

**VILNIAUS UNIVERSITETO
KAUNO FAKULTETAS**

**SOCIALINIŲ MOKSLŲ IR TAIKOMOSIOS INFORMATIKOS
INSTITUTAS**

Finansų technologijų studijų programa
Kodas 6211BX022

GABIJA GAVRONSKYTĖ

MAGISTRO BAIGIAMASIS DARBAS

**KIEKYBINĖ KRIPTOVALIUTŲ PORTFELIŲ RIZIKOS
ANALIZĖ TAIKANT MAŠININIO MOKYMOSI METODUS**

Kaunas 2025

**VILNIAUS UNIVERSITETO
KAUNO FAKULTETAS**

**SOCIALINIŲ MOKSLŲ IR TAIKOMOSIOS INFORMATIKOS
INSTITUTAS**

GABIJA GAVRONSKYTĖ

MAGISTRO BAIGIAMASIS DARBAS

**KIEKYBINĖ KRIPTOVALIUTŲ PORTFELIŲ RIZIKOS
ANALIZĖ TAIKANT MAŠININIO MOKYMOSI METODUS**

Magistrantas_____

(parašas)

Darbo vadovas_____

(parašas)

Darbo vadovas Dr. Mantas Vaitonis

Kaunas 2025

TURINYS

TURINYS	3
SANTRUMPŲ SĄRAŠAS	4
PAVEIKSLŲ SĄRAŠAS	5
LENTELIŲ SĄRAŠAS	6
PRIEDŲ SĄRAŠAS	8
SUMMARY	9
ĮVADAS.....	10
1. KRIPTOVALIUTŲ PORTFELIO RIZIKOS ANALIZĖS TAIKANT MAŠININIO MOKYMOSI METODUS TEORINIAI ASPEKTAI.....	15
1.1. Kripto valiutų svyravimus lemiantys veiksniai	15
1.1.1. Kripto valiutos kaip investavimo alternatyva.....	15
1.1.2. Faktoriai turintys įtakos kripto valiutų svyravimams.....	16
1.1.3. Socialinių tinklų sentimentų įtaka kripto valiutų svyravimams	20
1.2. Kripto valiutų portfelio rizikos vertinimo metodai	26
1.2.1. Klasikiniai rizikos vertinimo metodai kripto valiutų portfeliams	26
1.2.2. Mašininio mokymo rizikos vertinimo metodai kripto valiutų portfeliams	28
2. KRIPTOVALIUTŲ PORTFELIŲ RIZIKOS VERTINIMO SIŪLOMAS SPRENDIMAS ..	34
2.1. Socialinių tinklų sentimentų vertinimo metodai	35
2.2. Statistiškai reikšmingų faktorių pasirinkimas	37
2.3. Monte Karlo simuliacijos metodas kripto valiutų portfelio rizikos vertinimui.....	41
2.4. Mašininio mokymosi metodų taikymas kripto valiutų portfelio rizikos analizėje	42
3. KRIPTOVALIUTŲ PORTFELIŲ RIZIKOS ANALIZĖ TAIKANT MAŠININIO MOKYMOSI METODUS	46
3.1. Kripto valiutų duomenų rinkimas ir pasirinkimas portfelio sudarymui	46
3.2. Portfelio rizikos vertinimas taikant Monte Karlo simuliaciją	57
3.3. Portfelio rizikos vertinimas taikant mašininio mokymosi metodą.....	62
IŠVADOS IR PASIŪLYMAI.....	75
LITERATŪRA	78

SANTRUMPŲ SĄRAŠAS

LSTM – Ilgosios trumposios atminties tinklas

XGBoost (eXtreme Gradient Boosting) – Ekstremalusis gradientinio mokymosi modelis

SVR (Support vector regression) – Atraminių vektorių regresija

KNN – K artimiausių kaimynų metodas

ANN (Artificial neuron network) – Dirbtinis neuronų tinklas

RF (Random Forest) – Atsitiktinio miško modelis

DMLP - Dinaminis daugiasluoksnis perceptronas

BTC – Bitkoinas (Bitcoin)

ETH – Eteris (Ethereum)

BNB – Binance moneta (Binance coin)

SOL – Solana

MSE – Vidutinė kvadratinė paklaida

MAE – Vidutinė absoliutinė paklaida

PAVEIKSLŲ SĄRAŠAS

1 pav. Kriptovaliutų kainų svyravimus lemiantys veiksniai	17
2 pav. Normalizuotos prekybos apimtys Houbi ir Bleutrade keityklose.....	19
3 pav. Naujienų klasifikavimas	21
4 pav. Duomenų išgavimas iš teksto ir klasifikavimas	22
5 pav. Mašininio mokymosi ir sąsaja su dirbtiniu intelektu.....	28
6 pav. Tyrimo eigos struktūra	34
7 pav. Socialinių tinklų duomenų paruošimas sentimentų analizei	36
8 pav. Sentimentų poliarškumas	36
9 pav. Teigiami ir neigiami sentimentai.....	47
10 pav. BTC twitter sentimentų balų ir BTC kainų judėjimo grafikas	48
11 pav. Prognozuoti kainų laikotarpiai	72

LENTELIŲ SĄRAŠAS

1 lentelė Mašininio mokymosi algoritmai rizikos vertinime	29
2 lentelė Socialinių tinklų nuotaikų vertinimo balai ir kategorijos	37
3 lentelė Pearsono koreliacijos koeficiento reikšmių interpretavimas	38
4 lentelė Pasirinktos kriptovaliutos ir jų rinkos kapitalizacija	46
5 lentelė Teigiamų ir neigiamų sentimentų pasikartojimo dažnis	47
6 lentelė Pasirinkti nepriklausomi kintamieji ir jų žymėjimas	49
7 lentelė BTC nepriklausomų kintamųjų koreliacijos lentelė	50
8 lentelė ETH nepriklausomų kintamųjų koreliacijos lentelė	51
9 lentelė BNB nepriklausomų kintamųjų koreliacijos lentelė	52
10 lentelė SOL nepriklausomų kintamųjų koreliacijos lentelė	54
11 lentelė Duomenų stacionarumo tikrinimas naudojant ADF testą	55
12 lentelė Duomenų stacionarumo tikrinimas naudojant ADF testą po diferenciacijos	55
13 lentelė BTC kainos prognozavimas naudojant Monte Karlo simuliaciją	57
14 lentelė BTC pirkimai ir pardavimai vadovaujantis Monte Karlo simuliacija	58
15 lentelė BTC pelningumas ir rizika	59
16 lentelė ETH kainos prognozavimas naudojant Monte Karlo simuliaciją	59
17 lentelė BNB kainos prognozavimas naudojant Monte Karlo simuliaciją	60
18 lentelė SOL kainos prognozavimas naudojant Monte Karlo simuliaciją	60
19 lentelė Portfelio pelningumas naudojant Monte Karlo simuliaciją	61
20 lentelė Portfelio pelningumas ir rizikos analizė naudojant Monte Karlo simuliaciją	61
21 lentelė BTC kainos prognozavimas naudojant DMLP metodą	62
22 lentelė ETH kainos prognozavimas naudojant DMLP metodą	62
23 lentelė BNB kainos prognozavimas naudojant DMLP metodą	63
24 lentelė SOL kainos prognozavimas naudojant DMLP metodą	64
25 lentelė Portfelio pelningumas naudojant DMLP metodą	64
26 lentelė Portfelio pelningumas ir rizikos analizė naudojant DMLP metodą	65
27 lentelė BTC kainos prognozavimas naudojant DMLP metodą su sentimentų analize	65
28 lentelė ETH kainos prognozavimas naudojant DMLP metodą su sentimentų analize	66
29 lentelė BNB kainos prognozavimas naudojant DMLP metodą su sentimentų analize	66
30 lentelė SOL kainos prognozavimas naudojant DMLP metodą su sentimentų analize	67

31 lentelė Portfelio pelningumas naudojant DMLP metodą su sentimentų analize.....	67
32 lentelė Portfelio pelningumas ir rizikos analizė naudojant DMLP metodą su sentimentų analize	68
33 lentelė BTC kainos prognozavimas naudojant SVR metodą	68
34 lentelė ETH kainos prognozavimas naudojant SVR metodą	69
35 lentelė BNB kainos prognozavimas naudojant SVR metodą.....	69
36 lentelė SOL kainos prognozavimas naudojant SVR metodą	70
37 lentelė Portfelio pelningumas naudojant SVR metodą	70
38 lentelė Portfelio pelningumas ir rizikos analizė naudojant SVR metodą.....	71
39 lentelė Portfelių pelningumo ir rizikos palyginimas naudojant visus rizikos vertinimo metodus	71
40 lentelė Portfelių pelningumo ir rizikos palyginimas naudojant visus rizikos vertinimo metodus kilimo laikotarpyje	72
41 lentelė Portfelių pelningumo ir rizikos palyginimas naudojant visus rizikos vertinimo metodus kritimo ir kilimo laikotarpyje	73
42 lentelė Portfelių pelningumo ir rizikos palyginimas naudojant visus rizikos vertinimo metodus kritimo laikotarpyje	73

PRIEDŲ SĄRAŠAS

Priedas 1. Socialinių tinklų sentimentų skaičiavimo MATLAB kodas	87
Priedas 2. Duomenų stacionarumo tikrinimo MATLAB kodas.....	88
Priedas 3. Tiesinės regresijos MATLAB kodas	89
Priedas 4. Monte Karlo simuliacijos MATLAB kodas	91
Priedas 5. DMLP metodo MATLAB kodas.....	92
Priedas 6. SVR metodo MATLAB kodas	94

Gavronskytė, Gabija (2025). Quantitative Risk Analysis of Cryptocurrency Portfolios Using Machine Learning Methods. MBA Graduation Paper. Kaunas: Vilnius University, Kaunas Faculty, Institute of Social Sciences and Applied Informatics. 77 p.

SUMMARY

Since the inception of cryptocurrencies in 2009, when the first cryptocurrency, Bitcoin (BTC), was launched, this market has grown to a \$1.13 trillion market. It is predicted that by 2030 this market should exceed 4 trillion US dollars with an average annual growth of 27.8%. With the growing popularity of cryptocurrencies, risk analysis of cryptocurrency portfolios using machine learning methods is becoming relevant in the scientific community as well. This line of research allows you to evaluate and understand what factors influence the dynamics of the crypto currency market and provides new insights into investment effectiveness of strategies. Compared to traditional risk assessment methods, machine learning risk assessment methods enable the management of large and complex data sets and the discovery of non-linear relationships. Unlike traditional static models, machine learning algorithms are constantly learning and adapting to new data, making them highly responsive to volatile cryptocurrency markets. Additionally, machine learning techniques can integrate real-time sentiment analysis from multiple sources, increasing predictive accuracy. These capabilities allow for a more accurate and dynamic assessment of risk in the rapidly evolving cryptocurrency environment.

Based on the analysis of literature, it was found that DMLP machine learning technique together with sentiment analysis was used only on stock prices prediction and risk evaluation, so this model was chosen to be tested on cryptocurrencies. Before forecasting cryptocurrencies prices methods like sentiment analysis, correlation and regression analysis were carried out. To evaluate DMLP models' with sentiment analysis results, they were compared to the results received from Monte Carlo simulation, DMLP and SVR models. Predictions were calculated for 4 periods. For periods when market was consolidated DMLP model with sentiment analysis provided the most accurate results and when there was bull and bear markets, DMLP method had the best results.

This paper consists of 68 pages, 42 tables and 11 illustrations.

IVADAS

Nuo kriptovaliutų pradžios 2009 metais, kai buvo pradėta naudoti pirmoji kriptovaliuta – Bitcoin (BTC), ši rinka išaugo iki 1,13 trilijono JAV dolerių rinkos (CoinMarketCap, 2024). Prognozuojama, kad iki 2030 metų ši rinka turėtų viršyti 4 trilijonus JAV dolerių su vidutiniu 27,8% metiniu augimu (GrandViewResearch, 2022). Didėjant kriptovaliutų potencialui, daugėja ir investuotojų, kurie renkasi šį finansinį instrumentą, tačiau su didele grąža kartu yra ir didelė rizika, nes kriptovaliutų rinka yra gan nestabili ir nereguliuojama.

Temos aktualumas

Kriptovaliutų rinka pastaraisiais metais sparčiai augo, pritraukdama vis daugiau investuotojų (Best, 2024). Ši dinamiška rinka turi gausybę rizikos veiksnių, tokių kaip dideli kainų svyravimai, reguliavimo trūkumas ir technologiniai įvykiai galintys paveikti kainas. Technologinės galimybės, tokios kaip mašininis mokymasis, tampa labai svarbiu įrankiu analizuojant ir vertinant kriptovaliutų portfelių riziką (Huang, 2024).

Įmonėms, tokioms kaip Multicoine Capital, Digital Currency Group, Amber Group ir kitoms užsiimančioms kriptovaliutų portfelių valdymu, prognozuoti kriptovaliutų kainas ir vertinti riziką yra be galo svarbu siekiant sėkmingai funkcionuoti ir būti konkurencingais. Kompanijoms kaip Microsoft, Paypal, Starbucks, Burger King ir kitoms, kurios jau priima kriptovaliutas kaip atsiskaitymo priemonę, taip pat yra svarbu vertinti kriptovaliutų kainų svyravimo rizikas, nes tos įmonės susiduria su papildoma rizika dėl didelio kriptovaliutų kainų nepastovumo. Kadangi ši rinka nuolat kinta, tampa vis sudėtingesnė, yra veikiami daugybės veiksnių, todėl įmonės yra svarbu turėti efektyvius įrankius rizikos vertinimui ir sprendimų priėmimui (J. Almeida ir Gonçalves, 2022). Gera ir efektyvi rizikos analizė ir valdymas gali padėti sumažinti riziką, siekiant kuo didesnės grąžos ir stabilumo (Natale, Poppensieker, & Thun, 2022).

Kriptovaliutos skiriasi nuo kitų finansinių instrumentų dėl jų decentralizacijos ir blokų grandinės technologijos naudojimo. Jų prognozavimas yra sudėtingas, nes rinkos yra labai nepastovios ir stipriai priklausomos nuo spekuliacijų ir rinkos nuotaikų. Taip pat kriptovaliutas yra sudėtinga prognozuoti, nes jos nėra susietos su jokiais fiziniais aktyvais, todėl tradiciniai finansiniai prognozavimo modeliai yra sunkiai pritaikomi (Sebastião ir Godinho, 2021; Khan ir Hakami, 2022).

Augant kriptovaliutų populiarumui, kriptovaliutų portfelio rizikos analizė, taikant mašininio mokymosi metodus, tampa aktuali ir mokslinėje bendruomenėje. Ši tyrimo kryptis leidžia vertinti ir suprasti, kokie veiksniai turi įtakos kriptovaliutų rinkos dinamikai, bei suteikia naujų įžvalgų apie

investavimo strategijų efektyvumą (Sebastião ir Godinho, 2021). Lyginant su tradiciniais rizikos vertinimo metodais, mašininio mokymosi rizikos vertinimo metodai leidžia valdyti didelius ir sudėtingus duomenų rinkinius ir atrasti netiesinius ryšius. Skirtingai nuo tradicinių statinių modelių, mašininio mokymosi algoritmai nuolat mokosi ir prisitaiko prie naujų duomenų, todėl jie labai reaguoja į nepastovias kriptovaliutų rinkas. Be to, mašininio mokymosi metodai gali integruoti realaus laiko nuotaikų analizę iš įvairių šaltinių, didinant nuspėjimo tikslumą. Šios galimybės leidžia tiksliau ir dinamiškiau įvertinti riziką sparčiai besivystančioje kriptovaliutų aplinkoje (J. Chen, 2023).

Problemos ištyrimo lygis

Kriptovaliutų portfelių rizikos vertinimas taikant tradicinius ir mašininio mokymosi metodus yra aktuali ir nagrinėjama tema. Iš tradicinių rizikos vertinimo metodų buvo nagrinėti dispersijos, pusiau dispersijos, vidutinio nuokrypio, asimetrijos ir kurtozės koeficientai (Cibulskienė ir Brazauskas, 2016; Bowala ir Singh, 2022). Taip pat, portfelių rizikai vertinti plačiai naudojami VaR modeliai (Behera et al., 2023; Su ir Hung, 2018; Cibulskienė ir Brazauskas, 2016), GARCH modeliai (Bowala ir Singh, 2022; Barauskaitė ir Constantinescu, 2016) bei Monte Karlo simuliacija (Kozlovskiy et al., 2022; Likitrachoen et al., 2021). Rizikos vertinimui naudojant mašininio mokymosi metodus plačiai naudojami yra ANN ir BN modeliai (Ghasemi et al., 2018), Random Forest, XGBoost, KNN modeliai (Behera et al., 2023) bei SVM ir LSTM modeliai (Ma et al., 2021). Tačiau šiems modeliams trūksta tikslumo skaičiuojant kriptovaliutų portfelio riziką, nes GBT modelis gali persimokyti, kai yra naudojamas triukšmingose ir nepastoviose rinkose, tokiose kaip kriptovaliutų, RF yra labiau tinkamas klasifikavimui, o ne laiko eilučių prognozavimui, SVM yra labiau tinkamas dirbti su nedideliu duomenų rinkiniu (Sebastião ir Godinho, 2021; Khedr et al., 2021), todėl reikia rasti metodus, kaip pagerinti ML modelių tikslumą. Kuo tikslesni modeliai leidžia optimizuoti grąžą priimant strateginius sprendimus, veiksmingiau subalansuojant galimą pelną su susijusia rizika (Huras, 2023). Taip pat, finansiniai reglamentai dažnai reikalauja tikslaus rizikos įvertinimo, siekiant užtikrinti, kad įstaigos turėtų pakankamai kapitalo atsargų ir laikytųsi apdairios rizikos valdymo praktikos (Nilsson, Poppensieker, Schneider, & Thun, 2022).

Analizuojant mokslinę literatūrą pasigendama gilesnio požiūrio į panašų elgesį turinčių finansinių instrumentų rizikos vertinimo modelių pritaikymą kriptovaliutoms. Rizikai vertinti DMLP metodas kartu su sentimentų analize buvo naudotas akcijų rinkos rizikos vertinime (Liapis et al., 2023), kur modelis parodė efektyvius rezultatus. Kriptovaliutų rizikos vertinimui DMLP metodas buvo naudotas tik atskirai, be sentimentų analizės (Tharun et al., 2023; D. Almeida et al., 2022; Sebastião ir Godinho, 2021; J. Almeida ir Gonçalves, 2022). Tačiau žinant, kad kriptovaliutų kainos yra stipriai

paveiktos spekuliacijų ir rinkos nuotaikų, sentimentų analizė yra vienas iš pagrindinių veiksnių nurodančių nuotaikas socialiniuose tinkluose ir prognozuojančių, kuria linkme judės kainos (Abraham et al., 2018; C. Y. H. Chen ir Hafner, 2019). Taigi galima teigti, kad kriptovaliutų portfelio rizikos analizė taikant mašininio mokymosi metodus, kurie yra naudojami panašų elgesį turintiems finansiniams instrumentams yra ganėtinai aktuali tema, kurią svarbu ištirti ir išspręsti tiek teoriniu, tiek praktiniu lygmeniu.

Darbo problema

Kaip pagerinti kriptovaliutų portfelio rizikos vertinimo tikslumą taikant mašininio mokymosi metodus?

Darbo objektas

Mašininio mokymosi metodais grindžiamas portfelio rizikos vertinimas, naudojant kriptovaliutų dieninių kainų duomenis.

Darbo tikslas

Pritaikyti mašininio mokymosi metodus kriptovaliutų portfelio rizikos vertinimui ir palyginti jų tikslumą, taikant skirtingus vertinimo kriterijus.

Darbo uždaviniai:

1. Atlikti mokslinės literatūros analizę apie kriptovaliutas, jas veikiančius veiksnius bei išanalizuoti mašininio mokymosi metodus, taikomus portfelių rizikos vertinime
2. Apibrėžti tyrime naudojamus duomenis, metodus ir vertinimo kriterijus
3. Įgyvendinti kriptovaliutų portfelio rizikos vertinimo modelį, įvertinti jo efektyvumą ir palyginti jo tikslumą su kitais rizikos vertinimo metodais
4. Aptarti rezultatus ir pasiūlymus

Darbo struktūra.

Pirmoje darbo dalyje „Kriptovaliutų portfelio rizikos analizės taikant mašininio mokymosi metodus teoriniai aspektai“ nagrinėjami kriptovaliutų kainų svyravimams įtakos turintys veiksniai. Taip pat nagrinėjami rizikos vertinimo metodai, jų skirtumai ir pritaikomumas kriptovaliutų duomenų analizei.

Antroje darbo dalyje „Kriptovaliutų portfelių rizikos vertinimo siūlomas sprendimas“ išvardinamas kriptovaliutų rizikos vertinimo metodo eiliškumas. Paaiškinamos visos naudotos formulės ir jų prasmė modelyje.

Trečiojoje darbo dalyje „kriptovaliutų portfelių rizikos analizė taikant mašininio mokymosi metodus“ yra atliekama socialinių tinklų sentimentų analizė, skaičiuojama koreliacija ir regresija tarp priklausomų ir nepriklausomų kintamųjų bei atliekama kainų prognozavimo ir rizikos analizė naudojant Monte Karlo simuliaciją, DMLP ir SRV mašininio mokymosi metodus.

Darbe naudoti literatūros šaltiniai.

Teorinėje darbo dalyje daugiausia naudotasi užsienio autorių moksliniais darbais susijusiais su kriptovaliutų kainų svyravimams darančiais faktoriais ir kriptovaliutų rizikos vertinimo metodais. Praktiniams vertinimams ir pastebėjimams apie kriptovaliutų portfelių rizikos analizę ir metodus pagrįsti naudojama užsienio autorių straipsniuose ir internete pateikiama informacija.

Darbo ir tyrimo metodai.

Analizuojant kriptovaliutų kainų svyravimams įtakos turinčius veiksnius ir rizikos vertinimo metodus buvo naudojami šie tyrimo metodai – lyginamoji mokslinės literatūros analizė, abstrahavimas ir sisteminimas.

Atliekant empirinį tyrimą buvo naudotas koreliacijos koeficientas, regresinė analizė, vizualizacija, Monte Karlo simuliacija, DMLP ir SVR mašininio mokymosi metodai.

Darbo rezultatų teorinė reikšmė.

Atlikta teorinė analizė leido nustatyti, kad kriptovaliutų kainų svyravimams įtakos gali turėti išoriniai faktoriai, tokie kaip kriptovaliutų rinka, makroekonominiai ir politiniai faktoriai ir vidiniai faktoriai tokie kaip paklausa ir pasiūla. Taip pat nustatyta, kad iš mašininio mokymosi metodų DMLP kartu su sentimentų analize dar nebuvo naudota kriptovaliutų kainų prognozavimui ir rizikos vertinimui.

Darbo rezultatų praktinė reikšmė.

Surasti kurie faktoriai turi įtakos kiekvienos kriptovaliutos kainų svyravimams. Patikrinti, kurie metodai gali tiksliausiai prognozuoti kriptovaliutų kainų judėjimą ir teikti informaciją pelningam ir optimaliai rizikingam portfelio valdymui.

Darbo sunkumai, taikymo apribojimai.

Šio darbo apribojimai yra tai, kad socialinius tinklus mano darbe reprezentuoja Twitter, nes tai buvo vienintelė platforma, kuri suteikia prieigą prie istorinių duomenų. Dar vienas apribojimas yra tas, kad darbe analizuojami dieniniai duomenis, kadangi nepavyko pasiekti valandinių duomenų, kas leistų darbui būti tikslesniam.

Darbo struktūra ir apimtis.

Darbą sudaro įvadas, 3 dalys, išvados. Pagrindinė darbo medžiaga aprašyta 68 puslapių, įskaitant 42 lenteles, 11 paveikslų. Taip pat pateikiama 6 priedai. Panaudotos literatūros sąrašą sudaro 93 šaltiniai.

1. KRIPTOVALIUTŲ PORTFELIO RIZIKOS ANALIZĖS TAIKANT MAŠININIO MOKYMOSI METODUS TEORINIAI ASPEKTAI

Šiame skyriuje pateikiama kriptovaliutų samprata, analizuojami jas veikiantys veiksniai ir kokie metodai naudojami jų rizikos vertinime.

1.1. Kriptovaliutų svyravimus lemiantys veiksniai

Šiame poskyryje bus nagrinėjamos kriptovaliutos kaip finansinis instrumentas, lyginamas jų panašumas su kitais finansiniais instrumentais ir nagrinėjami faktoriai, kurie paveikia kriptovaliutų kainų svyravimus. Rasti faktorius, turinčius įtakos kriptovaliutų kainų svyravimams, yra labai svarbu tiek investuotojams, tiek mokslininkams. Tinkama svyravimų prognozė padėtų investuotojams priimti sprendimus ir įvertinti tikėtiną grąžą bei galimus kainų svyravimus.

1.1.1. Kriptovaliutos kaip investavimo alternatyva

Sparčiai vystantis mokslui ir technologijoms, finansų technologijos padarė daug proveržių finansų industrijoje. Vienas jų yra kriptografinės valiutos. Kriptovaliutos ir skaitmeninis turtas buvo pripažinti vienu įtakingiausių pastarojo dešimtmečio technologinių pasiekimų, sužavėjusių investuotojus, ieškančius didesnės grąžos. Kriptografinės valiutos mažina finansinės prekybos priklausomybę nuo finansinių tarpininkų ir prisideda prie skaitmeninės ekonomikos augimo.

Pirmą kartą 2009 metais Nakamoto pasiūlyta kriptovaliuta yra skaitmeninė, decentralizuota ir tiesioginė tarpusavio sandorių sistema be tarpininko. Dėl naujoviškų savybių ir nepriklausomybės nuo pasaulinės pinigų politikos kriptovaliutų rinka kyla ir tampa vis populiareesnė kaip vieta investuotojams, ieškantiems diversifikacijos. Privalumai, susiję su investicijomis į kriptovaliutą, yra prekybos visą parą galimybės ir sumažėjusias sandorių išlaidas, nes nėra finansinių tarpininkų (de Souza et al., 2023). Tačiau esant silpnoms reguliavimo sistemoms ir intensyviai spekuliacinei veiklai, ši nauja rinka dažnai pasižymi itin dideliu nepastovumu. Anot Huang (2024) kriptovaliutos gali veiksmingai išvengti centrinių finansų įstaigų įsitraukimo dėl jų decentralizavimo ir didelio skaidrumo, suteikiant abiem sandorio šalims didelę autonomiją ir žymiai sumažinant administracinius arba tarpininkų mokesčius, kuriuos ima finansų įstaigos vykdant tradicines sandorių formas. 2015 m. JAV žaliavų ateities sandorių prekybos komisija (CFTC) oficialiai apibrėžė Bitcoin kaip prekę Jungtinėse Valstijose, kuriai taikomas prekių biržos įstatymas, kartu su auksu ir nafta. 2021 m. lapkričio 9 d. kriptovaliutų rinkos vertinimas viršijo 3 trilijonus USD. Bitcoin rinkos kapitalizacija pakilo nuo debiutinės mažesnės nei 30 centų


kainos iki 19 141 USD 2017 m. pabaigoje, tada krito ir 2021 m. vėl pakilo iki 67 567 USD, o vėliau vėl smuko, kol 2024 pasiekė naujas aukštumas. Toks kainų svyravimas gali atnešti investuotojams neįtikėtino pelno ar sukelti didžiulių nuostolių.

Anot Huang (2024), atsižvelgiant į simetrinį ir asimetrinį priežastinį poveikį, tradicinių finansų rinkų priežastinis poveikis kriptovaliutoms yra periodiškas ir trumpalaikis, o ilgalaikio reikšmingo priežastinio poveikio nėra. Tačiau aukso ateities sandorių kursai turėjo reikšmingesnę ir ilgalaikę poveikį kriptovaliutoms nei akcijų rinkos svyravimai. Nitithumbundit ir Chan (2022) atliktas tyrimas taip pat parodė, kad kriptovaliutų rinka elgiasi kitaip nei tradicinės rinkos, tokios kaip akcijų, prekių ar valiutų. Tokios pat mintys buvo išreikštos ir Dubey (2022), kuris teigė, kad Bitcoin yra valiuta, kuri neseka jokios finansų rinkos pavyzdžiu ekonomikoje. Taip pat remiantis atlikto tyrimo rezultatais, nustatyta, kad tarp kriptovaliutų ir makro kintamųjų nėra jokio bendro integravimo ryšio, išskyrus Tether, kuris turi ryšį su aukso ir naftos kainomis. Pirgaip et al. (2019) taip pat patvirtina, kad kriptovaliutų rinka išlieka izoliuota nuo visų kitų finansinių aktyvų rinkos ir todėl yra gera apsidraudimo priemonė. Tačiau Panagiotidis (2018) nustatė, kad aukso kainos prisideda prie Bitcoin kainų nustatymo. Taip pat jis nustatė, kad Bitcoin kaina yra neigiamai susijusi su aukso kaina, juonio ir JAV dolerio valiutų kursu ir investuotojų nuotaikomis. Kartu Bitcoin teigiamai susiję su euro ir JAV dolerio valiutų kursu, akcijų rinkos SP500 indeksu ir paieškos tendencija. Tačiau anot Hanif et al., (2023), kriptovaliutų kainų svyravimai turi keletą panašumų su akcijų kainų svyravimais, ypač dėl nepastovumo ir reagavimo į rinkos nuotaikas. Abi rinkos yra veikiamos spekuliacijos, investuotojų nuotaikų ir išorinių ekonominių veiksnių, kurie ir lemia kainų nepastovumą. Pavyzdžiui, tyrimai parodė, kad Bitcoin ir kitos kriptovaliutos tam tikromis sąlygomis gali rodyti reikšmingą koreliaciją su akcijų rinkos indeksais, o tai rodo, kad esant rinkos įtampai ar ekonominiams įvykiams, abi rinkos gali reaguoti panašiai. Be to, tyrimais buvo ištirtas ryšys ir nepastovumo perdavimas tarp kriptovaliutų ir akcijų, įrodant, kad abiejų tipų turtas gali turėti panašią rizikos dinamiką neramiais rinkos laikotarpiais. *Taigi, apibendrinant galima teigti, kad kriptovaliutos yra išskirtiniai finansiniai instrumentai, kurie nėra susieti su jokių turtu ir nėra reguliuojami jokios centrinės valdžios, tačiau vis tiek galima rasti panašumų su tradiciniais finansiniais instrumentais, tokiais kaip akcijos. Tiek kriptovaliutų, tiek akcijų kainų svyravimus gali paveikti investuotojų nuotaikos, spekuliacijos ar ekonominiai įvykiai.*

1.1.2. Faktoriai turintys įtakos kriptovaliutų svyravimams

Siekiant prognozuoti kriptovaliutų svyravimus yra svarbu išsiaiškinti, kokie faktoriai turi įtakos ir gali paveikti kriptovaliutų kainas.

Anot Khedr et al. (2021), kriptovaliutų kainas veikiančius veiksnius galima suskirstyti į vidinius ir išorinius (1 pav.).



Šaltinis: sudaryta autoriaus pagal Khedr et al. (2021). *Cryptocurrency price prediction using traditional statistical and machine-learning techniques: A survey*, p. 7.

1 pav. Kriptovaliutų kainų svyravimus lemiantys veiksniai


Vidiniai faktoriai apima su paklausa ir pasiūla susijusius veiksnius, tokius kaip monetų ir žetonų skaičius cirkuliacijoje. Transakcijų mokesčiai ir kasimo sunkumas taip pat priskiriami vidiniams faktoriams. Išoriniai faktoriai yra išskirstomi į 3 dalis, kurios apima kriptovaliutų rinką, makroekonominius faktorius ir politinius faktorius. Kriptovaliutų rinka apima rinkos tendencijos, jos patrauklumas investuotojams ir spekuliacijos toje rinkoje. Makroekonominiai faktoriai apima akcijų ir Forex rinkas, palūkanų normas, aukso kainas ir kitus makroekonominius veiksnius. Prie politinių faktorių priskiriami kriptovaliutų apribojimai ir legalizavimas. Su kriptovaliutų rinka susiję veiksniai

tokie kaip prekybos apimtis, rinkos beta koeficientas ir nepastovumas taip pat gali būti laikomi vienu iš reikšmingų veiksnių, lemiančių kriptovaliutos kainą (Khedr et al., 2021).

Be anksčiau paminėtų, yra daugybė faktorių, kurie paveikia kriptovaliutų kainas. Vienas iš jų yra paieškų apie kriptovaliutas skaičius internete. Anot Özyeşil (2019), atlikto tyrimo nustatyta, kad kriptovaliutų paieškų internete skaičiaus padidėjimas teigiamai veikia visų kriptovaliutų kainas, grąžą ir prekybos apimtį. Atliktame tyrime buvo pastebėtas didžiausias poveikis kainoms ir prekybos apimčiai buvo „Bitcoin“. Tokie pat rezultatai buvo rasti ir Guo et al. (2021) atliktame tyrime. Jų tyrime buvo nustatyta, kad „Google Trends“ paieškų skaičius yra svarbus veiksnys prognozuojant kriptovaliutų kainas, nes jis rodo investuotojų dėmesį kriptovaliutomis. Taigi, iš šių tyrimo galima daryti išvadą, kad kriptovaliutos populiarumas gali būti laikomas svarbiu veiksniu, lemiančiu kriptovaliutos kainą ir prekybos apimtį.

Kad ir kokia populiari būti kriptovaliuta, kiekviena iš jų susiduria su bulių ir meškų rinka. Gunay (2019) atliko tyrimą kaip viešojoje erdvėje skelbiama informaciją per bulių ir meškų rinkas paveikia kriptovaliutos kainą ir pastebėjo, kad kai yra bulių rinka viešojoje erdvėje skelbiama teigiama informacija daro teigiamą įtaką kriptovaliutai (tame tyrime buvo tirta su Ripple), o meškų rinkoje, teigiama informacija neatitraukia kriptovaliutos nuo mažėjimo tendencijos. Taigi, galima teigti, kad bulių rinkoje kainos jau ir taip kyla ir teigiamos naujienos tik dar labiau sustipriną rinkos efektą, tačiau kai rinka yra meškų, net ir teigiamos naujienos nedaro statistiškai reikšmingo efekto.

Kriptovaliutų kainoms įtaką daro ne tik paieškų skaičius internete, bet ir prekybos apimtis, bei biržos dydis. Guo et al. (2021) atliktame tyrime pastebėta, kad yra skirtingo dydžio biržose prekybos apimtys skiriasi kintant kriptovaliutų kainai. Šie rezultatai atvaizduoti 2 pav.



Šaltinis: Guo, H., Zhang, D., Liu, S., Wang, L. ir Ding, Y. (2021). *Bitcoin price forecasting: A perspective of underlying blockchain transactions*, p. 2.

2 pav. Normalizuotos prekybos apimtys Houbi ir Bleutrade keityklose

Paveikslėlyje galima matyti, kad kai Bitcoin kaina krenta, didžiojoje biržoje (Hoibi) prekybos apimtys auga, kai tuo tarpu mažojoje biržoje (Bleutrade) krenta. Ir priešingai, kai Bitcoin kaina kyla, prekybos apimtys kyla mažesnėse biržose. Tai parodo, kad mažos ir didelės biržos prekybos apimtys turi skirtingą koreliaciją su kriptovaliutų kainomis ir kai kurios biržos turi daugiau įtakos kainų svyravimams ir jos turėtų būti įtrauktos į kriptovaliutų kainų prognozavimą.

Be kriptovaliutų populiarumo ir biržų, kuriose prekiaujama, įtakos kainų svyravimams turi ir pinigų politika. Aloui et al. (2024) atliko tyrimą, kuriame buvo tiriamas kriptovaliutų atsakas į pinigų politikos intervencijas. Rezultatai parodė teigiamą ryšį tarp Jungtinių Amerikos Valstijų centrinio banko politikos ir kriptovaliutų grąžos. Šį rezultatą galima paaiškinti taip, kad aukšta FED palūkanų norma yra susijusi su Bitcoin grąžos padidėjimu, nes dalis kapitalo nuteka į kriptovaliutų rinką, po pinigų politikos pokyčių, kai mažėja žmonių pasitikėjimas priimamais sprendimais. Tačiau yra tyrimų, kurie teigia, kad Bitcoin nereaguoja į Federalinių rezervų sistemos, Europos centrinio banko, Japonijos banko ir Anglijos banko sprendimus dėl pinigų (Vidal-Tomás ir Ibañez, 2018). Panašius rezultatus nurodo ir Lyócsa et al. (2020). Anot jo, Bitcoin nepastovumui įtakos neturi dauguma JAV makroekonominių naujienų ir pranešimų, tokių kaip vyriausybės biudžeto deficitas, infliacija ir net pinigų politikos pranešimai. Kai kurie tyrimai rodo, kad kriptovaliutos gali veikti kaip saugus

prieglobstis apsaugoti nuo ekonominės politikos neapibrėžtumo. Taigi, nors yra tyrimų, kurie rodo, kad pinigų politika gali turėti įtakos kriptovaliutų kainų svyravimams, didesnė dalis tyrimų vis tik prieštarauja šiai hipotezei ir teigia, kad nėra statistiškai reikšmingų rezultatų, pagrindžiančių šią hipotezę.

Be pinigų politikos, yra atlikta tyrimų, kad ir klimato politika gali paveikti kriptovaliutų kainas. Jin ir Yu (2023) atliko tyrimą ir nustatė, kad klimato politikos neapibrėžtumas daro didelę teigiamą įtaką kriptovaliutų kainų svyravimui ir kad šis poveikį daugiausia lemia ekstremalūs klimato politikos sukrėtimai. Tai reiškia, kad staigūs ir esminiai klimato politikos pokyčiai padidina kriptovaliutų kainų nepastovumą. Be to, skirtingos kriptovaliutos skirtingai reaguoja į klimato politikos neapibrėžtumą. Tuo metu, kai klimato kaita tampa vis ryškesnė ir klimato nelaimės dažnos, kai kurios šalys įgyvendino įvairią klimato politiką, siekdamos sušvelninti klimato kaitos poveikį visuomenei ir ekonomikai. Tačiau dėl klimato politikos kylantis netikrumas paveikė pasaulio ekonominę veiklą. Kadangi kriptovaliutų rinka pastaraisiais metais toliau kaista, šis poveikis taip pat persimetė į kriptovaliutų rinką. Todėl rinkos dalyviams itin svarbu tiksliai numatyti kriptovaliutų kainų svyravimus. Jų tyrimas pabrėžia lemiamą procesoriaus vaidmenį darant įtaką kriptovaliutų rinkos dinamikai. Klimato politikos neapibrėžtumo supratimas ir įtraukimas į prognozavimo modelius yra labai svarbus efektyviam rizikos valdymui ir pagrįstų sprendimų priėmimui nuolat besivystančioje kriptovaliutų rinkoje.

Naftos kainos taip pat yra veiksnys turintis įtakos kriptovaliutų kainų svyravimams. Bitcoin kainą sudaro ne tik jo paklausos ir pasiūlos santykis tačiau ir jo gamybos sąnaudos, o naftos kaina yra susijusi su jo išgavimo sąnaudomis. Dubey (2022) teigia, kad naftos kaina yra veiksnys turintis įtakos Bitcoin kainai tiek ilguoju, tiek trumpuoju laikotarpiu. Anot jo Bitcoin kaina vadovaujasi sąnaudomis pagrįstos kainodaros teorija.


Apibendrinant galima teigti, kad yra daugybė veiksnių darančių įtakos kriptovaliutų svyravimams. Kriptovaliutų paieškų skaičiaus internete augimas ir teigiami komentarai socialinėje erdvėje bulių rinkos metu gali turėti teigiamą įtaką kriptovaliutų kainų svyravimams. Prekybos apimtys ir biržos kuriose kriptovaliutomis prekiaujama taip pat gali paveikti kainų pokyčius. Galiausiai klimato politika ir naftos kainos taip pat gali būti reikšmingi faktoriai kainų svyravimams. Taigi, yra nemažai veiksnių, kurie paveikia kriptovaliutų kainas.

1.1.3. Socialinių tinklų sentimentų įtaka kriptovaliutų svyravimams

Nuo ankstyvųjų 2000-ųjų metų iki šių dienų socialiniai tinklai išaugo į didelį tinklą, kuris apima socialinių tinklų svetaines, socialinių apžvalgų svetaines, vaizdo ir nuotraukų dalijimosi svetaines,

diskusijų svetaines ir beveik viską, ką galima įsivaizduoti. Ir pagal statistiką nuo 2023 metų visame pasaulyje iš 8 milijardų žmonių, 4,9 milijardai naudoja socialinius tinklus ir šis skaičius per ateinančius 4 metus tikimasi, kad padidės iki 5,85 milijardų naudotojų. Vidutiniškai asmuo kasdien praleidžia apie dvi su puse valandos socialinių tinklų platformose (Ruby, 2023). Anot Pulido et al. (2020), mes esame antrame informacijos revoliucijos etape. Pirmasis buvo, kai buvo išrasta rašytinė spauda, o antrasis yra dabar - skaitmeninis transformavimas. Socialiniai tinklai beveik pakeitė pagrindinius žiniasklaidos kanalus, nes dauguma žmonių daugiau nebesiklauso radijo, nebeskaito spaudos žurnalų, laikraščių arba nebežiūri televizijos. Taigi, šie skaičiai parodo, kokie svarbūs socialiniai tinklai yra vidutiniam žmogui ir koks svarbus yra naujienų skelbimas šiose svetainėse.


Šiandien žiniasklaida yra klasifikuojama į dvi pagrindines grupes: tradicinę ir naująją žiniasklaidą. Tradicinė žiniasklaida apima spausdintus laikraščius, žurnalus, radiją ir televiziją, o naujoji žiniasklaida apima viską, kas skelbiama internete. Nors naujosios žiniasklaidos populiarumas auga, tyrimai rodo, kad žmonės vis dar daugiau pasitiki tradicine žiniasklaida, nes naujoji žiniasklaida yra mažiau tiksli (Fan et al., 2021). Abiejose tradicinės ir naujosios žiniasklaidos rūšyse naujienos yra tokios pačios: jas galima klasifikuoti kaip "kietas" ir "minkštas" naujienas (3 pav.).



3 pav. Naujienų klasifikavimas

Kietosios naujienos apima politikos, verslo, tarptautinių reikalų, finansų ir ekonomikos naujienas. Tai yra svarbi kasdieninė informacija visam pasauliui. Kita vertus, minkštos naujienos apima naujienas apie žvaigždes, meną, skandalus, sportą ir pramogas. Tai labiau susiję su žmonių asmeniniais gyvenimais. Pagal Fan et al. (2021) atliktą tyrimą, kietosios naujienos labiau tinkamos tradicinėms žiniasklaidos priemonėms, tuo tarpu minkštos naujienos yra populiareesnės naujojoje žiniasklaidoje, ir kai skirtingo tipo naujienos skelbiamos skirtingo tipo žiniasklaidoje, žmonėms gali būti sunku išlaikyti tą patį pasitikėjimo lygį.

Dėl didelio informacijos kiekio vis daugiau tyrimų yra atliekama, kaip surinkti, įvertinti ir išmatuoti tinkamus duomenis. Kadangi iš ilgo teksto yra sunku išgauti informaciją, naujienų teksto klasifikavimo metodai yra naudojami. Paprastas paaiškinimas, kas yra teksto klasifikavimas, pateiktas 4 pav.



Šaltinis: sudaryta autoriaus pagal Ahmed, J. ir Ahmed, M. (2021). *Online News Classification Using Machine Learning Techniques*, p. 2.

4 pav. Duomenų išgavimas iš teksto ir klasifikavimas

Pirmas žingsnis yra duomenų surinkimas ir apdorojimas. Po to iš duomenų yra pasirenkami ir išskiriami specifiniai požymiai. Tuomet duomenys yra testuojami ir įvertinami. Vienas iš dažniausiai naudojamų teksto klasifikavimo metodų yra gilieji mokymosi (DL) algoritmai. Šiame metode iš duomenų yra išskiriami atskiri žodžių vektoriai, ir žodžių tarpusavio sąryšis yra ignoruojamas. Kitais žodžiais, šis metodas vadinamas tekstų gavyba (M. Zhang, 2021). Giliuoju mokymusi galima naudotis ne tik duomenų klasifikavimui, bet ir įvykių aptikimui ar elgesio atpažinimui. Anot Jang et al. (2019), šis metodas tinkamas naujienų straipsniams ir Twitter žinutėms, nes jose yra didelis duomenų kiekis, tačiau nereikalinga informacija turi būti pašalinta, nes į duomenų rinkinį gali patekti reklama. Kitas būdas matuoti duomenis yra nuotaikų analizė. Tai yra nuomonių ir požiūrių tekste analizė. Nuotaikų

analizę galima suskirstyti į mašininio mokymosi metodus ir nuotaikų žodyno metodus (S. Zhang, 2021). Taigi, metodų skaičius yra didelis, bet kuris metodas duomenų analizei yra pasirenkamas, priklauso nuo reikiamų rezultatų ir analizuojamo duomenų rinkinio pobūdžio. *Taigi, dėl didžiulio informacijos kiekio šiandieniniame pasaulyje, sugebėti išsirinkti tinkamą informaciją yra be galo svarbu, nes tai vienintelis būdas kaip mes galime apdoroti mus svarbią ir aktualią informaciją. Tekstų gavybos metodas yra vienas iš dažniausiai naudojamų dėl savo didelio pritaikomumo.*

Socialinių tinklų sentimentų įtaka kriptovaliutų svyravimams yra plačiai nagrinėjama tema. Yra atlikta daugybė tyrimų bandančių nustatyti kaip tiksliai socialiniuose tinkluose skelbiamos naujienos paveikia kriptovaliutų rinką ir kaip galima tas naujienas panaudoti bandant nuspėti kainų judėjimo kryptį. „Twitter“ yra vienas iš pagrindinių socialinių tinklų puslapių, kuriame skelbiama informacija laikoma kaip turinti įtakos kriptovaliutų kainų svyravimams (Zhu et al., 2021). Anot Moser & Brauneis (2023), „Twitter“ paskelbtų žinučių skaičius gali būti vertinamas kaip vienas iš pagrindinių investuotojų susidomėjimo matavimo matų. Jų atliktame tyrime buvo nustatyta, kad 1% augimas „Twitter“ žinučių skaičiuje apie kriptovaliutas per 10 minučių padidina kriptovaliutų likvidumą apie 7% ir tas padidėjęs likvidumas gali tęstis iki 1 valandos. Panašūs rezultatai buvo nustatyti ir Dubey (2022) atliktame tyrime. Jų tyrimas atskleidė statistiškai reikšmingą kainos pokytį per pirmas 3 minutes po „Twitter“ žinutės paskelbimo. Tačiau jų tyrimas parodė, kad didesnis poveikis buvo padarytas ne nuotaikos buvusios žinutėje, o pačios turinio kokybės. Investuotojus pirmiausiai paveikę žodžių pasirinkimas ir „Twitter“ žinutės populiarumo skaičiaus. Taip pat jų tyrimas atskleidė, kad 15 minučių laikotarpis po žinučių paskelbimo nebuvo statistiškai reikšmingas. Tuo tarpu Li et al. (2022) savo atliktame tyrime rado, kad rinkoje esant burbului, socialiniuose tinkluose skelbiama informacija nepriklausomai ar ji yra teigiama ar neigiama, gali turėti įtakos iki sekančios dienos. Taip pat tyrimo metu buvo rastas dvipusis ryšys tarp socialiniuose tinkluose skelbiamų žinučių skaičiaus pokyčio ir kriptovaliutų kainų svyravimo. Anot jų atlikto tyrimo didelis kainos pokytis gali padidinti žinučių skaičių socialiniuose tinkluose. Panašius rezultatus, kad „Twitter“ žinutės gali turėti įtakos po 1 dienos rado ir Critien et al. (2022). Jo atliktame tyrime naudojant dirbtinio intelekto modelius ir „Twitter“ duomenis nuo 2018-08-30 iki 2019-11-23 buvo nustatyta, kad 1 dienos „Bitcoin“ kainos judėjimas pasižymėjo dideliu patikimumu ir siekė iki 64,2%. 3 ir 7 dienų prognozės jau buvo žymiai mažiau patikimos. Taigi, galima daryti išvadą, kad 1 dienos „Twitter“ žinučių įtaka gali tikrai būti statistiškai reikšminga ir paveikti kriptovaliutų kainų svyravimus.

Siekiant dar giliau įvertinti „Twitter“ įtaką kriptovaliutų svyravimams buvo sukurtas „Twitter“ laimės indeksas. Anot de Souza et al. (2023) „Twitter“ laimės indeksas turėjo įtakos šešioms

analizuotoms kriptovaliutoms. Jų atliktas tyrimas atskleidė, kad laimės indeksas turėjo galėti numatyti kriptovaliutų grąžą įvairiuose kvantiliuose, tačiau turėjo nedidelę galią prognozuoti grąžą tiek bulių, tiek meškų rinkose. Tačiau galutinė išvada buvo, kad investuotojų nuotaikos išreikštos socialiniuose tinkluose turi įtakos kriptovaliutų kainų svyravimams.

Socialinėje erdvėje nuomones skelbia ne tik investuotojai, bet ir nuomonės formuotojai bei kiti įžymus žmonės. Nuomonės formuotojai, tai žmonės, kurie mėgaujasi dideliu vartotojų susidomėjimu ir patikimumu. Anot Scheer ir Stern (1992), įmonės formuotojai gali panaudoti savo žinomumą perteikiant informaciją, patirtį ar siūlant paslaugą savo stebėtojų tinklui. Anot Ante (2023), Elonas Muskas yra vienas iš tokių žmonių, kuris naudoja savo sėkmingumą ir turtus bei buvimą technologijų novatoriumi, kad paveiktų investuotojus ir rinką. Atliktame tyrime analizuojant 47 kriptovaliutų kainų pokyčius ir Elono Musko „Twitter“ įvykių pavyzdžius buvo rastas statistiškai reikšmingas pokytis prekybos apimtyje ir kriptovaliutų kainose, nors tas poveikis buvo reikšmingas ne visoms kriptovaliutoms. Dogecoin kriptovaliuta buvo paveikta „Twitter“ žinučių žymiai labiau, nei Bitcoin kriptovaliuta. „Twitter“ žinutės padidindavo Bitcoin kriptovaliutos kainą iki 16,9% arba sumažindavo iki 11,8%. Taigi, šis tyrimas parodė, kokią didelę įtaką kriptovaliutų kainoms gali turėti įtakingų asmenų veikla socialiniuose tinkluose. Vienas iš pavyzdžių gali būti 2019-01-29, kai Elon Musk (tuo metu turtingiausias pasaulio žmogus) pakeitė savo „Twitter“ paskyros bio į „#bitcoin“. Per kelias valandas nuo šio įvykio Bitcoin kaina pakilo nuo 32 000 dolerių iki 38 000 dolerių. Tai rodo, kad padidėjęs „Twitter“ žinučių skaičius ir susidomėjimas padidina kriptovaliutų trumpalaikį likvidumą ir tai gali paaiškinti prekybos apimtį ir kainų svyravimus, o tų žinučių nuotaikos gali numatyti kainos pokyčio kryptį. *Taigi, nuomonės formuotojų įtaka išlieka reikšminga tik tol, kol ji nėra pastovi, nes jei visokios žinutės ir naujienos būtų skelbiamos kelis kartus per dieną, žmonės į tai pradėtų žiūrėti kaip į triukšmą, o ne reikšmingą informaciją. Tačiau, kai tokie įvykiai nėra dažni, jie didina riziką rinkos dalyviams dėl neprognozuojamų kainos pokyčių, kai viena Elon Musk „Twitter“ žinutė gali taip paveikti rinką trumpalaikėje perspektyvoje.*

Individualūs investuotojai finansų rinkose susiduria su informacijos pertekliumi. Net jei jie nėra priblokšti informacijos srauto, jie susiduria su sunkumais paskirstydami savo ribotą laiką ir dėmesį įvairiems informacijos šaltiniams. Dėl informacijos pertekliaus asmenims sunku ją tinkamai apdoroti, o tai, pavyzdžiui, sukelia psichologines problemas, trumpesnę dėmesio sutelkimą ar prastą sprendimų priėmimą (Agnew ir Szykman, 2005). 2022 m. liepos mėn. coinmarketcap.com (CMC) ir coingecko.com (CG) iš viso pateikia atitinkamai maždaug 20 000 ir 13 000 skirtingų kriptovaliutų. Be „bluechip“ kriptovaliutų, tokių kaip Bitcoin ir Ethereum, investuotojams yra prieinama daugybė

mažesnių ir net mažyčių kriptovaliutų projektų pagal rinkos kapitalizaciją. Tyrinėjant kriptovaliutų projektą, paprastai reikia skaityti informacinius dokumentus ir rinkti informaciją iš projekto svetainės. Vienas iš sprendimų perteklinei informacijai apdoroti yra pasitelkti išorinius informacijos tarpininkus, tokius kaip internetinės paieškos sistemos, finansų patarėjai, socialinių tinklų nuomonės formuotojai ar kitos šalys, kurių pareiškimai ir nuomonės palengvina vartotojų informacijos valdymą. Anot Moser ir Brauneis (2023), atsižvelgiant į kiekvieną dieną išleidžiamus naujus kriptovaliutų projektus, net patyrusiems investuotojams greičiausiai bus sunku neatsilikti nuo kiekvienos potencialiai pelningos monetos ar žetono. Todėl pagrįsta manyti, kad daugelis investuotojų pasikliaus specializuotų „YouTube“ kanalų pateikta informacija apie minimas kriptovaliutas, priimant investavimo sprendimus. Šie kanalai dažnai turi šimtus tūkstančių prenumeratorių, o vaizdo įrašai paprastai taip pat turi daug peržiūrų. Tai gali sukelti papildomą žetono paklausą, todėl taip pat turės įtakos žetono kainai ir prekybos apimčiai. Be to, daugelis šiuose vaizdo įrašuose aprašytų žetonų yra mažos kapitalizacijos, todėl greičiausiai yra nelikvidžios, o tai dar labiau padidina „YouTube“ poveikį kainoms ir prekybos apimčiai. Panašius rezultatus savo atliktame tyrime rado ir Critien et al. (2022). Anot jo, mažos kapitalizacijos kriptovaliutos yra gana paprastai manipuluojamos per nuomonės formuotojų ar „Youtube“ kanalus. Jei kriptovaliuta yra nusistovėjusi ir turinti didelę rinkos kapitalizaciją, ji bus mažiau pažeidžiama tokiems elgesio reiškiniams, kaip bandos elgesys ar manipuliavimas kainomis per socialinių tinklų įrašus. *Apibendrinant galima pasakyti, kad kriptovaliutų „YouTube“ kanalai tikriausiai yra pagrindinis informacijos šaltinis daugeliui mažų rinkos dalyvių. Pasirinkę, koks turinys bus rodomas kanale, šiuos kanalus valdantys žmonės gali turėti įtakos mažą kapitalizaciją turinčioms kriptovaliutomis.*

Be nuomonės formuotojų, „Youtube“ kanalų ir kitų žinomų žmonių, įtakos kriptovaliutų kainoms gali turėti ir „Blockchain“ programuotojų ir kūrėjų nuotaikos ir įžvalgos. Bartolucci et al. (2020) atliktame tyrime buvo atsižvelgta į „Blockchain“ kūrėjų pastabas ir veiklą ties „Bitcoin“ ir „Ethereum“ projektais „Github“ platformoje. Tyrime buvo rastas ryšys tarp „Blockchain“ programuotojų emocijų laiko eilučių ir „Bitcoin / Ethereum“ kainos naudojant „Granger“ priežastinį ryšį. Taip pat įtraukus įtakos laiko eilutes į LSTM, vidutinė kvadratinė klaida žymiai sumažėjo. Taigi, „Blockchain“ programuotojų nuotaikos ir emocijos socialinėje erdvėje gali turėti įtakos kriptovaliutų kainų svyravimams.

Apibendrinant socialinių tinklų sentimentų įtaką kriptovaliutų svyravimams, galima teigti, kad kriptovaliutos yra priklausomos nuo socialinių tinklų dėl jų didžiulio populiarumo ir kasdieninio naudojimo investuotojų gyvenime. Įtakos kriptovaliutų kainų svyravimams turi ne tik žinučių skaičius

„Twitter“ ar kituose socialiniuose tinkluose, tačiau ir žinomų žmonių, „Youtube“ kanalų ar blokų grandinės programuotojų elgesys. Nors socialinių tinklų įtaka yra pastebima visoms kriptovaliutomis, tačiau poveikis yra žymiai didesnis mažos kapitalizacijos kriptovaliutomis.

1.2. Kriptovaliutų portfelio rizikos vertinimo metodai

Investuojant pinigus tik į vieną finansinį turtą, galima gauti didžiulę grąžą, tačiau taip pat kyla nemaža rizika prarasti visą investiciją. Tokioje situacijoje pasitvirtina posakis „niekada nedėkite visų kiaušinių į vieną krepšį“. Kitaip tariant, investuotojas turėtų sudaryti įvairaus arba idealiu atveju nesusijusio finansinio turto portfelį, kad paskirstytų individuali kiekvieno turto rizika ir taip sumažintų bendrą portfelio riziką. Pasak šiuolaikinės portfelio teorijos pradininko Harry Markowitz, rizikos ir grąžos santykį galima padidinti optimaliai diversifikuojant ir atskiriant kiekvienos investicijos ir bendro portfelio rizikas, galima žymiai sumažinti riziką.

1.2.1. Klasikiniai rizikos vertinimo metodai kriptovaliutų portfeliams

Investicinių portfelių riziką galima vertinti daugybe skirtingų būdų, kurių pasirinkimas priklauso nuo to, į kokį finansinį instrumentą ar finansinių instrumentų portfelį yra investuojama.

Vienas iš plačiausiai studentų ir mokslininkų bei fondų valdytojų naudojamų rizikos matavimo metodų yra dispersija ir standartinis nuokrypis pasiūlyti 1952. 1956 metais Markowitz rizikos matavimui taip pat pasiūlė pusiau dispersiją, kuri yra geresnis požiūris į rizikos matavimą nei dispersija, nes rizika yra įvertinta atsižvelgiant į neigiamas grąžos vertes (Cibulskienė ir Brazauskas, 2016). Tačiau anot Bowala ir Singh (2022) portfelio standartinis nuokrypis ir dispersija nors ir yra plačiai paplitusios portfelių rizikos analizės priemonės, kriptovaliutomis ir jų portfeliams nėra tinkamas rizikos vertinimo būdas. Anot jų, po 2008 metų pasaulinės finansų krizės, finansų rinkos susiduria su būtinybe įdiegti tvarius prognozavimo modelius, įtraukiančius rinkos rizikas. Panašius rezultatus savo atliktame tyrime gavo ir Ahmadi-Javid (2023), kuris teigė, kad beveik visoms populiarioms rizikos priemonėms, pateiktoms literatūroje iki 2000 m. tokioms kaip vidutinė dispersija ar vidutinis standartinis nuokrypis, trūksta kai kurių aksiominių savybių, reikalingų nuoseklumui užtikrinti. Taip pat anot jo vidutinės dispersijos ir vidutinio standartinio nuokrypio rizikos matas, nėra monotoniškas, todėl jis ekonomiškai beprasmis. Kitas šios rizikos priemonės trūkumas yra tas, kad ji simetriškai atsižvelgia pelną ir nuostolius, o rizika yra asimetrinis reiškinys. Dėl šios priežasties šių rizikos matavimo priemonių populiarumas sumažėjo. Taigi, galima teigti, kad dispersija ir standartinis nuokrypis nėra tinkami rizikos vertinimo metodai kriptovaliutų portfeliui vertinti, nes kriptovaliutų

kainos yra labai svyruojančios ir šie klasikiniai rizikos vertinimo metodai neduotų reikiamos informacijos.

Kitas rizikos vertinimo metodas yra Bayesiniai tinklai. Anot Ghasemi et al. (2018), bayesiniai tinklai nurodo tiesioginius priežastinius ryšius tarp kintamųjų. Šis modelis gali greitai apskaičiuoti konkretų tikimybių skirstinį ir įvairiais būdais prisidėti prie rizikos analizės. BN taip pat padeda įvestinti kaip vienos ar daugiau rizikų pašalinimas gali paveikti kitas. Tačiau bayesiniai tinklai yra kritikuojami dėl rėmimosi ekspertų žiniomis, nes tai gali būti subjektyvu (Ghasemi et al., 2018). Taigi, bayesiniai tinklai gali būti naudojami, kai yra ekspertų, kurių žiniomis galima pasiremti.

Vienas iš plačiai paplitusių rizikos vertinimo modelių yra rizikos vertė arba VaR. Rizikos vertė apibūdina didžiausią nuostolį per tam tikrą laikotarpį su iš anksto nustatyta maža tikimybe, kad tie nuostoliai bus didesni (Cibulskienė ir Brazauskas, 2016). Anot Bowala ir Singh (2022), investavimą į kriptovaliutas galima prilyginti lošimui dėl neprognozuojamų kainų pokyčių, tačiau rizikos vertinimui jis siūlė naudoti VaR ir CVaR, nes šie metodai gali padėti kapitalo paskirstymo procese išvengti finansinių nesėkmių. Tačiau Ahmadi-Javid (2023) savo tyrime nustatė, kad nors VaR ir yra plačiai naudojamas, jis nėra nuoseklus ir jam trūksta subjektyvumo. Taip pat jis pastebėjo nesuderinamumą su gerai diversifikuotu portfeliu ir su šiuo rizikos vertinimo metodu susiję modeliai yra sunkiai valdomi, kai yra dideli duomenų kiekiai. Taigi, gali teigti, kad nors VaR ir yra populiarus rizikos vertinimo modelis, jis nėra pats tinkamiausias kriptovaliutų vertinimui vien dėl to, kad su kriptovaliutomis visada bus dideli duomenų kiekiai, kai ši rinka dirba kiekvieną dieną.

Vienas iš populiariausių kriptovaliutoms naudojamų rizikos metodų yra Monte Karlo simuliacija. Monte Karlo simuliacija leidžia numatyti galimas baigtis ir kokia to tikimybė. Monte Karlo modeliavimas ir atsitiktinių skaičių generavimas yra metodai, plačiai naudojami finansinėje analizėje kaip priemonė įvertinti rizikos lygį (Kozlovskiy et al., 2022). Anot Bányai, Tatay, Thalmeiner, ir Pataki (2024) Monte Karlo modeliavimas gali užfiksuoti uodegos riziką, dėl kurios atsiranda ekstremalūs ir reti įvykiai, kurie dažnai praleidžiami naudojant paprastesnius metodus. Panašius rezultatus, kad Monte Karlo simuliacija yra pranašesnė už kitus rizikos vertinimo modelius rado ir Ječmínek et al. (2020). Atliktame tyrime buvo naudojami parametriniai (GARCH ir EWMA), neparametriniai (istorinis VaR) rizikos vertinimo metodai ir Monte Karlo modeliavimas (pagal GBM). Tyrime buvo nustatyta, kad Monte Karlo simuliacija geriausius rezultatus vertinant kriptovaliutų vertės riziką dėl intensyvaus difuzijos proceso ir rezultatų patikimumo. Monte Karlo simuliacija buvo pasirinkta kaip geriausias kriptovaliutų rizikų vertinimo metodas, nes su istoriniu VaR Bitcoin kriptovaliuta viršydavo nustatytas ribas labiau nei kartu tirti kiti finansiniai instrumentai. Likitratcharoen et al. (2021) savo tyrime taip pat

rado, kad Monte Karlo simuliacija parodė puikius rezultatus kriptovaliutų rizikos vertinime 99% patikimumo lygiui ir parodė geresnius rezultatus nei istorinio VaR modeliavimo metodas. Tokie patys rezultatai buvo rasti ir Zheng et al. (2022) ir Matic et al. (2023) atliktuose tyrimuose. Taigi, galima teigti, kad Monte Karlo simuliacija parodė tikrai gerus rezultatus kriptovaliutų rizikos vertinime.

Apibendrinant galima teigti, kad yra daugybė klasikinių rizikos vertinimo metodų, tačiau šiais laikais, kai finansiniai instrumentai yra stipriai pasikeitę, klasikiniai metodai yra sunkiai pritaikomi. Iš atliktų tyrimų matoma, kad paprasti rizikos vertinimo metodai kaip standartinis nuokrypis ar dispersija nėra tinkami kriptovaliutų rizikos vertinimui, nes šis finansinis instrumentas yra labai nestabilus ir turi didelius kainos svyravimus. Iš klasikinių rizikos vertinimo būdų plačiausiai yra naudojami istorinis VaR ir Monte Karlo simuliacija, kuri rodo gerus rezultatus kriptovaliutų rizikos vertinime.

1.2.2. Mašininio mokymo rizikos vertinimo metodai kriptovaliutų portfeliams

Mašininis mokymasis yra dirbtinio intelekto (AI) sritis (5 pav.), suteikianti kompiuteriams galimybę mokytis iš duomenų tiesiogiai neprogramuojant. Tai procesas, kurio metu algoritmai analizuoja didelius duomenų kiekius, atpažįsta modelius ir pagal šiuos duomenis priima sprendimus.



Šaltinis: Sutienė, et al. (2024). *Enhancing portfolio management using artificial intelligence: literature review*, p. 5.

5 pav. Mašininio mokymosi ir sąsaja su dirbtiniu intelektu

Pats mašininis mokymasis apima gilųjį mokymąsi ir neuroninius tinklus. Anot Sutienės ir kitų (2024), rizikos vertinime mašininis mokymasis yra veiksmingesnis už klasikinius rizikos vertinimo metodus dėl šių priežasčių:

- Mašininis mokymasis yra specialiai sukurtas prognozavimo tikslams
- Mašininis mokymasis gali susitvarkyti su dideliu kintamųjų skaičiumi ir įveikti dimensiškumą apjungdamas silpus informacijos šaltinius
- Mašininis mokymasis gali aptikti netiesinius ir kompleksinius ryšius ir sumažinti persimokymą

Panašius rezultatus, kad mašininis mokymasis yra pranašesnis už klasikinius rizikos vertinimo modelius rado ir Pagnottoni (2019). Jo atliktame tyrime prognozavimo klaidos vidutiniškai buvo 46% mažesnės naudojant mašininį mokymąsi nei klasikinius rizikos vertinimo modelius. Taigi, galima teigti, kad mašininis mokymasis yra žymiai geresnis pasirinkimas kriptovaliutų rizikos vertinimui.

Tačiau mašininis mokymasis išsiskaido į daugybę skirtingų algoritimų, kiekvienas iš jų turi specifines savybes ir pritaikymo sritis.

1 lentelė

Mašininio mokymosi algoritmai rizikos vertinime

Mašininio mokymosi algoritmas	Kam dažniausiai naudota	Autoriai
GBT	Naudoja mokymosi algoritmus nustatyti geriausiai veikiančius turtus pagal pelningumą ir rizika tam tikram laikotarpiui.	(Sutiene, et al., 2024) (Wolff ir Echterling, 2024) (Chowdhury et al., 2020) (Liu et al., 2023)
RF	Eliminuoja nestabilumą duomenyse. Pasirenkamas efektyviausias kelias.	(Sutiene, et al., 2024) (Pinelis ir Ruppert, 2022) (Ma et al., 2021) (Wolff ir Echterling, 2024)
DL	Naudoja mokymosi algoritmus nustatyti geriausiai veikiančius turtus pagal pelningumą ir rizika tam tikram laikotarpiui	(Sutiene, et al., 2024)
ANN	Sumažina klaidas. Didelis tikslumas kainų prognozavimui.	(Sutiene, et al., 2024) (Wolff ir Echterling, 2024) (Chowdhury et al., 2020)
SVR	Laiko eilučių prognozavimas. Atmeta nereikalingus duomenis ir pagerina prognozavimą.	(Ma et al., 2021) (Paiva et al., 2019)
LSTM	Atpažįsta ilgalaikes sąsajas tarp kintamųjų.	(Ma et al., 2021) (Wolff ir Echterling, 2024) (Chowdhury et al., 2020) (Zuniga et al., 2023)
DMLP	Naudingas užduotims, kuriose reikia atpažinti sudėtingus modelius dideliuose duomenų rinkiniuose.	(Ma et al., 2021)

Mašininio mokymosi algoritmas	Kam dažniausiai naudota	Autoriai
XGB	XGBoost yra specifinė GBT implementacija, sukurta siekiant didesnio našumo ir efektyvumo. XGBoost įgyvendina daugybę optimizacijų, kurios daro šį algoritmą greitesnį ir efektyvesnį už tradicinius GBT.	(Liu et al., 2023)

Šaltinis: sudaryta autoriaus

Taigi, yra nemažai ML ir DL algoritmų ir kiekvienas iš jų skiriasi savo veikimo principu. Anot Chowdhury et al. (2020) GBT yra ypač naudingas kainų prognozavimo kontekste dėl kelių priežasčių. Visų pirma, šiam algoritmui nereikia normalizuoti duomenų. Antra, jis yra taisyklėmis pagrįstas mokymosi metodas ir jis sukuria galutinį modelį, pagrįstą atskirų modelių rinkiniu. Galiausiai, jis jau yra nemažai patikrintas ir sėkmingai veikia kriptovaliutų kainų prognozavimo procese. Tačiau GBT modelis gali persimokyti, kai yra naudojamas triukšmingose ir nepastoviose rinkose, tokiose kaip kriptovaliutos. Taip pat, GBT modeliai dažnai yra vadinami „juodosiomis dėžėmis“ dėl savo sudėtingumo interpretuojant rezultatus (Sebastião ir Godinho, 2021). Taigi, GBT modelis turi privalumų, nes nereikia normalizuoti duomenų, tačiau prognozavime gali būti netikslumų, kai rinkos yra nepastovios.

Kitas plačiai naudojamas prognozavimo modelis yra RF. RF yra mokymosi metodas, kuris veikia konstruojant kelis sprendimų medžius. Pagrindinis RF algoritmo naudojimo pranašumas yra tai, kad jis sumažina persimokymo riziką ir reikalingą treniruočių laiką. Anot Pinelis ir Ruppert (2022), dar vienas RF privalumas yra tas, kad optimizuojamų parametrų skaičius yra mažesnis nei daugelyje kitų mašininio mokymosi modelių. Pavyzdžiui, gilieji neuroniniai tinklai gali turėti šimtus parametrų, kuriuos reikia įvertinti, o galimos paslėptų sluoksnių ir neuronų konfigūracijos yra praktiškai nesuskaičiuojamos. Taip pat RF algoritmas siūlo aukštą tikslumo lygį ir efektyviai veikia dideliuose duomenų rinkiniuose, o jį galima naudoti tiek klasifikavimo, tiek regresijos problemoms spręsti. Tačiau anot Akyildirim et al. (2021), triukšmas duomenyse kartais gali privesti modelį prie persimokymo ir jis gali duoti labai klaidingus rezultatus. Panašias mintis, kad RF yra labiau tinkamas klasifikavimui, o ne laiko eilučių prognozavimui reiškė ir Khedr et al. (2021). Taigi, geriausias RF panaudojimas yra klasifikavimo problemoms spręsti, o laiko eilučių prognozavimui jis nėra taip dažnai naudojamas.

Kitas plačiai naudojamas modelis yra SVR. Anot Paiva et al. (2019), SVM metodu siekiama išspręsti modelio atpažinimo, klasifikavimo, regresijos įvertinimo ir laiko eilučių įvertinimo problemas. SVR metodas turi didesnę tikslumą nei kiti individualūs prognozavimo metodai. Jis pasižymi puikiu našumu, nes yra skirtas sumažinti struktūrinę riziką, o kiti metodai yra skirti empiriniam rizikos mažinimui (Akyildirim et al., 2021). Tačiau anot Khedr et al. (2021), SVR yra labiau tinkamas dirbti su nedideliu duomenų rinkiniu. Taigi, galima teigti, kad SVR yra tinkamas dirbti su laiko eilutėmis, tačiau iki galo nėra aišku ar jis tinkamas naudoti su dideliais duomenų rinkiniais.

ANN yra dar vienas paplitęs mašininio mokymosi algoritmas, kuris yra naudojamas kainų prognozavimui. Neuroniniai tinklai yra matematinis modelis, kuris yra paremtas biologinių neuroninių tinklų struktūra ir funkcijomis. Neuroninį tinklą sudaro tarpusavyje sujungtų dirbtinių neuronų tinklas, kuris apdoroja informaciją naudodamas jungtinį skaičiavimo metodą. Neuroniniai tinklai gali būti naudojami sudėtingiems ryšiams tarp įvesties ir išvesties modeliuoti arba duomenų modeliams surasti, kad būtų galima numatyti kriptovaliutų kainą (Chowdhury et al., 2020). ANN yra naudojamas kriptovaliutų kainų prognozavime, nes jis randa netiesinius santykius tarp kintamųjų ir gali rasti sudėtingus šablonus duomenyse. Taip pat ANN geba mokytis iš istorinių duomenų ir leidžia integruoti kitus duomenis, tokius kaip sentimentų analizė (Murray et al., 2023). Vienas iš ANN algoritmų LSTM yra plačiai naudojamas kriptovaliutų kainų prognozavime. Anot Dutta et al. (2020), LSTM veikia geriau nei tradiciniai laiko eilučių prognozavimo modeliai kriptovaliutų rinkoje. Tyrime buvo palyginti tradiciniai modeliai su LSTM algoritmu įvertinant būsimą BTC kainą ir LSTM algoritmas turėjo žymiai mažesnę vidutinę absoliučią paklaidą. Turėdami ribotus duomenis neuroniniai tinklai gali reguliuoti praeities informaciją, kad galėtų veiksmingai mokytis iš netiesinių ryšių. Tačiau anot Murray et al. (2023), LSTM mokymas reikalauja didelių skaičiavimo išteklių ir laiko, ypač naudojant didelius duomenų rinkinius. Taip pat LSTM tinklai turi daug hiperparametrų, tokių kaip sluoksnių skaičius, vienetų skaičius sluoksnyje ir mokymosi greitis, kuriuos reikia tiksliai sureguliuoti, kad būtų pasiektas optimalus našumas. Galiausiai, dėl didelio sudėtingumo LSTM modeliai gali lengvai prisitaikyti prie treniruočių duomenų ir persimokyti, ypač kai dirbama su mažais arba triukšmingais duomenų rinkiniais. Taigi, neuroniniai tinklai ir LSTM yra vieni iš dažniausiai naudojamų algoritmų dėl didelio tikslumo ir gebėjimo rasti netiesinius ryšius, tačiau panašiai kaip ir su kitais mašininio mokymosi algoritmais yra didelio rizika, kad jie persimokys ir didelis parametrų skaičius gali apsunkinti optimalaus našumo pasiekimą.

Lyginant SVR ir LSTM mašininio mokymosi modelius tarpusavyje yra keletas skirtumų. LSTM mašininio mokymosi metodas yra dažniausiai naudojamas metodas kriptovaliutų laiko eilučių

prognozavimui, tačiau jis yra labiau tinkamas, kai yra didelis duomenų rinkinys. SVR metodas yra plačiau naudojamas, kai duomenų aibė yra mažesnė, o LSTM kai duomenų aibė yra sąlyginai didelė. Vienas iš pagrindinių skirtumų tarp šių modelių yra jų kompleksiskumas. SVR yra pagrįstas optimizavimo metodais ir jo modeliai yra paprastesni, kai tuo tarpu LSTM yra neuroninis tinklas su daugybe pasikartojančių sluoksnių. Dėl modelių kompleksiškumo skirtumo, SVR modelis reikalauja mažesnių skaičiavimo išteklių. Taip pat, šių modelių efektyvus priklausos nuo duomenų apimties, taigi SVR modelis yra efektyvesnis, kai duomenų aibė yra nedidelė arba vidutinė, o LSTM tampa tinkamesnis, kai duomenų kiekis yra didelis (Goodday ir Ledisi, 2020). Taigi, apibendrinant, tiek SVR tiek LSTM yra tinkami modeliai kriptovaliutų kainų prognozavimui, tačiau pasirinkimas kurį modelį naudoti priklauso nuo duomenų imties.

DMLP yra mažiau naudotas algoritmas, kuris taip pat yra priskiriamas prie neuroninių tinklų. DMLP algoritmas yra sukurtas susitvarkyti su dinamiškais ir laikui bėgant kintančiais duomenimis, todėl jis yra tinkamas kainų prognozavimui finansų rinkose, įskaitant kriptovaliutas (Sebastião ir Godinho, 2021). Anot Murray et al. (2023), DMLP algoritmas turi daug privalumų, tokių kaip prisitaikymas. DMLP gali prisitaikyti prie duomenų paskirstymo pokyčių laikui bėgant, todėl jis labiau tinka dinamiškoms rinkoms, tokioms kaip kriptovaliutų rinka. DMLP gali fiksuoti nelineinius ryšius duomenyse, kurie yra įprasti finansinėse laiko eilutėse. Taip pat DMLP metodui gali tikri įvairios įvestis, tiek skaitiniai duomenys, tiek kategoriniai duomenys ar net tekstiniai duomenys, kurie derinami su kitais metodais, tokiais kaip sentimentų analizė. Galiausiai koreguodamas savo struktūrą, DMLP gali pasiekti geresnį prognozavimo tikslumą, palyginti su statiniais modeliais. Tačiau iš kitos pusės šis metodas gali turėti ir trūkumų, tokių kaip sudėtingumas, persimokymas ar priklausomybė nuo duomenų kokybės. DMLP metodas yra sudėtingesnis už kitus tradicinius modelius ir jis reikalauja daugiau skaičiavimo išteklių ir ilgesnio mokymosi laiko. Taip pat, jei duomenys yra riboti, gali būti didelė persimokymo rizika. Galiausiai modelio našumas labai priklauso nuo įvesties duomenų kokybės ir kiekio. Jei duomenų nepakanka arba jie yra triukšmingi, tai gali sumažinti modelio tikslumą.


Taigi, apibendrinant galima teigti, kad kriptovaliutų kainų prognozavimui naudojami įvairūs mašininio mokymosi (ML) ir gilaus mokymosi (DL) algoritmai, kurie skiriasi savo veikimo principais ir efektyvumu. GBT algoritmas yra naudingas dėl savo duomenų normalizavimo nereikalavimo ir taisyklių pagrindu veikiančio mokymosi, tačiau gali persimokyti triukšmingose rinkose. RF algoritmas sumažina persimokymo riziką ir reikalauja mažiau parametrų optimizavimo, tačiau gali būti netinkamas laiko eilučių prognozavimui. SVR algoritmas yra tikslus mažiems duomenų rinkiniams, tačiau gali būti mažiau efektyvus dideliems duomenims. ANN ir ypač LSTM tinklai geba rasti

netiesinius ryšius duomenyse ir mokytis iš istorinių duomenų, bet reikalauja didelių skaičiavimo išteklių ir turi daug hiperparametrų. DMLP algoritmas yra pritaikytas dinamiškiems duomenims ir gali apdoroti įvairius duomenų tipus, tačiau gali būti sudėtingas ir jautrus duomenų kokybei. Tinkamo algoritmo pasirinkimas gali žymiai padidinti prognozių tikslumą ir sumažinti riziką kriptovaliutų rinkose.

Kitame skyriuje bus parodyta tyrimo eiga ir kokie metodai bus naudojami tyrime.

2. KRIPTOVALIUTŲ PORTFELIŲ RIZIKOS VERTINIMO SIŪLOMAS SPRENDIMAS

Šiame skyriuje pateikiami metodai kaip bus gaunami ir analizuojami duomenys. Schema kaip bus atlikta praktinė dalis yra pavaizduota 6 pav.



Šaltinis: sudaryta autoriaus

6 pav. Tyrimo eigos struktūra

Darbo struktūra susideda iš trijų pagrindinių dalių, teorinės analizės, metodologinės dalies ir praktinės dalies. Teorinėje dalyje nagrinėjami faktoriai, kurie gali turėti įtakos kriptovaliutų kainų svyravimams ir nagrinėjama kaip tas poveikis daromas. Metodologinėje dalyje paminimi kokie metodai bus naudojami atliekant skaičiavimus. Praktinė dalis susidaro iš kelių dalių. Iš pradžių bus pasirenkamos kriptovaliutos, kurios bus nagrinėjamos. Tada bus surenkami statistiniai duomenys ir socialinių tinklų sentimentų duomenys, šiuo atveju duomenys bus renkami iš Twitter kadangi tai yra


vienintelė socialinių tinklų platforma, kuri dalinasi istoriniais duomenimis. Surinkus duomenis, bus atlikta duomenų analizė, bus patikrinta koreliacija tarp kintamųjų ieškant stipriai koreliuojančių faktorių. Tada bus atliekama regresinė analizė, kuri parodys, kurie duomenys yra statistiškai reikšmingi ir toliau bus naudojami kainų prognozei atlikti. Kai duomenys bus paruošti, bus atliekamas kainos prognozavimas naudojant Monte Karlo simuliaciją ir DMLP ir SVR mašininio mokymosi metodus. Tada gauti rezultatai bus aptarti ir interpretuoti.

2.1. Socialinių tinklų sentimentų vertinimo metodai

Rinkos nuotaikos yra bendras jausmas apie rinkos klimata. Kadangi žmonės yra socialios būtybės, jų sprendimus įtakoja kitų žmonių nuomonė, internete pateikiama informacija ir kiti komunikacijos kanalai, kurių skaičius auga eksponentiškai.

Sentimentus galima suskirstyti į du tipus, kurie yra aiškūs ir numanomi. Aiškūs jausmai yra tada, kai nuomonė yra aiškiai išreikšta, kita vertus, numanomame sakinyje tekstas reiškia nuomonę. Aiškius jausmus daug lengviau pastebėti ir analizuoti.

Sentimentų analizė yra labai glaudžiai susijusi su kompiuterine lingvistika, natūralios kalbos apdorojimu ir teksto gavyba. Procesas kaip duomenys paruošiami sentimentų analizei pavaizduotas 7 pav.




Šaltinis: Sudaryta autoriaus pagal Ontotext (2007)

7 pav. Socialinių tinklų duomenų paruošimas sentimentų analizei

Analizuojant jausmus, jausmai paprastai skirstomi į teigiamus ir neigiamus. Taip pat gali būti situacijų, kai yra mišraus poliškumo, nes tekste yra ir teigiamų, ir neigiamų jausmų, o kartais gali būti net neutralūs arba be poliškumo tekstai

Taigi, jausmų analizės procesas apima šiuos veiksmus:

- Sentimentų aptikimas – pirmoji užduotis yra aptikti objektyvumą. Tai galima apibūdinti kaip objektyvo-subjektyvaus poliškumo apskaičiavimą nuo 0 iki 1. Paprastai jis pagrįstas būdvardžių aptikimu tekste.
- Neigiamas-teigiamas klasifikavimas – šis žingsnis apima duomenų klasifikavimą į teigiamą, neutralų ir neigiamą. Kiekvienas žodis gali būti labai stiprus, stiprus, vidutinio sunkumo, silpnas.
- Tikslas identifikavimas – svarbiausia šio žingsnio dalis yra tiksliai nustatyti išreikšto jausmo tikslą. Tai vienas iš sunkiausių žingsnių, nes kartais taikinių gali būti daugiau nei vienas.
- Rinkimas ir agregavimas – šio žingsnio idėja yra apibendrinti ir paslėpti nuotaikas į vieną nuotaikų matą visiems tekstiniams duomenims. Šis veiksmas gali būti paprastas, jei apima tik teksto poliškumo ir stipriųjų pusių apibendrinimą, arba gali būti sudėtingas, jei jis apima semantinio agregavimo metodus iš natūralios kalbos apdorojimo. Šiame etape naudojami leksikonai. Pavyzdžiui, Prinstonio leksika turi išplėtimą, kuriame identifikuojamas teigiamas-neigiamas poliškumas ir subjektyvus-objektyvus poliškumas. Ten žodis turi tris dimensijas: pozityvumą, negatyvumą ir objektyvumą.



Šaltinis: Sudaryta autoriaus pagal Ontotext (2007)

8 pav. Sentimentų poliariškumas

Taigi, atlikus nuotaikų analizę, tekstui priskiriamas sentimentų balas. Kiekvienas žodis pagal leksiką ir jo vartojimo būdą gauna balą, o vėliau skaičiuojamas tų balų vidurkis, kuris yra nuotaikos balas. Sentimentų balas ir sentimentų kategorija pavaizduota

Yra keletas skirtingų idėjų, kaip suskirstyti į kategorijas ir įvertinti nuotaikų balo vertę.

2 lentelė

Socialinių tinklų nuotaikų vertinimo balai ir kategorijos

Vertės ribos	Sentimento kategorija
Nuo 0,5 iki 1	Labai pozityvu
Nuo 0,1 iki 0,5	Pozityvu
Nuo -0,1 iki 0,1	Neutralu
Nuo -0,1 iki -0,5	Negatyvu
Nuo -0,5 iki -1	Labai negatyvu

Šaltinis: Chohan, A. (2016)

Pagal aukščiau pateiktą lentelę reikšmės gali būti nuo 1 iki -1, o nuotaikos yra neutralios, jei reikšmės yra nuo -0,1 iki 0,1. Tai naudojama, kai kiekviename žodyje yra priskirtas 1, jei žodis ir teigiamas, ir -1, jei žodis yra neigiamas. Šiuo atveju vidurkis yra nuo -1 iki 1. Taigi, jei galutinis balas yra nuo 0,5 iki 1, tai reiškia, kad tekstas yra labai teigiamas. Jei reikšmė yra nuo -0,5 iki -1, tai yra labai neigiama. Jei reikšmė yra nuo -0,1 iki 0,1, tekstas yra neigiamas.

Taigi, nuotaikų analizė turėtų pateikti nuotaikų balus, kurie parodys įvertintą žmonių nuotaiką skaitine forma, kuri yra būtina norint toliau atlikti kainų prognozavimus.

2.2. Statistiškai reikšmingų faktorių pasirinkimas

Statistiškai reikšmingų faktorių pasirinkimas yra būtinas naudojant tiesinę regresiją, tačiau naudojant mašininių mokymąsi, tai nėra būtina, tačiau rekomenduotina. Reikšmingų nepriklausomų kintamųjų pasirinkimas gali būti svarbus dėl kelių priežasčių. Pirma priežastis yra pagerėja modelio tikslumas, nes pašalinus statistiškai nereikšmingus veiksnius, modelis gali labiau susitelkti į labiausiai nuspėjamas laiko eilutes. Taip pat tai sumažina duomenų triukšmą ir prognozės tampa patikimesnės (Awan et al., 2018). Antra priežastis – sumažėja skaičiavimo sudėtingumas. Mažesnis kintamųjų kiekis reiškia mažesnį skaičiavimo poreikį. Tai gali būti labai svarbu dirbant su dideliais duomenų rinkiniais ar realaus laiko sistemomis, kur duomenų apdorojimo greitis yra labai svarbus. Kintamųjų sumažinimas ne tik pagerina greitį, bet ir supaprastina modelį bei palengvėja jo atnaujinimas

(Brownlee, 2021). Galiausiai – geresnis rezultatų interpretavimas ir aiškumas. Supaprastinus modelį, jį lengviau interpretuoti ir paaiškinti, o tai yra ypač svarbu tokioje srityje kaip finansai, kur suinteresuotos šalys turi suprasti prognozių pagrindą (Awan et al., 2018). Taigi, nereikšmingų veiksnių pašalinimas suteikia modeliui tikslumo ir patikimumo.

Pirmas žingsnis prieš tikrinant ar veiksniai yra statistiškai reikšmingi yra patikrinti koreliaciją tarp pačių faktorių ir pašalinti faktorius, kurie koreliuoja tarpusavy. Kai yra daugiakolineariškumas tarp kintamųjų, modelio gebėjimas atskirti atskirų faktorių svarbą sumažėja. Kai kurie mašininio mokymosi algoritmai, kaip RF, GBM ar pasirinkimo medžiai, yra mažiau paveikti daugiakolineariškumo, nes jie sutelkia dėmesį į funkcijų svarbą ir medžių skaidymus, o ne į koeficientus. Tačiau pašalinus perteklines funkcijas, netgi šių modelių efektyvumas ir aiškinamumas gali padidėti. Pašalinus koreliuojančius veiksnius, modelis supaprastinamas, o tai gali padėti sumažinti persimokymo galimybę ir pagerinti rezultatus (Brownlee, 2021).

Koreliaciją galima patikrinti naudojant Pearsono koreliaciją r . Formulė, kaip apskaičiuoti Pearsono koreliacijos koeficientą, yra (Jaadi, 2019):

$$r = r_{xy} = \frac{cov(x,y)}{S_x * S_y} \quad (1)$$

Čia $Cov(x,y)$ yra dviejų kintamųjų kovariacija;

$S(x,y)$ yra kiekvieno kintamojo standartinis nuokrypis.

Pearsono koreliacijos koeficiento reikšmės gali būti nuo 1 iki -1. Jei koreliacijos reikšmė lygi 1 arba artima jai, tada tarp kintamųjų yra labai didelė teigiama koreliacija, o tai reiškia, kad vienam kintamajam padidėjus arba mažėjant, kitas judės beveik taip pat. Jei koreliacija artima nuliui, tai reiškia, kad nėra koreliacijos tarp kintamųjų ir kintamųjų judėjimas yra visiškai nesusijęs. Ir jei reikšmė yra artima minus vienam, tada tarp kintamųjų yra neigiama koreliacija ir kai vienas kintamasis didėja, kitas mažėja ir atvirkščiai.

3 lentelė

Pearsono koreliacijos koeficiento reikšmių interpretavimas

Koreliacijos dydis	Interpretacija
Nuo 0,9 iki 1 (-0,9 iki -1)	Labai aukšta teigiama (neigiama) koreliacija
Nuo 0,7 iki 0,9 (-0,7 iki -0,9)	Aukšta teigiama (neigiama) koreliacija
Nuo 0,5 iki 0,7 (-0,5 iki -0,7)	Vidutinė teigiama (neigiama) koreliacija

Koreliacijos dydis	Interpretacija
Nuo 0,3 iki 0,5 (-0,3 iki -0,5)	Žema teigiama (neigiama) koreliacija
Nuo 0 iki 0,3 (0 iki -0,3)	Koreliacijos nėra

Šaltinis: Sudaryta autoriaus pagal Jaadi, Z. (2019)

3 lentelėje parodyta, kaip interpretuoti kintamųjų koreliacijos koeficientą. Pearsono koreliacijos koeficientas naudojamas tik ryšiui tarp kintamųjų matuoti, tačiau jis nepaaiškina kaip nepriklausomo kintamojo pokyčiai paveiks priklausomą kintamąjį.

Po koreliacijos tarp kintamųjų patikros kitas žingsnis yra patikrinti ar duomenys yra stacionarūs. Norint patikrinti, ar laiko eilučių duomenys yra stacionarūs, naudojamas ADF testas. Apskaičiuoto ADF testo formulė yra (Prabhakaran, 2019):

$$y_t = c + \beta t + \alpha y_{t-1} + \varphi \Delta Y_{t-1} + e_t \quad (2)$$

Čia $y(t)$ – laiko eilutės reikšmė laiku t ;

c – konstanta, kai eilutės reikšmė nepriklauso nuo laiko t ;

$y(t-1)$ – 1 eilės laiko eilučių vėlavimas;

βt – laiko eilutės tendencija;

delta $y(t-1)$ – pirmasis laiko eilutės skirtumas laiku $(t-1)$;

e_t – klaida.

Jei ADF testo p reikšmė yra mažesnė nei 0,05, tada duomenys yra stacionarūs ir paruošti tolesnei analizei, tačiau jei p reikšmės rezultatai yra didesni nei 0,05, tada duomenys yra nestacionarūs ir juos reiktų diferencijuoti.

Patikrinus koreliacijos koeficientą tarp kintamųjų, kitas žingsnis yra sukurti regresijos modelį. Pagrindinis šio modelio tikslas – statistinėje analizėje ištirti nepriklausomų ir priklausomų kintamųjų ryšį. Regresijos modelis parodo, kaip nepriklausomo arba prognozuojamojo kintamojo pokyčiai turi įtakos priklausomo kintamojo pokyčiams. Kuriant regresijos modelį, pasirenkami nepriklausomi kintamieji su teoriniu pagrindimu. Kelių nepriklausomų veiksnių tiesinės regresijos modelio formulė atrodo taip (Eck, 2018):

$$Y_i = \beta_0 + \beta_1 X_{i,1} + \beta_2 X_{i,2} + \dots \beta_k X_{i,k} + \varepsilon_i \quad (3)$$

Čia Y_i – priklausomas kintamasis;

β – koeficientas nepriklausomies kintamiesiems;

X_i – nepriklausomi kintamieji;

ε_i – klaida;

k – nepriklausomų kintamųjų skaičius.

Beta koeficientas parodo, kiek priklausomas kintamasis pasikeis, kai vienas nepriklausomo kintamojo vienetas padidės. Beta nulis parodo, kokią reikšmę turėtų priklausantis kintamasis, jei visi nepriklausomi kintamieji būtų lygūs nuliui

Yra daugiau nei vienas būdas sukurti regresijos modelį. Šiame darbe bus naudojama atgalinė ir progresyvioji regresija. Regresijos modelis bus sukurtas naudojant Matlab programą. Atgaliniame MLR modelyje iš pradžių pridedami visi nepriklausomi kintamieji, o nepriklausomas kintamasis, turintis didžiausią p reikšmę, pašalinamas. Po to sukuriamas naujas MLR modelis ir vėl pašalinamas nepriklausomas kintamasis su didžiausia p reikšme. Šie veiksmai kartojami tol, kol liks modelis su tik reikšmingais kintamaisiais (Bahrami et al., 2020). Kintamųjų reikšmingumas gali būti 95 % arba 90 % pasitikėjimo intervalais. Kitas naudojamas tiesinės regresijos modelis yra progresyvusis MLR modelis. Šio modelio idėja yra gana aiški. Iš pradžių sukuriama atskiri modeliai su kiekvienu nepriklausomu kintamuoju. Pasirinktas modelis su didžiausiu pakoreguotu R kvadratu ir mažiausia p verte. Po to vėl sukuriami daug modelių, bet jau su pasirinktu nepriklausomu kintamuoju ir vėl pasirenkamas reikšmingiausias modelis (Hubens et al., 2021). Šie veiksmai kartojami tol, kol atsiranda modelis, kai visi nauji nepriklausomi kintamieji yra nereikšmingi, todėl modelis, kuris buvo sukurtas prieš tą etapą, yra galutinis modelis. Kintamųjų p reikšmė gali būti mažesnė nei 0,05 arba 0,1 – tai priklauso nuo pasiklovimo intervalo.

Taigi, kaip parenkamas geriausias modelis. Jis parenkamas atsižvelgiant į determinacijos koeficiento, R kvadrato ir pakoreguoto R kvadrato koeficientų reikšmes su statistiniu reikšmingumu, išmatuotu p reikšme. R kvadrato apskaičiavimo formulė yra tokia:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (4)$$

Čia $\sum (y_i - \hat{y}_i)^2$ – kvadratinių faktinių y_i reikšmių kitimas nuo pagal regresiją apskaičiuotų y_i reikšmių;

$\sum (y_i - \bar{y})^2$ – kvadratinių faktinių y_i reikšmių nukrypimas nuo vidurkio.

O pakoreguoto R kvadrato formulė yra tokia (Bhalla, 2014):

$$Pakoreguoto R^2 = 1 - \frac{(1-R^2)(N-1)}{N-p-1} \quad (5)$$

Čia R^2 – modelio R kvadratas;

p – nepriklausomų kintamųjų numeris;

N – visas imties dydis.

Jei p reikšmė yra didesnė nei 0,05, regresijos modelis yra neperspektyvus, todėl jo vykdyti nerekomenduojama. Jei p reikšmė yra mažesnė nei 0,05, regresijos modelis yra tinkamas prognozavimui. Pasirinkus geriausią modelį, galima interpretuoti koeficientus. Paprastais žodžiais tariant, R kvadratas parodo, kiek procentų priklausomo kintamojo galima paaiškinti nepriklausomais kintamaisiais MLR modelyje. Kuo didesnis R kvadratas, tuo geriau. R kvadratas paprastai didėja, kai į tiesinės regresijos modelį pridedama daugiau nepriklausomų kintamųjų. Kadangi R kvadratą gali paveikti nepriklausomų kintamųjų skaičius, taip pat naudojamas koreguotas R kvadratas, nes jo reikšmė nepriklauso ir nedidėja, jei pridedama daugiau kintamųjų, todėl parodo, ar pridedamas papildomas nepriklausomas kintamasis yra tikrai naudingas ar ne. Taigi modelis, turintis didžiausią pakoreguotą R kvadratą, yra geriausias MLR modelis.

2.3. Monte Karlo simuliacijos metodas kriptovaliutų portfelio rizikos vertinimui

Monte Karlo simuliacija yra skaičiavimo metodas, naudojamas modeliuoti ir analizuoti duomenis su neapibrėžtumu ir atsitiktiniais įvykiais. Tai apima daug bandymų vykdymą, kad būtų galima numatyti sudėtingų ar atsitiktinių problemų rezultatus generuojant atsitiktinius kintamuosius. Pagrindiniai Monte Karlo simuliacijos aspektai apima atsitiktinę atranką, tikimybinę išvestį ir taikymą. Monte Karlo simuliacija remiasi atsitiktine atranka, kad būtų galima ištirti daugybę scenarijų. Atlikus daugybę iteracijų, modeliavimas pateikia galimų rezultatų tikimybių pasiskirstymą. Tai leidžia įvertinti įvairių rezultatų tikimybę. Monte Karlo simuliacija naudojama finansuose kainų modeliavimui, rizikos vertinimui ar portfelio valdymui, fizikoje, inžinerijoje ir daugelyje kitų sričių (Mba et al., 2022).

Monte Karlo simuliacija yra plačiai naudojama kainų prognozavimui įvairiuose sektoriuose, nes ji gali modeliuoti neapibrėžtumą ir svyravimus. Siekiant prognozuoti akcijų kainas, Monte Karlo simuliacija yra dažnai naudojama su Geometrinio Browno judėjimo (GBM) modeliu. Taikant šį metodą, sukuriami keli kainų judėjimo keliai, atsižvelgiant į tikėtiną grąžą ir atsitiktinius kainų svyravimus. Tai leidžia analitikams įvertinti kainų svyravimų tikimybę ir riziką (Xiang et al., 2021).

Tačiau prognozuojant kriptovaliutų, tokių kaip Bitcoin, kainas Monte Karlo simuliacija gali būti integruojama su sudėtingesniais modeliais. Vienas tokių yra Ornstein-Uhlenbeck procesas, kuris fiksuoja vidutinės reversijos tendencijas. Šis modelis atsižvelgia į išskirtines kriptovaliutų kainų pokyčių savybes, tokias kaip netikėti šuoliai ir nestabilumo klasterizavimas, ir pateikia tikimybinės būsimų kainų prognozes (Mba et al., 2022).

Ornstein-Uhlenbeck proceso diferencialinė lygtis (Mba et al., 2022):

$$dX_t = \theta(\mu - X_t)dt + \sigma dW_t \quad (6)$$

Čia X_t – proceso vertė laiku t ;

μ – ilgalaikis vidurkis į kurį grįžta procesas;

θ – vidutinės reversijos greitis (kaip greitai procesas grįžta į μ);

σ – standartinis nuokrypis;

W_t – Vynerio procesas (Brauno judėjimas), kuris įtraukia atsitiktinumą.

Atliekant Monte Karlo simuliacijas galima pasirinkti kokį skaičių simuliacijų norima atlikti. Simuliacijų skaičius priklauso nuo kelių priežasčių. Kuo didesnis simuliacijų skaičius, tuo didesnis skaičiavimo tikslumas ir mažesnė tikimybė gauti atsitiktinį rezultatą. Didesnis simuliacijų skaičius leidžia turėti mažesnę prognozių paklaidą. Galiausiai simuliacijų skaičius gali priklausyti nuo kompiuterinių išteklių ir laiko sąnaudų, nes kuo daugiau simuliacijų atliekama, tuo didesni ištekliai yra reikalingi. Anot Glasserman (2004), 1000 simuliacijų gali būti pakankama reikšmė nesudėtingiems skaičiavimams atlikti.

2.4. Mašininio mokymosi metodų taikymas kriptovaliutų portfelio rizikos analizėje

Mašininis mokymasis atlieka vis svarbesnį vaidmenį prognozuojant finansinio turto kainų svyravimus, nes suteikia galimybę panaudoti didžiulius duomenų kiekius ir pažangius algoritmus. Tai leidžia pastebėti modelius, kuriuos tradiciniai modeliai galėtų praleisti ar nepastebėti.

DMLP gilaus mokymosi architektūros tipas, kuriame prie tinklo yra pridedami keli paslėpti sluoksniai, siekiant modeliuoti sudėtingus, nelinijinius ryšius. DMLP architektūrą sudaro 3 dalys: įvesties sluoksnis, paslėpti sluoksniai ir išvesties sluoksnis.

Įvesties sluoksnį sudaro (Heaton, 2018):

$$X = [x_1, x_2, \dots, x_d] \quad (7)$$

Čia $X \in R_d$ ir d yra nepriklausomų kintamųjų skaičius.

Paslėptus sluoksnius sudaro (Heaton, 2018):

$$Z^{(l)} = W^{(l)}A^{(l-1)} + b^{(l)} \quad (8)$$

Čia $l \in \{1, 2, \dots, L-1\}$ – paslėpti sluoksniai;

$Z^{(l)} \in R^{N_1}$ – svertinė įvestis sluoksnyje l ;

$W^{(l)} \in R^{N_1 \times N_{l-1}}$ – svorio matrica tarp sluoksnių $l-1$ ir l ;

$A^{(l-1)} \in R^{N_{l-1}}$ – aktyvinimas iš ankstesnio sluoksnio;

$b^{(l)} \in R^{N_1}$ – l sluoksnio šališkumo vektorius.

Aktyvavimo funkcija (Heaton, 2018):

$$A^{(l)} = f(Z^{(l)}) \quad (9)$$

Čia $f()$ – aktyvavimo funkcija;

$A^{(l)}$ – aktyvavimas l sluoksniui.

Išvesties sluoksnio formulė (Heaton, 2018):

$$Z^{(L)} = W^{(L)}A^{(L-1)} + b^{(L)} \quad (10)$$

Čia L – paskutinis sluoksnis.

DMLP yra treniruojamas siekiant sumažinti klaidų funkciją, tokią kaip MSE (vidutinę kvadratinę klaidą). Ji skaičiuojama naudojant šią formulę:

$$L(Y, \hat{Y}) = \frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 \quad (11)$$

Čia Y – faktinės priklausomo kintamojo reikšmės;

Y_i – faktinės priklausomo kintamojo reikšmės i laiku;

$\hat{Y}$ – prognozuojamos modelio reikšmės;

N – duomenų taškų skaičius duomenų rinkinyje.

Skaičiavimuose naudojant DMLP modelį galima naudoti tik priklausomąjį kintamąjį arba priklausomąjį kintamąjį ir nepriklausomus kintamuosius. DMLP modelis paprastai veikia geriau, kai naudojami ir nepriklausomi kintamieji, nes tai leidžia gauti papildomos informacijos ir įvertinti sudėtingus ryšius tarp kintamųjų ir priklausomojo kintamojo. Taigi, DMLP modelį, nepriklausomų kintamųjų įtraukimas įprastai padidina modelio tikslumą, nes suteikia papildomų duomenų, leidžiančių modeliui giliau išmokyti priklausomybės struktūrą ir geriau suprasti prognozuojamo kintamojo svyravimus.

Kitas mašininio mokymosi algoritmas, kuris bus naudojamas šiame darbe yra SVR modelis. Šis modelis pasirinktas, dėl jo tinkamumo ir efektyvumo su mažais duomenų rinkiniais. Šis algoritmas yra skirtas regresijai, pagrįstai klasifikacijos principu. SVR formulė yra pagrįsta optimizavimu, kad klaida būtų minimizuota.

SVR algoritmo tikslas yra rasti funkciją $f(x)$, kuri būtų kuo arčiau priklausomojo kintamojo y , kai nepriklausomų kintamųjų reikšmės yra x . SVR algoritmo formulė yra (Smola & Schölkopf, 2004):

$$f(x) = w_1x_1 + w_2x_2 + \dots + w_dx_d + b \quad (12)$$

Čia d – nepriklausomų kintamųjų skaičius;

w_1 – svorio koeficientas kiekvienam nepriklausomam kintamajam;

b – poslinkio terminas.

Tikslas yra minimalizuoti žemiau pateiktą optimizavimo funkciją (Smola & Schölkopf, 2004):

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (13)$$

Čia $\|w\|^2$ – svorių vektorių norma, kuri reguliuoja sprendimo paviršių ir sumažina modelio sudėtingumą;

C – reguliavimo koeficientas;

ξ_i ir ξ_i^* - klaidos kintamieji.

Modelyje taip pat atsiranda apribojimų, kurie išreiškiami pagal šią formulę (Smola & Schölkopf, 2004):

$$\begin{cases} y_i - (w * x_i + b) \leq \epsilon + \xi_i \\ (w * x_i + b) - y_i \leq \epsilon + \xi_i^* \end{cases} \quad (14)$$

Čia y_i – tikroji priklausomojo kintamojo reikšmė;

x_i – nepriklausomo i-to kintamojo reikšmė;

$w * x_i$ – sandauga tarp svorio koeficientų ir nepriklausomojo kintamojo.

SVR algoritmas yra skirtas regresijai, kai yra priklausomas ir nepriklausomi kintamieji. Gali būti vienas ar daugiau kintamųjų, tačiau skaičiavimai nebus atlikti tik su istoriniais priklausomo kintamojo duomenimis (Smola & Schölkopf, 2004).

Tiek DMLP tiek SVR metodams reikia duomenis padalinti į treniravimo ir testavimo dalis. Behera et al. (2023) atliktame tyrime buvo testuojama, su koku treniravimo ir testavimo santykiu gaunama mažiausia santykinė klaida. Buvo testuoti 60:40, 70:30, 80:20 ir 90:10 treniravimo ir testavimo santykiai ir santykis 70:30 turėjo mažiausią vidutinę absoliučią klaidą (MAE), vidutinę kvadratinę klaidą (MSE) ir kvadratinės vidutinės klaidos šaknį (RMSE). Dalinti duomenis į treniravimo ir testavimo reikia todėl, kad tai leidžia įvertinti modelio tikslumą ir palyginti skirtingus modelius.

Pasirinkti duomenų atrankos metodai, socialinių tinklų sentimentų analizė, statistinė analizė ir rizikos vertinimo metodai padės pasiekti užsibrėžtus darbo tikslus bei ištirti, kurie metodai yra mažiausiai rizikingi ir turi didžiausią pelningumą.

Kitame skyriuje bus atlikta praktinė tyrimo dalis.

3. KRIPTOVALIUTŲ PORTFELIŲ RIZIKOS ANALIZĖ TAIKANT MAŠININIO MOKYMOSI METODUS

Šioje darbo dalyje bus siekiama išsiaiškinti, kuris rizikos vertinimo ir kainų prognozavimo metodas duoda tiksliausius rezultatus pasirinktam prognozavimo laikotarpiui.

3.1. Kriptovaliutų duomenų rinkimas ir pasirinkimas portfelio sudarymui

Pirmas žingsnis sudarant kriptovaliutų portfelį yra kriptovaliutų pasirinkimas. Pasak J. Almeida ir Gonçalves (2023), portfelyje derinant įvairių tipų kriptovaliutas kaip monetas ir žetonus, galima sumažinti portfelio riziką. Todėl į portfelį pasirinkta imti po 2 didžiausias monetas ir žetonus pagal rinkos kapitalizaciją. Tos kriptovaliutos yra BTC, ETH, BNB ir SOL.

4 lentelė

Pasirinktos kriptovaliutos ir jų rinkos kapitalizacija

Monetos	Rinkos kapitalizacija (2024.10.30)	Šaltinis
Bitcoin (BTC)	1 420 495 103 942	(CoinMarketCap.com, 2024)
Ethereum (ETH)	322 656 425 425	
Žetonai		
Binance coin (BNB)	87 236 981 846	
Solana (SOL)	82 243 429 182	


Šaltinis: sudaryta autoriaus

Pasirinkus kriptovaliutas, sekantis žingsnis yra surasti tų kriptovaliutų socialinių tinklų sentimentų balą. Šis balas bus skaičiuojamas nuo 2024.01.01 iki 2024.11.05 kiekvienai dienai. Iš Twitter žinutės buvo ieškomos pagal kriptovaliutų pavadinimus. Pavyzdžiui BTC twitter žinutės buvo ieškomos pagal du raktažodžius:

- „BTC“
- „Bitcoin“

Surinkus kiekvienos dienos Twitter žinutes pagal raktažodžius, kitas žingsnis yra įvertinti tų žinučių nuotaiką ir gauti sentimentų balą. Žinučių nuotaika yra vertinama suskirstant žodžius į teigiamus ir neigiamus. Žodžių suskirstymas pavaizduotas 9 pav.

Bitcoin Twitter sentimentų balai nuo 2024.01.01 iki 2024.11.05 atrodė taip:



Šaltinis: Parengta autoriaus

10 pav. BTC twitter sentimentų balų ir BTC kainų judėjimo grafikas

Iš vizualizacijos (10 pav.) atrodytų, kad kainų pakilimai ar nuosmukiai gan sutampa su Twitter sentimentų pakilimais ir nuosmukiais, tačiau statistškai sentimentų judėjimo kryptis su BTC kainos judėjimo kryptimi sutapo 160 kartų iš 345 kartų arba 47,54% kartų. 22,90% BTC kainų pakilimų sutampa su teigiamais Twitter sentimentų balų pakilimais ir lygiai taip pat 24,64% BTC kainų kritimų taškų sutampa su neigiamais sentimentų balais.

Suskaičiavus BTC, ETH, BNB ir SOL sentimentų balus, kitas žingsnis yra surinkti teorinėje darbo dalyje analizuotų, nepriklausomų faktorių, darančių įtaką kriptovaliutų kainų svyravimams, duomenis. Tie faktoriai apima socialinių tinklų duomenis, tokius kaip paieškų skaičius internete ar paminėjimų skaičius bei socialinių tinklų dominavimo procentas. Taip pat duomenis apie kitus finansinius instrumentus yra įtraukiami, tie duomenis apima akcijų rinką, kuri yra atspindėta S&P 500 indekso kainų, tada bankų palūkanų rinką, kuri yra atspindėta JAV Federalinio banko nustatytos palūkanų normos, obligacijų rinkos, kuri yra atspindėta 3 mėnesių T-bills palūkanų norma ir aukso rinkos, kuri atspindėta aukso kainos per unciją kainos. Likę faktoriai apima rinkos dominavimo

procentą, prekybos apimtį ir kelis kriptovaliutų vertinimo reitingavimus. Visi faktorių duomenys buvo surinkti nuo 2024.01.01 iki 2024.11.05 kasdienai (6 lentelė).

6 lentelė

Pasirinkti nepriklausomi kintamieji ir jų žymėjimas

Faktorius	Žymėjimas	Reikšmė	Matavimo vnt.	Šaltinis
Kaina	PRICE	Kasdieninė kaina	USD	(CoinMarketCap.com, 2024)
Sentimentų balas	SENTSCORE	Socialinių tinklų (Twitter) sentimentų balas	Skaičius	
Alt reitingas	ALTRANK	AltRank balas buvo sukurtas įvertinti ir palyginti kriptovaliutas atsižvelgiant į rinkos apimtį, socialinio balo reitingą ir procentinį pokytį su BTC.	Balas	(LunarCrush.com, 2024)
Galaxy balas	GALSCORE	Tai patentuotas balas, kuris vertina kriptovaliutas ir rodo kaip gerai jos veikia.	Balas	(LunarCrush.com, 2024)
Paieškų skaičius	ENGAGE	Paieškų skaičius internete per dieną	Skaičius	(LunarCrush.com, 2024)
Paminėjimų skaičius	MENTIONS	Paminėjimų socialinėje erdvėje skaičius per dieną	Skaičius	(LunarCrush.com, 2024)
Sentimentai	SENTIMENT	Nuotaikos – tai pranešimų, kurių teigiamas svertinis įvertinimas pagal įsipareigojimus, procentas. 100 % balas reiškia, kad visi įrašai buvo teigiami, o 0 % reiškia, kad visi įrašai buvo neigiami.	Procentai	(LunarCrush.com, 2024)
Socialinis dominavimas	SOCDOM	Rodo kriptovaliutos apimtį socialinėje erdvėje .	Procentai	(LunarCrush.com, 2024)
Rinkos kapitalizacija	MARKETCAP	Rinkos kapitalizacija kasdien	Skaičius	(CoinMarketCap.com, 2024)
Rinkos dominavimas	MARKDOM	Dominavimas rinkoje apskaičiuojamas imant monetų rinkos kapitalizaciją ir padalijus ją iš visos kriptovaliutų rinkos kapitalizacijos.	Procentai	(LunarCrush.com, 2024)
Prekybos apimtis	TRADEVOL	Prekybos apimtis kasdien	Skaičius	(CoinMarketCap.com, 2024)
SP500 indeksas	SP500	S&P500 akcijų indeksas	USD	(Investing.com, 2024)
JAV fed. banko palūkanų %	INTRATE	JAV federalinio banko palūkanų norma	Procentai	(TradingEconomics.com, 2024)

Faktorius	Žymėjimas	Reikšmė	Matavimo vnt.	Šaltinis
3 mėn. T-Bills palūkanų norma	TBILL	3 mėnesių T-Bills palūkanų norma	Procentai	(Fred.com, 2024)
Aukso kaina	GOLD	Aukso kaina per unciją	USD	(Gold.org, 2024)

Šaltinis: sudaryta autoriaus.

Surinkus visus duomenis, jiems yra priskiriamas žymėjimas, kuris bus naudojamas tolimesniuose skaičiavimuose, paaiškinama faktorių reikšmė bei jų matavimo vienetai. Surinkus duomenis, kitas žingsnis yra patikrinti duomenų koreliaciją tarpusavy ir pašalinti stipriai koreliuojančius duomenis, siekiant išvengti klaidingų rezultatų.

Pirmiausiai buvo suskaičiuota BTC duomenų koreliacija ir koreliacijos lentelė yra pateikta žemiau.

7 lentelė

BTC nepriklausomų kintamųjų koreliacijos lentelė

	PRICE	SENTSCORE	ALTRANK	GALSCORE	ENGAGE	MENTIONS	SENTIMENT	SOCDOM	MARKETCAP	MARKDOM	TRADEVOL	SP500	INTRADE	TBILL	GOLD
PRICE	x	0,46	0,02	0,19	0,42	0,17	0,24	0,33	1,00	0,02	0,21	0,55	0,489	0,17	0,55
SENTSCORE	0,46	x	0,03	0,01	0,02	0,16	0,19	0,07	0,46	0,06	0,06	0,15	0,010	0,16	0,20
ALTRANK	0,02	0,03	x	0,17	0,19	0,24	0,06	0,23	0,03	0,02	0,05	0,50	0,299	0,62	0,52
GALSCORE	0,19	0,01	0,17	x	0,21	0,06	0,01	0,08	0,19	0,01	0,11	0,09	0,111	0,20	0,01
ENGAGE	0,42	0,02	0,19	0,21	x	0,47	0,21	0,44	0,43	0,06	0,15	0,42	0,570	0,08	0,39
MENTIONS	0,17	0,16	0,24	0,06	0,47	x	0,17	0,27	0,17	0,01	0,18	0,12	0,132	0,22	0,17
SENTIMENT	0,24	0,19	0,06	0,01	0,21	0,17	x	0,09	0,24	0,08	0,22	0,37	0,419	0,21	0,42
SOCDOM	0,33	0,07	0,23	0,08	0,44	0,27	0,09	x	0,33	0,06	0,08	0,38	0,483	0,07	0,35
MARKETCAP	1,00	0,46	0,03	0,19	0,43	0,17	0,24	0,33	x	0,02	0,21	0,56	0,497	0,18	0,56
MARKDOM	0,02	0,06	0,02	0,01	0,06	0,01	0,08	0,06	0,02	x	0,02	0,13	0,081	0,03	0,08
TRADEVOL	0,21	0,06	0,05	0,11	0,15	0,18	0,22	0,08	0,21	0,02	x	0,05	0,068	0,02	0,03

7 lentelės tęsinys

	PRICE	SENTSCORE	ALTRANK	GALSCORE	ENGAGE	MENTIONS	SENTIMENT	SOCDOM	MARKETCAP	MARKDOM	TRADEVOL	SP500	INTRADE	TBILL	GOLD
SP500	0,55	0,15	0,50	0,09	-	0,12	0,37	0,38	0,56	0,13	0,05	x	0,634	-	0,90
INTRADE	0,49	-	0,30	0,11	-	0,13	0,42	0,48	0,50	0,08	0,07	0,63	x	-	0,64
TBILL	-	-	-	-	0,08	0,22	0,21	0,07	-	-	0,02	-	-0,14	x	-
GOLD	0,55	0,20	0,52	0,01	-	0,17	0,42	0,35	0,56	0,08	0,03	0,90	0,64	0,77	x

Šaltinis: sudaryta autoriaus.

Iš 7 lentelės galima matyti, kad koreliacija tarp BTC kainos ir rinkos kapitalizacijos yra 1, nes rinkos kapitalizacija yra apskaičiuojama padauginus kriptovaliutos kainą iš cirkuliacijoje esančių monetų ar žetonų. BTC kaina taip pat turėjo vidutinę teigiamą koreliaciją su sentimentų balu, S&P500 indeksu, JAV federalinio banko palūkanų norma ir aukso kaina. BTC kaina turėjo vidutinę neigiamą koreliaciją su paieškų skaičiumi internete. Vidutinė arba aukšta koreliacija taip pat buvo tarp S&P500 indekso ir JAV federalinio banko palūkanų normos, 3 mėnesių JAV obligacijų palūkanų normos procentu ir aukso kainos.

Sekantis žingsnis buvo apskaičiuoti ETH duomenų koreliaciją tarpusavyje. Koreliacijos lentelė yra pavaizduota žemiau.

8 lentelė

ETH nepriklausomų kintamųjų koreliacijos lentelė

	PRICE	SENTSCORE	ALTRANK	GALSCORE	ENGAGE	MENTIONS	SENTIMENT	SOCDOM	MARKETCAP	MARKDOM	TRADEVOL	SP500	INTRADE	TBILL	GOLD
PRICE	x	0,31	0,24	0,37	0,26	0,20	0,22	0,11	1,00	0,57	0,25	0,04	0,133	0,51	0,15
SENTSCORE	0,31	x	0,08	0,01	0,09	0,25	0,11	0,12	0,30	0,13	0,05	0,15	0,010	0,16	0,20
ALTRANK	0,24	0,08	x	0,22	0,19	0,13	0,10	0,10	0,24	0,30	0,03	0,27	0,101	0,35	0,26
GALSCORE	0,37	0,01	0,22	x	0,14	0,01	0,08	0,19	0,37	0,19	0,14	0,05	0,292	0,33	0,04
ENGAGE	0,26	0,09	0,19	0,14	x	0,27	0,06	0,51	0,26	0,47	0,29	0,63	0,585	0,48	0,68
MENTIONS	0,20	0,25	0,13	0,01	0,27	x	0,01	0,17	0,20	0,08	0,20	0,00	0,091	0,02	0,01

8 lentelės tęsinys

	PRICE	SENTSCORE	ALTRANK	GALSCORE	ENGAGE	MENTIONS	SENTIMENT	SOCDOM	MARKETCAP	MARKDOM	TRADEVOL	SP500	INTRADE	TBILL	GOLD
SENTIMENT	0,22	0,11	0,10	0,08	0,06	0,01	x	0,05	0,22	0,18	0,04	0,02	0,022	0,13	0,10
SOCDOM	0,11	0,12	0,10	0,19	0,51	0,17	0,05	x	0,11	0,42	0,06	0,65	0,532	0,37	0,68
MARKETCAP	1,00	0,30	0,24	0,37	0,26	0,20	0,22	0,11	x	0,56	0,25	0,04	0,135	0,51	0,15
MARKDOM	0,57	0,13	0,30	0,19	0,47	0,08	0,18	0,42	0,56	x	0,07	0,59	0,327	0,81	0,76
TRADEVOL	0,25	0,05	0,03	0,14	0,29	0,20	0,04	0,06	0,25	0,07	x	0,02	0,016	0,01	0,03
SP500	0,04	0,15	0,27	0,05	0,63	0,00	0,02	0,65	0,04	0,59	0,02	x	0,634	0,72	0,90
INTRADE	0,13	0,01	0,10	0,29	0,59	0,09	0,02	0,53	0,13	0,33	0,02	0,63	x	0,14	0,64
TBILL	0,51	0,16	0,35	0,33	0,48	0,02	0,13	0,37	0,51	0,81	0,01	0,72	-0,14	x	0,77
GOLD	0,15	0,20	0,26	0,04	0,68	0,01	0,10	0,68	0,15	0,76	0,03	0,90	0,64	0,77	x

Šaltinis: sudaryta autoriaus.

Iš 8 lentelės galima matyti, kad ETH kaina turi vidutinę koreliaciją su Twitter sentimentų balu, su Galaxy balu, su rinkos dominavimo procentu ir 3 mėnesių JAV obligacijų palūkanų normos procentu. Tarp kitų faktorių vidutinė koreliacija buvo tarp AltRank ir 3 mėnesių JAV obligacijų palūkanų normos, paieškų skaičiaus internete ir socialinio dominavimo procento, rinkos dominavimo procento, S&P500 indekso kainos, JAV federalinio banko palūkanų normos ir aukso kainos. Taip pat tarp socialinio dominavimo procento ir S&P500 indekso kainos, JAV federalinio banko palūkanų normos ir aukso kainos.

Po to buvo apskaičiuota BNB kriptovaliutos kainos ir ją veikiančių faktorių duomenų tarpusavio koreliacija. Ji pavaizduota lentelėje žemiau.

9 lentelė

BNB nepriklausomų kintamųjų koreliacijos lentelė

	PRICE	SENTSCORE	ALTRANK	GALSCORE	ENGAGE	MENTIONS	SENTIMENT	SOCDOM	MARKETCAP	MARKDOM	TRADEVOL	SP500	INTRADE	TBILL	GOLD
PRICE	x	0,32	0,04	0,23	0,13	0,15	0,24	0,26	1,00	0,87	0,38	0,66	0,662	0,25	0,70
SENTSCORE	0,11	x	0,01	0,14	0,03	0,01	0,02	0,06	0,11	0,07	0,00	0,15	0,076	0,11	0,13

	PRICE	SENTSCORE	ALTRANK	GALSCORE	ENGAGE	MENTIONS	SENTIMENT	SOCDOM	MARKETCAP	MARKDOM	TRADEVOL	SP500	INTRADE	TBILL	GOLD
ALTRANK	- 0,04	- 0,01	x	- 0,12	- 0,16	- 0,13	- 0,23	- 0,13	- 0,06	- 0,05	- 0,12	- 0,23	- 0,146	- 0,34	- 0,25
GALSCORE	- 0,23	- 0,14	- 0,12	x	- 0,13	- 0,01	- 0,03	- 0,10	- 0,23	- 0,19	- 0,01	- 0,01	- 0,203	- 0,20	- 0,03
ENGAGE	- 0,13	- 0,03	- 0,16	- 0,13	x	- 0,34	- 0,31	- 0,24	- 0,11	- 0,28	- 0,28	- 0,21	- 0,392	- 0,18	- 0,33
MENTIONS	- 0,15	- 0,01	- 0,13	- 0,01	- 0,34	x	- 0,15	- 0,27	- 0,16	- 0,02	- 0,14	- 0,06	- 0,162	- 0,10	- 0,09
SENTIMENT	- 0,24	- 0,02	- 0,23	- 0,03	- 0,31	- 0,15	x	- 0,33	- 0,21	- 0,42	- 0,07	- 0,55	- 0,379	- 0,47	- 0,54
SOCDOM	- 0,26	- 0,06	- 0,13	- 0,10	- 0,24	- 0,27	- 0,33	x	- 0,24	- 0,40	- 0,00	- 0,40	- 0,403	- 0,25	- 0,43
MARKETCAP	- 1,00	- 0,11	- 0,06	- 0,23	- 0,11	- 0,16	- 0,21	- 0,24	x	- 0,86	- 0,40	- 0,63	- 0,640	- 0,21	- 0,68
MARKDOM	- 0,87	- 0,07	- 0,05	- 0,19	- 0,28	- 0,02	- 0,42	- 0,40	- 0,86	x	- 0,12	- 0,70	- 0,749	- 0,33	- 0,77
TRADEVOL	- 0,38	- 0,00	- 0,12	- 0,01	- 0,28	- 0,14	- 0,07	- 0,00	- 0,40	- 0,12	x	- 0,16	- 0,087	- 0,03	- 0,08
SP500	- 0,66	- 0,15	- 0,23	- 0,01	- 0,21	- 0,06	- 0,55	- 0,40	- 0,63	- 0,70	- 0,16	x	- 0,634	- 0,72	- 0,90
INTRADE	- 0,66	- 0,08	- 0,15	- 0,20	- 0,39	- 0,16	- 0,38	- 0,40	- 0,64	- 0,75	- 0,09	- 0,63	x	- 0,14	- 0,64
TBILL	- 0,25	- 0,11	- 0,34	- 0,20	- 0,18	- 0,10	- 0,47	- 0,25	- 0,21	- 0,33	- 0,03	- 0,72	- -0,14	x	- 0,77
GOLD	- 0,70	- 0,13	- 0,25	- 0,03	- 0,33	- 0,09	- 0,54	- 0,43	- 0,68	- 0,77	- 0,08	- 0,90	- 0,64	- 0,77	x

Šaltinis: sudaryta autoriaus.

Iš 9 lentelės galima matyti, kad BNB kaina turi vidutinę teigiamą koreliaciją su rinkos dominavimo procentu, S&P500 indekso kaina, JAV federalinio banko palūkanų norma ir aukso kaina. Kiti faktoriai kaip socialinis dominavimas turi negiamą vidutinę koreliaciją su S&P500 indekso kaina, JAV federalinio banko palūkanų norma ir aukso kaina. Rinkos dominavimas turi didelę teigiamą koreliaciją su S&P500 indekso kaina, JAV federalinio banko palūkanų norma ir aukso kaina.

Galiausiai buvo apskaičiuota SOL kriptovaliutos ir ją veikiančių faktorių duomenų tarpusavio koreliacija. Ji yra pavaizduota lentelėje žemiau.

SOL nepriklausomų kintamųjų koreliacijos lentelė

	PRICE	SENTSCORE	ALTRANK	GALSCORE	ENGAGE	MENTIONS	SENTIMENT	SOCDOM	MARKETCAP	MARKDOM	TRADEVOL	SP500	INTRADE	TBILL	GOLD
PRICE	x	0,44	-	-	0,48	0,46	0,02	0,10	0,99	0,77	0,27	0,50	0,48	0,14	0,51
SENTSCORE	0,44	x	0,09	0,03	0,03	0,05	0,07	0,02	0,02	0,05	0,09	0,01	0,02	0,03	0,00
ALTRANK	0,07	0,09	x	0,10	0,08	0,04	0,14	0,17	0,05	0,04	0,09	0,13	0,08	0,15	0,11
GALSCORE	0,05	0,03	0,10	x	0,06	0,09	0,03	0,09	0,03	0,12	0,03	0,17	0,10	0,28	0,06
ENGAGE	0,48	0,03	0,08	0,06	x	0,21	0,05	0,05	0,43	0,20	0,46	0,08	0,01	0,31	0,14
MENTIONS	0,46	0,05	0,04	0,09	0,21	x	0,14	0,13	0,51	0,57	0,04	0,55	0,39	0,34	0,50
SENTIMENT	0,02	0,07	0,14	0,03	0,05	0,14	x	0,03	0,05	0,23	0,00	0,17	0,17	0,10	0,18
SOCDOM	0,10	0,02	0,17	0,09	0,05	0,13	0,03	x	0,08	0,05	0,01	0,02	0,19	0,03	0,07
MARKETCAP	0,99	0,02	0,05	0,03	0,43	0,51	0,05	0,08	x	0,82	0,22	0,60	0,55	0,22	0,60
MARKDOM	0,77	0,05	0,04	0,12	0,20	0,57	0,23	0,05	0,82	x	0,09	0,69	0,61	0,46	0,71
TRADEVOL	0,27	0,09	0,09	0,03	0,46	0,04	0,00	0,01	0,22	0,09	x	0,20	0,17	0,17	0,14
SP500	0,50	0,01	0,13	0,17	0,08	0,55	0,17	0,02	0,60	0,69	0,20	x	0,63	0,72	0,90
INTRADE	0,48	0,02	0,08	0,10	0,01	0,39	0,17	0,19	0,55	0,61	0,17	0,63	x	0,14	0,64
TBILL	0,14	0,03	0,15	0,28	0,31	0,34	0,10	0,03	0,22	0,46	0,17	0,72	0,14	x	0,77
GOLD	0,51	0,00	0,11	0,06	0,14	0,50	0,18	0,07	0,60	0,71	0,14	0,90	0,64	0,77	x

Šaltinis: sudaryta autoriaus.

Iš 10 lentelės galima matyti, kad SOL kaina turi stiprią arba vidutinę teigiamą koreliaciją su paieškų skaičiumi internete, paminėjimų skaičiumi, rinkos dominavimo procentu, S&P500 indekso kaina, JAV federalinio banko palūkanų norma ir aukso kaina. Tarp faktorių aukštesnė koreliacija buvo tarp paieškų skaičiaus ir prekybos apimtys, paminėjimų socialinėje erdvėje ir S&P500 indekso kainos, JAV federalinio banko palūkanų normos ir aukso kainos. Taip pat tarp rinkos dominavimo ir ir S&P500 indekso kainos, JAV federalinio banko palūkanų normos ir aukso kainos.

Apskaičiavus koreliaciją tarp veiksnių, kitas žingsnis yra patikrinti duomenų stacionarumą. Duomenų stacionarumas yra tikrinimas naudojant ADF testą. Jei testo p-vertės yra daugiau nei 0,05,

reiškia duomenys yra nestacionarūs ir nėra tinkami tolimesniems skaičiavimams. ADF testo p-vertės yra pavaizduotos lentelėje žemiau.

11 lentelė

Duomenų stacionarumo tikrinimas naudojant ADF testą

	PRICE	SENTSCORE	ALTRANK	GALSCORE	ENGAGE	MENTIONS	SENTIMENT	SOCDOM	MARKDOM	TRADEVOL	SP500	INTRADE	TBILL	GOLD
BTC	0,86	0,001	0,001	0,21	0,001	0,99	0,53	0,001	0,001	0,001	0,98	0,84	0,004	0,99
ETH	0,60	0,001	0,001	0,18	0,004	0,83	0,52	0,04	0,41	0,001	0,98	0,84	0,004	0,99
BNB	0,85	0,001	0,001	0,17	0,001	0,99	0,55	0,001	0,64	0,03	0,98	0,84	0,004	0,99
SOL	0,72	0,001	0,001	0,24	0,03	0,49	0,61	0,06	0,58	0,001	0,98	0,84	0,004	0,99

Šaltinis: sudaryta autoriaus.

Iš 11 lentelės galima matyti, kad kriptovaliutų kaina, Galaxy balas, paminėjimų skaičius internete, sentimentų balas, rinkos dominavimas, S&P500 indekso kaina, JAV federalinio banko palūkanų norma ir aukso kaina yra nestacionarūs duomenys. Todėl jų reikšmės buvo diferencijuotos 1 kartą siekiant gauti stacionarius duomenis. Po diferenciacijos ADF testas buvo atliktas dar kartą ir naujos p-reikšmės yra pavaizduotos lentelėje žemiau.

12 lentelė

Duomenų stacionarumo tikrinimas naudojant ADF testą po diferenciacijos

	PRICE	SENTSCORE	ALTRANK	GALSCORE	ENGAGE	MENTIONS	SENTIMENT	SOCDOM	MARKDOM	TRADEVOL	SP500	INTRADE	TBILL	GOLD
BTC	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,004	0,001
ETH	0,001	0,001	0,001	0,001	0,004	0,001	0,001	0,04	0,001	0,001	0,001	0,001	0,004	0,001
BNB	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,03	0,001	0,001	0,006	0,001
SOL	0,001	0,001	0,001	0,001	0,02	0,001	0,001	0,07	0,001	0,03	0,001	0,001	0,006	0,001

Šaltinis: sudaryta autoriaus.

Iš 12 lentelės galima matyti, kad 1 lygmens diferenciacija buvo pakankama, siekiant gauti stacionarius duomenis.

Kai duomenys yra paruošti tolimesniems skaičiavimams, kitas žingsnis yra rasti statistiškai reikšmingus faktorius naudojant tiesinės regresijos modelį. Atlikus atgalinės ir progresyvosios tiesinės regresijos metodus buvo gauti tokie patys rezultatai ir galutiniai modeliai atrodė taip.

BTC regresijos modelis:

$$PRICE = 0.0010 + 1.32 * SP500 + 0.11 * SENTIMENT + e \quad (15)$$

Kai $R^2=0.117$ ir koreguotas $R^2 = 0.111$.

Iš regresijos modelio galima matyti, kad BTC kaina turi tendenciją kilti neveikiama kitų faktorių. Iš nepriklausomų kintamųjų tik S&P 500 kainų indeksas ir sentimentų balai buvo reikšmingi faktoriai. Kai S&P 500 kainų indeksas pakyla vienu procentu, BTC kaina pakyla 1,32 procento ir kai sentimentų balas pakyla 1 procentu, tai BTC kaina pakyla 0,11 procento. Apskritai žiūrint į koreguoto R kvadratą, šie kintamieji paaiškina tik 11,1% BTC kainos judėjimo, kas yra labai mažai.

Kitas buvo apskaičiuotas ETH regresijos modelis ir jis atrodė taip:

$$PRICE = -0,0039 + 0,72 * BTC + 0,31 * MARKDOM + 0,39 * SP500 + 0,007 * SENTSCORE + 0,29 * GOLD + 0,0001 * ENGAGE + e \quad (16)$$

Kai $R^2=0.779$ ir koreguotas $R^2 = 0.774$.

Iš modelio galima matyti, kad ETH kaina yra veikiama daugybės kintamųjų, tokių kaip BTC kainos, rinkos dominavimo procento, S&P 500 kainų indekso, socialinių tinklų sentimentų balo, aukso kainos ir paieškų skaičiaus internete. Neįtraukiant jokių nepriklausomų faktorių, ETH kaina turėtų tendenciją mažėti, tačiau visų nepriklausomų kintamųjų ji yra veikiama teigiamai. Labiausiai ETH kaina reaguoja į BTC kainą, nes kai BTC kaina pakyla 1 procentu, ETH kaina pakyla 0,72 procento. Kai rinkos dominavimo procentas pakyla 1 procentu, ETH kaina pakyla 0,31 procento. ETH kaina taip pat stipriau reaguoja į S&P 500 kainų indekso ir aukso kainų svyravimus. Tačiau labai didelis skirtumas nuo BTC atsiranda žiūrint į koreguotą R kvadratą, kuris yra 0,774. Tai rodo, kad šie nepriklausomi kintamieji paaiškina 77,4% ETH kainų judėjimo, kas yra labai daug.

Sekantis buvo apskaičiuotas BNB regresijos modelis, kuris atrodė taip:

$$PRICE = -0,0054 + 0,64 * BTC + 0,23 * MARKDOM + 0,004 * TRADEVOL - 0,001 * ALTRANK + e \quad (17)$$

Kai $R^2=0.543$ ir koreguotas $R^2 = 0.537$.

Iš regresijos modelio galima matyti, kad BNB kaina yra veikiama BTC kainos, rinkos dominavimo procento, prekybos apimties ir Alt reitingo verčių. Neįtraukiant jokių nepriklausomų

faktorių, BNB kaina turėtų tendenciją mažėti, tačiau dauguma nepriklausomų kintamųjų ją veikia teigiamai. Kai BTC kaina pakyla 1 procentu, BNB kaina pakyla 0,64 procento. Kai rinkos dominavimo procentas pakyla 1 procentu, BNB kaina pakyla 0,23 procento. Koreguotas R kvadratas yra 0,537, ir tai rodo, kad šie nepriklausomi kintamieji paaiškina 53,7% BNB kainos judėjimo, kas yra nemažai.

Galiausiai buvo apskaičiuotas SOL regresijos modelis ir jis atrodė taip:

$$PRICE = 0,0048 + 0,73 * BTC + 0,45 * MARKDOM - 0,002 * ALTRANK + e \quad (18)$$

Kai $R^2=0.768$ ir koreguotas $R^2 = 0.766$.

Iš regresijos modelio galima matyti, kad SOL kaina yra veikiamą BTC kainos, rinkos dominavimo procento ir Alt reitingo verčių. Neįtraukiant jokių nepriklausomų faktorių, SOL kaina turėtų tendenciją didėti ir dauguma nepriklausomų kintamųjų ją veikia teigiamai. Kai BTC kaina pakyla 1 procentu, SOL kaina pakyla 0,73 procento. Kai rinkos dominavimo procentas pakyla 1 procentu, SOL kaina pakyla 0,45 procento. Koreguotas R kvadratas yra 0,766, ir tai rodo, kad šie nepriklausomi kintamieji paaiškina 76,6% SOL kainos judėjimo, kas yra didelis procentas.

3.2. Portfelio rizikos vertinimas taikant Monte Karlo simuliaciją

Pirmas žingsnis prieš atliekant kriptovaliutų portfelio rizikos vertinimą, yra portfelio sudarymas. Kaip minėta 3 skyriaus pradžioje, portfelis bus sudarytas iš 2 žetonų ir 2 monetų turinčių didžiausią kapitalizaciją. Jos visos sudarys vienodą dalį investiciniame portfelyje, tai yra po 25%. Piniginiu atžvilgiu portfelis bus 1 000 000 USD, taigi kiekvienos kriptovaliutos bus perkama už 250 000 USD.

Kriptovaliutų kainos bus prognozuojamos nuo 2024-10-21 iki 2024-11-05 ir jų kainų prognozė bus lyginama su tikrąja verte. Pirmi prognozavimai buvo atlikti prognozuojant BTC kainą dienai į priekį su 1000 Monte Karlo simuliacijų (13 lentelė).

13 lentelė

BTC kainos prognozavimas naudojant Monte Karlo simuliaciją

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28
Prog. kaina		69215	67551	67439	66789	68325	66698	67272	68141

Veiksmas	Pirk.	-	-	-	-	-	-	-	-
Reali kaina	69031	67371	67427	66664	68192	66697	67087	68005	69954
Prog. kryptis		↑	↑	↑	↑	↑	↑	↑	↑
Reali kryptis		↓	↑	↓	↑	↓	↑	↑	↑
Data	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05	
Prog. kaina	70035	72858	72340	70549	69702	69400	69088	67930	
Veiksmas	-	Pard.	Pirk.	-	-	-	-		
Reali kaina	72730	72348	70405	69545	69259	68910	67826	69433	
Prog. kryptis	↑	↑	↓	↑	↑	↑	↑		
Reali kryptis	↑	↓	↓	↓	↓	↓	↓		

Šaltinis: sudaryta autoriaus.

Prognozės buvo atliekamos kiekvienai dienai atskirai ir pagal kiekvieną prognozę buvo priimami investiciniai sprendimai. Jei kitai dienai buvo prognozuojama, kad kaina kils, tai buvo perkami BTC ir jeigu prognozuojama kaina buvo mažesnė nei esamos dienos, tada BTC buvo parduodami.

Vadovaujantis Monte Karlo simuliacijos prognozuojamomis kainomis, rezultatai gavosi tokie:

14 lentelė

BTC pirkimai ir pardavimai vadovaujantis Monte Karlo simuliacija

Data	Balansas	Kiekis	BTC kaina, USD
2024-10-20	250000	3,621588	69030,5
2024-10-21	243991,1	3,621588	67371,3
2024-10-22	244193,9	3,621588	67427,3
2024-10-23	241428,5	3,621588	66663,7
...			
2024-11-03	256450,2	3,721509584	68910,26
2024-11-04	252415,6	3,721509584	67826,14
2024-11-05	258395,6	3,721509584	69433
Skirtumas	8395,575		
Pokytis %	3,36%		

Šaltinis: sudaryta autoriaus.

Iš lentelės galima matyti, kad su Monte Karlo simuliacija, 16 dienų laikotarpyje BTC buvo 3,36% pelningas. Bendra Monte Karlo simuliacijos rezultatų lentelė pateikta žemiau.

15 lentelė

BTC pelningumas ir rizika

Kriptovaliuta	BTC
Pelningumas	3,36%
Krypties tikslumas	46.66%
Normalizuotas MSE	0,0496
Normalizuotas MAE	0,1911

Šaltinis: sudaryta autoriaus.

Iš lenetlės galima matyti, kad BTC kainos prognozavimas su Monte Karlo simuliacija buvo 46,66% tikslingas, nes modelis teisingai prognozavo kainos judėjimo kryptį 46,66% kartų.

Tada buvo prognozuojama ETH su 1000 simuliacijų ir rezultatai buvo tokie.

16 lentelė

ETH kainos prognozavimas naudojant Monte Karlo simuliaciją

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		2747	2664	2627	2529	2541	2443	2485	2513	2566	2641	2663	2517	2525	2488	2453	2404
Veiksmas	-	-	Pirk.	-	-	-	-	-	Pard	Pirk.	-	Pard	Pirk.	-	Pard	Pirk.	
Reali kaina	2747	2667	2622	2526	2536	2441	2483	2507	2567	2639	2659	2518	2515	2487	2455	2399	2430
Prog. kryptis			↓	↑	↑	↑	↑	↑	↑	↓	↑	↑	↓	↑	↑	↓	↑
Reali kryptis		↓	↓	↓	↑	↓	↑	↑	↑	↑	↑	↓	↓	↓	↓	↓	↑

Šaltinis: sudaryta autoriaus

Iš 16 lentelės galima matyti, kad ETH kriptovaliutos pelningumas vadovaujantis Monte Karlo simuliacija buvo -7,6%.

Tada buvo prognozuojama BNB su 1000 simuliacijų ir rezultatai buvo tokie.

BNB kainos prognozavimas naudojant Monte Karlo simuliaciją

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		608	601	591	583	591	576	584	589	603	607	597	577	573	567	557	553
Veiksmai	Pirk	-	Pard.	Pirk.	Pard.	Pirk.	-	-	-	-	-	-	-	Pard.	-	Pirk.	
Realioji kaina	606	599	593	582	594	574	583	589	601	606	596	576	572	568	558	552	564
Prog. kryptis		↑	↑	↓	↑	↓	↑	↑	↓	↑	↑	↑	↑	↑	↓	↓	↑
Realioji kryptis		↓	↓	↓	↑	↓	↑	↑	↑	↑	↓	↓	↓	↓	↓	↓	↑

Šaltinis: sudaryta autoriaus

BNB kriptovaliutos pelningumas vadovaujantis Monte Karlo simuliacija buvo 1,02%.

Tada buvo prognozuojama SOL su 1000 simuliacijų ir rezultatai buvo tokie.

SOL kainos prognozavimas naudojant Monte Karlo simuliaciją

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		167	167	168	172	177	166	171	177	179	179	175	168	166	165	163	159
Veiksmai	-	Pirk.	-	-	-	-	-	Pard.	Pirk.	-	-	Pard.	-	-	-	Pirk.	
Realioji kaina	167	166	167	171	177	165	171	177	178	179	175	169	166	165	163	158	167
Prog. kryptis		↑	↑	↑	↑	↓	↑	↑	↓	↑	↑	↓	↑	↑	↓	↑	↑
Realioji kryptis		↓	↑	↑	↑	↓	↑	↑	↑	↑	↓	↓	↓	↓	↓	↓	↑

Šaltinis: sudaryta autoriaus

SOL kriptovaliutos pelningumas vadovaujantis Monte Karlo simuliacija buvo 6,58%.

Bendrai žiūrint į viso portfelio pelningumą, jis buvo teigiamas.

19 lentelė

Portfelio pelningumas naudojant Monte Karlo simuliaciją

	BTC	ETH	BNB	SOL	Portfelis	Pokytis %
2024-10-20	250000	250000	250000	250000	1000000	
2024-10-21	243991,1	250000	247233,66	250000	991224,8	-0,88%
2024-10-22	244193,9	250000	244980,66	251569,2	990743,7	-0,93%
2024-10-23	241428,5	240875,5	244980,66	257092,6	984377,2	-1,56%
2024-10-24	246961,5	241807,1	249893,68	266454,5	1005117	0,51%
2024-10-25	241548,3	232778	249893,68	247804,1	972024,1	-2,80%
2024-10-26	242960,7	236720	253615,41	256751,9	990048	-1,00%
2024-10-27	246284,6	239091,4	256187,11	265540,4	1007104	0,71%
2024-10-28	253344,9	244814,6	261356,93	265540,4	1025057	2,51%
2024-10-29	263399,5	244814,6	263564,17	267412,8	1039191	3,92%
2024-10-30	262013,9	246668,4	259238,46	260799,4	1028720	2,87%
2024-10-31	262013,9	233665,2	250662,35	252129,7	998471,2	-0,15%
2024-11-01	258810,9	233665,2	248760,69	252129,7	993366,5	-0,66%
2024-11-02	257747,1	231109,9	247241,97	252129,7	988228,7	-1,18%
2024-11-03	256450,2	228102,2	247241,97	252129,7	983924,1	-1,61%
2024-11-04	252415,6	228102,2	247241,97	252129,7	979889,5	-2,01%
2024-11-05	258395,6	231007,7	252551,44	266448,6	1008403	0,84%

Šaltinis: sudaryta autoriaus.

Visų likusių kriptovaliutų ir bendro portfelio rezultatų lentelė naudojant Monte Karlo simuliaciją pateikta žemiau.

20 lentelė

Portfelio pelningumas ir rizikos analizė naudojant Monte Karlo simuliaciją

Kriptovaliuta	ETH	BNB	SOL	Portfelis
Pelningumas	-7,6%	1,02%	6,58%	0,84%
Krypties tikslumas	56,25%	56,25%	62,5%	55,425%
Normalizuotas MSE	0,0576	0,0365	0,0554	0,0498
Normalizuotas MAE	0,1947	0,1713	0,1815	0,1847

Šaltinis: sudaryta autoriaus.

Apibendrinant, per laikotarpį nuo 2024.10.21 iki 2024.11.05 su Monte Karlo simuliacijos metodu portfelis buvo pelningas 0,84 procento. Modeliui atspėti kriptovaliutos kryptį pavyko 55,425% tikslumu.

3.3. Portfelio rizikos vertinimas taikant mašininio mokymosi metodą

Tada tam pačiam 1 000 000 USD portfeliui buvo atliekamas prognozavimas nuo 2024.10.21 iki 2024.11.05 naudojant DMLP mašininio mokymosi metodą.

Pirma buvo prognozuota BTC kriptovaliuta naudojant DMLP modelį ir rezultatai buvo tokie:

21 lentelė

BTC kainos prognozavimas naudojant DMLP metodą

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		66825	66602	65153	64749	65357	61709	63128	65662	65953	68094	62690	66010	63427	65898	64377	66311
Veiksmas	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Real. kaina	69031	67371	67427	66664	68192	66697	67087	68005	69954	72730	72348	70405	69545	69259	68910	67826	69433
Prog. kryptis		.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
Real. kryptis		.	+	.	+	.	+	+	+	+	.	.	.	.	.	.	+

Šaltinis: sudaryta autoriaus

Pagal DMLP prognozes BTC net nebuvo nupirktas, nes visos prognozės būdavo mažesnės, jei reali kaina skaičiuojamą dieną, todėl BTC pelningumas buvo 0%. Tada buvo prognozuota ETH kaina naudojant DMLP metodą.

22 lentelė

ETH kainos prognozavimas naudojant DMLP metodą

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		2662	2613	2554	2581	2569	2520	2777	2707	2663	2590	2638	2510	2496	2505	2483	2445
Veiksmai		-	-	Pirk.	-	-	-	-	-	Pard.	-	-	-	Pirk.	-	-	-
Real. kaina	2747	2667	2622	2526	2536	2441	2483	2507	2567	2639	2659	2518	2515	2487	2455	2399	2430

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kryptis		-	-	-	+	+	+	+	+	+	-	-	-	-	+	+	+
Realioji kryptis		-	-	-	+	-	+	+	+	+	+	-	-	-	-	-	+

Šaltinis: sudaryta autoriaus.

ETH pelningumas per laikotarpį nuo 2024.10.21 iki 2024.11.05 buvo 2,04%. Tada buvo prognozuota BNB kaina naudojant DMLP metodą.

23 lentelė

BNB kainos prognozavimas naudojant DMLP metodą

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		592	588	584	599	583	593	596	613	617	598	597	580	565	572	553	582
Veiksmas	-	-	-	Pirk	Par	Pirk	-	-	-	Par	Pirk	-	Par	Pirk	Par	Pirk	
Realioji kaina	606	599	593	582	594	574	583	589	601	606	596	576	572	568	558	552	564
Prog. kryptis		-	-	-	+	-	+	+	+	+	-	-	-	-	-	-	+
Realioji kryptis		-	-	-	+	-	+	+	+	+	-	-	-	-	-	-	+

Šaltinis: sudaryta autoriaus.

BNB pelningumas per laikotarpį nuo 2024.10.21 iki 2024.11.05 buvo 3,49%. Galiausiai buvo prognozuota SOL kaina naudojant DMLP metodą.

SOL kainos prognozavimas naudojant DMLP metodą

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. Kaina		175	179	178	190	170	177	188	194	199	186	171	170	186	177	165	189
Veiksmas	Pirk.	-	-	-	Pard.	Pirk.	-	-	-	-	Pard.	Pirk.	-	-	-	-	
Reali kaina	167	166	167	171	177	165	171	177	178	179	175	169	166	165	163	158	167
Prog. Kryptis		+	+	+	+	-	+	+	+	+	+	-	+	+	+	+	+
Reali kryptis		-	+	+	+	-	+	+	+	+	-	-	-	-	-	-	+

Šaltinis: sudaryta autoriaus

SOL pelningumas per laikotarpį nuo 2024.10.21 iki 2024.11.05 buvo 11,08%. Bendras portfelio pelningumas buvo žymiai didesnis nei su Monte Karlo simuliacija. Portfelio pelningumas atrodė taip:

Portfelio pelningumas naudojant DMLP metodą

	BTC	ETH	BNB	SOL	Portfelis	Pokytis %
2024-10-20	250000	250000	250000	250000	1000000	
2024-10-21	250000	250000	250000	248917,3	998917,3	-0,11%
2024-10-22	250000	250000	250000	250479,7	1000480	0,05%
2024-10-23	250000	250000	250000	255979,2	1005979	0,60%
2024-10-24	250000	250966,9	255013,69	265300,6	1021281	2,13%
2024-10-25	250000	241595,7	255013,69	265300,6	1011910	1,19%
2024-10-26	250000	245687	258811,66	274880,1	1029379	2,94%
2024-10-27	250000	248148,3	261436,05	284289,2	1043874	4,39%
2024-10-28	250000	254088,3	266711,8	286794,3	1057594	5,76%
2024-10-29	250000	261137,7	268964,26	288816,5	1068919	6,89%
2024-10-30	250000	261137,7	268964,26	281673,8	1061776	6,18%
2024-10-31	250000	261137,7	260066,4	281673,8	1052878	5,29%
2024-11-01	250000	261137,7	258093,4	276410,4	1045642	4,56%
2024-11-02	250000	261137,7	258093,4	275577,6	1044809	4,48%
2024-11-03	250000	257739,2	253296,4	270764	1031800	3,18%
2024-11-04	250000	251886	253296,4	262785,6	1017968	1,80%
2024-11-05	250000	255094,5	258735,88	277709,6	1041540	4,15%
	0,00%	2,04%	3,49%	11,08%		

Šaltinis: sudaryta autoriaus.

Tada bendri portfelio rezultatai su pelningumu, tikslumu ir klaidomis buvo paskaičiuoti ir jie pavaizduoti lentelėje žemiau.

26 lentelė

Portfelio pelningumas ir rizikos analizė naudojant DMLP metodą

Kriptovaliuta	BTC	ETH	BNB	SOL	Portfelis
Pelningumas	0%	2,04%	3,49%	11,08%	4,15%
Krypties tikslumas	56,25%	75%	100%	62,5%	73,44%
Normalizuotas MSE	0,4906	0,1243	0,0351	0,3673	0,2543
Normalizuotas MAE	0,6173	0,2421	0,1563	0,5357	0,3879

Šaltinis: sudaryta autoriaus.

Bendras portfelio pelningumas naudojant DMLP metodą buvo 4,15% su 73,44% tikslumu prognozuojant sekančios dienos kriptovaliutos kainą.

Tada buvo prognozuoti portfelio kriptovaliutų kainų svyravimai naudojant DMLP su sentimentų analize ir buvo gauti tokie rezultatai:

Iš pradžių paskaičiuoti BTC kainos svyravimai nuo 2024.10.21 iki 2024.11.05.

27 lentelė

BTC kainos prognozavimas naudojant DMLP metodą su sentimentų analize

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		65348	66402	65893	68165	70560	67702	65899	71937	68521	68584	63155	73010	70440	69753	70510	68688
Veiksmas		-	-	Pirk	-	-	Pard.	Pirk.	Pard.	-	-	Pirk.	-	-	-	-	-
Reali kaina	69031	67371	67427	66664	68192	66697	67087	68005	69954	72730	72348	70405	69545	69259	68910	67826	69433
Prog. kryptis		.	.	+	+	+	+	.	+	.	.	.	+	+	+	+	+
Reali kryptis		.	+	.	+	.	+	+	+	+	.	.	.	.	.	.	+

Šaltinis: sudaryta autoriaus.

BTC pelningumas per laikotarpį nuo 2024.10.21 iki 2024.11.05 buvo 2,09%. Tada buvo prognozuota ETH kaina naudojant DMLP metodą.

ETH kainos prognozavimas naudojant DMLP metodą su sentimentų analize

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		2662	2613	2554	2581	2569	2520	2777	2707	2663	2590	2638	2510	2496	2505	2483	2445
Veiksmas		-	-	Pirk.	-	-	-	-	-	Pard.	-	-	-	Pirk.	-	-	-
Reali kaina	2747	2667	2622	2526	2536	2441	2483	2507	2567	2639	2659	2518	2515	2487	2455	2399	2430
Prog. kryptis		-	-	-	+	+	+	+	+	+	-	-	-	-	+	+	+
Reali kryptis		-	-	-	+	-	+	+	+	+	+	-	-	-	-	-	+

Šaltinis: sudaryta autoriaus.

ETH pelningumas per laikotarpį nuo 2024.10.21 iki 2024.11.05 buvo 2,04%. Tada buvo prognozuota BNB kaina naudojant DMLP metodą.

BNB kainos prognozavimas naudojant DMLP metodą su sentimentų analize

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		592	604	600	588	580	584	601	602	613	589	595	583	573	571	560	566
Veiksmas		Pirk.	-	-	Pard	Pirk.	-	-	-	Pard	-	-	-	-	-	-	-
Reali kaina	606	599	593	582	594	574	583	589	601	606	596	576	572	568	558	552	564
Prog. kryptis		-	+	+	+	-	+	+	+	+	-	-	+	+	+	+	+
Reali kryptis		-	-	-	+	-	+	+	+	+	-	-	-	-	-	-	+

Šaltinis: sudaryta autoriaus.

BNB pelningumas per laikotarpį nuo 2024.10.21 iki 2024.11.05 buvo 4,65%. Galiausiai buvo prognozuota SOL kaina naudojant DMLP metodą.

30 lentelė

SOL kainos prognozavimas naudojant DMLP metodą su sentimentų analize

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		161	167	170	180	163	170	192	179	180	175	174	166	164	171	161	173
Veiksmas		Pirk.	-	-	Pard	Pirk.	-	-	-	Pard	-	-	-	Pirk.	Pard	Pirk.	
Reali kaina	167	166	167	171	177	165	171	177	178	179	175	169	166	165	163	158	167
Prog. kryptis		.	+	+	+	.	+	+	+	+	.	.	.	.	+	.	+
Reali kryptis		.	+	+	+	.	+	+	+	+	.	.	.	.	.	.	+

Šaltinis: sudaryta autoriaus.

SOL pelningumas per laikotarpį nuo 2024.10.21 iki 2024.11.05 buvo 20,48%. Bendras portfelio pelningumas buvo žymiai didesnis nei su Monte Karlo simuliacija. Portfelio pelningumas atrodė taip:

31 lentelė

Portfelio pelningumas naudojant DMLP metodą su sentimentų analize

	BTC	ETH	BNB	SOL	Portfelis	Pokytis %
2024-10-20	250000	250000	250000	250000	1000000	
2024-10-21	250000	250000	250000	250000	1000000	0,00%
2024-10-22	250000	250000	247721,79	251569,2	999290,9	-0,07%
2024-10-23	250000	250000	243176,49	257092,6	1000269	0,03%
2024-10-24	255729,5	250966,9	248053,33	266454,5	1021204	2,12%
2024-10-25	250124,1	241595,7	248053,33	266454,5	1006228	0,62%
2024-10-26	251586,7	245687	251747,65	276075,7	1025097	2,51%
2024-10-27	251586,7	248148,3	254300,41	285525,7	1039561	3,96%
2024-10-28	258799	254088,3	259432,16	288041,7	1060361	6,04%
2024-10-29	258799	261137,7	261623,14	290072,7	1071633	7,16%
2024-10-30	258799	261137,7	261623,14	290072,7	1071633	7,16%
2024-10-31	258799	261137,7	261623,14	290072,7	1071633	7,16%
2024-11-01	255635,2	261137,7	261623,14	290072,7	1068469	6,85%
2024-11-02	254584,5	261137,7	261623,14	290072,7	1067418	6,74%
2024-11-03	253303,5	257739,2	261623,14	285005,9	1057672	5,77%
2024-11-04	249318,5	251886	261623,14	285005,9	1047834	4,78%
2024-11-05	255225	255094,5	261623,14	301191,8	1073134	7,31%
	2,09%	2,04%	4,65%	20,48%		

Šaltinis: sudaryta autoriaus.

Tada bendri portfelio rezultatai su pelningumu, tikslumu ir klaidomis buvo paskaičiuoti ir jie pavaizduoti lentelėje žemiau.

32 lentelė

Portfelio pelningumas ir rizikos analizė naudojant DMLP metodą su sentimentų analize

Kriptovaliuta	BTC	ETH	BNB	SOL	Portfelis
Pelningumas	2,09%	2,04%	4,65%	20,48%	7,31%
Krypties tikslumas	43,75%	75%	62,5%	93,75%	68,75%
Normalizuotas MSE	0,2305	0,1243	0,0333	0,057	0,1113
Normalizuotas MAE	0,3766	0,2421	0,1551	0,1548	0,2321

Šaltinis: sudaryta autoriaus.

Bendras portfelio pelningumas naudojant DMLP metodą kartu su socialinių tinklų sentimentų analize buvo 7,31% su 68,75% tikslumu prognozuojant sekančios dienos kriptovaliutos kainą.

Galiausiai buvo atlikti skaičiavimai su SVR mašininio mokymosi metodu prognozuojant kainas kasdienai nuo 2024.10.21 iki 2024.11.05.

Pirma buvo prognozuota BTC kriptovaliuta naudojant SVR modelį ir rezultatai buvo tokie:

33 lentelė

BTC kainos prognozavimas naudojant SVR metodą

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		67468	66979	64214	64389	65290	62404	63465	65079	67251	67490	63465	64648	63647	64485	63602	65449
Veiksmas	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
Reali kaina	69031	67371	67427	66664	68192	66697	67087	68005	69954	72730	72348	70405	69545	69259	68910	67826	69433
Prog. kryptis		.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
Reali kryptis		.	+	.	+	.	+	+	+	+	.	.	.	.	.	.	+

Šaltinis: sudaryta autoriaus.

Tada buvo prognozuota ETH kriptovaliuta naudojant SVR modelį ir rezultatai buvo tokie:

ETH kainos prognozavimas naudojant SVR metodą

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		2773	2680	2787	2672	2669	2635	2573	2853	2856	2718	2790	2554	2523	2523	2553	2555
Veiksmas	Pirk.	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Reali kaina	2747	2667	2622	2526	2536	2441	2483	2507	2567	2639	2659	2518	2515	2487	2455	2399	2430
Prog. kryptis		+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
Reali kryptis		-	-	-	+	-	+	+	+	+	+	-	-	-	-	-	+

Šaltinis: sudaryta autoriaus.

Tada buvo prognozuota BNB kriptovaliuta naudojant SVR modelį ir rezultatai buvo tokie:

BNB kainos prognozavimas naudojant SVR metodą

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		592	596	597	594	588	588	591	603	566	581	560	540	559	567	564	573
Veiksmas	-	-	Pirk.	-	Pard	Pirk.	-	-	Pard	-	-	-	-	-	Pirk	-	
Reali kaina	606	599	593	582	594	574	583	589	601	606	596	576	572	568	558	552	564
Prog. kryptis		-	-	+	+	-	+	+	+	-	-	-	-	-	-	+	+
Reali kryptis		-	-	-	+	-	+	+	+	+	-	-	-	-	-	-	+

Šaltinis: sudaryta autoriaus.

Galiausiai buvo prognozuota SOL kriptovaliuta naudojant SVR modelį ir rezultatai buvo tokie:

SOL kainos prognozavimas naudojant SVR metodą

Data	2024-10-20	2024-10-21	2024-10-22	2024-10-23	2024-10-24	2024-10-25	2024-10-26	2024-10-27	2024-10-28	2024-10-29	2024-10-30	2024-10-31	2024-11-01	2024-11-02	2024-11-03	2024-11-04	2024-11-05
Prog. kaina		178	184	179	176	168	176	174	166	162	172	173	168	188	177	168	185
Veiksmas	Pirk	-	-	-	Pard	Pirk.	-	Pard	-	-	-	-	Pirk.	-	-	-	
Real. kaina	167	166	167	171	177	165	171	177	178	179	175	169	166	165	163	158	167
Prog. kryptis		+	+	+	+	-	+	+	-	-	-	-	-	+	+	+	+
Real. kryptis		,	+	+	+	,	+	+	+	+	,	,	,	,	,	,	+

Šaltinis: sudaryta autoriaus.

Galiausiai buvo prognozuota SOL kriptovaliuta naudojant SRV modelį ir rezultatai buvo tokie:

Portfelio pelningumas atrodė taip:

Portfelio pelningumas naudojant SVR metodą

	BTC	ETH	BNB	SOL	Portfelis	Pokytis %
2024-10-20	250000	250000	250000	250000	1000000	
2024-10-21	250000	242663,7	250000	248917,3	991581	-0,84%
2024-10-22	250000	238580,5	250000	250479,7	989060,2	-1,09%
2024-10-23	250000	229872,8	245412,9	255979,2	981264,9	-1,87%
2024-10-24	250000	230761,9	250334,59	265300,6	996397,1	-0,36%
2024-10-25	250000	222145,2	250334,59	265300,6	987780,4	-1,22%
2024-10-26	250000	225907,1	254062,88	274880,1	1004850	0,49%
2024-10-27	250000	228170,2	256639,12	284289,2	1019099	1,91%
2024-10-28	250000	233632	261818,06	284289,2	1029739	2,97%
2024-10-29	250000	240113,9	261818,06	284289,2	1036221	3,62%
2024-10-30	250000	241932	261818,06	284289,2	1038039	3,80%
2024-10-31	250000	229178,5	261818,06	284289,2	1025286	2,53%
2024-11-01	250000	228841,8	261818,06	284289,2	1024949	2,49%
2024-11-02	250000	226339,3	261818,06	283432,7	1021590	2,16%
2024-11-03	250000	223393,7	261818,06	278481,8	1013694	1,37%
2024-11-04	250000	218320,5	259099,4	270276	997695,9	-0,23%
2024-11-05	250000	221101,4	264663,5	285625,4	1021390	2,14%
	0,00%	-11,56%	5,87%	14,25%		

Šaltinis: sudaryta autoriaus.

Tada bendri portfelio rezultatai su pelningumu, tikslumu ir klaidomis buvo paskaičiuoti ir jie pavaizduoti lentelėje žemiau.

Portfelio pelningumas ir rizikos analizė naudojant SVR metodą

Kriptovaliuta	BTC	ETH	BNB	SOL	Portfelis
Pelningumas	0%	-11,56%	5,87%	14,25%	2,14%
Krypties tikslumas	56,25%	43,75%	81,25%	56,25%	59,375%
Normalizuotas MSE	0,5087	0,3775	0,0858	0,3050	0,3193
Normalizuotas MAE	0,6462	0,5278	0,2199	0,4524	0,4616

Šaltinis: sudaryta autoriaus.

Bendras portfelio pelningumas naudojant SVR metodą buvo 2,14% su 59,375% tikslumu prognozuojant sekančios dienos kriptovaliutos kainą.

Visų portfelių pelningumas atrodė taip:

Portfelių pelningumo ir rizikos palyginimas naudojant visus rizikos vertinimo metodus

Kriptovaliuta	Monte Karlo	DMLP	DMLP su sentimentais	SVR
Pelningumas	0,84%	4,15%	7,31%	2,14%
Krypties tikslumas	55,425%	73,44%	68,75%	59,375%
Normalizuotas MSE	0,0498	0,2543	0,1113	0,3193
Normalizuotas MAE	0,1847	0,3879	0,2321	0,4616

Šaltinis: sudaryta autoriaus.

Vertinant visus metodus šalia, geriausi rezultatai yra gauti iš DMLP metodo naudojamo kartu su socialinių tinklų sentimentų analize, antroje vietoje būtų paprastas DMLP metodas, trečioje vietoje Monte Karlo simuliacijos metodas ir paskutinis SVR metodas. Lyginant pelningumo atžvilgiu DMLP su ir be sentimentų analizės parodė geriausius rezultatus. DMLP su sentimentų analize nors ir buvo mažiau tikslesnis krypties prognozavimo atžvilgiu, socialinių sentimentų balai padėdavo nustatyti, kada keisis kryptis ir tai leido šiam modeliui būti pelningiausiam. Monte Karlo simuliacijos rezultatai pelningumo ir krypties prognozavimo atžvilgiu buvo ganėtinai prasti, tačiau šis modelis turėjo mažiausias normalizuotas MSE ir MAE reikšmes, kad reiškia, kad jo prognozuojamos vertės buvo arčiausiai tikrųjų verčių. SVR metodo rezultatai buvo ganėtinai prasti, nors ir lenkė Monte Karlo simuliaciją pelningumu ir krypties prognozavimo atžvilgiu, tačiau rizikos atžvilgiu šis modelis buvo pats rizikingiausias, nes MAE ir MSE buvo didžiausi.

Atlikus skaičiavimus buvo nuspręsta patikrinti ar tokie patys rezultatai būtų gauti ir kai rinka yra kylanti ar krintanti, taigi visi skaičiavimai buvo pakartoti dar 3 kartus kai rinka kilo, kilo ir krito ir kai tik krito. Periodai, kuriems buvo atlikti skaičiavimai pavaizduoti **11** pav.



Šaltinis: sudaryta autoriaus

11 pav. Prognozuoti kainų laikotarpiai

Iš paveikslėlio galima matyti, kad prognozuoti laikotarpiai buvo nuo 2024-08-13 iki 2024-08-26, nuo 2024-08-31 iki 2024-09-13 ir nuo 2024-09-30 iki 2024-10-12.

Pirma buvo prognozuotas laikotarpis nuo 2024-08-13 iki 2024-08-26. Portfelijų rezultatai naudojant Monte Karlo simuliaciją, DMLP metodą, DMLP metodą su sentimentų analize ir SVR metodą buvo tokie.

40 lentelė

Portfelijų pelningumo ir rizikos palyginimas naudojant visus rizikos vertinimo metodus kilimo laikotarpyje

	Monte Karlo	DMLP	DMLP su sentimentais	SVR
Pelningumas	0,19%	6,63%	3,44%	5,33%
Krypties tiksumas	46,43	62,5	50,00	51,79
Normalizuotas MSE	1,1669	0,1984	0,4982	1,5998
Normalizuotas MAE	0,9706	0,3355	0,5258	0,7191

Šaltinis: sudaryta autoriaus

Iš lentelės galima matyti, kad DMLP modelis turėjo geriausius rezultatus, nes jis buvo pelningiausias, turėjo geriausią krypties tikslumą ir mažiausias normalizuotas MSE ir MAE. Galima

daryti išvadą, sentimentų analizė DMLP modeliui neturėjo teigiamos įtakos, nes kilimo laikotarpiu apie 42,31% sentimentų buvo neigiami.

Tada buvo prognozuotas laikotarpis nuo 2024-08-31 iki 2024-09-13. Portfelio rezultatai naudojant Monte Karlo simuliaciją, DMLP metodą, DMLP metodą su sentimentų analize ir SVR metodą buvo tokie.

41 lentelė

**Portfelio pelningumo ir rizikos palyginimas naudojant visus rizikos vertinimo metodus
kritimo ir kilimo laikotarpyje**

	Monte Karlo	DMLP	DMLP su sentimentais	SVR
Pelningumas	2,12%	2,80%	3,11%	2,11%
Krypties tiksumas	57,1425	58,9275	55,36	57,14
Normalizuotas MSE	0,9646	0,3213	0,2557	0,5676
Normalizuotas MAE	0,7160	0,4148	0,3953	0,6158

Šaltinis: sudaryta autoriaus

Iš lentelės galima matyti, kad DMLP modelis kartu su sentimentų analize turėjo geriausius rezultatus, nes jis buvo pelningiausias ir turėjo mažiausias normalizuotas MSE ir MAE. DMLP metodas be sentimentų analizės buvo 3,57% tikslesnis prognozuojant kainų kryptį.

Galiausiai buvo prognozuotas laikotarpis nuo 2024-09-30 iki 2024-10-12. Portfelio rezultatai naudojant Monte Karlo simuliaciją, DMLP metodą, DMLP metodą su sentimentų analize ir SVR metodą buvo tokie.

42 lentelė

**Portfelio pelningumo ir rizikos palyginimas naudojant visus rizikos vertinimo metodus
kritimo laikotarpyje**

	Monte Karlo	DMLP	DMLP su sentimentais	SVR
Pelningumas	-1,70%	1,91%	-0,20%	-0,83%
Krypties tiksumas	57,69	62,09	55,77	55,77
Normalizuotas MSE	2,2537	0,1096	0,3709	0,3285
Normalizuotas MAE	1,2849	0,2650	0,4693	0,4455

Šaltinis: sudaryta autoriaus

Iš lentelės galima matyti, kad geriausius rezultatus parodė DMLP modelis be sentimentų analizės, nes jis vienintelis buvo pelningas kritimo laikotarpiu, turėjo geriausią kainos krypties prognozavimą ir mažiausias normalizuotas klaidas. Antroje vietoje buvo DMLP metodas su sentimentų

analize visuose vertinimo kriterijuose. DMLP metodas su sentimentų analize galėjo turėti prastesnius rezultatus, nes kol rinka krito, vidutiniškai 6 iš 13 dienos sentimentų balai buvo teigiami, kas galėjo sumažinti DMLP metodo su sentimentų analize įtaką.

Palyginus rezultatus po visų keturių prognozavimo periodų, DMLP metodas kartu su sentimentų analize parodė geriausius rezultatus tada, kai rinka buvo konsoliduota. Tačiau perioduose, kai kaina kilo ar krito, DMLP metodas be sentimentų analizės turėjo geriausius rezultatus. Šiuo atveju galima interpretuoti, kad sentimentų analizė, kai rinka kildavo ar krisdavo būdavo daugiau kaip triukšmas ir DMLP metodas be sentimentų analizės turėjo geresnius rezultatus.

IŠVADOS IR PASIŪLYMAI

1. Atlikus literatūros analizę, buvo nustatyta, kad įtakos kriptovaliutų kainų svyravimams turi ne tik žinučių skaičius „Twitter“ ar kituose socialiniuose tinkluose, tačiau ir žinomų žmonių, „Youtube“ kanalų ar blokų grandinės programuotojų elgesys. Nors socialinių tinklų įtaka yra pastebima visoms kriptovaliutoms, tačiau poveikis yra žymiai didesnis mažos kapitalizacijos kriptovaliutoms. Taip pat buvo nustatyta, kad kriptovaliutų kainų prognozavimui naudojami įvairūs mašininio mokymosi (ML) ir gilaus mokymosi (DL) algoritmai, kurie skiriasi savo veikimo principais ir efektyvumu. GBT algoritmas yra naudingas dėl savo duomenų normalizavimo nereikalavimo ir taisyklių pagrindu veikiančio mokymosi, tačiau gali persimokyti triukšmingose rinkose. RF algoritmas sumažina persimokymo riziką ir reikalauja mažiau parametrų optimizavimo, tačiau gali būti netinkamas laiko eilučių prognozavimui. SVM algoritmas yra tikslus mažiems duomenų rinkiniams, tačiau gali būti mažiau efektyvus dideliems duomenims. ANN ir ypač LSTM tinklai geba rasti netiesinius ryšius duomenyse ir mokytis iš istorinių duomenų, bet reikalauja didelių skaičiavimo išteklių ir turi daug hiperparametrų. DMLP algoritmas yra pritaikytas dinamiškiems duomenims ir gali apdoroti įvairius duomenų tipus, tačiau gali būti sudėtingas ir jautrus duomenų kokybei. Tinkamo algoritmo pasirinkimas gali žymiai padidinti prognozių tikslumą ir sumažinti riziką kriptovaliutų rinkose. Atlikus literatūros analizę, pastebėta, kad DMLP algoritmas kartu su sentimentų analize naudotas akcijų kainų prognozavimui ir rizikos vertinimui, tačiau kriptovaliutoms buvo taikytas tik DMLP metodas be sentimentų analizės. Kadangi socialinių tinklų sentimentai, anot literatūros analizės, yra reikšmingas faktorius kriptovaliutų kainų svyravimams, pasirinkta kriptovaliutų rizikos vertinimui naudoti DMLP metodą kartu su sentimentų analize.
2. Siekiant patikrinti socialinių tinklų nuotaikų įtaką kriptovaliutų kainų svyravimams, buvo naudota sentimentų analizė, kai twitter žinutės buvo filtruotos pagal raktažodžius. Atlikus analizę nustatyta, kad kriptovaliutų kainų judėjimo kryptis sutapo su socialinių tinklų sentimentų balu 47,54% kartų. Nepriklausomų veiksnių įtakai matuoti kriptovaliutų kainų svyravimams buvo pasirinkta koreliacijos koeficientas ir regresinė analizė. Šie metodai buvo pasirinkti, nes tai yra vieni dažniausiai naudojamų metodų. Kriptovaliutų kainų prognozavimui ir rizikos vertinimui buvo naudoti Monte Karlo simuliacija, DMLP metodas su statistiškai reikšmingais kintamaisiais, DMLP metodas kartu su sentimentų analize ir SVR metodas. Monte Karlo simuliacija buvo pasirinkta kaip vienas iš dažniausiai naudojamų ne mašininio mokymosi

metodų, kuris sugeba modeliuoti sudėtingus ir netiesinius ryšius. DMLP metodas su sentimentų analize buvo pasirinktas kaip naujumas kriptovaliutų kainų prognozavime ir rizikos vertinime. DMLP metodas be sentimentų analizės buvo pasirinktas tam, kad būtų galima patikrinti ar sentimentų analizė tikrai padeda gauti geresnius rezultatus. SVR metodas buvo pasirinktas, nes jis geba modeliuoti sudėtingus ryšius ir yra tikslus prognozuojant nedidelius duomenų rinkinius.

3. Kriptovaliutų portfeliui buvo pasirinktos kriptovaliutos su didžiausia rinkos kapitalizacija ir tai buvo BTC, ETH, BNB ir SOL kriptovaliutos. Atlikus regresinę analizę buvo nustatyta, kad kiekviena kriptovaliuta yra veikiamą skirtingų faktorių. BTC kaina buvo veikiamą tik S&P 500 kainų indekso ir sentimentų balo, tačiau šiek faktoriai paaiškino tik 11,1% BTC kainų judėjimo. ETH kainai statistiškai reikšmingi kintamieji buvo BTC kaina, rinkos dominavimo procentas, S&P 500 kainų indeksas, socialinių tinklų sentimentų balas, aukso kaina ir paieškų skaičius internete. BNB kainai įtaką darė BTC kaina, rinkos dominavimo procentas, prekybos apimtis ir Alt reitingo vertės ir SOL buvo veikiamą BTC kainos, rinkos dominavimo procento ir Alt reitingo vertės.
4. Radus statistiškai reikšmingus kintamuosius, buvo prognozuotos kainos naudojant skirtingus metodus nuo 2024-10-21 iki 2024-11-05. Naudojant Monte Karlo simuliaciją, kriptovaliutų portfelis buvo pelningas tik 0,84% su 55.425% krypties tikslumu. Atliktos prognozės su DMLP modeliu, rezultatai buvo geresni nei su Monte Karlo simuliacija, nes portfelio pelningumas buvo 4,15% ir kainų prognozės krypties tikslumas buvo 73,44%. Atlikus kainų prognozę su DMLP modeliu, kai buvo įtraukti ir socialinių tinklų sentimentų balai, modelis parodė geriausius rezultatus, nes portfelio pelningumas buvo 7,31% ir krypties tikslumas 68.75%. Galiausiai buvo atlikta prognozė su SVR metodu ir portfelio pelningumas buvo 2,14%, o krypties tikslumas 59.375%. Atlikus analizę su visais metodais, galima teigti, kad DMLP metodas kartu su sentimentų analize turėjo geriausius rezultatus, nes portfelis buvo pelningiausias ir nors krypties tikslumas buvo 4,69% mažesnis nei su paprastu DMLP metodu, tačiau pelningumas buvo 3,16% didesnis ir normalizuotos MSE ir MAE buvo mažesnės. Palyginus rezultatus po visų keturių prognozavimo periodų, DMLP metodas kartu su sentimentų analize parodė geriausius rezultatus tada, kai rinka buvo konsoliduota, tačiau perioduose, kai kaina kilo ar krito, DMLP metodas be sentimentų analizės turėjo geriausius rezultatus.

5. Ateityje tyrimas šia tema galėtų būti praplėstas nagrinėjant ne dieninius, o valandinius arba minutinius duomenis, kadangi nemažai literatūros teigė, kad didžiausia socialinių tinklų sentimentų įtaka gali būti nuo 1 iki 3 valandų po paskelbimo socialiniuose tinkluose.

LITERATŪRA

1. Abraham, J., Higdon, D., & Nelson, J. (2018). Cryptocurrency price prediction using tweet volumes and sentiment analysis. *SMU Data Science Review*, 1(3).
2. Agnew, J. R., & Szykman, L. R. (2005). Asset Allocation and Information Overload: The Influence of Information Display, Asset Choice, and Investor Experience. *Journal of Behavioral Finance*, 6(2). https://doi.org/10.1207/s15427579jpfm0602_2
3. Ahmadi-Javid, A. (2023). Correction to: f-Betas and portfolio optimization with f-divergence induced risk measures (Quantitative Finance, (2023), 23, 10, (1483-1496), 10.1080/14697688.2023.2230629). In *Quantitative Finance* (Vol. 23, Issue 11). <https://doi.org/10.1080/14697688.2023.2239659>
4. Ahmed, J., & Ahmed, M. (2021). Online News Classification Using Machine Learning Techniques. *IIUM Engineering Journal*, 22(2). <https://doi.org/10.31436/iiumej.v22i2.1662>
5. Akyildirim, E., Goncu, A., & Sensoy, A. (2021). Prediction of cryptocurrency returns using machine learning. *Annals of Operations Research*, 297(1–2). <https://doi.org/10.1007/s10479-020-03575-y>
6. Almeida, D., Dionísio, A., Vieira, I., & Ferreira, P. (2022). Uncertainty and Risk in the Cryptocurrency Market. *Journal of Risk and Financial Management*, 15(11). <https://doi.org/10.3390/jrfm15110532>
7. Almeida, J., & Gonçalves, T. C. (2022). A Systematic Literature Review of Volatility and Risk Management on Cryptocurrency Investment: A Methodological Point of View. In *Risks* (Vol. 10, Issue 5). <https://doi.org/10.3390/risks10050107>
8. Almeida, J., & Gonçalves, T. C. (2023). Portfolio Diversification, Hedge and Safe-Haven Properties in Cryptocurrency Investments and Financial Economics: A Systematic Literature Review. In *Journal of Risk and Financial Management* (Vol. 16, Issue 1). <https://doi.org/10.3390/jrfm16010003>
9. Aloui, D., Zouaoui, R., Rachdi, H., Guesmi, K., & Yarovaya, L. (2024). The impact of ECB's Quantitative Easing on cryptocurrency markets during times of crisis. *Research in International Business and Finance*, 69. <https://doi.org/10.1016/j.ribaf.2023.102203>
10. Ante, L. (2023). How Elon Musk's Twitter activity moves cryptocurrency markets. *Technological Forecasting and Social Change*, 186. <https://doi.org/10.1016/j.techfore.2022.122112>
11. Awan, S. E., Bennamoun, M., Sohel, F., Sanfilippo, F. M., Chow, B. J., & Dwivedi, G. (2018). Feature selection and transformation by machine learning reduce variable numbers and improve prediction for heart failure readmission or death. *PLoS ONE*, 14(6).

<https://doi.org/10.1371/journal.pone.0218760>

12. Bahrami, M., Shabani, A., Mahmoudi, M. R., & Didari, S. (2020). Determination of effective weather parameters on rainfed wheat yield using backward multiple linear regressions based on relative importance metrics. In *Complexity* (Vol. 2020). <https://doi.org/10.1155/2020/6168252>
13. Bányai, A., Tatay, T., Thalmeiner, G., & Pataki, L. (2024). Optimising Portfolio Risk by Involving Crypto Assets in a Volatile Macroeconomic Environment. *Risks*, 12(4), pp. 68-98.
[doi:10.3390/risks12040068](https://doi.org/10.3390/risks12040068)
14. Barauskaitė, K., & Constantinescu, M. (2016). Impact of Time-Varying Distributional Parameters on Portfolio Performance. *Applied Economics: Systematic Research*, 10(1).
<https://doi.org/10.7220/aesr.2335.8742.2016.10.1.2>
15. Bartolucci, S., Destefanis, G., Ortu, M., Uras, N., Marchesi, M., & Tonelli, R. (2020). The Butterfly “Affect”: impact of development practices on cryptocurrency prices. *EPJ Data Science*, 9(1).
<https://doi.org/10.1140/epjds/s13688-020-00239-6>
16. Behera, J., Pasayat, A. K., Behera, H., & Kumar, P. (2023). Prediction based mean-value-at-risk portfolio optimization using machine learning regression algorithms for multi-national stock markets. *Engineering Applications of Artificial Intelligence*, 120.
<https://doi.org/10.1016/j.engappai.2023.105843>
17. Best, R. d. (2024). Number of identity-verified cryptoasset users from 2016 to November 2023. Retrieved from Statista.com: <https://www.statista.com/statistics/1202503/global-cryptocurrency-user-base/>
18. Bhalla, D. (2014). Difference between adjusted R-squared and R-squared. Retrieved from Listendata.com: <https://www.listendata.com/2014/08/adjusted-r-squared.html>
19. Bowala, S., & Singh, J. (2022). Optimizing Portfolio Risk of Cryptocurrencies Using Data-Driven Risk Measures. *Journal of Risk and Financial Management*, 15(10).
<https://doi.org/10.3390/jrfm15100427>
20. Brownlee, J. (2021). An Introduction to Feature Selection. Retrieved from Machine Learning Mastery: <https://machinelearningmastery.com/an-introduction-to-feature-selection/>
21. Chen, C. Y. H., & Hafner, C. M. (2019). Sentiment-Induced Bubbles in the Cryptocurrency Market. *Journal of Risk and Financial Management*, 12(2). <https://doi.org/10.3390/jrfm12020053>
22. Chen, J. (2023). Analysis of Bitcoin Price Prediction Using Machine Learning. *Journal of Risk and Financial Management*, 16(1). <https://doi.org/10.3390/jrfm16010051>
23. Chohan, A. (2016). Analysing survey comments using sentiment scores. Retrieved from GOV.UK:

- <https://dataingovernment.blog.gov.uk/2016/02/18/analysing-survey-comments-using-sentiment-scores>
24. Chowdhury, R., Rahman, M. A., Rahman, M. S., & Mahdy, M. R. C. (2020). An approach to predict and forecast the price of constituents and index of cryptocurrency using machine learning. *Physica A: Statistical Mechanics and Its Applications*, 551. <https://doi.org/10.1016/j.physa.2020.124569>
 25. Cibulskienė, D., & Brazauskas, M. (2016). A theoretical approach to quantitative downside risk measurement methods. *Central and Eastern European Journal of Management and Economics (CEEJME)*, 2.
 26. CoinMarketCap.com. (2024). Today's Cryptocurrency Prices by Market Cap. Retrieved from CoinMarketCap.com: <https://coinmarketcap.com/>
 27. Critien, J. V., Gatt, A., & Ellul, J. (2022). Bitcoin price change and trend prediction through twitter sentiment and data volume. *Financial Innovation*, 8(1). <https://doi.org/10.1186/s40854-022-00352-7>
 28. De Souza, K. G., Barboza, F., & Garruti, D. V. T. (2023). A Discourse Analysis of Tweets and Its Implications for Cryptocurrency Prices and Trade Volumes. *Computational Economics*. <https://doi.org/10.1007/s10614-023-10504-1>
 29. Dubey, P. (2022). Short-run and long-run determinants of bitcoin returns: transnational evidence. *Review of Behavioral Finance*, 14(4). <https://doi.org/10.1108/RBF-02-2022-0040>
 30. Dutta, A., Kumar, S., & Basu, M. (2020). A Gated Recurrent Unit Approach to Bitcoin Price Prediction. *Journal of Risk and Financial Management*, 13(2). <https://doi.org/10.3390/jrfm13020023>
 31. Eck, D. J. (2018). Bootstrapping for multivariate linear regression models. *Statistics and Probability Letters*, 134. <https://doi.org/10.1016/j.spl.2017.11.001>
 32. Fan, B., Liu, S., Pei, G., Wu, Y., & Zhu, L. (2021). Why Do You Trust News? The Event-Related Potential Evidence of Media Channel and News Type. *Frontiers in Psychology*, 12. <https://doi.org/10.3389/fpsyg.2021.663485>
 33. Fred.com. (2024). 3-Month Treasury Bill Secondary Market Rate, Discount Basis. Retrieved from Fred.com: <https://fred.stlouisfed.org/series/DTB3>
 34. Ghasemi, F., Sari, M. H. M., Yousefi, V., Falsafi, R., & Tamošaitienė, J. (2018). Project portfolio risk identification and analysis, considering project risk interactions and using Bayesian Networks. *Sustainability (Switzerland)*, 10(5). <https://doi.org/10.3390/su10051609>

35. Glasserman, P. (2004). Monte Carlo method in financial engineering. In *Quantitative Finance* (Vol. 4, Issue 4). <https://doi.org/10.1080/14697680400008601>
36. Gold.org. (2024). Gold spot prices. Retrieved from Gold.org:
<https://www.gold.org/goldhub/data/gold-prices#registration-type=facebook&just-verified=1>
37. Goodday, N. L., & Ledisi, K. G. (2020). Enhancing Stock Price Prediction Using Support Vector Machine Approach. *The International Journal of Science & Technoledge*, 8(1).
<https://doi.org/10.24940/theijst/2020/v8/i1/st2001-006>
38. GrandViewResearch. (2022). Cryptocurrency Exchange Platform Market Size, Share & Trends Analysis Report By End-use, By Cryptocurrency Type, By Region, And Segment Forecast, 2022-2030. Retrieved from GrandViewResearch.com: <https://www.grandviewresearch.com/industry-analysis/cryptocurrency-exchange-platform-market-report>
39. Gunay, S. (2019). Impact of Public Information Arrivals on Cryptocurrency Market: A Case of Twitter Posts on Ripple. *East Asian Economic Review*, 23(2).
<https://doi.org/10.11644/kiep.eaer.2019.23.2.359>
40. Guo, H., Zhang, D., Liu, S., Wang, L., & Ding, Y. (2021). Bitcoin price forecasting: A perspective of underlying blockchain transactions. *Decision Support Systems*, 151.
<https://doi.org/10.1016/j.dss.2021.113650>
41. Hanif, W., Ko, H. U., Pham, L., & Kang, S. H. (2023). Dynamic connectedness and network in the high moments of cryptocurrency, stock, and commodity markets. *Financial Innovation*, 9(1).
<https://doi.org/10.1186/s40854-023-00474-6>
42. Heaton, J. (2018). Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning. *Genetic Programming and Evolvable Machines*, 19(1–2). <https://doi.org/10.1007/s10710-017-9314-z>
43. Huang, L. (2024). The relationship between cryptocurrencies and convention financial market: Dynamic causality test and time-varying influence. *International Review of Economics and Finance*, 91. <https://doi.org/10.1016/j.iref.2024.01.032>
44. Hubens, W. H. G., Kievit, M. T., Berendschot, T. T. J. M., de Coo, I. F. M., Smeets, H. J. M., Webers, C. A. B., & Gorgels, T. G. M. F. (2021). Plasma GDF-15 concentration is not elevated in open-angle glaucoma. *PLoS ONE*, 16(5 May). <https://doi.org/10.1371/journal.pone.0252630>
45. Huras, N. (2023). AI-Powered Portfolio Optimization: the future of Asset Management? Retrieved from Swiss Finance Technology Association: <https://swissfinte.ch/ai-powered-portfolio-optimization-future-of-asset-management/>
46. Investing.com. (2024). S&P 500 (SPX) Live. Retrieved from Investing.com:

https://uk.investing.com/indices/us-spx-500-historical-data?utm_source=google&utm_medium=cpc&utm_campaign=18502377045&utm_content=676327823039&utm_term=dsa-1518303930164_&GL_Ad_ID=676327823039&GL_Campaign_ID=18502377045&ISP=1&gad_source=1&gclid=Cj0KCQiA_q

47. Jaadi, Z. (2019). Everything you need to know about interpreting correlations. Retrieved from Towardsdatascience.com: <https://towardsdatascience.com/everything-you-need-to-know-about-interpreting-correlations-2c485841c0b8>
48. Jang, B., Kim, I., & Kim, J. W. (2019). Word2vec convolutional neural networks for classification of news articles and tweets. *PLoS ONE*, 14(8). <https://doi.org/10.1371/journal.pone.0220976>
49. Ječmínek, J., Kukalová, G., & Moravec, L. (2020). Volatility modelling and VAR: The case of Bitcoin, ether and ripple. *Danube*, 11(3). <https://doi.org/10.2478/danb-2020-0015>
50. Jin, D., & Yu, J. (2023). Predicting cryptocurrency market volatility: Novel evidence from climate policy uncertainty. *Finance Research Letters*, 58. <https://doi.org/10.1016/j.frl.2023.104520>
51. Khan, R., & Hakami, T. A. (2022). Cryptocurrency: usability perspective versus volatility threat. *Journal of Money and Business*, 2(1). <https://doi.org/10.1108/jmb-11-2021-0051>
52. Khedr, A. M., Arif, I., Pravija Raj, P. V., El-Bannany, M., Alhashmi, S. M., & Sreedharan, M. (2021). Cryptocurrency price prediction using traditional statistical and machine-learning techniques: A survey. In *Intelligent Systems in Accounting, Finance and Management* (Vol. 28, Issue 1). <https://doi.org/10.1002/isaf.1488>
53. Kozlovskiy, S., Petrunenko, I., Mazur, H., Butenko, V., & Ivanyuta, N. (2022). Assessing the probability of bankruptcy when investing in cryptocurrency. *Investment Management and Financial Innovations*, 19(3). [https://doi.org/10.21511/imfi.19\(3\).2022.26](https://doi.org/10.21511/imfi.19(3).2022.26)
54. Li, Y., Zhang, W., Urquhart, A., & Wang, P. (2022). The role of media coverage in the bubble formation: Evidence from the Bitcoin market. *Journal of International Financial Markets, Institutions and Money*, 80. <https://doi.org/10.1016/j.intfin.2022.101629>
55. Liapis, C. M., Karanikola, A., & Kotsiantis, S. (2023). Investigating Deep Stock Market Forecasting with Sentiment Analysis. *Entropy*, 25(2). <https://doi.org/10.3390/e25020219>
56. Likitratcharoen, D., Kronprasert, N., Wiwattanalamporn, K., & Pinmanee, C. (2021). The accuracy of risk measurement models on bitcoin market during covid-19 pandemic. *Risks*, 9(12). <https://doi.org/10.3390/risks9120222>
57. Liu, Y., Li, Z., Nekhili, R., & Sultan, J. (2023). Forecasting cryptocurrency returns with machine

- learning. *Research in International Business and Finance*, 64.
<https://doi.org/10.1016/j.ribaf.2023.101905>
58. LunarCrush.com. (2024). Cryptocurrencies. Retrieved from LunarCrush.com:
<https://lunarcrush.com/categories>
59. Lyócsa, Š., Molnár, P., Plíhal, T., & Širaňová, M. (2020). Impact of macroeconomic news, regulation and hacking exchange markets on the volatility of bitcoin. *Journal of Economic Dynamics and Control*, 119. <https://doi.org/10.1016/j.jedc.2020.103980>
60. Ma, Y., Han, R., & Wang, W. (2021). Portfolio optimization with return prediction using deep learning and machine learning. *Expert Systems with Applications*, 165.
<https://doi.org/10.1016/j.eswa.2020.113973>
61. Matic, J. L., Packham, N., & Härdle, W. K. (2023). Hedging cryptocurrency options. *Review of Derivatives Research*, 26(1). <https://doi.org/10.1007/s11147-023-09194-6>
62. Mba, J. C., Mwambi, S. M., & Pindza, E. (2022). A Monte Carlo Approach to Bitcoin Price Prediction with Fractional Ornstein–Uhlenbeck Lévy Process. *Forecasting*, 4(2).
<https://doi.org/10.3390/forecast4020023>
63. Moser, S., & Brauneis, A. (2023). Should you listen to crypto YouTubers? *Finance Research Letters*, 54. <https://doi.org/10.1016/j.frl.2023.103782>
64. Murray, K., Rossi, A., Carraro, D., & Visentin, A. (2023). On Forecasting Cryptocurrency Prices: A Comparison of Machine Learning, Deep Learning, and Ensembles. *Forecasting*, 5(1).
<https://doi.org/10.3390/forecast5010010>
65. Natale, A., Poppensieker, T., & Thun, M. (2022). From risk management to strategic resilience. Retrieved from McKinsey.com: <https://www.mckinsey.com/capabilities/risk-and-resilience/our-insights/from-risk-management-to-strategic-resilience>
66. Nilsson, B., Poppensieker, T., Schneider, S., & Thun, M. (2022). Financial institutions and nonfinancial risk: How corporates build resilience. Retrieved from McKinsley&Company: <https://www.mckinsey.com/capabilities/risk-and-resilience/our-insights/financial-institutions-and-nonfinancial-risk-how-corporates-build-resilience>
67. Nitithumbundit, T., & Chan, J. S. K. (2022). Covid-19 impact on Cryptocurrencies market using Multivariate Time Series Models. *Quarterly Review of Economics and Finance*, 86.
<https://doi.org/10.1016/j.qref.2022.08.006>
68. Ontotext. (2007). From Text to. Retrieved from Ontotext.fbk.eu: <https://ontotext.fbk.eu/>
69. Özyeşil, M. (2019). The Relationship Between the Popularity of Cryptocurrencies and their Prices,

- Returns and Trading Volumes: A Structural Break and Comparative Analysis. *Istanbul Journal of Economics / İstanbul İktisat Dergisi*. <https://doi.org/10.26650/istjecon2019-0017>
70. Pagnottoni, P. (2019). Neural Network Models for Bitcoin Option Pricing. *Frontiers in Artificial Intelligence*, 2. <https://doi.org/10.3389/frai.2019.00005>
 71. Paiva, F. D., Cardoso, R. T. N., Hanaoka, G. P., & Duarte, W. M. (2019). Decision-making for financial trading: A fusion approach of machine learning and portfolio selection. *Expert Systems with Applications*, 115. <https://doi.org/10.1016/j.eswa.2018.08.003>
 72. Panagiotidis, P. (2018). TECHNOLOGIES AND LANGUAGE LEARNING: TOWARDS NEXT GENERATION DIGITAL LEARNING ENVIRONMENTS. *ICERI2018 Proceedings*, 1. <https://doi.org/10.21125/iceri.2018.1364>
 73. Pinelis, M., & Ruppert, D. (2022). Machine learning portfolio allocation. *Journal of Finance and Data Science*, 8. <https://doi.org/10.1016/j.jfds.2021.12.001>
 74. Pirgaip, B., Dinçergök, B., & Haşlak, Ş. (2019). Bitcoin Market Price Analysis and an Empirical Comparison with Main Currencies, Commodities, Securities and Altcoins. In *Contributions to Economics*. https://doi.org/10.1007/978-3-030-25275-5_8
 75. Prabhakaran, S. (2019). Augmented Dickey Fuller Test (ADF Test) . Retrieved from Macjinelearningplus.com: https://www.machinelearningplus.com/time-series/augmented-dickey-fuller-test/#google_vignette
 76. Prabhakaran, S. (2020). ARIMA Model - complete guide to time series forecasting in python. Retrieved from <https://www.machinelearningplus.com/>: <https://www.machinelearningplus.com/time-series/arima-model-time-series-forecasting-python/>
 77. Pulido, C. M., Ruiz-Eugenio, L., Redondo-Sama, G., & Villarejo-Carballido, B. (2020). A new application of social impact in social media for overcoming fake news in health. *International Journal of Environmental Research and Public Health*, 17(7). <https://doi.org/10.3390/ijerph17072430>
 78. Ruby, D. (2023, January 4). Social Media Users - How many people Use Social Media in 2023. Retrieved from Demand Sage: <https://www.demandsage.com/social-media-users/>
 79. Scheer, L. K., & Stern, L. W. (1992). The Effect of Influence Type and Performance Outcomes on Attitude toward the Influencer. *Journal of Marketing Research*, 29(1). <https://doi.org/10.1177/002224379202900111>
 80. Sebastião, H., & Godinho, P. (2021). Forecasting and trading cryptocurrencies with machine learning under changing market conditions. *Financial Innovation*, 7(1).

<https://doi.org/10.1186/s40854-020-00217-x>

81. Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. In *Statistics and Computing* (Vol. 14, Issue 3). <https://doi.org/10.1023/B:STCO.0000035301.49549.88>
82. Su, J. Bin, & Hung, J. C. (2018). The value-at-risk estimate of stock and currency-stock portfolios' returns. *Risks*, 6(4). <https://doi.org/10.3390/risks6040133>
83. Sutiene, K., Schwendner, P., Sipos, C., Lorenzo, L., Mirchev, M., Lameski, P., . . . Cernevičienė, J. (2024, April 08). Enhancing portfolio management using artificial intelligence: literature review. *Artificial Intelligence in Finance*, 7, 1-30.
84. Tharun, S. V., Saranya, G., Tamilvizhi, T., & Surendran, R. (2023). Cryptocurrency Price Prediction Using Deep Learning. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 13924 LNAI. https://doi.org/10.1007/978-3-031-44084-7_27
85. TradingEconomics.com. (2024). United States Fed Funds Interest Rate. Retrieved from TradingEconomics.com: <https://tradingeconomics.com/united-states/interest-rate>
86. Vidal-Tomás, D., & Ibañez, A. (2018). Semi-strong efficiency of Bitcoin. *Finance Research Letters*, 27. <https://doi.org/10.1016/j.frl.2018.03.013>
87. Wolff, D., & Echterling, F. (2024). Stock picking with machine learning. *Journal of Forecasting*, 43(1). <https://doi.org/10.1002/for.3021>
88. Xiang, J. N. P., Velu, S. R., & Zygiaris, S. (2021). Monte Carlo Simulation Prediction of Stock Prices. *Proceedings - International Conference on Developments in ESystems Engineering, DeSE, 2021-December*. <https://doi.org/10.1109/DESE54285.2021.9719349>
89. Zhang, M. (2021). Applications of Deep Learning in News Text Classification. *Scientific Programming*, 2021. <https://doi.org/10.1155/2021/6095354>
90. Zhang, S. (2021). Sentiment Classification of News Text Data Using Intelligent Model. *Frontiers in Psychology*, 12. <https://doi.org/10.3389/fpsyg.2021.758967>
91. Zheng, Z., Lu, Y., & Zhang, J. (2022). Multiscale complexity fluctuation behaviours of stochastic interacting cryptocurrency price model. *Physica A: Statistical Mechanics and Its Applications*, 593. <https://doi.org/10.1016/j.physa.2022.126939>
92. Zhu, P., Zhang, X., Wu, Y., Zheng, H., & Zhang, Y. (2021). Investor attention and cryptocurrency: Evidence from the Bitcoin market. *PLoS ONE*, 16(2 February). <https://doi.org/10.1371/journal.pone.0246331>
93. Zuniga, E. W. V., Ranieri, C. M., Zhao, L., Ueyama, J., Zhu, Y. T., & Ji, D. (2023). Maximizing

portfolio profitability during a cryptocurrency downtrend: A Bitcoin Blockchain transaction-based approach. *Procedia Computer Science*, 222. <https://doi.org/10.1016/j.procs.2023.08.192>

Priedas 1. Socialinių tinklų sentimentų skaičiavimo MATLAB kodas

```
filename = "DataBTC1248.xlsx";
tbl = readtable(filename,'TextType','string');
head(tbl)
str = tbl.Text;
documents = tokenizedDocument(str);
documents(1:5)
compoundScores = vaderSentimentScores(documents);
compoundScores(1:5)
M = mean(compoundScores)
disp(M)
idx = compoundScores > 0.1;
% disp(idx)
Idx1 = compoundScores < -0.1;
% disp(Idx1)
strPositive = str(idx);
strNegative = str(Idx1);
figure
subplot(1,2,1)
wordcloud(strPositive);
title("Positive Sentiment")
subplot(1,2,2)
wordcloud(strNegative);
title("Negative Sentiment")
C1 = wordCloudCounts(strPositive)
C2 = wordCloudCounts(strNegative)
```

Priedas 2. Duomenų stacionarumo tikrinimo MATLAB kodas

Load data from Excel file

```
filename = 'Data magistras.xlsx';
```

```
sheet = 'SOL';
```

```
data = readtable(filename, 'Sheet', sheet, 'Range', 'B:P');
```

```
numCols = size(data, 2);
```

```
adfResults = cell(numCols, 2);
```

```
for i = 1:numCols
```

```
    columnData = data{:, i};
```

```
    [~, pValue, ~, ~] = adfTest(columnData);
```

```
    adfResults{i, 1} = data.Properties.VariableNames{i};
```

```
    adfResults{i, 2} = pValue;
```

```
end
```

```
disp('ADF Test Results for Stationarity:');
```

```
disp(array2table(adfResults, 'VariableNames', {'Column', 'pValue'}));
```

Priedas 3. Tiesinīs regresijos MATLAB kods

```
filename = 'Data magistras.xlsx';
sheet = 'SOL';
data = readtable(filename, 'Sheet', sheet);
date = datetime(data{:, 1}, 'InputFormat', 'yyyy-MM-dd');
y = data{:, 2};
X = data{:, 3:end};
varNames = data.Properties.VariableNames(3:end);
selectedVars = [];
remainingVars = 1:size(X, 2);
bestModel = [];
disp('Forward Selection Process:');
while ~isempty(remainingVars)
    bestPValue = Inf;
    bestVar = [];
    for i = remainingVars
        currentVars = [selectedVars, i];
        XCurrent = X(:, currentVars);
        mdl = fitlm(XCurrent, y);
        pValues = mdl.Coefficients.pValue;
        if length(pValues) > length(selectedVars)
            currentPValue = pValues(end);
            if currentPValue < bestPValue
                bestPValue = currentPValue;
                bestVar = i;
            end
        end
    end
    end
    if ~isempty(bestVar) && bestPValue < 0.05
```

```

selectedVars = [selectedVars, bestVar];
remainingVars(remainingVars == bestVar) = [];
bestModel = fitlm(X(:, selectedVars), y);
disp(['Selected Variable: ', varNames{bestVar}, ', p-value: ', num2str(bestPValue)]);
else
    break;
end
end
disp('Final Model:');
disp(bestModel);

```

Priedas 4. Monte Karlo simuliacijos MATLAB kodas

```
filename = 'ETHF.xlsx';
data = readtable(filename);
data.DATE = datetime(data.DATE, 'InputFormat', 'yyyy-MM-dd');
filteredData = data(data.DATE >= datetime('2024-01-01') & data.DATE <= datetime('2024-10-29'), :);
y = filteredData.PRICE;
numSimulations = 1000;
numDays = 1;
returns = diff(y) ./ y(1:end-1);
meanReturn = mean(returns);
stdReturn = std(returns);
predictedPrices = zeros(numSimulations, 1);
lastPrice = y(end);
for i = 1:numSimulations
    randomReturn = meanReturn + stdReturn * randn(numDays, 1);
    simulatedPrice = lastPrice * (1 + randomReturn);
    predictedPrices(i) = simulatedPrice;
end
predictedPrice = mean(predictedPrices);
predictionStdDev = std(predictedPrices);
disp(['Predicted price for 2024-10-30: ', num2str(predictedPrice)]);
disp(['Prediction standard deviation: ', num2str(predictionStdDev)]);
```

Priedas 5. DMLP metodo MATLAB kodus

```
filename = 'BTCF.xlsx';
data = readtable(filename);
data.DATE = datetime(data.DATE, 'InputFormat', 'yyyy-MM-dd');
filteredData = data(data.DATE >= datetime('2024-01-01') & data.DATE <= datetime('2024-10-29'), :);
y = filteredData.PRICE;
X = filteredData{:, 3:end};
y_mean = mean(y);
y_std = std(y);
y_normalized = (y - y_mean) / y_std;
[X, X_mean, X_std] = normalize(X);
inputSize = size(X, 2);
layers = [
    featureInputLayer(inputSize)
    fullyConnectedLayer(50)
    reluLayer
    fullyConnectedLayer(25)
    reluLayer
    fullyConnectedLayer(1)
    regressionLayer
];
options = trainingOptions('adam', ...
    'MaxEpochs', 400, ...
    'MiniBatchSize', 16, ...
    'InitialLearnRate', 0.001, ...
    'Plots', 'training-progress', ...
    'Verbose', false);
net = trainNetwork(X, y_normalized, layers, options);
nextDayData = data(data.DATE == datetime('2024-10-30'), 3:end);
```

```
nextDayData = (nextDayData - X_mean) ./ X_std;  
predictedPrice_normalized = predict(net, nextDayData);  
predictedPrice = predictedPrice_normalized * y_std + y_mean;  
disp(['Predicted (denormalized) price for 2024-10-30: ', num2str(predictedPrice)]);
```

Priedas 6. SVR metodo MATLAB kodos

```
filename = 'BTCFF.xlsx';
data = readtable(filename);
data.DATE = datetime(data.DATE, 'InputFormat', 'yyyy-MM-dd');
filteredData = data(data.DATE >= datetime('2024-01-01') & data.DATE <= datetime('2024-11-04'), :);
y = filteredData.PRICE;
X = filteredData{:, 3:end};
y_mean = mean(y);
y_std = std(y);
y_normalized = (y - y_mean) / y_std;
[X, X_mean, X_std] = normalize(X);
cv = cvpartition(size(X,1), 'HoldOut', 0.3);
XTrain = X(training(cv), :);
yTrain = y_normalized(training(cv));
XTest = X(test(cv), :);
yTest = y_normalized(test(cv));
svmModel = fitrsvm(XTrain, yTrain, 'KernelFunction', 'rbf', 'Standardize', true);
yPredictedTest = predict(svmModel, XTest);
mseTest = mean((yTest - yPredictedTest).^2);
maeTest = mean(abs(yTest - yPredictedTest));
rmseTest = sqrt(mseTest);
disp(['Test MSE: ', num2str(mseTest)]);
disp(['Test MAE: ', num2str(maeTest)]);
nextDayRow = data(data.DATE == datetime('2024-11-05'), :);
if isempty(nextDayRow)
    error('Data for 2024-10-21 is not available.');
```

```
end
nextDayData = nextDayRow{:, 3:end};
nextDayData = (nextDayData - X_mean) ./ X_std;
```

```
predictedPrice_normalized = predict(svmModel, nextDayData);  
predictedPrice = predictedPrice_normalized * y_std + y_mean;  
disp(['Predicted (denormalized) price for 2024-11-05: ', num2str(predictedPrice)]);
```