valiutos LSTM algoritmo prognozės 2019-08-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės




9 PRIEDAS. BTC skaitmeninės valiutos LSTM algoritmo prognozės 2020-04-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės




10 Priedas. BNB skaitmeninės valiutos LSTM algoritmo prognozės 2020-04-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės



11 PRIEDAS. XRP skaitmeninės valiutos LSTM algoritmo prognozės 2020-04-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės



12 PRIEDAS. BCH skaitmeninės valiutos LSTM algoritmo prognozės 2020-04-01 – 2020-07-31 mokymosi laikotarpiui

Šaltinis: sudaryta autorės

13 PRIEDAS. Portfelio sudarymas „RStudio“ programoje

```
#Išvalome apinką:
rm(list = setdiff(ls(), lsf.str()))
# Atsisiųsti reikiamus duomenis iš Yahoo Finance
p.from = as.Date("2017-08-01")
p.to = as.Date("2020-07-31")
# Pirmiausiai atsisiunčiame rinkos indekso s&p500 duomenis
getSymbols("^GSPC", src = "yahoo", from = p.from, to = p.to)
head(GSPC); tail(GSPC) # Patikriname atsisiųstus duomenis
plot(GSPC[,6])
plot(Ad(GSPC))
candleChart(GSPC,multi.col=TRUE,theme='white')
#Analizei atsisiunčiame "TOP4"
symbols <- c("BTC-USD","XRP-USD", "BNB-USD", "LTC-USD")
# Funkcija kainoms atsisiųsti
getHistPrices<-function(tickers, from, to )
{
  xtsStocks <- xts()
```

```

AdjPrices <- xts()

for (i in 1:length(symbols))
{
  xtsStocks <- getSymbols(tickers[i],src = "yahoo",
                        from = as.Date(from), to =as.Date(to) )
  #Get the adjusted price
  AdjPrices <- merge(AdjPrices, Ad(get(tickers[i])))
}
return(AdjPrices)
}
# Atsisiunčiame kainas
portf7.pp<-getHistPrices(symbols,from =p.from, to =p.to)
head(portf7.pp); tail(portf7.pp); dim(portf7.pp)
# Išaugome kainas diske
save(portf7.pp, GSPC, file = "kainos.RData")
load("kainos.RData")
#### rm(list=ls())
# Writing to xls
library(xlsx)
write.xlsx(portf7.pp, "out1.xlsx", sheetName="Sheet1",
          col.names=TRUE, row.names=TRUE, append=F)
#Apskaičiuojame grąžą
# Paprastos ir logaritmines grąžos
log(1+0.105) ; exp(log(1+0.105))-1
GSPC_index.rr<-diff(log(GSPC [,6]))
GSPC_index.rr.smpl <-GSPC [,6] / lag(GSPC [,6], 1) - 1
# nusipiešiam grąžos grafiką
myplot(c(GSPC_index.rr,GSPC_index.rr.smpl))
# To convert month end prices:
prices_monthly <- to.monthly(GSPC['2017:.',6], indexAt = "last", OHLC = FALSE)
r.monthly <- diff(log(prices_monthly)) # convert prices to log returns
r1.monthly <- exp(r.monthly)-1 # log to simple returns
portf7.rr<-periodReturn(portf7.pp, period='monthly', type='arithmetic', leading=TRUE)
head(portf7.rr) ### vienos eilutės grąža
myret<-function(ret){
  res<-periodReturn(ret, period='monthly', type='arithmetic', leading=TRUE)
  return(res)
}
portf7.rr <- lapply(portf7.pp,function(x) myret(x))
portf7.rr2 <- lapply(portf7.pp,function(x) periodReturn(x,
          period='monthly', type='arithmetic', leading=TRUE))

portf7.rr <- do.call(merge, portf7.rr)
head(portf7.rr); class(portf7.rr)
# sutvarkome stulpelius
index(portf7.rr)<- as.Date(index(portf7.rr))
colnames(portf7.rr)<-symbols ; head(portf7.rr); tail(portf7.rr)
write.xlsx(portf7.rr, "outporfgra.xlsx", sheetName="Sheet1",
          col.names=TRUE, row.names=TRUE, append=F)
portf7.rr
# Portfelio gražų grafikas
myplot(portf7.rr)

```

13 PRIEDAS (tęsinys). Portfelio sudarymas „RStudio“ programoje

```
#paprastosios gražos
portf7.rr.cum<- cumprod(1+portf7.rr)-1; tail(portf7.rr.cum)
myplot(portf7.rr.cum)
portf7.rr.cum
#library(PerformanceAnalytics)
Return.cumulative(portf7.rr,geometric=TRUE)
chart.CumReturns(portf7.rr,legend.loc="topleft",
                  main="Cumulative Monthly Returns for portfolio",geometric=TRUE)
plot(portf7.sd.ann,portf7.rr.ann)
chart.RiskReturnScatter(portf7.rr)
table.Stats(portf7.rr)
table.DownsideRisk(portf7.rr)

# Palyginame su rinkos indeksu
GSPC_index.rr<-periodReturn(GSPC[,6], period='monthly', type='arithmetic',
leading=TRUE)
head(GSPC_index.rr)
colnames(GSPC_index.rr)<-"GSPC_index"
chart.CumReturns(cbind(portf7.rr,GSPC_index.rr),legend.loc="topleft",
                  main="Cumulative Monthly Returns for portfolio",geometric=TRUE)
chart.RiskReturnScatter(cbind(portf7.rr,GSPC_index.rr))
portf7_index<-cbind(portf7.rr,GSPC_index.rr)
save(portf7_index, file = "grazos.RData")
load("grazos.RData")
head (cbind(portf7.rr,GSPC_index.rr))
portf7_index

#Apskaiciuojame gražą
#load the rda file
library(magrittr)
head(portf7.rr)

# Portfelio graža ir rizika # Padaliname duomenis į dvi dalis
in1.rr<-portf7.rr ['2017::2018'] ;head(in1.rr);tail(in1.rr); dim(in1.rr)
in2.rr<-portf7.rr ['2019::'] ;head(in2.rr);tail(in2.rr); dim(in2.rr)
in1.er<-apply(in1.rr,2,mean)
in1.vcov<-cov(in1.rr)
cor(in1.rr)
#install.packages("ggcorrplot")
library(ggcorrplot)
ggcorrplot(cor(in1.rr), hc.order = TRUE, type = "lower", lab = TRUE)
cor(in2.rr)
library(ggcorrplot)
ggcorrplot(cor(in2.rr), hc.order = TRUE, type = "lower", lab = TRUE)
cor(portf7.rr)
library(ggcorrplot)
ggcorrplot(cor(portf7.rr), hc.order = TRUE, type = "lower", lab = TRUE)
#vienodų svorių vektorius
#in1.eqw<-matrix(rep(0.25,4),ncol=1)
```

13 PRIEDAS (tęsinys). Portfelio sudarymas „RStudio“ programoje

```
#Vienodų svorių portfelio laukiama grąža ir rizika
#t(in1.eqw) %*% matrix(in1.er,ncol=1)
#t(in1.eqw) %*% in1.vcov %*% in1.eqw
#w<-in1.eqw
#er.port <- crossprod(in1.er,in1.eqw)
#sd.port <- sqrt(t(w) %*% in1.vcov %*% w)

# Vienodų svorių portfelio grąža pirmajam intervalui

#in1.eqw_p.rr<-Return.portfolio(in1.rr, weights =rep(0.25,4))
#colnames(in1.eqw_p.rr)<-"eqw_t1"
#mean parodo portfelio grąžos vidurkį
#mean(in1.eqw_p.rr);
#cov(in1.eqw_p.rr)

# Pasiskaičiuojame portfelio grąžą, standartinę nuokrypį rizikai įvertinti ir Šarpo rodiklį

#in1.eqw_p.rr.ann<-Return.annualized(in1.eqw_p.rr, scale = NA, geometric = FALSE)
#simple returns
#in1.eqw_p.rr.Sd.ans<-StdDev.annualized(in1.eqw_p.rr)
#SharpeRatio.annualized(in1.eqw_p.rr, Rf = 0, geometric=FALSE)
#vienodu svoriu t1 periode
in1.eq_t1.rr<-Return.portfolio(in1.rr, weights =rep(0.25,4))
colnames(in1.eq_t1.rr) <-"eqw_t1"

#Pasiskaičiuojame tuos pačius rodiklius sudarant vienodų svorių portfelį su antruoju periodu

(in2):
in1.eq_t1.rr.ann<-Return.annualized(in1.eq_t1.rr, scale = NA, geometric = FALSE)
in1.eq_t1.rr.sd.ann<-StdDev.annualized(in1.eq_t1.rr)
SharpeRatio.annualized(in1.eq_t1.rr, Rf = 0, geometric=FALSE)

#t2 periode

in2.eq_t2.rr<-Return.portfolio(in2.rr, weights =rep(0.25,4))
colnames(in2.eq_t2.rr) <-"eqw_t2"

#Pasiskaičiuojame tuos pačius rodiklius sudarant vienodų svorių portfelį su antruoju periodu

(in2):
in2.eq_t2.rr.ann<-Return.annualized(in2.eq_t2.rr, scale = NA, geometric = FALSE)
in2.eq_t2.rr.sd.ann<-StdDev.annualized(in2.eq_t2.rr)
SharpeRatio.annualized(in2.eq_t2.rr, Rf = 0, geometric=FALSE)
# Palyginimui sudaromas vienodų svorių portfelis 2017-2020 m. laikotarpiui:
portf7.eqw_p.rr<-Return.portfolio(portf7.rr, weights =rep(0.25,4))
colnames(portf7.eqw_p.rr)<-"eqw"

#Paskaičiuojami rodikliai

portf7.eqw_p.rr.ann<-Return.annualized(portf7.eqw_p.rr, scale = NA, geometric = FALSE)
```

```

portf7.eqw_p.rr.Sd.ans<-StdDev.annualized(portf7.eqw_p.rr)
SharpeRatio.annualized(portf7.eqw_p.rr, Rf = 0, geometric=FALSE)

# pasilyginam grafike

chart.RiskReturnScatter(cbind(in2.rr, in2.eq_t2.rr))

#Palyginame

#Sugeneruojame vienodų svorių portfelį pirmam periodui (eqw_t1). Nubraižome grafiką
palyginimui su rinkos indeksu ir akcijoms.
#(cbind(in1.rr, GSPC_index.rr, in1.eqw_p.rr))
#chart.RiskReturnScatter(cbind(in1.rr, GSPC_index.rr, in1.eqw_p.rr, in2.eq_t2.rr,
portf7.eqw_p.rr))

GSPC_index.rr
#gražos

GSPC_index.rr.ann<-Return.annualized(GSPC_index.rr, scale = NA, geometric = FALSE)
GSPC_index.rr.sd.ann<-StdDev.annualized(GSPC_index.rr)
SharpeRatio.annualized(GSPC_index.rr, Rf = 0, geometric=FALSE)
GSPC_index_t1.rr<- GSPC_index.rr ['2017::2018']
;head(GSPC_index_t1.rr);tail(GSPC_index_t1.rr); dim(GSPC_index_t1.rr)
GSPC_index_t2.rr<- GSPC_index.rr ['2019::']
;head(GSPC_index_t2.rr);tail(GSPC_index_t2.rr); dim(GSPC_index_t2.rr)
GSPC_index_t1.rr.ann<-Return.annualized(GSPC_index_t1.rr, scale = NA, geometric =
FALSE)
GSPC_index_t1.rr.sd.ann<-StdDev.annualized(GSPC_index_t1.rr)
SharpeRatio.annualized(GSPC_index_t1.rr, Rf = 0, geometric=FALSE)
GSPC_index_t2.rr.ann<-Return.annualized(GSPC_index_t2.rr, scale = NA, geometric =
FALSE)
GSPC_index_t2.rr.sd.ann<-StdDev.annualized(GSPC_index_t2.rr)
SharpeRatio.annualized(GSPC_index_t2.rr, Rf = 0, geometric=FALSE)
chart.RiskReturnScatter(cbind(in1.eq_t1.rr, in2.eq_t2.rr, portf7.eqw_p.rr,in1.rr,
GSPC_index.rr, GSPC_index_t2.rr, GSPC_index_t1.rr))
chart.RiskReturnScatter(cbind(GSPC_index.rr, GSPC_index_t2.rr, GSPC_index_t1.rr,
portf7.rr))

#Grafikai
chart.RiskReturnScatter(cbind(GSPC_index.rr, portf7.rr))
chart.RiskReturnScatter(cbind(in1.eq_t1.rr, in2.eq_t2.rr, portf7.eqw_p.rr, portf7.rr))
chart.RiskReturnScatter(cbind(in1.eq_t1.rr, in2.eq_t2.rr, portf7.eqw_p.rr, portf7.rr,
GSPC_index.rr))

```

14 PRIEDAS. Maknickienė ir Miškinytės (2020) straipsnis „Skaitmeninių valiutų kainų prognozavimas naudojant giliojo mokymosi algoritmą“



SKAITMENINIŲ VALIUTŲ KAINŲ PROGNOZAVIMAS NAUDOJANT GILIOJO MOKYMOSI ALGORITMĄ

Nijolė MAKNICKIENĖ, Kristina MIŠKINYTĖ*

*Vilniaus Gedimino technikos universitetas, Verslo vadybos fakultetas,
Finansų inžinerijos katedra, Saulėtekio al. 11, LT-10223, Vilnius, Lietuva*

**El. paštas kristina.miskinyte@stud.vgtu.lt*

Santrauka. Kriptovaliutos vis dar yra finansų rinkos naujovė ir iki galo neiširta finansinis instrumentas. Tai išlaiko kriptovaliutas įdomia ir aktualia tema, tiek mokslininkams, tiek reguliacinėms institucijoms bei investuotojams. Kriptovaliutų rinka yra auganti, nestabili ir nuolat besikeičianti, kas suteikia jai aukštą riziką ir plačias galimybes. Finansinis išmanymas ir toliaregiškas prognozavimas, nepasimetant pinigų vertės, rizikos ir nenuspėjamumo chaose yra ypač svarbus šiandieninėje ekonomikoje. Sudėtingas kriptovaliutų rinkos pobūdis reikalauja plataus profilio duomenų kiekio, kuriam apdoroti taikomi įvairūs metodai, tokie kaip statistinė, techninė, sentimentų, sprendimų bei kita analizė. Ankstesni tyrimai kriptovaliutų kainas numatė dviem būdais: empirine analize ir mašinų mokymosi algoritmų analize. Šiame straipsnyje testuojamas giliojo mokymosi algoritmo taikymo galimybės kriptovaliutų kainų prognozavime. Taikant ilgalaikės trumpalaikės atminties tinklo (angl. *long, short-term network*, toliau LSTM) algoritmą, prognozuojamas trumpalaikis kriptovaliutų kainų kitimas bei įvertinamas sugeneruotų duomenų tikslumas. Rezultatai parodė, kad giliojo mokymosi algoritmas kainas prognozuoja su maža paklaida ir tiksliai nuspėję kainos pokyčio tendenciją, kas leidžia teigti, kad giliojo mokymosi algoritmas yra efektyvi rizikos mažinimo priemonė finansų rinkoje.

Reikšminiai žodžiai: dirbtinis intelektas, gilusis mokymasis, LSTM, prognozavimas, kriptovaliutos, kriptovaliutų rinka.

Įvadas

Finansų rinkoje yra svarbus ne tik finansinis išmanymas bet ir toliaregiškas prognozavimas, nepasimetant pinigų vertės, rizikos ir nenuspėjamumo chaose. Kriptovaliutos nėra naujiena tiek finansų rinkai, tiek jos dalyviams. Aktyvų investavimą ir susidomėjimą šiuo finansiniu produktu iššaukė 2017 m. įvykęs kirpto-bumas. Tuometinė kriptovaliutų rinkos kapitalizacija sausio mėnesį siekė 17,000 mln. JAV dolerių, o jau birželį buvo pašokusi iki 90,000 mln. JAV dolerių. Jau 2018 gegužę tik dviejų didžiausių kriptovaliutų (Bitcoin ir Ethereum) bendra rinkos vertė coinmarketcap.com (2019) duomenimis siekė 160,9 milijardų JAV dolerių. Kapitalizacijos dydis ir kitimas yra vertės rodiklis suinteresuotam vartotojui ar investuotojui. Jis yra gaunama padauginus esamų rinkoje žetonų skaičių iš tuometinės jų kainos, taip išreiškiant investicijos dydį. Investavimo rizikos mažinimui vis dažniau pasitelkiamas dirbtinis intelektas, kuris automatizuoja ne tik fizinį bet ir protinį darbą, šiuo atveju – strateginį sprendimų priėmimą išanalizuojant tūkstančius duomenų sekundžių greičiu. Atlikta literatūros analizė parodė, kad yra tik keli moksliniai darbai, skirti analizuoti kriptovaliutų kainų prognozavimą taikant giliojo mokymosi algoritmus. Mokslinių tyrimų stoka skatina analizuoti šią tyrimo sritį giliau. Būtent todėl straipsnio tikslas – pritaikant giliojo mokymosi algoritmą nustatyto trumpalaikį kriptovaliutų kainos kitimą. Straipsnyje nagrinėjamas dirbtinis intelektas ir jo panaudojimas kriptovaliutų kainų prognozavimui, apžvelgti dažniausiai taikomi algoritmai bei palyginti trumpalaikių prognozuojamų kainų rezultatai su realiais duomenimis.

1. Dirbtinio intelekto taikymo kriptovaliutų rinkoje apžvalga


Pirmoje straipsnio dalyje apžvelgiamas dirbtinis intelektas, jo svarba ir taikymas kriptovaliutų rinkoje. Pagrindinis dėmesys skiriamas giliojo mokymosi algoritmo pritaikymo galimybės kriptovaliutų kainų prognozavimui bei rezultatų tikslumo nagrinėjimui.

Kriptovaliutos nėra nei naujas produktas, nei faktiniai pinigai, tai visiškai skaitmeninė vertės perdavimo priemonė, kurios naudojimo ir ateities galimybių aspektai yra vis dar tiriami ir teisiškai apibrėžiami. Kriptovaliutų pradžia laikomi 2009 metai, kai buvo pristatyta Bitcoin kriptovaliuta. Nepaisant to, intensyvus susidomėjimas ir

naudojimas investiciniu pobūdžiu yra ganėtinai naujas reiškinys, kuris stokoja detalių tyrimų tiek ties kriptovaliutų rinkos kainų kitimu, tiek investavimu ir prognozavimu. Kriptovaliutų apibrėžimas yra dažnai tapatinamas su elektroninių pinigų sąvoka, kas teisiškai neatitinka elektroninių pinigų ir elektroninių pinigų įstaigų XIII-1094 įstatymo apibrėžtų būtinų sąlyga, tokių kaip plataus priimtumo ar leidėjui privalomo išpirkimo. Lietuvos Bankas (2017) kriptovaliutas apibūdina kaip nereguliuojamus skaitmeninius pinigus, kurių išleidimo į apyvartą negarantuoja centrinis bankas. Virtualūs pinigai arba kriptovaliuta literatūroje apibūdinama kaip elektroniniu būdu išleidžiama valiuta, kurios pakeitimas į realios vertės pinigus nėra garantuotas valstybės. Dauguma mokslininkų kriptovaliutas apibūdina kaip virtualų turtą, kurio paskirtis yra būti mainų priemone ar terpe. Tam sukurti naudojama sudėtinga kriptografijos technologija, kuri užtikrina finansinių operacijų srauto saugumą ir papildomų kriptovaliutų generavimą (Schueffel, 2017; Chohan, 2018). Andrianto (2017) apibūdina kriptovaliutas kaip sparčiai besiplečiančią mokėjimo sistemą, priklausančią nuo skaitmeninės blokų grandinės sistemos. Dourado ir Brito (2014) įvardina virtualias valiutas kaip sistemą, kuri naudoja kriptografiją, kad užtikrintų saugų skaitmeninių žetonų pardavimą ar keitimąsi decentralizuotu būdu. Tad bendrai tariant, kriptovaliuta tai – mokėjimų terpės sistema, naudojanti kriptografijos technologiją, kad sukurtų virtualaus turto vertę.

Baur et al. (2018) kriptovaliutas apibrėžia, kaip investavimo priemonę. Mokslininkai teigia, kad virtualios valiutos nėra tik mokėjimų sistema, tačiau ir ypač sparčiai populiarėjanti investavimo priemonė. Kriptovaliutų rinka yra auganti, nestabili ir nuolat besikeičianti, kas paverčia ją ypač rizikinga. Augantis susidomėjimas investavimo srityje išbalansuoja kriptovaliutų kainas, sukeldamos vertės nepastovumą, kas atbaido potencialius valiutos naudotojus. Taip pat nevertėtų užmiršti ir rizikos dėl didelės kriptovaliutų koncentracijos vienoje vietoje, ko pasekoje galimas dirbtinis kainos sukėlimas. Paprasčiausias pavyzdys būtų sutartinis sandoris tarp dviejų santykinai didelį kiekį kriptovaliutų turinčių šalių, kur dirbtinai atliekant pirkimo ir pardavimo sandorius, skatinamas dirbtinis kainos augimas. Stabili pusiausvyra tarp investuotojų ir vartotojų yra ypač svarbi, siekiant išlaikyti kriptovaliutų, kaip mainų priemonės, matavimo mato ir kaupimo būdo sėkmę (Platanakis ir Urquhart, 2019).

Rinkos pokyčio krypties prognozavimas yra sudėtingas ir tuo pat įdomus mokslininkams, siekiantiems pagerinti jau egzistuojančius prognozavimo modelius. Kiekvieno investuotojo tikslas, renkantis investavimo strategiją, remiantis modeliais, medija ir naujausia informacija, ekonomikos prognozėmis ir panašiai, yra atlikti sprendimus, kurie sumažintų riziką ir padidintų pelną. Kriptovaliutos ypač pasižymi savo kainų nepastovumu, ką virtualios valiutos ypač aiškiai įrodė 2017–2018 metais (1 paveikslas). Kainos kintamumas rodo, kiek yra rizikingas turto laikymas tam tikru metu ar laikotarpiu. Kuo didesnis kainos pokyčio procentas, tuo didesnė tikimybė, kad vertė gali arba smarkiai pakilti arba taip pačiai nukristi. Tai sudaro ganėtinai didelę riziką, tačiau tuo pat metu padidina šansus patirti didelį pelną per trumpą laiko tarpą. Theblockcrypto.com (2019) atlikta kainų kitimo analizė parodė, kad 2009 birželį Bitcoin buvo pati nestabiliausia valiuta – kainos pokytis siekė 102 %. Nepaisant to, Bitcoin išliko pelningiausia kriptovaliuta, kurios vertė netgi pakilo 30 %. „Ltecoin“ kainų svyravimas siekė 98 %, „XRP“ – 82 %. Bitcoin kainos augimas sukėlė rinkos dalyviams vilčių, kad tai numatoma rinkos augimo kryptis. Dėl to dauguma investuotojų koncentruojasi į kriptovaliutų rinkos augimo galimybes. Coinmarketcap.com duomenimis, dabartinėje rinkoje yra 2,895 kriptovaliutos, kurių kapitalizacija, paklausa ir cirkuliavimas rinkoje yra skirtingas. Atsižvelgiant į tai, kad investavimo rizika yra didelė, ypač aktualus ir svarbus yra tikslingas rinkos prognozavimas.



1 paveikslas. Bendra kriptovaliutų rinkos kapitalizacija (JAV doleriais) 2013–2019 metais (coingecko.com, 2019)

Nors klasikinis sprendimų priėmimo požiūris yra grindžiamas laiko patikrintomis sprendimų priėmimo taisyklėmis, šiuolaikinis sprendimų palaikymas daugiausia grindžiamas statistiniais įrodymais, kurie gaunami analizuojant patikimus duomenis (Feuerriegel ir Fehrer, 2016). Ši duomenų pagrįstumu palaikoma sprendimų priėmimo būdą paskatino suvokimas, kad žmonės ir jų kompiuteriai generuoja daug ir įvairių duomenų, kuriuos yra įmanoma analizuoti. Šis atotrūkis ir bandymas fiksuoti ir naudoti pusiau struktūruotų ir nestrukūruotų duomenų vadinamas „Big Data“ – didžiųjų duomenų era. Terminas apima nuolat didėjančių duomenų kieki ir sparčiai besivystančios kompiuterinės technikos tobulinimą, kad sprendimų priėmimas būtų grindžiamas sudėtingų duomenų analize (Power, 2014). Tikslingam, greitam ir efektyviam gaunamos informacijos analizavimui pasitelkiami algoritmai. Mašininio mokymosi procese, sudarytam algoritmui duodamas duomenų rinkinys, kurio pagrindu atliekamos prognozės ar sprendimai (Mahdavia ir Ghorbani, 2019). Gilusis mokymasis yra mašininio mokymosi atšaka, kuriame mokymasis yra sudarytas iš neuronų sluoksnių, kurių kiekvienas pateikia mokymosi proceso algoritmą. Neuronų sluoksniai leidžia palaipsniui išgauti savybes, būdingas kiekvienam lygiui iš pateiktų tyrimo duomenų. Giliojo mokymosi algoritmas sudaro struktūrą, kuri veikia atgaline seka, kurios metu kiekviename sluoksnyje gauti parametrai yra pritaikomi prieš tai gautiems parametrams, tam, kad būtų sudaryta visus sluoksnius atspindinti veiksmų struktūra (Zhong et al., 2018; Aldweesh et al., 2019).

Kaip ir akcijų rinkos prognozavime, taip ir kriptovaliutų rinkoje, kyla klausimas – ar yra įmanoma nuspėti kriptovaliutų elgesį, kai šis yra toks dinamiškas, kas iš esmės prieštarauja Efektyvios rinkos hipotezei, pagal kurią kainų kitimas yra atsitiktinis (Sun et al., 2020). Ankstesni tyrimai virtualių valiutų kainas numatė dviem būdais: empirine analize ir mašinų mokymosi algoritmų analize. Šiame straipsnyje apžvelgiama giliojo mokymosi algoritmų metodų taikymas literatūroje, kriptovaliutų kainų prognozavimui.

Sun et al. (2020) atliko kainų prognozavimą taikydami tris skirtingus metodus: „LightGBM“, SVM („Support Vector Machines“) ir RF („Random Forests“). Tyrimui buvo naudojamos 42 kriptovaliutos, pasirinktos pagal aktyvumą. Gauti rezultatai parodė, kad modeliai geriausiai veikia naudojant dviejų savaičių prognozavimo laikotarpį. Atlikus tą patį tyrimą pasirinkus 10 stipriausių valiutų, prognozavimas buvo šiek tiek tikslesnis. To pasėkoje autoriai priėjo išvada, kad prognozavimo tikslumas koreliuoja su kriptovaliutų stiprumu ir prognozavimo laikotarpiu. Lyginant tris modelius, LightGBM parodė geresnius rezultatus lyginant su likusiais dviem.

Lahmiri ir Bekiros (2019) kriptovaliutų kainų prognozavimui pasirinko siauresnę imtį – tris pačias aktyviausias kriptovaliutas – Bitcoin, Digital Cash ir Ripple. Taikant giliojo mokymosi algoritmus. Šiuo tikslu buvo pasirinkti du algoritmai – LSTM ir apibendrintas regresinis tinklas (angl. *generalized regression neural networks*, toliau GRNN). Autoriai taip pat šiek tiek patobulino LTSM modelį, pertaikydami jam „kontroliuojančius vartus“, kurių galutinis tikslas – filtruoti informaciją, kuri yra reikšminga, ir galiausiai taptų prognoze. Tyrimo rezultatai parodė, kad LSTM giliojo mokymosi sistema, geriau sugebėjo išmokyti trijų pasirinktų valiutų kitimo dinamiką ir pateikti tikslesnei prognozes, lyginant su GRNN. Autoriai taip pat pabrėžė, kad giliojo mokymosi sistemos sugeba įsisavinti tiek trumpalaikę tiek ilgalaikę informaciją tuo pat metu, kas suteikia pranašumo siekiant atskleisti kitimo seką.

Madan et al. (2015) taip pat taikė giliojo mokymosi algoritmus Bitcoin kainų prognozavimui. Bendrai duomenų kitimo tendencija aptikti, taikytas atraminių vektorių klasifikatoriaus (SVM) algoritmas. Tyrimo rezultatai buvo teigiami – autorių algoritmas 98,7 % tikslumu numatė Bitcoin dienos kainas, ir 50–55 % aukšto dažnio kainas. Bitcoin kainą taip pat prognozavo ir Chen et al. (2020). Autoriai naudojo tiek statistinius metodus tiek mašininio mokymosi metodus. Dienos kainos prognozavime, statistiniai metodai pasiekė 66 % tikslumą, kur giliojo mokymosi algoritmų rezultatai pasiekė 65 % tikslumą. Tačiau lyginant su aukšto dažnio kainų prognozavimu, mokymosi modelių rezultatai pasiekė 67,2 % tikslumą, kai statistinio prognozavimo tikslumo vidurkis siekė – 53 %. Rebane et al. (2018), Torres ir Qiu (2018) savo darbuose, taip pat lygino giliojo mokymosi prognozavimo rezultatus su laiko eilučių analizės modelio rezultatais. Abu darbai patvirtino, kad algoritmo pateiktos prognozės yra tikslesnės negu laiko eilučių statistinio prognozavimo metodo.


Kim et al. (2016) kriptovaliutų kainos vertinimui naudojo virtualių valiutų svetainių naudotojų išreiškiamus komentarus taikant sentimentų analizę, kaip veikiančią jų kainos svyravimo ir naudojimo faktorių. Mokslininkai pritaikė šį paprastą, tačiau efektyvų būdą trijų populiariausių kriptovaliutų kainų ir operacijų prognozavimui. Autoriams pavyko pasiekti 79,57 % prognozavimo tikslumą taikant Granger priežastingumo modelį. Tyrimas parodė, kad tiek kainų kitimas, tiek operacijų apimtis yra stipriai susiję su teigiamomis temomis, komentarais bei atsakymais. Mai et al. (2018) atliko tyrimą apie Bitcoin kainos kitimo ir socialinių tinklų sąsają. Šis tyrimas parodė, kad socialiniuose tinklai sudaryti iš 95 % pasyvių naudotojų, kas palieka 5 % aktyvių vartotojų, kurie paskelbia didžiąją dalį komentarų ir diskusijų, veikiančių kriptovaliutų kainų svyravimus. Tyrimo rezultatai leido priėti išvadą, kad sentimentų analizė yra svarbus ir efektyvus kriptovaliutų kainų prognozavimo būdas.

Apžvelgus šiuos ir panašius empirinius tyrimus, pastebėta, kad tyrimui naudojant dažną kainos kitimą, giliojo mokymosi algoritmų rezultatai yra tikslesni. Kai kurie mokslininkų darbai parodė, kad taikant statistinius metodus prognozavimui, galimi netgi tikslesni rezultatai. Žinoma, rezultatų gavimui yra ypač svarbus duomenų dažnumo pasirinkimas, dėl ypač greitai kintančios kriptovaliutų kainos bei prognozavimo laikotarpio pasirinkimas. Nepaisant to, galima pabrėžti, kad dirbant su dideliu kiekiu duomenų, dirbtinis intelektas yra pranašesnis, mat duomenys apdorojami su mažesniu žmogiškųjų klaidų faktoriumi.

2. Giliojo mokymosi algoritmai kriptovaliutų prognozavime


Kaip jau minėta, gilusis mokymasis yra mašininio mokymosi atšaka. Šis algoritmas buvo sukurtas remiantis žmogaus biologine smegenų struktūra ir jos neuroninio tinklo funkcijomis. Neuronų tinklas yra programavimo sistema, sudaryta iš sujungtų neuronų, kuriais yra perduodami signalai. Ši sistema leidžia kompiuteriui mokytis iš stebėjimo duomenų, taip palaipsniui tobulindama veiksmų atlikimą signalų perdavimo metu (Talo et al., 2019). Vieno neurono signalo išvestis (angl. *output*) veikia kaip kito neurono įvestis (angl. *input*). Algoritmo veikimo principas yra daugkartiniu informacijos apdorojimu, kas suteikia gilesnį ir naudingesnį mokymąsi. Neuronų tinklai dažniausiai yra sudaryti iš sluoksnių, kurių kiekvieną sudaro daugybė neuronų. Tokia struktūra leidžia kompiuteriui rinkti apdorotus duomenis, kurie moko, kaip turėtų būti pakeisti vidiniai parametrai, kad būtų atvaizduotas kiekvieno sluoksnio rezultatas. Rezultatai ar atpažinti pasikartojantys veiksmai yra skaitiniai ir išreikšti vektoriuose, kurie vartotojui pateikiami kaip vaizdai, tekstas, laiko eilutės ir pan. (Zhong et al., 2018).

Sluoksniai yra surišti mazgais (sinapsėmis), kuriuose vyksta skaičiavimai. Mazgas derina duomenų įvestį su koeficientų arba svorių rinkiniu, kurie tą įvestį arba sustiprina, arba sumažina, taip priskirdami įvesties reikšmę užduočiai, kurią bando išmokyti algoritmas. Sinapsių ir neuronų sandaugų suma sudaro aktyvavimo funkciją, kuri apriboja neurono išvesties amplitudę. Naudojant aktyvavimo funkciją yra nustatoma, ar ir koku mastu išvesties signalas toliau turėtų būti siunčiamas per tinklą. Jei signalas praeina, neuronas tampa „aktyvuotas“ (Selman, 2012; MahdaviFar ir Ghorbani, 2019). 2 paveikslas vaizduoja neurono tinklo veiklos struktūrą.




2 paveikslas. Neurono tinklo veiklos struktūra (Love, 2007)

Visų pirma yra sudedamos neuronų reikšmės, kurios buvo prieš tai prijungtuose stulpeliuose. Paveiksle vaizduojami keturi signalai (X_1, X_2, X_3, X_4), taigi turime keturis neuronus besijungiančius prie vieno. Kiekvienas signalas yra sudauginamas iš atitinkamo svorio (w_1, w_2, w_3, w_4). Kiekviena neuronų jungtis turi savo svorius reikšmes, kurios yra vienintelės kintančios mokymosi proceso metu. Trečiu žingsniu yra gaunama sandaugų suma. Suma keliauja į aktyvacijos funkciją, kuri dažniausiai yra pakeičiama į reikšmę nuo 0 iki 1. Tam dažniausiai naudojama Sigmoido funkcija, dar vadinama logistine funkcija (3 paveikslas). Gauta reikšmė, siunčiama toliau, kaip signalas kitam neuronui (Selman, 2012; MahdaviFar ir Ghorbani, 2019). Pagrindinė neuronų tinklo užduotis yra sugeneruoti išvesties rezultatą kiekvienam signalui. Iš pradžių algoritmas bando nustatyti ir suderinti teisingų atsakymų skaičių, taip kartais tiesiog atspėjant atsakymus. Spėjimai lyginami su realiai duomenimis, pagal ką keičiami parametrai, kol gaunamas rezultatas, taptų panašesnis į pateiktus „tikruosius“ duomenis. Taigi, kol algoritmas „mokosi“ jis tūkstančius kartų spėlioja, lygina, priskiria svorius ir vėl lygina rezultatus, kol spėlionės nustoja tikslėti arba tikslumas tampa per mažas tolesniam tikslinimui (Tang et al., 2018).



3 paveikslas. Sigmoido funkcija (Chang et al., 2012)


Pagrindinis giliojo mokymosi skiriasis bruožas nuo kitų mašininio mokymosi metodų yra, tai, kad giliojo mokymosi algoritmas klasifikuoja ir mokosi daugiau pagal sutapimus ir tam tikrus aptinkamus duomenų bruožus, negu specifinių užduočių algoritmus. Tai yra naudinga kriptovaliutų prognozavimui, kai pateikus didelį duomenų kiekį, algoritmas surenka panašius kainų pokyčius. Taip pat algoritmo klasifikatoriai mokosi su įvairiu duomenų kiekiu, kurio rezultato tikslumas gerėja didėjant duomenų kiekiui (4 paveikslas) (Tang et al., 2018).



4 paveikslas. Duomenų kiekio įtaka dirbtinio intelekto metodų rezultatų tikslumui (Tang et al., 2018)

Ilgalaikės trumpalaikės atminties tinklas (LSTM) yra besikartojančių neuronų tinklo (angl. *recurrent neural network*, toliau RNN) algoritmo tęsinys (Hochreiter ir Schmidhuber, 1997). RNN algoritmas geba aptikti stebimų duomenų sekas ir jas tiksliai suklasifikuoti pagal koreliacijos stiprumą. Siekiant pašalinti RNN algoritmo netikslumus besimokant iš laiko-eilučių duomenų, buvo sukurta patobulinta jo versija, kuri geba apdoroti ir mokytis iš ilgesnių laiko eilučių – LSTM (Nakisa et al., 2018). Būtent dėl šios priežasties LSTM yra tinkamas metodas kriptovaliutų kainų prognozavimui. Straipsnio tikslui pasiekti bus taikomas sekos eilės mokymosi regresinis modelis (angl. *sequence-to-sequence learning*). Šiame ilgalaikės trumpalaikės atminties modelio mokymo būde gauti atsakymai yra mokymosi seka, kurios reikšmės keičiasi per vieną periodą. To pasėkoje, kiekvienos įvesties laiko žingsnyje, LSTM tinklas mokosi numatyti kito laiko žingsnio reikšmę.

Taikant šį prognozavimo metodą, LSTM algoritmas mokosi prognozuoti. Tam kad būtų vykdomi žemiau pateikti modelio mokymosi žingsniai (5 paveikslas) taikomas algoritmo kodas:



5 paveikslas. Ilgalaikės trumpalaikės atminties neuronų tinklo struktūra (Le et al., 2019)

LSTM tinklas yra sudarytas iš atminties blokų, kurie vadinami ląstelėmis (angl. *cells*). Duomenų srauto judėjimą sudaro būsenų perdavimas iš vienos ląstelės į kitą: ląstelės būsenos (C_{t-1}), kuri siunčia paskutinio LSTM vieneto atminties informaciją ir paslėptos būsenos (h_{t-1}) – paskutinė LSTM vieneto išvesties. Paslėptoji būseną veikia, kaip neuronų tinklo atmintis – saugo informaciją iš apdorotų duomenų prieš tai. Ši būseną gaunama sudarant vektorius iš esamos ir buvusių įvesčių, taip saugant informaciją apie ne tik esamą bet ir visas buvusias įvestis. Vektorius toliau

keliauja per aktyvacijos funkciją (σ), kurios gautas rezultatas yra nauja paslėpta būseną (h_t), kuri toliau keliauja link naujos įvesties (X_t) (Le et al., 2019).

Duomenys iš ląstelės gali būti pašalinti arba pridėti per sigmoido vartus, kartais dar vadinamus reguliatoriais (angl. *sigmoid gate*). Vartai yra sudaryti iš svorių. LSTM dažniausiai turi tris vartus: įvesties (σ_i), išvesties (σ_o) ir pamiršimo (σ_f). Jų paskirtis yra skirstyti ir reguliuoti duomenų srautus. Išvesties vartai atskiria, kuri informacija turėtų būti palikta, o kuri išmesta. Čia, jei iš sigmoido funkcijos gauta reikšmė yra arti 0, vadinasi, turi būti pamiršta, jei, kuo arčiau 1 – išsaugota. Įvesties vartai skirti ląstelės būsenos atnaujinimui. Čia pirmiausia paskutinė paslėpta būseną ir nauja įvesties suma yra paverčiami į reikšmę, nuo 0 iki 1, naudojant sigmoido funkciją. Suma neuroniniais tinklais keliauja ir į tanh funkciją, kur priskiriama reikšmė nuo -1 iki 1, tam kad tinklas būtų sureguliuotas. Abiejų funkcijų išskirtys yra sudauginamos ir keliauja į sigmoido funkciją, kur vėl yra sprendžiama ar rezultatas turėtų būti atsimintas ar pamirštas. Apdorota informacija keliauja link prieš tai buvusios ląstelės būsenos (C_{t-1}), kurios reikšmė yra sudauginama su pamiršimo vartų išvestimi. Gauta sandauga yra susumuojama su įvesties ir tanh funkcijų sandauga. Ši išvestis keliauja toliau, kaip atnaujinta ląstelės funkcija – C_t (Tran et al., 2018).

Išvesties vartai skirti paslėptos ląstelės būsenos atnaujinimui. Tam prieš tai esanti paslėpta ląstelės būsenos reikšmė siunčiama į sigmoido funkciją, kartu su nauja įvestimi. Tuomet gauta reikšmė sudauginama su reikšme gauta siunčiant atnaujintą ląstelę (C_t) į tanh funkciją. Sandauga yra nauja paslėpta išvestis (h_t). Apibendrinant, vartai mokosi, kuriuos duomenis reikia palikti, kuriuos išmokti ir saugoti. Tokiu būdu informacija perduodama ilgoje sekų grandinėje (Tran et al., 2018).

Tyrimo praktinėje dalyje ilgalaikės trumpalaikės atminties modelio algoritmas mokomas prognozuoti kriptovaliutos kainą. Tyrimui buvo pasirinktos penkios kriptovaliutos, pagal jų kapitalizaciją rinkoje, remiantis naujausiais coinmarketcap.com duomenimis: Bitcoin, XRP, Bitcoin Cash, Litecoin, Binance Coin. Algoritmo mokymui yra pasirinktas kasdieninis uždarymo kainos kitimas periodui nuo 2017 m. sausio 1 iki 2019 m. spalio 31. Duomenys surinkti iš finance.yahoo.com atviros prieigos svetainės. Žemiau pateikti, duomenų prognozavimo žingsniai:

- Algoritmas mokosi nuspėti reikšmės naudojant prieš tai buvusią laiko eilutės reikšmę iš eilės pagal seką, taip paslenkant kiekvieną buvusią vertę per vieną laiko žingsnį. Mokymuisi bus testuojama ir mokomasi iš 90 % pateiktų duomenų, likusius 10 % prognozuojant ir vertinant nuokrypį nuo gautų reikšmių ir realių duomenų.
- Kad algoritmo mokymasis būtų tikslesnis ir neiškryptų, duomenys standartizuojami, taip kad vidurkio ir vieneto dispersija būtų lygi nuliui. Duomenų prognozavimui bus naudojami tokie patys parametrai, kaip ir treniruočių duomenims.
- Duomenų prognozavimui algoritmas mokomas su kiekviena nauja įvestimi numatyti būsimą reikšmę. Taigi algoritmas mokysis iš numatytų reikšmių sekos principu.
- Numatytos reikšmės lyginamos su mokymosi duomenimis skaičiuojant kvadratų vidurkio kvadratinės šaknies nuokrypį (angl. *root mean square error*, toliau RMSE).
- Naudojant realius duomenis, LSTM tinklas bus atnaujintas, tam kad prognozuojant sekančią laiko žingsnio reikšmę, būtų naudojami realūs duomenys, vietoj prieš tai išprognozuoto.
- Vertinamas prognozavimo tikslumas, skaičiuojant kvadratų vidurkio kvadratinės šaknies nuokrypį ir vidutinę absoliutinę procentinę paklaidą su atnaujintais duomenimis.

3. Giliojo mokymosi algoritmo taikymo kriptovaliutų kainų prognozavimui tyrimas


Tyrimas atliekamas naudojant Matlab programinę terpę, kuri yra skirta įvairiems matematiniams veiksams atlikti, vienos iš jų – operacijos matricomis. Ši programa pasirinkta dėl savo neuroninių tinklų funkcijų rinkinio, kuris skirtas neuroninių tinklų kūrimui. Tyrimo metu visiems duomenims naudojami vienodi parametrai. Kad duomenys mokymosi proceso metu neiškryptų ir būtų tinkami neuronų tinklo formavimui, nustatomi nulinio vidurkio ir vieneto dispersijos standartizavimo rėmai. Kadangi duomenų kiekis didelis, nustatoma, kad LSTM sluoksnis turės 200 paslėptųjų jungčių. Prognozavimas vyks sekos principu, tam algoritme nurodama, kad mokymasis vyktų iš išvesties, t. y. su kiekvieną įvestimi, LSTM numatys sekantį žingsnį, jo atsakymas bus naudojamas kito žingsnio numatymui ir t. t. dėl ko mokymasis neturi galutinės mokymosi įvesties. Tam, kad prognozavimas būtų tikslus, duomenų atnaujinimui nurodoma 300 epochų. Šios epochos reprezentuoja, kiek kartų visi mokymo vektoriai bus naudojami svorių atnaujinimui. Šiame etape 90 % testuojamų duomenų yra naudojami mokymuisi prieš svorių atnaujinimą.

Lentelė 1 pateikia testuojamų kriptovaliutų atnaujinto neuronų tinklo prognozavimo kvadratų vidurkio kvadratinės šaknies nuokrypį prognozuotam laikotarpiui ir vidutinę absoliutinę procentinę paklaidą (angl. *mean absolute percentage error*, toliau MAPE) pirmai prognozės savaitei. Čia MAPE reprezentuoja prognozavimo tikslumą – paklaidos dydį procentais nuo tikrųjų reikšmių, RMSE parodo nuokrypių sklaidą, tad kuo didesnis RMSE, tuo didesnis prognozių nuokrypiai nuo realių reikšmių.

1 lentelė. Prognozavimo su atnaujintai duomenimis nuokrypiai (sudaryta autorių)


	Bitcoin	XRP	Bitcoin Cash	Litecoin	Binance Coin
RMSE	459,68	0,0097	13,11	2,9338	1,96
MAPE	0,813 %	0,027 %	0,033 %	0,024 %	0,027 %

Iš 1 lentelės matome, kad didžiausias tiek RMSE tiek MAPE nuokrypis yra Bitcoin kriptovaliutos duomenims. Tai galimai yra dėl to, kad tai pati nepastoviausia kriptovaliuta, turinti didžiausią kapitalizaciją ir investuotojų susidomėjimą, kas lemia akivaizdžią RMSE reikšmės atotrūkį, nuo likusių rezultatų. Kadangi Bitcoin kainos pokyčiai taip pat jautresni tiek ekonomikos svyravimams, tiek socialinėse erdvėse vyraujantiems vartotojų lūkesčiams, algoritmui yra sunkiau mokytis ir tiksliau prognozuoti kainos pokyčius, ko pasėkoje nuokrypis yra didžiausias. Tačiau žvelgiant į 6 paveikslą, matome, kad kainos kitimo tendencija atitinka realius duomenis. Iš prognozės grafiko, pastebima, kad modelio prognozės pateikė žemesnes, negu realias kainas.




6 paveikslas. LSTM prognozės su atnaujintai duomenimis Bitcoin kriptovaliutai (sudaryta autorių)

Žvelgiant į tiksliausias prognozes, čia galima išskirti dvi kriptovaliutas – Ripple (XRP), turintį mažiausią RMSE ir Litecoin, su mažiausiu MAPE. 7 paveikslas vaizduoja XRP kriptovaliutos prognozes su atnaujintais duomenimis. Visų pirma pastebima, kad kainos kitimo tendencija yra tarsi pasislinkusi per vieną laiko žingsnį. Taip pat iš paklaidos sklaidos matome, kad ji yra tolygiai pasiskirsčiusi, vadinasi prognozuojama kaina buvo svyruojanti – tiek didesnė, tiek mažesnė negu realūs duomenys. Stebina, tai, kad modelis išprognozavo ganėtinai staigų kainos šuolį ir kritimą 60–70 dienomis, tiek visą kainos kitimo tendenciją. Tam įtakos gali turėti žemesnė kriptovaliutos kaina, ko pasėkoje gaunama mažesnė paklaidos sklaida.




7 paveikslas. LSTM prognozės su atnaujintai duomenimis XRP kriptovaliutai (sudaryta autorių)

Žvelgiant į Litecoin prognozių rezultatus 8 paveiksle, taip pat yra matomas tikslus realių duomenų atkartojimas, tiek ties kainos dydžiu, tiek pačia kainos kitimo tendenciją. Besimokydamas iš Litecoinduomenų, algoritmas tiksliau išpranašavo, kainos dydžius, negu XRP kriptovaliutai, tai pastebima ne vien tik iš MAPE geresnio rezultato, bet ir iš to, kad prognozuojama linija yra šiek tiek labiau „užlipus“ ant stebimų duomenų.




8 paveikslas. LSTM prognozės su atnaujintai duomenimis Litecoin kriptovaliutai (sudaryta autorių)

Iš 1 lentelės matome, kad Binance Coin turi mažiausią RMSE nuokrypį po XRP kriptovaliutos bei tik 0,003 % didesnę MAPE nuo mažiausio rezultato. Tačiau iš 9 paveikslą matome, kad prognozuojamų duomenų atotrūkis pastebimai didesnis ir beveik visą prognozuojamą laikotarpį laikosi aukščiau realių kainų, lyginant su kitomis prognozėmis.



9 paveikslas. LSTM prognozės su atnaujintai duomenimis Binance Coin kriptovaliutai (sudaryta autorių)

10 paveiksle vaizduojama antra pagal nuokrypį netikslingiausiai išprognozuotos kriptovaliutos – Bitcoin Cash – vertės raida. Prognozės atrodo netgi tikslesnės už Litecoin, tačiau RMSE yra didesnis. Tam įtakos turi kainų skirtumai, mat lyginant pagal MAPE santykinį nuokrypį, Bitcoin Cash rezultatai yra tik 0,03 %.



10 paveikslas. LSTM prognozės su atnaujintai duomenimis Bitcoin Cash kriptovaliutai (sudaryta autorių)

Apibendrinant galima teigti, kad LSTM modelis tiksliai atvaizduoja kainos kitimo tendenciją. Pastebima, kad mažesnės kainos kriptovaliutų prognozės yra tikslesnės ir su mažesne paklaida. LSTM modelis visoms penkioms kriptovaliutoms prognozavo realius duomenis atitinkančias kainų kitimo tendencijas. Nors giliojo mokymosi algoritmas neatkartoja tiksliai būsimų kainų prognozių, nuokrypis yra sąlyginai mažas – neperkopia 0,8 % didžiausią kapitalizaciją turinčiomis kriptovaliutomis. Tokie rezultatai leidžia prognozuoti, kad dirbtinio intelekto technologijos bus sparčiai integruojamos į finansų rinką, taip plečiant finansinių paslaugų šaką elektroninėje erdvėje tiek privatiems asmenims, tiek įmonėms. Kriptovaliutų perdavimo ir vertės kitimo stebėjimo bei investavimo raliu laiku poreikis stimuliuoja paklausą ir galimybes fintech produktams, kurie leistų vartotojui saugiai, greitai ir patogiai dalyvauti kriptovaliutų rinkoje bei integruoti kriptografijos bei giliojo mokymosi technologijas į verslo modelius.

Išvados

Dauguma mokslininkų kriptovaliutas apibūdina kaip virtualų turtą, kurio paskirtis yra būti mainų priemone ar terpe, kur reguliacinės įstaigos kriptovaliutas mato, kaip nereguliuojamą virtualią vertės išraišką, kuri gali būti naudojama, kaip pinigų alternatyva bei investavimo priemonė. Užtikrintumo ir saugumo poreikis, skatina turėti mechanizmą ar prognozavimo modelį, kuris tai atliktų už juos ir garantuotų pelną su mažiausia rizika.

Mokslinės literatūros apžvalgos parodė, kad yra keli dirbinio intelekto naudojimo modeliai, kurie gali būti pritaikyti kriptovaliutų kainų ir operacijų prognozavime. Vieni iš dažniausiai naudojamų modelių buvo LSTM ir Random Forest. Tyrimui pasirinktas ilgalaikės trumpalaikės atminties tinklo algoritmas, dėl laiko-eilučių duomenų apdorojimo pritaikomumo. Gauti rezultatai parodė, kad prognozių paklaida yra didesnė kriptovaliutoms, turinčioms istoriškai didesnę kainos svyravimą, lyginant su stabilesnėmis, žemesnę kainą turinčios kriptovaliutomis. Nepaisant to, vidutinė absoliutinė procentinė paklaida analizuotoms kriptovaliutoms neviršijo 0,8 %, ką galima laikyti geru prognozavimo rezultatu. Taigi galima teigti, kad LSTM modelis yra tinkamas kriptovaliutų kainų prognozavimui. Remiantis šiais rezultatais, giliojo mokymosi algoritmų bei kriptografijos technologija gali būti pritaikyta sudarant optimalius investicinius portfelius bei jų rizikos valdyme. Šių technologijų pritaikymas finansų rinkoje užtikrintų finansinių pavedimų saugumą, greitį ir anonimiškumą. Plečiantis kriptovaliutų primitivumui ir dvipusisškumui, auga fintech paslaugų paklausa bei reguliacinė reikmė, užtikrinanti finansinį makroekonomikos stabilumą. Visos šios technologinės galimybės kelia gilesnio tyrimo reikalaujančią problemą: kaip išlaikyti finansinį stabilumą, kai finansų dalyviai vis labiau remiasi kompiuterio sprendimais bei renkasi necentralizuotas ir nereguliuojamas investavimo priemones. Tai verčia hipnotizuoti, kas bus jei visi finansų rinkos dalyviai žinos kaip uždirbti su maža rizika? Apibendrinant, giliojo mokymosi algoritmų pritaikymas investavimo procese, tiek pačios kriptovaliutų rinkos vystymasis rodydamas daug potencialo, neslepia ir galimų rizikų.

Literatūra

- Aldweesh, A., Derhab, A., & Emam, A. Z. (2019). Deep learning approaches for anomaly-based intrusion detection systems: A survey, taxonomy, and open issues. *Knowledge-Based Systems*, 189, 105124. <https://doi.org/10.1016/j.knosys.2019.105124>
- Andrianto, Y. (2017). The effect of Cryptocurrency on investment portfolio effectiveness. *Journal of Finance and Accounting*, 5(6), 229–238. <https://doi.org/10.11648/j.jfa.20170506.14>
- Baur, D. G., Hong, K. H., & Lee, A. D. (2018). Bitcoin: Medium of exchange or speculative assets? *Journal of International Financial Markets, Institutions and Money*, 54, 177–189. <https://doi.org/10.1016/j.intfin.2017.12.004>
- Chang, J., Arbeláez, P., Switz, N., Reber, C., Tapley, A., Davis, J. L., Cattamanchi, A., Fletcher, D., & Malik, J. (2012). Automated tuberculosis diagnosis using fluorescence images from a mobile microscope. In N. Ayache, H. Delingette, P. Golland, & K. Mori (Eds.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2012*. (Lecture Notes in Computer Science, Vol. 7512). Springer. https://doi.org/10.1007/978-3-642-33454-2_43
- Chen, Z., Li, C., & Sun, W. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365, 112395. <https://doi.org/10.1016/j.cam.2019.112395>
- Chohan, U. (2018). Cryptocurrencies: A brief thematic review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3024330>
- Dourado, E., & Brito, J. (2014). Cryptocurrency. *The New Palgrave Dictionary of Economics*, 50(1), 1–10. <https://doi.org/10.1016/j.jempfin.2018.11.002>
- Feuerriegel, S., & Fehrer, R. (2016). *Improving decision analytics with deep learning: The case of financial disclosures*. Paper presented at the 24th European Conference on Information Systems, ECIS 2016.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Kim, Y. B., Kim, J. G., Kim, W., Im, J. H., Kim, T. H., Kang, S. J., & Kim, C. H. (2016). Predicting fluctuations in cryptocurrency transactions based on user comments and replies. *PLoS ONE*, 11(8), 0161197. <https://doi.org/10.1371/journal.pone.0161197>
- Lahmri, S., & Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons and Fractals*, 118, 35–40. <https://doi.org/10.1016/j.chaos.2018.11.014>
- Le, X. H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of Long Short-Term Memory (LSTM) neural network for flood forecasting. *Water (Switzerland)*, 11(7). <https://doi.org/10.3390/w11071387>
- Lietuvos Bankas. (2017). *Lietuvos bankas skelbia poziciją dėl virtualiųjų valiutų*. <https://www.lb.lt/lt/naujienos/lietuvos-bankas-skelbia-pozicija-del-virtualiuju-valiutu>
- Lietuvos Respublikos Seimas. (2018). *Lietuvos Respublikos elektroninių pinigų ir elektroninių pinigų įstaigų įstatymo Nr. XI-1868 pakeitimo įstatymas* (XIII-1094). <https://e-seimas.lrs.lt/portal/legalAct/lt/TAD/dbc23950488011e89197e1115e5dbee/KnGurqJGeD?positionInSearchResults=2&searchModelUUID=b12ba5d1-1a92-405d-b771-123d20928ad2>
- Love, J. (2007). Artificial Neural Networks. In *Process Automation Handbook* (pp. 929–943). https://doi.org/10.1007/978-1-84628-282-9_109

- Madan, I., Saluja, S., & Zhao, A. (2015). *Automated Bitcoin trading via machine learning algorithms*. [http://cs229.stanford.edu/proj2014/Isaac Madan, Shaurya Saluja, Aojia Zhao,Automated Bitcoin Trading via Machine Learning Algorithms.pdf](http://cs229.stanford.edu/proj2014/Isaac%20Madan,%20Shaurya%20Saluja,%20Aojia%20Zhao,Automated%20Bitcoin%20Trading%20via%20Machine%20Learning%20Algorithms.pdf)
- MahdaviFar, S., & Ghorbani, A. A. (2019). Application of deep learning to cybersecurity: A survey. *Neurocomputing*, 347, 149–176. <https://doi.org/10.1016/j.neucom.2019.02.056>
- Mai, F., Shan, Z., Bai, Q., Wang, X. (Shane), & Chiang, R. H. L. (2018). How does social media impact bitcoin value? A test of the silent majority hypothesis. *Journal of Management Information Systems*, 35(1), 19–52. <https://doi.org/10.1080/07421222.2018.1440774>
- Platanakis, E., & Urquhart, A. (2019). Portfolio management with cryptocurrencies: The role of estimation risk. *Economics Letters*, 177, 76–80. <https://doi.org/10.1016/j.econlet.2019.01.019>
- Power, D. J. (2014). Using ‘Big Data’ for analytics and decision support. *Journal of Decision Systems*, 23(2), 222–228. <https://doi.org/10.1080/12460125.2014.888848>
- Rebane, J., Karlsson, I., Denic, S., & Papapetrou, P. (2018, August). *Seq2Seq RNNs and ARIMA models for cryptocurrency prediction: a comparative study*. Paper presented at the SIGKDD Fintech’18 (pp. 2–6).
- Schueffel, P. (2017). *The concise Fintech compendium*. [http://www.heg-fr.ch/FR/HEG-FR/Communication-et-evenements/evenements/SiteAssets/Pages/patrick-schueffel/Schueffel \(2017\) The Concise Fintech compendium.pdf](http://www.heg-fr.ch/FR/HEG-FR/Communication-et-evenements/evenements/SiteAssets/Pages/patrick-schueffel/Schueffel%20(2017)%20The%20Concise%20Fintech%20compendium.pdf)
- Selman, S. (2012). Distinction of the authors of texts using multilayered feedforward neural networks. *Southeast Europe Journal of Soft Computing*, 1(1). <https://doi.org/10.21533/scjournal.v1i1.82>
- Sun, X., Liu, M., & Sima, Z. (2020). A novel cryptocurrency price trend forecasting model based on LightGBM. *Finance Research Letters*, 32, 101084. <https://doi.org/10.1016/j.frl.2018.12.032>
- Talo, M., Baloglu, U. B., Yıldırım, Ö., & Rajendra Acharya, U. (2019). Application of deep transfer learning for automated brain abnormality classification using MR images. *Cognitive Systems Research*, 54, 176–188. <https://doi.org/10.1016/j.cogsys.2018.12.007>
- Tang, A., Tam, R., Cadrin-Chênevert, A., Guest, W., Chong, J., Barfett, J., ... Shabana, W. (2018, May 1). Canadian association of radiologists white paper on artificial intelligence in radiology. *Canadian Association of Radiologists Journal*, 69, 120–135. <https://doi.org/10.1016/j.carj.2018.02.002>
- Theblockcrypto.com. (2019). *Bitcoin has been the most volatile and best performing major cryptocurrency in June - The Block*. <https://www.theblockcrypto.com/linked/29595/bitcoin-has-been-the-most-volatile-and-best-performing-major-cryptocurrency-in-june>
- Torres, G. D., & Qiu, H. (2018). *Applying recurrent neural networks for multivariate time series forecasting of volatile financial data* (pp. 1–10). <https://www.researchgate.net/project/Applying-Recurrent-Neural-Networks-for-Multivariate-Time-Series-Forecasting-of-Volatile-Financial-Data>
- Tran, D., Mac, H., Tong, V., Tran, H. A., & Nguyen, L. G. (2018). A LSTM based framework for handling multiclass imbalance in DGA botnet detection. *Neurocomputing*, 275, 2401–2413. <https://doi.org/10.1016/j.neucom.2017.11.018>
- Zhong, G., Ling, X., & Wang, L. (2018). From shallow feature learning to deep learning: Benefits from the width and depth of deep architectures. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(1) <https://doi.org/10.1002/widm.1255>

FORECASTING OF DIGITAL CURRENCY PRICES USING DEEP LEARNING ALGORITHM

Nijolė MAKNICKIENĖ, Kristina MIŠKINYTĖ

Abstract. Cryptocurrencies are still a novelty in the financial market which is not fully explored yet. This makes cryptocurrencies an interesting and relevant topic for researchers, regulators and investor. The cryptocurrency market is constantly growing, volatile and ever-changing, making it extremely risky for investments. Financial literacy, long-term prescience and correct focus without getting lost in chaos of risk, value and unpredictability are especially important in today's economy. Due to complex nature of the cryptocurrency market the large amount of profile data is generated, which can be processed using a variety of methods such as statistical, technical, sentiment, solution and other analysis. Previous studies have used two main method for cryptocurrency prices prediction: empirical and machine learning algorithm analysis. The aim of this article is to test the applicability of LSTM deep learning algorithm for cryptocurrency price forecasting as well as to evaluate the results. The research results showed that deep learning algorithm are able to forecast with low error magnitude, moreover trend of predicted values is accurate when compared to observed values. The results suggest that deep learning algorithm application for forecasting of cryptocurrency market price is a suitable alternative for risk minimization.

Keywords: artificial intelligence, deep learning, LSTM, forecasting, cryptocurrencies, cryptocurrencies market.