



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Išorinių veiksnių poveikis bitkoino kainos pokyčiui

Baigiamasis magistro studijų projektas

Ieva Norvilytė

Projekto autorė

doc. dr. Kristina Šutienė

Vadovė

doc. dr. Egidijus Rybakovas

Vadovas

Kaunas, 2023



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Išorinių veiksnių poveikis bitkoino kainos pokyčiui

Baigiamasis magistro studijų projektas

Didžiųjų verslo duomenų analitika (6213AX001)

doc. dr. Egidijus Rybakovas

Vadovas

doc. dr. Viktorija Varaniūtė

Recenzentė

Ieva Norvilytė

Projekto autorė


doc. dr. Kristina Šutienė

Vadovė

prof. dr. Robertas Alzbutas

Recenzentas

Kaunas, 2023



Kauno technologijos universitetas
Matematikos ir gamtos mokslų fakultetas

Ieva Norvilaitė

Išorinių veiksnių poveikis bitkoino kainos pokyčiui

Akademinių sąžiningumo deklaracija

Patvirtinu, kad:

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

Vardas Pavardė: _____

Parašas: _____

Kaunas, 2023

Norvilytė Ieva. Išorinių veiksnių poveikis bitkoino kainos pokyčiui. Magistro studijų baigiamasis projektas / vadovė doc. dr. Kristina Šutienė; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Taikomoji matematika (Matematikos mokslai).

Reikšminiai žodžiai: finansinių produktų rinka, kriptovaliutos, bitkoinas, vartotojų elgsena, laiko eilutės.

Kaunas, 2023. 86 p.

Santrauka

Stebint pastarųjų metų ekonomikos pokyčius pasaulyje ir stebint precedento neturinčius veiksnius, susijusius su pandemija, karu Ukrainoje, investuotojai vis labiau ieško būdų, kaip išvengti infliacijos ir pinigų nuvertėjimo problemos. Akcijų rinkos, žaliavos, vertybiniai popieriai, valiutos ir kiti investiciniai produktai sulaukia stabilaus investuotojų dėmesio, tačiau palyginus neseniai atsiradusi rinka – kriptovaliutos, sparčiai populiarėja, didėja susidomėjimas šia investicija. Šiame tyrime siekiama ištirti išorės veiksnių bei bitkoino kainos pokyčio sąsajas. Šio darbo tikslas – atlikti išorinių veiksnių poveikio tyrimą, bitkoino kainos (investicinės gražos) analizei, kuris padėtų apibendrinti investuotojų elgseną.

Pagal pirmoje darbo dalyje atliktą ekonominę literatūros analizę, kurioje apibendrinami skirtumai tarp finansinių produktų rinkos ir vartotojų prekių rinkos nustatyta, kad po COVID-19 pandemijos, vartotojų elgsena pasikeitė kardinaliai – stebimi nauji vartojimo, taupymo ir investavimo įpročiai. Toliau, tyrimo fokusas yra ištirti kriptovaliutų rinkos pokyčius, stebimus per 2013-2023 metus. Galima daryti išvadą, kad nuo 2013 metų, kriptovaliutų rinka pasikeitė neatpažįstamai, stebima pagrindinių kriptovaliutų kapitalizacijos augimas, taip pat stebima, kad vis dar didžiausią rinkos dalį užima bitkoinas. Bitkoino kainos volatilumas ir staigūs šuoliai ir nukritimai yra sunkiai apskaičiuojami ir prognozuojami į ateitį. Toliau, šis tyrimas apima ir vartotojų spekuliacinės veiklos analizę, kuomet kalbama apie išankstinius susitarimus ir nelegalią veiklą, susijusią su investavimu į kriptovaliutas. Pabrėžtina tai, kad vartotojų spekuliacinis elgesys yra viena iš galimų priežasčių, kodėl bitkoino kaina yra sunkiai prognozuojama. Antroje darbo dalyje pateikiami tyrime taikomų matematinių modelių aprašymai, remiantis matematine literatūra. Galiausiai, trečioje darbo dalyje atliekama bitkoino kainos ir išorės faktorių kainos analizė, skaičiuojamos investicinių produktų gražos, atliekama stilizuotų faktų analizė bitkoino laiko eilutei, atliekamas GARCH modeliavimas, koreliacinė analizė ir sudaromi mašininio mokymosi metodai, regresiniam uždaviniui spręsti. GARCH modeliavimo metu, sudaromas modelis, suskaičiuojamos GARCH liekanos bitkoino kainai. Toliau, atlikta koreliacinė analizė parodo, kad nėra lengvai identifikuojamų tiesinių ryšių tarp GARCH modeliu sumodeliuotų bitkoino gražų ir išorės faktorių logaritminių gražų. Šis ryšys yra silpnas, neegzistuoja arba yra ne tiesinis. Galiausiai, sudaromi matematiniai mašininio mokymosi metodai, naudojant *Random Forest*, *XGBoost* ir *Neural Network* algoritmus. Gauta, kad geriausiai regresinį bitkoino gražos kainos uždavinį prognozuoja *XGBoost* algoritmas, o reikšmingiausi kintamieji yra bitkoino gražų ankstiniai ir Londono Robusta kavos ankstiniai ir *Apple* įmonės akcijos.

Norviljė Ieva. Impact of External Factors on Bitcoin Price Change. Master's Final Degree Project / supervisor doc. dr. Kristina Štutienė; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology.

Study field and area (study field group): Applied Mathematics (Mathematical Sciences).

Keywords: financial product market, cryptocurrency, bitcoin, consumer behaviour, time series.

Kaunas, 2023. 86 pages.

Summary

Observing the economic changes in recent years worldwide and the unprecedented factors related to the pandemic and the war in Ukraine, investors are increasingly seeking ways to avoid the problems of inflation and currency depreciation. While stock markets, commodities, securities, currencies, and other investment products continue to attract stable investor attention, a relatively recent market, cryptocurrencies, is rapidly gaining popularity, generating increased interest as an investment. This study aims to explore the relationships between external factors and changes in the price of Bitcoin. The objective of this work is to conduct a study on the impact of external factors on the analysis of Bitcoin prices (investment returns), which would help summarize investor behavior.

Based on the economic literature analysis conducted in the first part of this work, which summarizes the differences between the financial product market and the consumer goods market, it has been determined that consumer behavior has undergone significant changes following the COVID-19 pandemic, with new habits in consumption, saving, and investing being observed. Furthermore, the focus of the study is to examine the changes in the cryptocurrency market observed from 2013 to 2023. It can be concluded that since 2013, the cryptocurrency market has changed beyond recognition, witnessing the growth of major cryptocurrency capitalizations, with Bitcoin still occupying the largest market share. The volatility of Bitcoin prices and its sudden jumps and drops are difficult to calculate and predict for the future. Additionally, this study includes an analysis of speculative activities by consumers, involving prearranged agreements and illegal activities related to cryptocurrency investments. The second part of the work presents descriptions of mathematical models applied in the study, based on mathematical literature. Finally, in the third part of the work, an analysis of Bitcoin prices and the prices of external factors is performed. Investment product returns are calculated, a stylized fact analysis of the Bitcoin time series is conducted, GARCH modeling is performed, correlation analysis is carried out, and machine learning methods are employed to address the regression problem. During GARCH modeling, a model is created, and GARCH residuals of Bitcoin prices are calculated. Furthermore, the correlation analysis indicates that there are no easily identifiable linear relationships between the modeled Bitcoin returns by GARCH models and the logarithmic returns of external factors. This relationship is weak, nonexistent, or nonlinear. Ultimately, mathematical machine learning methods are employed using *Random Forest*, *XGBoost*, and *Neural Network* algorithms. It is found that the *XGBoost* algorithm performs the best in predicting the regression problem of Bitcoin returns, with the most significant variables being the lagged Bitcoin returns and the lagged London Robusta coffee and Apple company.

Turinys

Lentelių sąrašas	2
Paveikslų sąrašas	3
Įvadas	4
1 Literatūros apžvalga	8
1.1 Sąsajų tarp pasaulinės ekonomikos tendencijų, ekonominių rodiklių, vartojimo prekių rinkos ir finansinių rinkų tyrimų apžvalga	8
1.2 Kriptovaliutų rinkos tendencijų apžvalga 2010–2023 metais	19
1.3 Kriptovaliutų spekuliacijos ir vartotojų elgsena investavimo metu	26
1.4 Matematiniai metodai kriptovaliutų kainos pokyčiui analizuoti	30
1.5 Literatūros apibendrinimas ir atliekamo tyrimo problematikos išgryninimas	33
2 Tyrimo objektas ir metodai	34
2.1 Tyrimo metodologinė schema	34
2.2 Duomenų apžvalga	34
2.3 Bitkoino laiko eilutės analizė: aprašomoji statistika	43
2.4 Bitkoino laiko eilutės analizė: stilizuoti faktai	48
2.5 Matematiniai metodai	52
2.5.1 GARCH modelis	52
2.5.2 Random Forest	53
2.5.3 XGBoost	55
2.5.4 Neural Network	55
3 Tyrimų rezultatai ir jų aptarimas	58
3.1 Tyrimo rezultatai	58
3.1.1 GARCH modelis	58
3.1.2 Bitkoino gražos ir išorinių veiksnių gražų koreliacinė analizė	61
3.1.3 Random Forest	62
3.1.4 XGBoost	65
3.1.5 Neural Network	67
3.2 Matematinų modelių rezultatų palyginimas	68
3.3 Tyrimo trūkumai	72
Išvados	74
Literatūros sąrašas	76

Lentelių sąrašas

1	Vartojimo prekių rinkos ir finansų rinkos palyginimas	18
2	Top 10 kriptovaliutų pagal kapitalizaciją palyginimas. 2023-04-21 duomenys	22
3	Didelį kriptovaliutų kapitalą turinčių piniginių pavyzdžiai. 2023-04-27 duomenys . .	27
4	Matematiniai metodai naudojami finansų rinkos moksliniuose tyrimuose	31
5	Tyrimo kintamieji. Šaltinis <i>Investing.com</i>	35
6	Aprašomoji statistika: bitkoino kaina	45
7	Aprašomoji statistika: bitkoino logaritminės grąžos	46
8	Statistiniai testai	58
9	GARCH modeliai	59
10	Didžiųjų duomenų mokslo modelių regresijos uždaviniui spręsti palyginimas	68

Paveikslų sąrašas

1	E. Ludvik, L. Komarkova, D. Egerova ir M. Mičik vartotojų elgsenos COVID-19 pandemijos metu tyrimo modelis. Šaltinis: <i>Journal of Retailing and Consumer Services</i>	10
2	Accenture įmonės tyrimo „COVID-19 Consumer Research“, atlikto 2020 04 02-06, N = 1118 respondentų, dirbančių namuose apklausos rezultatai. Šaltinis: <i>Accenture</i>	11
3	Accenture įmonės tyrimo „COVID-19 Consumer Research“, atlikto 2022 03 19-25 ir 2020 04 02-06, apklausos apie apsipirkimo įpročius rezultatai. Šaltinis: <i>Accenture</i>	12
4	Pasaulinis infliacijos lygis 2000–2021 metais ir infliacijos lygio prognozė iki 2027 metų. Šaltinis: <i>Statista</i>	13
5	Pasaulinis nedarbo lygis 2002–2021 metais. Šaltinis: <i>Statista</i>	14
6	Pasaulinis bendrasis vidaus produktas 1980–2022 metais ir BVP prognozė iki 2027 metų. Šaltinis: <i>Statista</i>	15
7	JAV mėnesinės palūkanų normos 1982–2022 metais. Šaltinis: <i>Statista</i>	16
8	Pasaulinis vartotojų pasitikėjimo indeksas išsivysčiusiose ir kylančios ekonomikos šalyse 2020-2023 metais. Šaltinis: <i>Statista</i>	17
9	Kripto valiutų aktyvo vertinimo grafikas pagal kapitalizaciją (<i>heatmap</i>), 2023-04-21 duomenys. Šaltinis: <i>Yahoo Finance</i>	21
10	TOP 10 kripto valiutų pagal kapitalizaciją. 2023-04-21 duomenys. Šaltinis: <i>CoinCapMarket</i>	22
11	<i>Bitcoin</i> dominavimo diagrama 2013 05 05 – 2023 04 21. Šaltinis: <i>CoinCapMarket</i>	25
12	<i>Bitcoin</i> žvakių diagrama 2016–2023 metais. Šaltinis: <i>Yahoo Finance</i>	26
13	Kripto valiutų vagysčių vertė visame pasaulyje 2016-2020 metais. Šaltinis: <i>Statista</i>	30
14	Tyrimo metodologinė schema	34
15	Bitkoino kainos laiko eilutė 2010–2023 metais	44
16	Bitkoino kainos laiko eilutė logaritmuota 2010–2023 metais	44
17	Bitkoino kainos laiko eilutės histograma	45
18	Bitkoino logaritminės grąžos 2010–2023 metais	46
19	Bitkoino logaritminių grąžų histograma	47
20	ACF grafikas logaritminėms bitkoino grąžoms	49
21	ACF kvadratinėms ir absoliučioms bitkoino logaritminėms grąžoms	50
22	Bitkoino logaritminių grąžų box plot grafikas	51
23	QQ plot grafikas	51
24	Bitkoino absoliučių grąžų volatilumo grupės	52
25	Koreliacijų matrica	62

Išvadas

Šiuolaikiniame ekonomikos pasaulyje tampa vis sunkiau prognozuoti finansinių produktų ateities dinamiką. Investuotojai, akcininkai, kredito bendrovės bei valstybės stengiasi sukurti ir išstbulinti vis labiau prisitaikančius matematinius metodus, kurie gali padėti priimti ilgalaikius ekonominius sprendimus. Tokie sprendimai – ilgalaikė projekcija, dažnu atveju struktūriniai projektai, savo tikslu, projekto komandos dydžiu bei projekto trukme trunkantys ilgą laiko tarpą. Šiems projektams sukurti bei įgyvendinti, reikalinga turėti ne tik įvairių resursų kaip laikas, personalas, informacija, bet taip pat ne mažiau svarbu surinkti tinkamus, informatyvius duomenis, kuriais remiantis bus kuriami įvairūs finansiniai bei matematiniai modeliai [1] [2]. Šiomis dienomis, vis sunkiau rasti personalą, žmogiškuosius resursus, kurie gebėtų kurti tikslus bei informatyvius matematinius modelius. Tačiau kartu su žmogiškuoju faktoriumi, paaiškėja ir kita opi problema – trūkumas tikslingų bei teisingai surinktų duomenų, kuriais remiantis būtų galima kurti tikslus prognozavimo modelius. 2020 metais prasidėjusi COVID-19 ligos pandemija, bei susidariusi pasaulinė situacija iškėlė vis labiau ryškėjusią problemą – netinkamą duomenų rinkimą bei netinkamą duomenų naudojimą [3]. Vis daugiau valstybių, privataus bei viešojo sektoriaus įmonių, privačių žmonių susidūrė su staigia skaitmenizacija, kuri lėmė daugelio fizinių procesų persikėlimą į virtualią erdvę. Didelė dalis finansinių operacijų, bankinių procesų, susitikimų, skambučių bei kitų veiklų, kurios buvo įprastos fiziniu pasauliu, tapo nuotolinės. Atsirado poreikis privačiame bei viešajame sektoriuje rinkti duomenis, juos analizuoti bei remiantis duomenimis grįžtais įrodymais, priimti atsakingus sprendimus.

Ekonominiame pasaulyje, sekant ekonomikos raidą bei pokyčius, svarbu atlikti įvairius prognozavimus, dažniausiai – finansinius. Finansinis prognozavimas yra procesas, kuriuo siekiama numatyti finansinių rodiklių reikšmes ir tendencijas ateityje. Tai gali apimti spėjimus dėl svarbių finansinių rodiklių kaip pelnas, pardavimai, investicijos, pinigų srautai ir kita. Finansinis prognozavimas naudojamas siekiant prognozuoti, kaip įmonės veiks ateityje ir kaip galės pasiekti savo tikslus. Finansinis prognozavimas pradėtas naudoti gana seniai, kai buvo pradėti kaupti ir analizuoti finansiniai duomenys. Šis procesas tapo ypač svarbus pramonės revoliucijos laikais, kai buvo pradėti naudoti gamybos ir finansiniai rodikliai. Šiandien finansinis prognozavimas yra itin svarbus finansinio planavimo ir sprendimų priėmimo procesuose, taip pat šis procesas yra nebe įsivaizduojamas be teisingų duomenų [4]. Įmonės, bankai, draudimo bendrovės ir valdžios institucijos naudoja finansinį prognozavimą, siekdamas numatyti savo ateities finansinius rezultatus ir nustatyti galimas kliūtis ar problemas ateityje. Finansiniam prognozavimui naudojami įvairūs duomenys, įskaitant finansinius ir ekonominius rodiklius, makroekonominius duomenis, rinkos duomenis. Dažnai tai apima finansinius rodiklius: pelnas, pajamos, kapitalizacija, turto vertė, skolos lygis, bei makroekonominius rodiklius – informacija apie ekonomikos būklę ir tendencijas – pavyzdžiui: BVP augimas, nedarbo lygis, infliacija, valiutos kurso svyravimai [5]. Taip pat yra tiriami rinkos duomenys: akcijų kainos, obligacijų kainos, valiutos kursai ar socialiniai duomenys: gyventojų amžius, lytis, išsilavinimas, gyvenimo būdas [6]. Visi šie duomenys yra naudingi finansiniam prognozavimui, nes leidžia numatyti, kaip galėtų pasikeisti finansinės sąlygos ateityje ir padeda priimti duomenimis pagrįstus sprendimus. Be visų šių rodiklių, įmonės bei valstybės vis dažniau pradeda rinkti naujus rodiklius, kurie atspindi esamą

šių dienų situaciją: versle renkami verslo veiklos duomenys, pavyzdžiui: užsakymų skaičius, klientų skaičius, pardavimų skaičius bei dažnis, valstybės lygmeniu vis dažniau tenka ieškoti duomenų apie naujienas, vykstančias šiuo metu, ir taip siekiama prognozuoti netolimą ateitį – kito mėnesio pardavimus, sergamumo skaičių šalyje ar kita. Prognozės, kurios remiasi šių dienų aktualijomis yra vadinamos dabarties prognozavimu, arba angliškai *nowcasting*. *Nowcasting* yra ekonominės analizės metodas, kuris naudoja aktualiąją informaciją, statistiką ir duomenų analizę, siekiant prognozuoti ekonominius rodiklius trumpuoju laikotarpiu. *Nowcasting* metodas leidžia prognozuoti ekonominius rodiklius, kai oficialios statistikos duomenys dar nėra paskelbti, nėra surinkti ar renkami iš viso arba yra per seni, kad atspindėtų naujausius pokyčius ekonomikoje [7].

Po COVID-19 pandemijos bei karo Ukrainoje kontekste, šių dienų pasaulis išgyvena naują ekonominę situaciją, kurią dažnu atveju ekonomistai vadina nauja ekonomikos krize [8]. Ši situacija yra kitokia nei prieš tai buvusios krizės dėl pasikeitusios ekonomikos, vis labiau nutrūkstančiu santykiu su Rytų šalimis, tokiomis kaip Kinija, Rusija. Ši krizė vadinama energetikos krize, kuomet Europos šalims teko atsisakyti energetinės priklausomybės nuo Rusijos gamtinių išteklių, taip pat po pandemijos vis dar stebimos sutrikusios tiekimo grandinės, naujų produktų tiekimo disbalansas. Ši situacija dar labiau iškėlė poreikį domėtis investicijomis tiek versle, tiek privatiems asmenims ir vis dažniau kalbama apie investavimą, kaip atsaką į infliaciją. Dėl įvairių rizikos tolerancijos faktorių dažniausiai renkamasi investuoti į įmonių akcijas, valstybinės obligacijas, investicinius fondus, nekilnojamą turtą, įvairias žaliavas (auksą, naftą) bei kriptovaliutas [9]. Svarbu paminėti, kad kiekvienas investavimo produktas turi savo rizikas ir privalumus, tačiau vis labiau populiarėja ir daugėja investicijų į naujausią, kol kas labiausiai kintantį produktą – kriptovaliutas. Visų populiariausia, didžiausia pagal kapitalizaciją kriptovaliuta šioje rinkoje yra bitkoinas. Nepaisant to, kad yra įvairių metodų ir priemonių, nėra garantijų dėl investicijų grąžos investuojant į kriptovaliutas.

Šiuo metu egzistuoja keli pagrindiniai kriptovaliutų rinkų tendencijų prognozavimo metodai. Pirmasis metodas – techninė analizė – yra rinkų analizės metodas, kuris remiasi istorine finansinių produktų kainų dinamika, siekiant prognozuoti ateities tendencijas. Šiam tikslui naudojami techniniai rodikliai ir grafikai, kurių pagalba siekiama identifikuoti rinkos kainų judėjimo modelius ir prognozuoti būsimus kainų pokyčius. Šios analizės metu yra vertinami finansinio produkto kainos istoriniai pokyčiai, siekiama rasti dažnai pasikartojančius šablonus (angl. *patterns*), kuriuos suvokus parengiama ateities akcijų kainos prognozė. Tiesa, svarbu tai, kad šis metodas daugiausia remiasi ekspertų duomenimis ir dažniausiai analizuojami rodikliai yra kainos kitimo greitis (angl. *ROC – Rate of change*) – impulso indikatorius stebintis apimtį ir kainos pokyčius per tam tikrą laiką taip pat slankiųjų vidurkių konvergencijos/divergencijos rodiklis (angl. *MACD – Moving Average Convergence/Divergence*) [10] [11]. Antrasis kriptovaliutų rinkos prognozavimo metodas – fundamentalioji analizė, kurios metu kriptovaliutos vertė nustatoma analizuojant ne tik kompanijos vidinę būklę, bet ir jai įtaką darančius išorės veiksnius, tokius kaip tarptautinė politinė situacija, mokesčiai, įstatymai, infliacija bei ekonominiai ciklai [12]. Trečiasis metodas – finansinių laiko eilučių analizė. Viena iš finansinių laiko eilučių analizės taikymo sričių yra laiko eilutės reikšmių prognozavimas ateičiai. Taikomi ARCH, GARCH, VAR metodai, remiantis istoriniais duomenimis, prognozei į ateitį [13]. Ketvirtasis metodas, skiriamas siekiant prognozuoti kriptovaliutų kainą ateityje yra netiesinių metodų taikymas – į šią grupę įeina tokie mašininio mokymosi uždaviniai kaip klasifikacija, regresijos modelio sudarymas. Dažniausiai naudojami metodai yra: regresiniai modeliai, atsitiktinių miškų metodas (angl. *random*

forest), dirbtiniai neuroniniai tinklai (DTI) ir kiti metodai [14] [15]. Penktasis metodas – sentimentinė analizė, šis metodas apima kriptovaliutų rinkos nuotaikų ir investuotojų požiūrio analizę. Investuotojai stebi socialinius tinklus, naujienas, diskusijų forumus ir kitus informacijos šaltinius, kad nustatytų, kaip investuotojai vertina kriptovaliutas ir kokie yra jų lūkesčiai [16] [17] [18].

Šių dienų kontekste, tiriant jau tradicinėmis laikomų akcijų biržų kainas, vis dažniau yra renkama investuoti į kriptovaliutų rinką, dėl jos naujumo, įdomumo ir didelio volatilumo. Kriptovaliutų, o labiausiai – bitkoino kainos pokytis yra viena iš aktualiausių temų finansų sektoriuje. Nors kriptovaliutos gali būti rizikingas investicinis pasirinkimas, jas verta apsvarstyti kaip galimybę padidinti investicinio portfelio diversifikaciją ir galimybę gauti aukštesnį pelną [19]. Kaip decentralizuota valiuta, bitkoinas yra nepriklausomas nuo vyriausybių ir bankų, todėl jo kaina gali labai svyruoti. Bitkoino kaina nuolat kinta, ir tai sukuria daug nerimo bei neaiškumo tiek investuotojams, tiek ekspertams. Nors bitkoino kainų svyravimai gali būti įdomūs analizuoti, jie taip pat gali kelti rimtų grėsmių investicijoms ir kriptovaliutų rinkai apskritai. Analizuojant bitkoino kainos pokytį, svarbu atsižvelgti į įvairius veiksnius, tokius kaip vartotojų pasitikėjimas bitkoinu, investuotojų elgesys ir technologinių inovacijų įtaka. Remiantis šiais anksčiau aptartais finansinių rinkų analizės metodais magistrinio darbo tyrimo metu bus sudaromi mašininio mokymo matematiniai modeliai, sprendžiant regresinės analizės uždavinį bei atliekama koreliacijos analizė, siekiant įvertinti išorinių veiksnių poveikį bitkoino kainos pokyčiui. Visas tyrimas bus paremtas finansinių produktų grąžų skaičiavimu, taip išvengiant skirtingų skalių (apimčių) (angl. *scale*) įtakos. Darbe taip pat bus nagrinėjami įvairūs kainų pokyčių veiksniai, pavyzdžiui staigūs kainos šuoliai ir nukritimai.

Šio magistrinio darbo tyrimo objektas yra bitkoino kainos pokyčio analizė bei sąsaja su išorės faktoriais. Kainų dinamikos tyrimas yra svarbi ekonomikos srities tema, nes kainos yra vienas iš pagrindinių ekonomikos rodiklių, lemiančių rinkos sąlygas ir vartotojų elgesį. Baigiamojo projekto tikslas – išorinių veiksnių poveikio tyrimas bitkoino kainos (investicinės grąžos) analizei, kuris padėtų apibendrinti investuotojų elgseną.

Tyrimo uždaviniai:

- išnagrinėti bitkoino laiko eilutę, rasti paaiškinamas priežastis galimiems kainos šuoliams ir nukritimams; įvertinti kainos augimo ar kainos kritimo tendencijas;
- atlikti išorinių veiksnių analizę, surasti veiksnius, turinčius reikšmingą įtaką bitkoino kainos svyravimams;
- panaudojant didžiųjų duomenų mokslo metodus sudaryti kelis bitkoino grąžos priklausomumo regresinius matematinius modelius, juos palyginti, rasti geriausią modelį bei aptarti jo rezultatus.

Baigiamojo projekto problematika: bitkoino kaina yra susijusi su išoriniais veiksniais tokiais kaip pasaulio ekonomikos tendencijos, politinė įtampa ir teisiniai reguliavimai, įtempta geopolitinė situacija pasaulyje, spekuliacijos ir įvairūs vartotojų elgsenos pokyčiai.

Matematikos ir ekonomikos integralumas: šis magistro baigiamasis projektas jungia abi matematikos ir ekonomikos mokslo šakas, nes yra naudojami ekonominiai duomenys, nagrinėjamos sąsajos tarp

kainos šuolių ir naujienų vykstančių pasaulyje taip pat yra taikomi matematiniai metodai, sudaromi didžiųjų duomenų mokslo modeliai.

1. Literatūros apžvalga

Ekonomikoje finansinių rinkų analizėje ypač svarbus dėmesys skiriamas finansinio produkto kainai, kuri iš esmės apsprendžia finansinio produkto stabilumą, konkurencingumą, naudingumą kitų finansinių produktų atžvilgiu. Finansiniai produktai yra įvairūs finansinės rinkos instrumentai, kuriais prekiaujama siekiant gauti pelno arba apsaugoti nuo pinigų praradimo rizikos. Šiuo tikslu, investuotojai dažniausiai investuoja į šiuos finansinius produktus – akcijas, obligacijas, vertybinius popierius, valiutas, žaliavas, ateities sandorius bei kriptovaliutas.

Svarbu paminėti, kad 2020 metais prasidėjusi pasaulinė COVID–19 pandemija paskatino technologinę evoliuciją ir pažangą įvairiose srityse, taip pat pagreitino jau vykstančius procesus bei pokyčius tiek valstybiniu lygiu, tiek privačiuose versluose bei investicijose. Puikus šios situacijos pavyzdys, kai 2021 metais esant nestabiliui pasaulio ekonomikai, vis labiau išpopuliarėjo dar 2014 metais sukurta NFT technologija [20]. NFT (angl. *non-fungible token*) yra unikalus vertybinis popierius, kurio vertė priklauso nuo jo unikalumo ir patikimumo. Tai yra blokų grandinės technologijos naudojimas kūriniams, kurie gali būti virtualūs arba realūs, paversti unikaliais skaitmeniniais turtais. NFT technologijos populiarėjimas pasaulyje kuria naują tendenciją – pabrėžiama, kad vis daugiau vartotojų ieško naujų, blokų grandine pagrįstų finansinių produktų, į kuriuos skiriama vis daugiau investicijų. Technologinė pažanga padėjo pagrindą naujiems mokėjimo, atsiskaitymo metodų atsiradimams. Blokų grandinės technologija pakeitė verslo aplinką, transformavo egzistuojančius ekonominius, aplinkos saugos, bei organizacinius procesus [21]. Todėl akivaizdu, jog pandeminė situaciją atnešė pokyčius ir į investicijų pasaulį. Tačiau norint prognozuoti pasaulinę ekonomikos tendenciją, svarbu rasti ir apibrėžti sąsajas tarp tradicinių finansinių produktų ir naujų technologijų, bei atsižvelgti į istorinius ekonominių rodiklių duomenis.

Kita vertus, mokslinėje literatūroje siekiant prognozuoti finansinių produktų kainos dinamiką, plačiau siai analizuojami metodai, kurie padeda nustatyti, tinkamiausią įsigijimo ar pardavimo laiką, taip siekiant sulaukti maksimalios ekonominės grąžos investuotojams. Čia svarbu paminėti, kad finansinių produktų rinkos svyravimams reikšmingą įtaką turi realiu laiku vykstantys pasauliniai įvykiai: politiniai sprendimai, psichologinė aplinka, investuotojų lūkesčiai. Todėl norint tinkamai bei pagrįstai išanalizuoti kriptovaliutų rinkos pagrindinio finansinio produkto bitkoino kainos pokytį, svarbu suvokti sąsajas tarp ekonominių rodiklių ir kriptovaliutų rinkos tendencijų.

1.1. Sąsajų tarp pasaulinės ekonomikos tendencijų, ekonominių rodiklių, vartojimo prekių rinkos ir finansinių rinkų tyrimų apžvalga

Svarbiausias finansų rinkos teorijos uždavinys – rasti bei gebėti apibūdinti finansinio produkto kainos sudarymo mechanizmą pasirinktoje rinkoje. Finansų rinka yra vieta, kur prekiaujama vertybiniais popieriais, pavyzdžiui, akcijomis ir obligacijomis, o šie finansiniai produktai priklauso atitinkamoms rinkoms: pinigų rinka, valiutos rinka ir išvestinių vertybinių popierių rinka. Investicinių prekių rinkos, tokios kaip brangiųjų metalų rinka, taip pat yra priskiriamos finansų rinkoms. Svarbu paminėti, jog atliekant ekonomikos analizę, privaloma atsižvelgti ir į vartojimo prekių rinką. Vartojimo prekių rinka


kaip reiškinyis atsirado bei išpopuliarėjo XVIII-XIX a. Anglijoje, siejamas su pramonės revoliucija [22] [23]. Kaip teigia J. Brewer ir R. Porter pramonės perversmo laikais Anglijoje prasidėjo vartotojų revoliucija (angl. *consumer revolution*). XVIII amžiuje Europoje vyko didelis ekonominis, socialinis ir kultūrinis pokytis, kuris turėjo įtaką ne tik prekių ir paslaugų gamybos būdo pasikeitimams, bet ir vartotojų elgsenai bei požiūriui į vartojimą [24]. Vartotojai tapo aktyvesni ir pradėjo daugiau dėmesio skirti savo asmeninių namų ūkių poreikių tenkinimui. Jie pradėjo vertinti ne tik prekių praktiškumą, bet ir jų grožį, pradėjo siekti statuso ir socialinio prestižo, vartojant tam tikras prekes. Tai skatino gamintojus ir prekybininkus kurti naujas prekių rinkas ir plėtoti marketingo ir reklamos priemones, kad būtų pritraukti vartotojus ir padidinti pardavimus. Šis vartotojų elgsenos pokytis turėjo svarbių padarinių ekonomikai, pramonės plėtrai, kultūrai ir visuomenės struktūrai [25]. Taip susiformavo vartojimo prekių rinka, kurią žiname šiandien. Vartojimo prekių rinka yra viena svarbiausių ekonomikos dedamųjų dalių, nes jos dydis ir augimas yra svarbus bendrai pasaulinei ekonomikai apskritai. Be to, ši rinka yra labai svarbi vartotojų poreikių patenkinimui ir gyvenimo kokybės gerinimui, kasdieniniam vartojimui. Vartojimo prekių rinkos egzistavimas taip pat skatina naujų produktų kūrimą, inovacijas, konkurenciją tarp gamintojų ir prekybininkų, kainų mažinimą ir kokybės gerinimą. Todėl, gerai veikianti vartojimo prekių rinka yra svarbi visuomeniniu, verslo bei valstybiniu lygiu.

Tačiau sugrįžtant prie pastarųjų metų ekonomikos pasaulyje, galima teigti, kad 2020 metais prasidėjusi pasaulinė pandemija, kartu su nevaldomai plintančiu virusu, pradėjo ir naują pramonės bei vartojimo revoliuciją. Kaip teigia L. Bonilla-Molina, COVID-19 pandemija paskatino naują skaitmenizacijos etapą, kuomet daugelis privačių asmenų, verslų bei valstybių turėjo staigiai prisitaikyti prie nevaldomo viruso plitimo [26]. Pažymėtina, kad šis pokytis vadinamas ketvirtąją pramonės revoliucija (angl. *fourth industrial revolution*) ir pasižymi technologiniu tobulėjimu, tokiu kaip daiktų internetas, dirbtinis intelektas ir 3D spausdinimas, integracija, dėl kurios vystosi vis labiau optimizuoti bei automatizuoti gamybiniai procesai. Taip pat, COVID-19 pandemija turėjo didelę įtaką vartojimo prekių rinkai. Pandemijos metu daugelyje šalių valstybiniu lygiu buvo įvesti karantinai ir ribojimai, kurie sumažino vartotojų galimybes apsilankyti fizinėse parduotuvėse, teko keisti taip egzistuojančius vartojimo įpročius [27]. E. Ludvik, L. Komarkova, D. Egerova ir M. Mičik šiame straipsnyje pabrėžia, kad naujų laikų vartotojų pirkimo įpročiai buvo paveikti baimės ir neapibrėžtumo, o pagrindiniai vartotojų poreikiai pandeminiu laikotarpiu iš esmės gali būti apibūdinti pagal 11 išskirtų kriterijų. Šie kriterijai yra:

- artimųjų sveikata;
- asmeninė sveikata;
- maisto ir vaistų atsargų turėjimas;
- finansinis stabilumas;
- hobiai;
- bendruomeniškumas (įsitraukimas į visuomenę);
- draugystė (ryšiai);
- pramogos (laisvalaikis);
- išsilavinimas;

- pasitenkinimas darbu (karjera);
- asmeninė sėkmė.

Įdomu ir tai, kad prieš pradėdami tyrimą, autoriai išskyrė tris vartotojų klases pagal amžiaus grupę – kartą, kuriai priklauso apklaustieji. Hipotezė, kurią iškėlė straipsnio autoriai buvo tokia "yra kartų skirtumai tarp vartojimo poreikių, kurie daro įtaką pasirinktų kartų vartotojų apsipirkimui COVID-19 pandemijos metu". Šią ir kitas likusias tyrimo hipotezes pavaizdavo tyrimo modelio grafu (žr. 1 pav.):



1 Pav.: E. Ludvik, L. Komarkova, D. Egerova ir M. Mičik vartotojų elgsenos COVID-19 pandemijos metu tyrimo modelis. Šaltinis: *Journal of Retailing and Consumer Services*


Šis aukščiau aptartas tyrimas siejasi ir koreliuoja su duomenų analitikos srityje veikiančios įmonės *Accenture* atliktu tyrimu apie vartotojų elgesį COVID-19 pandemijos kontekste [28]. Išskiriami keli vartotojų elgesio pokyčiai ir prognozuojama, jog naujos vartojimo elgsenos tendencijos išliks ir po pandemijos. Dar 2020 metų pavasarį identifikuoti šie vartotojų elgsenos pokyčiai:

- dabartiniai vartotojų pirkiniai yra sutelkti į pagrindinių poreikių patenkinimą, tačiau žmonės yra labiau linkę apgalvoti savo pirkimus. Pastebima, jog jie renkasi vietinius produktus, taip pat pirmenybę teikia apsipirkimui internetu;
- vartotojai naudojami technologijomis, kad susisiektų, mokytųsi ir dirbtų ir pramogautų virtualiu būdu. Manoma, kad fiziniai susitikimai ir toliau bus keičiami susitikimais nuotoliniu būdu, konferencijomis, skambučiais;
- numatomas virtualios darbo jėgos augimas ateityje, kadangi vis daugiau žmonių dirba iš namų. Pastebėtina, kad darbo iš namų situacija aktuali ir šiuo metu.

Sugrįžtant į šiandieną, galime drąsiai teigti, jog abu šie tyrimai ir gauti rezultatai iš tiesų pateikia teisingas išvadas apie po pandeminę situaciją pasaulyje. Kaip teigia *Accenture* tyrimas, 57% apklaustųjų

nurodo, kad nors anksčiau niekada nedirbo iš namų, planuoja tęsti darbo nuotoliu ir ateityje, o net 30% apklaustųjų žada dirbti daugiau laiko iš namų, nei įprastai (žr. 2 pav.).

Change in work-from-home frequency from pre- to post-outbreak




2 Pav.: Accenture įmonės tyrimo „COVID-19 Consumer Research“, atlikto 2020 04 02-06, N = 1118 respondentų, dirbančių namuose apklausos rezultatai. Šaltinis: *Accenture*

Toliau apžvelkime, tyrimo rezultatus, susijusius su vartojimo įpročiais (žr. 3 pav.). Rezultatai, gauti balandžio mėnesio tyrimo metu rodo, kad net 68% apklaustųjų teigia, jog pandemijos kontekste riboja sunaudojamo maisto švaistymą. 59% respondentų perka sveikesnius produktus kasdieniam vartojimui ir 54% apklaustųjų yra linkę priimti tvarius sprendimus apsipirkimo metu. Atsakydami į klausimą, apie vartojimo sąmoningumą, 49% respondentų teigia apsiperkantys sąmoningiau nei prieš tai ir net 46% apklaustųjų yra linkę apsipirkti vietinėse, netoliese esančiose parduotuvėse.

Consumers expect their shopping habits to change permanently

Limiting food waste and shopping more health consciously are the top two priorities for consumers
Proportion that agree or significantly agree with statement and are likely to sustain this post-outbreak




3 Pav.: Accenture įmonės tyrimo „COVID-19 Consumer Research“, atlikto 2022 03 19-25 ir 2020 04 02-06, apklausos apie apsipirkimo įpročius rezultatai. Šaltinis: *Accenture*

Šių, iš pažiūros paprastų apklausų rezultatai, atspindi pirmines vartojimo tendencijas po pandemijės ekonomikoje. Iš tiesų dauguma vartotojų persikėlė į elektronines parduotuves, kurios labai išpopuliarėjo bei užsitikrino savo vietą rinkoje. Be to, daugelis žmonių pandeminiame kontekste susidūrė su ekonominėmis problemomis dėl darbo netekimo ir finansinių sunkumų. Šios priežastys lėmė tai, kad vartotojai pradėjo atidžiau stebėti savo išlaidas ir pasirinkti pigesnius arba labiau savo galimybes atitinkančius tiek maisto, tiek bendrojo naudojimo produktus. Pandemijos metu prekybininkai prisitaikė prie situacijos, siekdami patenkinti vartotojų poreikius ir norus. Vienas iš būdų buvo pasiūlyti produktus už mažesnę kainą, kadangi daug vartotojų pradėjo stebėti savo išlaidas ir pasirinkti pigesnius produktus. Dėl šių priežasčių ir pastangų prekybininkai išlaikė savo klientų lojalumą ir užsitikrino savo įmonės prekybinį konkurencingumą rinkoje. Nors individualios įmonės, kurios prisitaikė prie situacijos sustiprėjo, pandemijos kontekste pasaulinis prekybos balansas buvo paveiktas ir susilpnėjo. Kai kurie pramonės sektoriai patyrė didelius nuostolius, o kai kurie išaugo dėl paklausos pokyčių. Pavyzdžiui, turizmo, pramogų ir aviacijos sektorius buvo stipriai paveiktas pandemijos, nes daugybė kelionių buvo atšauktos, o žmonės daugiau laiko praleido namuose ir nebegalėjo lankytis renginiuose. Tačiau kiti sektoriai, pavyzdžiui, maisto produktų, medicinos prekių ir technologijų sektoriai išaugo, nes padidėjo paklausa, žmonės daugiau laiko praleido namuose ir turėjo didesnę poreikį šiems produktams. Žvelgiant į tarptautinę prekybą, ši taip pat sumažėjo dėl logistikos apribojimų. Vis dėlto, kai kurie regionai ir šalys, tokios kaip Kinija ir Jungtinės Amerikos Valstijos, išlaikė didelę prekybos dalį ir netgi padidino savo prekybos apimtį. Tačiau pandemijos sukeltos logistikos problemos yra aktualios ir šiandien. Privatus ir valstybinis sektorius vis dar susiduria su tiekimo grandinių problema, kuri sukėlė didelius įvairių produktų kainų svyravimus, o taip pat pasidarė sunkiau planuoti savo išlaidas.

Dėl vis dar besitęsiančio finansinio neapibrėžtumo ir globalios politinės įtampas karo Ukrainoje kontekste, visas pasaulis buvo paveiktas padidėjusios infliacijos (žr. 4 pav.).

Global inflation rate from 2000 to 2021, with forecasts until 2027 (percent change from previous year)



4 Pav.: Pasaulinis infliacijos lygis 2000–2021 metais ir infliacijos lygio prognozė iki 2027 metų. Šaltinis: Statista

Kaip teigia G. Wangas ir kiti [29] didėjanti globali infliacija turi neigiamą įtaką naftos kainai, kuri atlieka svarbų vaidmenį energijos rinkose ir skatina ekonominį augimą visoje pasaulio ekonomikoje. Kaip minėta anksčiau, šiuo metu ekonomika yra stipriai susijusi su energetikos kainos pokyčiu, kuris lėmė daugelio valstybių bei privačių asmenų būtinybę taupyti energetiką, tausoti šiuos šaltinius nuo perteklinio vartojimo. Nors infliacija yra svarbus ekonominis rodiklis, norint suvokti realią ekonominę aplinką, reikia tirti ir daugiau rodiklių. Pavyzdžiui, nedarbo lygis (angl. *unemployment rate*), bendrasis vidaus produktas (angl. *gross domestic product*), palūkanų normos (angl. *interest rate*), vartotojų pasitikėjimo indeksas (angl. *consumer confidence index*). Ištirkime nuosekliai:

- nedarbo lygis – yra vienas iš svarbiausių makroekonominių rodiklių, kuris apibūdina darbo rinkos būklę ir ekonominę padėtį. Pasauliniu mastu nedarbo lygis skiriasi tarp skirtingų šalių ir regionų, ir priklauso nuo daugelio veiksnių, tokių kaip ekonominės ir politinės sąlygos, technologinė pažanga, švietimo ir mokymosi galimybės. Pagal pasaulinio nedarbo rodiklio pokyčio grafiką (žr. 5 pav.), ryškus nedarbo lygio padidėjimas stebimas 2020 metais, sietinas su COVID-19 pandemija, siekė net 6.9%. Tačiau pastebėtina, kad 2021 metais šis rodiklis nukrenta iki 6.2% ir norint palyginti, galima teigti, kad 2021 metais, nedarbo lygis pasaulyje pasiekia panašią situaciją kaip ir 2009–2011 metais, kuomet dėl JAV nekilnojamojo turto burbulų sprogdimo, kilo pasaulinė finansų krizė.

Global unemployment rate from 2002 to 2021

(as a share of the total labor force)




5 Pav.: Pasaulinis nedarbo lygis 2002–2021 metais. Šaltinis: *Statista*

- bendrasis vidaus produktas (BVP) – yra svarbiausias makroekonominis rodiklis, rodantis visų prekių ir paslaugų vertę, kurios buvo pagamintos per metus visoje pasaulio ekonomikoje. Rodiklis leidžia matuoti ir lyginti šalių ekonomikos dydžius ir augimą, bei atskleisti pasaulinės ekonomikos tendencijas. Pasaulinis BVP yra dažnai naudojamas kaip svarbus rodiklis, kai yra vertinami tarptautiniai prekybos santykiai, investicijos ir valstybių ekonominis bendradarbiavimas. Pagal pasaulinio BVP rodiklio grafiką (žr. 6 pav.) matome tris ryškius pasaulinio BVP rodiklio nukritimus: 1982 m. rodiklis siekė 0.69%, 2009 m. rodiklis siekė -0.08%, tačiau 2020 m. rodiklis nukrito iki dar nebuvusių žemumų ir siekė -2.95%. Šie nukritimai paaiškinami:
 - 1982 metais pasaulinio BVP nukritimas buvo susijęs su ekonomine recesija, kuri kilo dėl kainų kilimo, aukšto nedarbo lygio ir ekonomikos nuosmukio daugelyje pasaulio šalių, šaltojo karo tarp SSRS ir JAV.
 - 2009 metais pasaulinio BVP nukritimas buvo susijęs su finansų krizės padariniais, kurie buvo išprovokuoti nekilnojamojo turto burbulų sprogimo JAV ir tolesnių vykstančių po krizinių įvykių. Tai turėjo didelį neigiamą poveikį pasaulio ekonomikai, sukeliant žymius nuostolius ir silpninant paklausą, apstojo vartojimas.
 - 2020 metais pasaulinio BVP nukritimas buvo iš dalies susijęs su COVID-19 pandemija, kuri sukėlė visuotinį ekonomikos nuosmukį, dėl daugelyje šalių įvestų karantinų. Verslo veikla ir tarptautinė prekyba buvo sutrikdyta, prasidėjo tiekimo grandinės sutrikimai, trūkumas elektronikos komponentų, dėl padidėjusio elektronikos prietaisų vartojimo.

Growth of the global gross domestic product (GDP) from 1980 to 2022, with forecasts until 2027

(compared to the previous year)




6 Pav.: Pasaulinis bendrasis vidaus produktas 1980–2022 metais ir BVP prognozė iki 2027 metų. Šaltinis: Statista

- palūkanų normos – šiuo atveju nagrinėjama JAV mėnesinės palūkanų normos, kurios yra svarbus ekonominis rodiklis, kuris nurodo kokią palūkanų normą, bankai moka vienas kitam skolindamiesi pinigus. Šis rodiklis gali turėti didelę įtaką ne tik JAV, bet ir kitų šalių ekonomikai, nes jis gali paveikti investicijų sprendimus, vartotojų pirkimo galimybes ir valdžios politiką. Federalinių Rezervų Sistemos valdyba (angl. *Federal Reserve Board*) reguliuoja JAV mėnesines palūkanų normas siekdama palaikyti ekonomikos stabilumą. Pagal JAV mėnesinių palūkanų normų pokyčio grafiką (žr. 7 pav.) matome kelis žymius nukritimus:

- 2012-05-01 iki 2013-05-01 JAV palūkanų norma pirmą kartą istorijoje nukrito žemiau 0%. 2012-02-01 siekė -0.09% iki kol 2013-06-01 vėl paaugo aukščiau 0%, ir siekė 0.23%. Šis nukritimas žemiau 0% buvo reakcija į ekonomikos sulėtėjimą [30], kuris susijęs su dideliais nuostoliais, patirtais po 2008 metų finansų krizės. Siekiant paskatinti ekonomikos augimą ir skatinti investicijas, JAV Federalinių Rezervų Sistemos valdyba nusprendė sumažinti palūkanų normas. Šis sprendimas taip pat padėjo sumažinti mokesčių našą ir skolinimosi išlaidas. JAV istorijoje tai buvo pirmas kartas, kai palūkanų normos nukrito žemiau 0% [31].
- 2020-03-01 iki 2021-09-01 JAV palūkanų norma antrą kartą istorijoje nukrito žemiau 0%. 2020-03-01 siekė -0.13% iki kol 2021-10-01 vėl paaugo aukščiau 0%, ir siekė 0.09%. Antrasis nukritimas žemiau 0% sietinas su pandemijos sukelta ekonomine krize ir jos padariniais [32]. JAV Federalinių Rezervų Sistemos valdyba nusprendė sumažinti palūkanų normas, siekiant padėti stabilizuoti rinkas, paskatinti skolinimąsi ir investicijas, taip pat skatinti vartotojų išlaidas ir valdžios vykdomą ekonominę politiką. Šis žemas palūkanų

lygis taip pat padėjo sumažinti skolinimosi išlaidas ir padidino infliaciją [33]. Tai buvo antras kartas JAV istorijoje, kai palūkanų normos nukrito žemiau 0%.

Monthly 10-year real interest rate in the United States from 1982 to 2022



7 Pav.: JAV mėnesinės palūkanų normos 1982–2022 metais. Šaltinis: *Statista*

- pasaulinis vartotojų pasitikėjimo indeksas – pasaulinis vartotojų pasitikėjimo indeksas yra ekonominis rodiklis, atspindintis vartotojų požiūrį į dabartinę ir ateities ekonomiką, vartotojų finansinius lūkesčius ir galimybes. Šis indeksas gali būti naudingas analizuojant ekonomikos rinkos tendencijas, prognozuojant vartotojų elgesio pokyčius ir įvertinant bendrą ekonomikos sveikatos būklę. Žvelgiant (žr. 8 pav.) į 2020–2023 metų pasaulinio vartotojo pasitikėjimo indekso pokytį, galima daryti kelias išvadas:
 - 2020 balandžio mėnesį, po COVID-19 pandemijos protrūkio, pasaulio vartotojų pasitikėjimo indeksas sumažėjo iki 39,5 balo 23 šalyse.
 - Po to laiko indeksas lėtai didėjo ir 2021 metų liepos mėnesį pasiekė 49,1 balą.
 - vėliau pasaulinis vartotojų pasitikėjimas sumažėjo 2022 metų antroje pusėje, kai pradėjo kilti infliacija, tačiau po to, nuo 2022 metų lapkričio mėnesio pradėjo dėsningai augti.

Global consumer confidence in developed and emerging countries from January 2020 to February 2023



8 Pav.: Pasaulinis vartotojų pasitikėjimo indeksas išsivysčiusiose ir kylančios ekonomikos šalyse 2020-2023 metais. Šaltinis: *Statista*

Plačiau apžvelgus pasaulinę ekonomikos tendenciją, išanalizavus pasikeitusią vartotojų elgseną nūdienos kontekste, tikslinga ir teisinga sugrįžti ir plačiau apžvelgti efektyviosios rinkos teoriją. Efektyvios rinkos teorija (ERT) yra finansų teorija, teigianti, kad rinkos visada yra efektyvios ir produkto kaina atspindi visą turimą informaciją apie prekes, akcijas ar kitus finansinius instrumentus [34]. Teorija taip pat pabrėžia, kad kainų pokyčiai yra atsitiktiniai ir neprognozuojami, ir teigia, kad jokia strategija ar informacija negali suteikti pranašumo prieš rinką. Ši teorija yra viena iš pagrindinių, kurių remiasi finansų ekspertai ir investuotojai norėdami suprasti rinkų dinamiką ir priimti efektyvius investavimo sprendimus. Čia svarbu atskirti dvi rinkas – vartojimo prekių rinką (kurios analizė yra atlikta aukščiau, tiriant vartotojų elgsenos pokyčius) ir finansų rinką – susijusią su investicijomis. Dėl informacinių technologijų pažangos finansų rinkos turi didžiulę duomenų bazę, kurioje saugoma ne tik specifinių akcijų ir obligacijų kainos, bet ir prekybos apimtys, prekybos šaltinis ir kiti duomenys. Tokius duomenis, kuriuos dažnai gauname per dieną, galima analizuoti naudojant pažangiais metodais grįstą duomenų analizę, kuri šiuo metu plėtojasi labai greitai. Kaip teigia VU MIF profesorai R. Leipus ir R. Jovaiša, finansų rinka yra svarbi rinkos ekonomikos dalis, leidžianti bendrovėms ir investuotojams optimaliai paskirstyti išteklius [35]. Finansų rinkų elgsena yra laikoma rodikliu, atspindinčiu šalies ekonomikos būklę, bet tiesioginio ryšio tarp finansų rinkos ir ekonomikos nėra daug požymių. Įvairių šalių finansų rinkų indeksai, tokių kaip *DJIA*, *S&P*, *NASDAQ*, *NIKKEI225*, *DAX* ir kiti, yra laikomi rinkos „veidrodžiais“. Kaip teigia ekonomistė M.Jasienė, Lietuvoje tokiais rodikliais buvo akcijų indeksai Litin (iki 2004 metų), Litin-G (iki 2004 metų) iki kol 2006 metais pradėti skaičiuoti nauji akcijų indeksai visoms trijoms Baltijos šalims [36]. Tai yra šie indeksai: OMX Baltic Benchmark (kuris apima likvidžiausias ir didžiausias kapitalizacijos Baltijos šalių biržose prekiaujamų bendrovių akcijas), OMX Baltic 10 (kuris apima 10 likvidžiausias Baltijos šalių biržose prekiaujamų bendrovių akcijas) ir OMX Baltic (kuris apima informaciją iš oficialių ir papildomų sąrašų apie bendrovių akci-

jas iš visų trijų Baltijos šalių biržų).

Finansų rinkos yra dinamiškesnės ir turinčios daugiau neapibrėžtumų nei vartojimo prekių rinkos. Šių rinkų palyginimas pateiktas 1 lentelėje (žr. 1 lent.).

1 lentelė: Vartojimo prekių rinkos ir finansų rinkos palyginimas

Vartojimo prekių rinka	Finansų rinka
• konkurencija: rinkoje yra daug pardavėjų ir pirkėjų, kurie konkuruoja tarpusavyje, siekdami gauti geriausią pasiūlymą ar kainą. • paklausa ir pasiūla: rinka valdoma paklausos ir pasiūlos sąlygomis, kurios reguliuoja kainas ir kieki. • marketingas: įvairios įmonės stengiasi įtikinti pirkėjus pirkti savo prekes ar paslaugas, naudodamos reklamas, renginius ir kitas marketingo priemones. • skirtingi vartojimo prekių tipai: rinkoje yra skirtingų tipų vartojimo prekių, kurios skiriasi savo kokybe, kainomis ir vartojimo būdais. • vartotojų poreikiai ir norai: vartotojai turi skirtingus poreikius ir norus, kurie formuoja rinkos paklausą ir reguliuoja prekių kainas • sąveika: rinkos dalyviai turi sąveikauti tarpusavyje, kad būtų sudaryti sandoriai ir suderintos abiejų šalių naudos sąlygos.	• didelis kompleksiskumas: finansiniai produktai yra labai įvairūs ir sudėtingi, todėl norint juos suprasti, reikia turėti specializuotų žinių ir analitinės patirties. • rizika: finansiniai produktai dažnai yra susiję su rizika, kurios dydis gali skirtis priklausomai nuo produkto ir pačios rinkos sąlygų, kurioje šis finansinis produktas yra prekiaujamas. • greitas pokytis: finansinių produktų rinkos dažnai kinta labai greitai, dėl to investuotojams ir prekyautojams reikia nuolat stebėti situaciją, kad galėtų reaguoti į pokyčius ir pasinaudoti galimybėmis. • likvidumas: finansiniai produktai dažnai prekiaujami rinkose, kuriose yra didelis dalyvių skaičius ir aktyvumas, todėl finansiniai produktai pasižymi aukštu likvidumu. • tarpininkavimas: dauguma finansinių produktų reikalauja tarpininkavimo, pavyzdžiui, banko arba maklerio, kuris teikia reikiamas paslaugas ir patogumus, tačiau tai taip pat sukelia papildomas išlaidas investuotojui. • informacijos asimetrija: rinkoje gali egzistuoti informacijos asimetrijos, kai vienos šalies informacija yra geriau komuniikuojama nei kitų. Tai gali sukelti problemų investavimo metu bei reikalauti papildomų pastangų, siekiant teisingai įvertinti produktų vertę ir riziką.

Norint suprasti, ką žmonės dabar daro su savo turimais pinigais, svarbu atkreipti dėmesį, kad vis daugiau vartotojų domisi ir stengiasi investuoti į įvairius finansinius produktus. Kaip rodo anksčiau aptartas tyrimas, vartotojai stengiasi vis adekvačiau vertinti savo kasdienius pirkinius, siekia mažinti vartotojiškumą, todėl vartojimo prekių rinka šiek tiek stabilizuojasi, tačiau ne greitai. Vienas iš tokių

signalų, reiškiančių apmažėjusį vartojimą, yra vis didesnis susidomėjimas finansiniu investavimu, kuris yra naudojamas kaip priemonė apsaugoti turtą nuo infliacijos. Kaip minėta anksčiau, infliacija yra tokia ekonominė būklė, kai bendros prekių ir paslaugų kainos didėja, o perkamoji galia mažėja. Todėl, laikant pinigus tiesiog banko sąskaitoje, jų vertė gali nuvertėti ir vartotojo perkamoji galia sumažėja. Kartu su didėjančia infliacija, ekonomistai vis labiau ir drąsiau šneka apie ekonominę recesiją. Recesija yra ekonominio ciklo fazė, kai ekonomikos augimas sulėtėja arba sustoja, o tai dažniausiai reiškia, kad mažiau gaminama ir prekiaujama, todėl šalyje reikalinga turėti mažiau darbo vietų. Etatų mažinimas gali būti vadinamas „darbuotojų skaičiaus mažinimu“ arba „darbuotojų atleidimu“. Taip pat, terminai, kurie dažnai naudojami šia tema yra „darbuotojų rinkos restruktūrizacija“, „darbo jėgos sumažinimas“, „darbuotojų atleidimas“ arba tiesiog „atleidimas“. Paprastai tariant, recesija įvyksta, kai tam tikri ekonomikos rodikliai, tokie kaip BVP, pramonės gamybos rodikliai, prekybos apimtys pradeda mažėti, o nedarbo lygis išauga. Priežastys, dėl kurių gali kilti recesija, yra įvairios, pavyzdžiui, finansų krizės, didėjantis nedarbo lygis pasaulyje, mažėjantis vartotojų ir verslo pasitikėjimas, gamybos ir prekybos apimčių mažėjimas. Kaip teigia P. Termin, recesijos metu dažnai kyla ekonominė ir socialinė įtampa, sietina su visuomenės depresija [37]. Todėl valstybės ir ekonomistai stengiasi imtis veiksmų, kad būtų sumažintos recesijos pasekmės ir atkurtas ekonomikos augimas. 2021 metais Graikijoje atlikto tyrimo rezultatai rodo, kad depresija, nerimas, trauminis stresas, perdegimai sveikatos sektoriaus darbuotojų yra susiję su Graikijoje besitęsiančia ekonomine recesija [38].

Taigi, siekiant išvengti infliacijos ir recesijos įtakos, vartotojai vis labiau investuoja į finansines priemones, tokias kaip akcijos, obligacijos ar investiciniai fondai, kriptovaliutos ir kita. Taip žmonės turi galimybę gauti didesnę pelną nei laikydami pinigus tiesiog banko sąskaitoje ar kitose mažiau pelningose priemonėse. Taip pat, investuojant, yra galimybė rinktis investicines priemones, kurios yra mažiau rizikingos ir saugesnės, kurios ne tik padeda išlaikyti turto vertę, bet ir didina turimą turtą. Nors investavimas yra rizikingas procesas, tačiau investuodami į finansines priemones tačiau vartotojai vis tiek didina galimybes užsitikrinti finansinį stabilumą. Be to, ilgalaikėje perspektyvoje ir diferencijuojant investicinį portfelį, renkantis investuoti į skirtingas priemones, investavimo rizika gali būti sumažinta ir stabilus pelnas gali būti pasiektas. Kitame skyriuje apžvelgsime investavimo tendencijas į kriptovaliutų rinką.


1.2. Kriptovaliutų rinkos tendencijų apžvalga 2010–2023 metais

Kriptovaliutų rinkos tendencijos per pastaruosius kelis dešimtmečius buvo intensyviai stebimos ir analizuojamos. Kriptovaliutos tapo nauju ir įdomiu finansų pasaulio reiškiniu, kuris pritraukė didelį dėmesį visame pasaulyje, o ypač pastaraisiais metais, kai ekonomika susidūrė su karo, pandemijos ir recesijos reiškiniais. Per pastaruosius kelis dešimtmečius kriptovaliutų rinka pasiekė didžiulę vertę ir tapo viena iš sparčiausiai augančių finansinių rinkų, pritraukiančia dėmesį visoje finansų bendruomenėje, ypatingai išpopuliarėjo tarp investuotojų. Ši rinka yra patraukli tuo, nes nepaisant įvairių pokyčių pasaulinėje ekonomikoje, šiandien kriptovaliutų rinka tęsia savo augimą ir raidą, o atskiri kriptovaliutų projektai, tokie kaip *Bitcoin*, *Ethereum* ir kiti, turi didelį poveikį finansų pasauliui ir gali sukelti bei diktuoti naujas finansines tendencijas ateityje. Kriptovaliutų rinkos potencialą pastebėjo ne tik patys kriptovaliutų entuziastai, bet ir didžiulės finansų korporacijos, investuotojai, verslai, valstybės. Naujos technologijos ir inovacijos, kurios yra naudojamos kriptovaliutų rinkoje ir produktuose, yra labai patrauklios dėl technologinės pažangos ir yra manoma, kad kriptovaliutos gali sukurti naujas

finansų ir technologijų platformas. Nepaisant to, kad kriptovaliutos buvo laikomos alternatyviosiomis investicijomis, daugelis vartotojų pradėjo matyti jų potencialą kaip tikrai naudingo ir patikimo finansinio instrumento. Kriptovaliutos leidžia lengviau atlikti mokėjimus, investuoti į turtą, gauti paskolas ir kitaip naudoti finansų paslaugas. Ši kriptovaliutų rinka yra decentralizuota ir nesusijusi su tradicinėmis finansų institucijomis. Finansų krizės, lėmusios bankams didelius nuostolius 2008 metais, gali būti priežastis, kodėl dar ir dabar žmonės jaučiasi nepasitikintys bankais. Čia pranašesnės kriptovaliutos, kurios siūlo alternatyvą tradicinėms finansų institucijoms, kurias kai kurie žmonės laiko neperskaitomomis ir nevertomis pasitikėjimo. Be to, kriptovaliutos vartotojui siūlo didesnę privatumą ir anonimiškumą, kas yra svarbu tiems, kurie nenori, kad jų finansiniai veiksmai būtų stebimi ar kontroliuojami valstybiniu lygiu. Žmonės šiais laikais yra linkę saugoti savo duomenis, nes yra jaučiamas vis labiau didėjantis susirūpinimas dėl privatumo ir saugumo. Dažnėjant technologijų naudojimui ir interneto plėtrai, vartotojai palieka daug asmeninės informacijos internete, kuri gali būti perduodama, naudojama netinkamais tikslais ar net vagiama be jų sutikimo. Kaip parodė karo Ukrainoje kontekstas, jaučiamas didėjantis pavojus dėl kibernetinių išpuolių, kurie gali sukelti didelę žalą asmeninėms finansinėms priemonėms, taip pat asmeniniam gyvenimui ir reputacijai. Šiuo aspektu gana sparčiai dirba ir daug savo finansų skiria nedraugiškos Rytų šalys – Kinija, Rusija. Dėl šių priežasčių žmonės pradeda daugiau dėmesio skirti privatumui ir saugumui, naudoja šifruotus ryšius, virtualų privatų tinklą (angl. *virtual private network (VPN)*), saugius slaptažodžius ir stengiasi naudotis kitomis priemonėmis, kad apsaugotų savo asmeninę informaciją. Dėl to vartotojus traukia kriptovaliutos, kurios yra decentralizuotos ir taip pat siūlo greitesnius ir pigesnius mokėjimus, aktualius žmonėms, gyvenantiems šalyse, kuriose tradicinės bankų paslaugos yra neprieinamos arba brangios.

Toliau apžvelgsime pačią kriptovaliutų rinką, atsiradimo laiką, svarbiausius faktus žinomus šiandien, ir naudojamą technologiją. Kriptovaliutų pramonės analizės tyrime R. Farrelis teigia, kad nors kriptovaliutų rinka kaip reiškinys atsirado tik 2009 metais, per savo trumpą gyvavimo laiką pasikeitė ir išstobulėjo nuo prototipinio modelio [39]. Kriptovaliutų rinka siejama su pirmosios kriptovaliutos atsiradimu – *Bitcoin*. 2023 metų naujienų įmonės *Forbes* pateiktame straipsnyje teigiama, kad šiuo metu remiantis *CoinMarketCap* duomenimis egzistuoja net 22932 skirtingos kriptovaliutos, kurių bendra kapitalizacijos vertė siekia daugiau kaip 1,1 trilijoną dolerių [40]. Pažvelkime į *Yahoo Finance* pateikiama kriptovaliutų aktyvų vertinimo grafiką (angl. *Market Cap Intraday*) (žr. 9 pav.). Tai yra finansinio aktyvo, šiuo atveju, kriptovaliutų rinkos vertė, apskaičiuota kaip šios prekės prekybos kaina rinkoje padauginta iš jos visų išleistų vienetų skaičiaus. Tai yra svarbi finansinio aktyvo vertinimo metrika, nes ji padeda investuotojams nustatyti, kokia yra bendra prekės vertė, koks yra prekės populiarumas ir kaip prekė yra vertinama rinkos dalyvių. *Intraday Market Cap* reiškia šios vertės pokyčius per prekybos dienos laikotarpį. Kaip matome grafike (žr. 9 pav.) didžiausią kriptovaliutų rinkos kapitalizaciją užima *Bitcoin*, toliau *Etherium*, *Tether*, *Binance Coin*, *USD Coin* ir *XRP* kriptovaliutos.

Cryptocurrencies / Latest News



9 Pav.: Kriptovaliutų aktyvo vertinimo grafikas pagal kapitalizaciją (*heatmap*), 2023-04-21 duomenys.
Šaltinis: *Yahoo Finance*

Šiame grafike taip pat pateikiamas ir dienos kainos pasikeitimas, išreikštas procentais. Matoma, kad šiame pavyzdyje, *karščio žemėlapyje* grafike, dominuoja raudona spalva, reiškia, kad kriptovaliutų kaina nuo praėjusios dienos sumažėjo (neigiamas prieaugio procentas).

Norint detaliau pažvelgti į tikslią kriptovaliutos kainą, kapitalizaciją, pokytį, reikalinga vertinti kuo naujausius duomenis (žr. 10 pav.). Šiuo atveju pateikiami 2023-04-21 dienos duomenys, apžvalga pateikiama lentelėje (žr. 2 lent.).

TOP 10 cryptocurrencies by market capitalization



(Date: 2023-04-21)

Results were generated a few mins ago. Pricing data is updated frequently. Currency in USD

Symbol	Name	Price (Intraday)	Change	% Change	Market Cap	Volume in Currency (Since 0:00 UTC)	Volume in Currency (24Hr)	Total Volume All Currencies (24Hr)	Circulating Supply
BTC-USD	Bitcoin USD	28,183.25	-543.51	-1.89%	545.413B	21.001B	21.001B	21.001B	19.352M
ETH-USD	Ethereum USD	1,915.10	-41.97	-2.14%	230.609B	11.707B	11.707B	11.707B	120.416M
USDT-USD	Tether USD	0.9999	-0.0004	-0.0435%	81.394B	35.323B	35.323B	35.323B	81.406B
BNB-USD	BNB USD	327.10	+2.03	+0.62%	50.983B	974.504M	974.504M	974.504M	155.865M
USDC-USD	USD Coin USD	1.0000	-0.0000	-0.0040%	30.969B	5.494B	5.494B	5.494B	30.968B
XRP-USD	XRP USD	0.4669	-0.0249	-5.0620%	24.160B	1.53B	1.53B	1.53B	51.751B
ADA-USD	Cardano USD	0.4000	-0.0150	-3.6088%	13.917B	442.628M	442.628M	442.628M	34.789B
DOGE-USD	Dogecoin USD	0.0840	-0.0074	-8.0823%	11.682B	1.456B	1.456B	1.456B	139.03B
STETH-USD	Lido Staked ETH USD	1,902.27	-37.19	-1.92%	11.567B	41.064M	41.064M	41.064M	6.081M
HEX-USD	HEX USD	0.0584	-0.0100	-14.6324%	10.133B	14.496M	14.496M	14.496M	173.411B

10 Pav.: TOP 10 kriptovaliutų pagal kapitalizaciją. 2023-04-21 duomenys. Šaltinis: *CoinCapMarket*

2 lentelė: Top 10 kriptovaliutų pagal kapitalizaciją palyginimas. 2023-04-21 duomenys

Pavadinimas	Kaina (USD)	Kapitalizacija (USD)	Komentaras
Bitcoin (<i>BTC</i>)	28 183,25	545 413 100 157	Pirmoji ir didžiausia kriptovaliuta pagal kapitalizaciją, paremta blokų grandinės technologija (angl. <i>blockchain</i>). Sukurta 2009 metais. <i>Bitcoin</i> yra vertinama kaip saugi ir decentralizuota valiuta, nepriklausoma nuo valstybių ir centrinių bankų.
Ethereum (<i>ETH</i>)	1 915,10	230 609 200 235	Antra pagal kapitalizacijos dydį kriptovaliuta, kuri buvo sukurta 2015 metais ir taip pat paremta blokų grandinės technologija. <i>Ethereum</i> turi savo kriptovaliutos (<i>ETH</i>) mokėjimo formą, vadinamą išmaniuoju kontraktu (angl. <i>smart contract</i>).

Tęsinys kitame puslapyje

Pavadinimas	Kaina (USD)	Kapitalizacija (USD)	Komentaras
Tether (<i>USDT</i>)	0,99	81 394 114 667	Tai 2014 metais sukurta stabilioji kriptovaliuta (angl. <i>stablecoin</i>), susiejama su JAV dolerio kursu. <i>Tether</i> yra naudojama kaip alternatyva tradiciniams bankų pavedimams ir mokėjimams, ir yra dažnai naudojama prekyboje kriptovaliutomis, nes suteikia galimybę greitai konvertuoti kriptovaliutas į JAV dolerius ir atvirkščiai.
Binance Coin (<i>BNB</i>)	327,10	50 983 272 408	Tai 2017 metais sukurta kriptovaliuta, susijusi su įmone <i>Binance</i> – viena iš didžiausių kriptovaliutų biržų pasaulyje. <i>BNB</i> naudojama kaip valiuta mokėti mokesčiams, o taip pat suteikia nuolaidas <i>Binance</i> biržoje prekiaujantiems vartotojams.
USD Coin (<i>USDC</i>)	1,00	30 968 075 424	2018 metais sukurta kriptovaliuta, kurios vertė yra susieta su JAV dolerio kursu, ir tai reiškia, kad vienas <i>USDC</i> yra lygi vienam JAV doleriui. Priskiriama stabiliosioms kriptovaliutomis, nes vertė yra fiksuota ir negali smarkiai kisti.
XRP (<i>XRP</i>)	0,47	24 160 336 539	XRP yra 2011 metais finansų technologijų bendrovės <i>Ripple</i> sukurta kriptovaliuta. <i>Ripple</i> platforma leidžia atlikti greitas ir pigias tarptautines pavedimų operacijas, o <i>XRP</i> valiuta yra naudojama valiutų keitimo operacijose platformos viduje. Ši kriptovaliuta turi platus taikymo spektrą.
Cardano (<i>ADA</i>)	0,40	13 917 057 606	Tai kriptovaliuta, kuri buvo sukurta 2015 metais, o jos platforma leidžia vartotojams kurti ir decentralizuotai naudoti aplikacijas. <i>Cardano</i> yra vertinama už savo technologinį inovatyvumą ir saugumą.

Tęsinys kitame puslapyje


lentelė 2 – tęsinys

Pavadinimas	Kaina (USD)	Kapitalizacija (USD)	Komentaras
Dogecoin (<i>DOGE</i>)	0,08	11 682 581 513	<i>Dogecoin</i> yra populiari kriptovaliuta, kuri išsiskiria žaismingu ir netgi juokingu stiliaus požiūriu lyginant su kitomis kriptovaliutomis. Nors ši kriptovaliuta 2013 metų pabaigoje buvo sukurta kaip juokas, dabar turi didelį populiarumą ir kapitalizaciją.
Lido Staked ETH (<i>STETH</i>)	1 902,27	11 567 963 254	Ši kriptovaliuta buvo sukurta 2020 metais, veikia ant <i>Ethereum</i> tinklo. Jis leidžia vartotojams „pastatyti“ savo <i>ETH</i> tam tikroje skaitmeninių kontraktų sistemoje, siekiant gauti palūkanų už savo indėlį. <i>STETH</i> padeda užtikrinti tinklo saugumą ir efektyvumą, skatina vartotojus išlaikyti savo <i>ETH</i> tam tikruose sandoriuose, o ne laikyti juos neaktyviai.
HEX (<i>HEX</i>)	0,06	10 133 258 541	<i>HEX</i> yra decentralizuota kriptovaliuta, sukurta 2019 metais Richardo Hearto, <i>Bitcoin</i> investuotojo ir konsultanto. Ji remiasi <i>Ethereum</i> blokų grandine ir naudoja <i>HEX</i> kontraktą. Vartotojams leidžiama užstatyti savo turimą <i>HEX</i> ir gauti procentą nuo savo investicijos.

Taip pat, reikšminga pažvelgti į *Bitcoin* dominavimo diagramą, kuri kokia dalis visos kriptovaliutų rinkos kapitalizacijos priklauso nuo *Bitcoin*. Ši diagrama padeda atskleisti, kaip stipriai *Bitcoin* paveikia visą kriptovaliutų rinką (žr. 14 pav.).

Major Cryptoassets By Percentage of Total Market Capitalization (Bitcoin Dominance Chart)

May 5, 2013 — Apr 21, 2023



11 Pav.: Bitcoin dominavimo diagrama 2013 05 05 – 2023 04 21. Šaltinis: CoinCapMarket

Toliau apžvelgsime šios rinkos kainos dinamiškumo tendenciją. Kaip ir kituose finansiniuose produktuose, kriptovalitoms taip pat būdingos šios dvi rinkos būsenos kainos augimo periodas (angl. *bull market*) ir kainos kritimo periodas (angl. *bear market*). Tai yra periodiškai pokyčiai, kurie veikia rinkos vertę, prekių paklausą ir investuotojų elgseną. Kainos augimo laikotarpis, yra periodas kai rinkos vertė didėja ir investuotojai yra optimistiškai nusiteikę dėl rinkos ateities, renkasi investuoti daugiau. Toks laikotarpis gali trukti nuo kelių mėnesių iki kelių metų, dažnai šiuo periodu investuotojai sulaukia pelno. Tačiau, tai gali būti ir netikras rinkos burbulas, kai kainos kilimas tampa per didelis ir neatspindi realios rinkos vertės. Priešingai, kainos kritimo laikotarpis yra laikas, kai kriptovaliutos kaina nuolat mažėja, jaučiamos pesimistinės nuotaikos dėl rinkos ateities. Šiuo laiku investuotojai dažnai yra linkę laikyti savo investicijas arba siekia jas parduoti, taip bandydami sumažinti savo nuostolius. Geriausias būdas matyti kriptovaliutų kainų nestabilumą grafike yra naudojant žvakių diagramą (angl. *candlestick chart*). Šis grafikas yra dažnai naudojamas finansų srityje ir rodo tam tikro finansinio produkto atidarymo, uždarymo, aukščiausią ir žemiausią kainas pasirinktam laiko periodui. Pažvelgus į bitkoino mėnesinį žvakės grafiką, galima matyti, kokia nestabili ši valiuta buvo nagrinėjamu periodu: nuo 2016 iki 2023 metų (žr. 12 pav.). Ilgos žalios žvakės stebimos nuo 2020 metų spalio mėnesio iki 2021 metų kovo mėnesio. Čia ryškus kainos pakilimo laikotarpis – stebimas *bull market* reiškinys. Taip pat, išskirtini du ryškūs periodai, kai bitkoino kaina krito, tai 2021 metų lapkričio – 2022 metų sausio periodas ir 2022 metų balandžio – liepos mėnesiai, kuomet pastebimas *bear market* reiškinys. Šiame pavyzdyje, dėl vizualinių priežasčių, pasirinkta stebėti mėnesinių duomenų žvakių diagramą, tačiau pabrėžtina tai, kad tiriant trumpuoju periodu – valandinius, dieninius, savaitinius duomenis, matoma ir daugiau kainos pakilimo ir nukritimo tendencijų.

Bitcoin USD (BTC-USD)

Monthly BTC Candlestick Patterns (2016 to 2023)

Data source: CCC - CoinMarketCap



12 Pav.: Bitcoin žvakių diagrama 2016–2023 metais. Šaltinis: Yahoo Finance

Tolimesniame skyriuje apžvelgsime priežastis, kodėl taip stipriai keičiasi kriptovaliutų kainos ir kodėl kriptovaliutų rinka yra laikoma viena greičiausiai besikeičiančių finansinių produktų rinka.

1.3. Kriptovaliutų spekuliacijos ir vartotojų elgsena investavimo metu

Ryškūs kainos kritimo ir augimo periodai, nurodo dar vieną signalą, susijusį su investuotojų elgsena. Kriptovaliutų rinka dažnai yra laikoma ar finansų ekspertų vadinama nepatikima, dėl didelių vartotojų spekuliacijų, išorės veiksnių. Kaip teigia Y. Zhangas ir kiti [41] pastaraisiais metais kriptovaliutų rinkose stebimas itin neramus laikotarpis, stebimi ryškūs kainos augimo ir kritimo periodai rodo didelį šios rinkos volatilumą. V. Kallinterakis ir Y. Wang tyrime [42] pastebi, kad šie kainos pakilimo ir nukritimo periodai turi reikšmingą ryšį su investuotojų elgesiu, kuomet investuotojai pamiršdami asmeninius investavimo motyvus, pradeda elgtis kaip visi – atsiranda bandos jausmas (angl. *herding behaviour*). Šis investuotojų elgesys ekspertams sukelia abejones, ar kriptovaliutų rinka gali būti ta rinka, kurioje yra galimos patikimos ilgalaikės investicijos, tokios kaip akcijų, obligacijų rinkose. Būtent dėl šių nepastovių, ar neprognozuojamų vartotojų elgsenos pokyčių, daugelis kriptovaliutų yra labai volatiliškos (dinamiškos) – darosi vis sunkiau ir sunkiau matematiniais modeliais aprašyti bei prognozuoti kriptovaliutų grąžas. Čia verta paminėti apie kriptovaliutų rinkai būdingą terminą – privačių asmenų ar įmonių valdomas didelio kapitalo kriptovaliutų pinigines – *kriptovaliutų banginius* (angl. *crypto whale wallets*). Kadangi kriptovaliutų perlaidos yra viešos, tačiau anonimiškos, pritaikius algoritmus bei sekant naujienas, galima identifikuoti pagrindinius asmenis ar organizacijas, kurie yra sukaupę reikšmingą kriptovaliutų kapitalą. Sekant *kriptovaliutų banginių* elgesį, mažesnę kapitalą turintys investuotojai yra linkę kartoti lyderiaujančių investuotojų elgesį ir taip atsiranda terpė kriptovaliutų spekuliacijoms. Žemiau lentelėje (žr. 3 lent.) pateikiama informacija apie didelį kapitalą ir didelę įtaką kriptovaliutų rinkos investuotojams darančias pinigines.

3 lentelė: Didelį kriptovaliutų kapitalą turinčių piniginių pavyzdžiai. 2023-04-27 duomenys

Pavadinimas	Vertė kriptovaliuta	Kapitalizacija (USD)	Komentaras
Bitcoin Wallet Bitfinex-coldwallet	193 958,12 <i>BTC</i>	5 622 313 769	Šaltinis www.bitinfocharts.com
Binance hot wallet	10 815 099 <i>BNB</i>	3 589 531 484	Šaltinis www.bscscan.com
BlueWhale0144	1 780 840 <i>ETH</i>	3 088 043 180	Šaltinis www.whalestats.com
Dumbledore	450 118 <i>ETH</i>	724 978 665	Šaltinis www.whalestats.com
Daenerys	325 000 <i>ETH</i>	528 672 692	Šaltinis www.whalestats.com
Frodo	259 958 <i>ETH</i>	472 657 557	Šaltinis www.whalestats.com
Moiraine	254 248 <i>ETH</i>	413 866 643	Šaltinis www.whalestats.com
Xena	250 000 <i>ETH</i>	410 636 275	Šaltinis www.whalestats.com
BitMEX cold wallet	14 143,12 <i>BTC</i>	410 517 785	Šaltinis www.bitinfocharts.com
Aragorn	243 300 <i>ETH</i>	396 088 601	Šaltinis www.whalestats.com

Taip pat, remiantis *DailyCoin* [43] duomenimis, yra žinomi keli svarbūs investuotojai, kurių veiksmams kriptovaliutų rinkoje yra stebimi mažų investuotojų ir sekami bei sau pritaikomi investiciniai sprendimai. Šie investuotojai yra:

- Vitalik Buterin – yra *Ethereum* kriptovaliutos bendrąkūrėjas. *Ethereum* yra antra pagal rinkos kapitalizaciją kriptovaliuta, o Vitalik Buterin yra gerai žinomas asmuo kriptovaliutų rinkoje. Jis dalyvavo šios valiutos kūrimo projekte ir dirbo kuriant išmaniuosius kontraktus ir decentralizuotas aplikacijas. Vitalik Buterin prisidėjo prie to, kad *Ethereum* technologija taptų plačiai naudojama ir vertinama kriptovaliutų bendruomenėje;
- Elon Musk – Tesla ir SpaceX vadovas ir įkūrėjas, žinomas dėl savo įtakos kriptovaliutų rinkai naudojant platformos *Twitter* įrašus ir žinutes. Jo komentarai dažnai sukelia didelių kainų svyravimus *Bitcoin* ir *Dogecoin* kriptovaliutose. Tai parodo, kad įtakingo žmogaus komentarai ir nuomonė yra svarbus argumentas kriptovaliutų investuotojams;
- Brian Armstrong – yra *Coinbase*, vienos didžiausių kriptovaliutų biržos Jungtinėse Amerikos Valstijose, vadovas. Jis yra svarbus asmuo, prisidedantis prie kriptovaliutų populiarinimo ir jų prieinamumo didinimo plačiai visuomenei. Šis žmogus tai daro naudodamas ir populiarindamas *Coinbase* platformą, kuri yra laikoma patogia ir saugia kriptovaliutų pirkimui, pardavimui ir saugojimui;
- Changpeng Zhao – yra *Binance*, vienos didžiausių kriptovaliutų biržų pasaulyje, vadovas. Jis yra žinomas dėl savo iniciatyvumo ir ryžtingumo, kuris padėjo *Binance* biržai sparčiai išaugti nuo jos įkūrimo 2017 metais. Per pastaruosius metus Changpeng Zhao ir *Binance* komanda sukūrė patikimą ir efektyvią kriptovaliutų biržą, kurioje yra prekiaujama daugybe kriptovaliutų. Šis žmogus taip pat siekia plėsti *Binance* veiklą, pavyzdžiui, sukurdamas savo kriptovaliutų ekosistemą, kurioje vartotojai galėtų naudoti kriptovaliutas ne tik prekybai, bet ir kitoms paslaugoms, tokioms kaip mokėjimai ir finansinės paskolos;


- Winklevoss twins – Cameron Winklevoss ir Tyler Winklevoss plačiai išgarsėjo po to, kai laimėjo bylą prieš Mark Zuckerberg, kurioje jie tvirtino, kad jų socialinio tinklo platformos idėja buvo pavogta. 2012 metais, jie laimėjo šią bylą ir prisiteisė 65 milijonus dolerių, kuriuos nusprendė didžiąją dalimi investuoti į *Bitcoin*. Šiuo metu jie turi daugiau nei 70 000 *Bitcoin* ir kitų kriptovaliutų. 2014 metais, broliai įkūrė *Gemini* kriptovaliutų biržą, kurią investuotojai noriai naudojami ir pasitiki [44].

Spekuliacijos ar kiti grupiniai susitarimai tarp investuotojų iškreipia tikrą rinkos vertę, atsiranda ekonominis kainos burbulas. Kaip teigia J. Čiburienė [45] spekuliacijos atlieka tam tikrą ekonominę funkciją – perkelia prekes iš jų pertekliaus sąlygų (su mažomis kainomis) į deficito sąlygas (su didelėmis kainomis). Taip pat, spekuliacinės tendencijos turi didelę įtaką rinkos paklausos, pasiūlos ir kainų pokyčiams. Pastebima, kad dažnas kokių nors finansinių produktų supirkimas gali sukelti netikėtą šių finansinių produktų kainų padidėjimą (vadinamąjį kainų burbulą), po kurio dažniausiai įvyksta visuotinis jų pardavimas ir žymus kainų kritimas [46]. Įdomu tai, kad remiantis L. Ante [47] tyrimu, E. Musko pasisakymai platformoje *Twitter* turi įtaką kriptovaliutų *Bitcoin* ir *Dogecoin* kainai tą dieną, kai jis kažką paskelbia. Tai yra vadinama Musko efektu (angl. *Musk Effect*). Šis tyrimas rodo, kokia reikšminga yra socialinės žiniasklaidos veikla, kuomet tai yra susiję su įtakingų asmenų pasisakymais apie kriptovaliutų rinką. Pailčiai rinkai tai rodo konfliktą tarp moralės, rinkos manipuliavimo rizikų ir investuotojų apsaugos.

Be šių rinkos kainos iškreipimo faktų dėl vartotojų elgsenos ar šiai rinkai įtakingų žmonių veiksmų, kriptovaliutų rinka taip pat yra laikoma rizikinga dėl to, kad yra decentralizuota ir anonimiška, o tai sudaro sąlygas įvairiems finansiniams nusikaltimams [48]. Nors kai kurios kriptovaliutos yra saugios ir yra naudojamos kaip pervedimo ir mokėjimų priemonės, tačiau yra ir kriptovaliutų, kurių vartotojai yra labiau linkę į nusikalstamas, nelegalias transakcijas. Yra žinoma, kad kriptovaliutos gali būti naudojamos neteisėtoms veikloms, tokioms kaip, narkotikų prekyba, prekyba ginklais, pinigų plovimas ar terorizmo finansavimas, o dėl anonimiškumo fakto yra sunku jas aptikti ir sustabdyti. Šioje rinkoje dažnai kalbama apie *Ponzi* schemas – tai schemas, kurios yra vadinamos „pinigų perkėlimo“ schemomis. Tai tokia schema, kurios metu sukčiautojai sukuria netikrą investicinę sistemą, ir jie teigia, kad investuojant į šią sistemą, investuotojai gali gauti didelius pelnus arba dideles palūkanas per trumpą laiką. Šios sistemos savininkas apgauna naujus investuotojus ir naudoja jų pinigus, kad išmokėtų ankstesnius įsipareigojimus ankstesniems investuotojams. Kaip teigia S. Baum [49] dažniausiai sukčių finansinis produktas (investicinis fondas, akcijos, obligacijos, kriptovaliutos ir kita) neturi nė vieno realios finansinio produkto vieneto, o naujus investuotojus pritraukia suklustotomis ataskaitomis, nerealistišką aukštą pelną žadančiais skaičiais ir netikromis „senųjų investuotojų“ rekomendacijomis. Tokiu pagrindu ir tokiomis schemomis remiantis, atsiranda vis daugiau finansinių technologijų įmonių (angl. *fintech*) tiek Lietuvoje, tiek visame pasaulyje. Remiantis naujienų portalu *Verslo žinios* informacija, 2022 metų duomenimis, Lietuvoje 2021 metų pabaigoje buvo registruotos net 256 finansinių technologijų bendrovių (angl. *fintech*), ir jose dirbo daugiau nei 5 900 žmonių [50]. Čia taip pat svarbu paminėti ir tai, kad Lietuvos bankas, 2020 metų lapkritį, vienai žymiausių Lietuvos finansinių technologijų įmonei *Paysera*, skyrė 370 tūkstančių eurų baudą dėl pinigų plovimo prevencijos pažeidimų, tačiau pernai Vilniaus apygardos administracinis teismas (VAAT) beveik per pusę – iki 200 tūkst. eurų baudą sumažino. Šį teismo sprendimą apskundė ir Lietuvos bankas, ir įmonė [51].

Sugrįžtant prie globalios kriptovaliutų rinkos, svarbu suvokti, kaip skirtingose valstybėse yra reguliuojamos ir sekamos transakcijos, siekiant užtikrinti, kad jos būtų legalios. Kriptovaliutos gali būti reguliuojamos skirtingai priklausomai nuo to, kurioje šalyje jos naudojamos ir kokie yra tos šalies įstatymai ir reglamentavimo aktai. Kai kuriose šalyse kriptovaliutos yra reguliuojamos ir jų naudojimas yra ribojamas arba net draudžiamas, o kitose šalyse kriptovaliutos yra laikomos legalia priemone atlikti kasdienėms transakcijoms. Yra valiutų, kurios yra sukuriamos taip, nebūtų įmanoma atsekti transakcijų arba sekti jų perdavimo. Tokios kriptovaliutos yra žinomos kaip anoniminės arba privačios kriptovaliutos, remiantis *Investopedia* duomenimis [52] tai yra: *Monero (XMR)*, *Zcash (ZEC)*, *Dash (DASH)*, *Horizen (ZEN)*, *Verge (XVG)*, *Beam (BEAM)*. Tačiau kai kurios kriptovaliutos gali būti sekamos ir reguliuojamos, pavyzdžiui, jei jos yra susijusios su finansų institucijomis ar kitais reguliuojamais sektoriais. Svarbu atkreipti dėmesį, kad kriptovaliutos yra palyginti nauja technologinė finansinė priemonė, dėl to dauguma šalių ir bankų vis dar neranda tinkamų reguliavimo priemonių ir naudojimo taisyklių. Reguliavimo požiūris gali skirtis priklausomai nuo šalies, kurioje naudojamos kriptovaliutos ir nuo to, kaip greitai toje šalyje yra svarstomi nauji įstatymai, reguliavimai. Manoma, kad mažiau išsivysčiusios ekonomikos šalyse gali būti sunkiau sekti kriptovaliutas, nes šių šalių finansų infrastruktūros gali būti mažiau išsivysčiusios ir dažnai yra mažiau reglamentuojamos. Be to, kriptovaliutų naudojimas gali būti labiau paplitęs būtent šiose šalyse, nes jos gali suteikti lengvesnę prieigą prie finansinių paslaugų ir mažesnes mokesčių naudojantis kriptovaliutomis. Galima teigti, kad Malta yra viena iš šalių, kurios laikomos santykinai palankiomis kriptovaliutų reguliavimo ir mokesčių politikos požiūriu [53]. Malta tapo kriptovaliutų ir blokų grandinių verslo centru, nes įgyvendino aiškius įstatymus, kuriuose nurodomos gairės kriptovaliutų biržoms ir kitoms kriptovaliutų susijusioms įmonėms, o reguliavimo aplinka yra palanki kriptovaliutų pramonei. Kitos šalys, kurios yra laikomos tinkamomis kriptovaliutų rinkai yra Šveicarija, Singapūras ir Estija. Šios šalys visos ėmėsi veiksmų, kad suteiktų teisinį aiškumą apie kriptovaliutas ir siūlo palankias mokesčių politikas investuotojams ir verslams, naudojantiems kriptovaliutas. Čia svarbu pažymėti, kad kriptovaliutų reguliavimo aplinka vis dar vystosi ir prekiavimo sąlygos gali greitai pasikeisti [54]. Dėl vis dar neapibrėžto reguliavimo, daugėja kriptovaliutų vagysčių, pasinaudojant tinklu, manipuliacijomis ir kita. *Statista* duomenimis (žr. 13 pav.), 2018 metais kriptovaliutų vagysčių vertė buvo įvertinta 950 milijonais dolerių per metus, kai 2016 metais ši suma buvo 6,25 karto mažesnė ir siekė 152 milijonus dolerių. Įdomu tai, kad nors vagysčių 2019 metais buvo mažiau nei 2018 metais, tačiau 2020 metais, ši suma vėl paaugo ir siekė net 516 milijonų dolerių.

Value of cryptocurrency theft worldwide from 2016 to 2020
(in million U.S. dollars)



13 Pav.: Kriptovaliutų vagysčių vertė visame pasaulyje 2016-2020 metais. Šaltinis: *Statista*

Pagal *Statista* pateiktą statistiką, per ketverius metus, nuo 2018 iki 2022 metų globaliai sklidusių kenkėjiškų programų atakų dalis, kurios buvo vykdomos elektroninio pašto būdu, išaugo nuo 33 iki 86 procentų. Tuo tarpu, interneto atakų procentas sumažėjo nuo 67% 2018 metais iki 14% procentų 2022 metais [55]. R. Best teigimu nuo 2020 iki 2021 metų bendra kriptovaliutų vertė, kurios patyrė saugumo grėsmes ir buvo prarastos, išaugo daugiau nei devynis kartus. 2021 metų rugpjūčio mėnesį, internetinės atakos metu, kuri yra laikoma viena didžiausių kriptovaliutų vagysčių istorijoje, vienas asmuo pasirinko kaip tikslą *Ethereum* pagrindu veikiančią *DeFi* programą *Poly Network*, pasinaudodamas klaida tinklo kode įsilaužė į sistemą. Atakos metu hakeris pasisavino apie 610 milijonų dolerių. Po to, kai *Poly Network* kreipėsi į hakerį, anoniminis hakeris grąžino apie pusę pinigų – 342 milijonų dolerių – teigdamas, kad padarė vagystę „dėl linksmybių“ [56].

Statistika rodo, kad kriptovaliutų rinka yra labai dinamiška, tiek dėl kainos, tiek dėl saugumo, o tai gali sukelti nerimą ir paniką investuotojams. Dauguma vartotojų turi tendenciją sekti greito pelno siekiančias strategijas, tačiau tokia elgsena gali būti rizikinga ir investuotojai gali prarasti pinigus. Šie duomenys dar kartą įrodo, kad kuo daugiau laiko vartotojai praleidžia internete – virtualioje erdvėje, tuo daugiau finansinės veiklos jie vykdo, dėl to vis daugiau pasitaiko sukčių sukurtos atakos. Šios atakos yra nukreiptos prieš vartotojus ir orientuotos į tai, kad pavyktų neteisėtai pasisavinti pinigus vartotojų pinigus. Toliau apžvelgsime matematinius metodus, naudojamus anksčiau atliktuose tyrimuose.

1.4. Matematiniai metodai kriptovaliutų kainos pokyčiui analizuoti

Šiame skyriuje apžvelgsime matematinius metodus, naudojamus panašiuose moksliniuose tyrimuose. Tyrimų matematinių metodų apžvalgos lentelė (žr. 4 lent.):

4 lentelė: Matematiniai metodai naudojami finansų rinkos moksliniuose tyrimuose

Autorius, metai	Tyrimo objektas	Matematiniai metodai
D. B. Nelson, 1991 m. [57]	Volatilumą ir liekanų heteroskedastiškumo priklausomybę tiriantis mokslinis straipsnis susijęs su finansinių produktų grąžos vertinimu.	ARCH modelių patobulinimas, GARCH modelių kūrimo pradžia
N. Abu Bakar, S. Rosbi, 2017 m. [58]	Šiame straipsnyje atliekama kriptovaliutos kainos grąža ir volatilumo analizė, siekiama išanalizuoti kriptovaliutų kainų svyravimus, sukurti modelius volatilumo prognozavimui.	ARIMA, ACF ir PACF tiria BTC-USD valiutos kurso svyravimus
R. Matkovskyy, 2019 m. [59]	Šio tyrimo tikslas yra palyginti euro (<i>EUR</i>), dolerio (<i>USD</i>) ir britų svarą (<i>GBP</i>) centralizuotas ir decentralizuotas bitkoin kriptovaliutų rinkas, atsižvelgiant į kainos grąžos svyravimus ir tarpusavio priklausomybę. Gauta, kad decentralizuotoje bitkoin rinkoje stebimi didesni svyravimai, o centralizuotose rinkose stebima grąžų uodegos priklausomybę (angl. <i>tail dependency</i>).	ARIMA modeliai, GARCH, regresijos modeliai, koreliacijos, kointegracijos.
X. Zhong, D. Enke, 2019 m. [60]	Šio tyrimo objektas yra dieninės akcijų rinkos grąžos krypties numatymas naudojant hibridinius mašininio mokymosi algoritmus. Straipsnyje analizuojama S&P 500 indekso grąžos kryptis, remiantis daugiau nei 60 finansinių ir ekonominių rodiklių duomenimis.	PCA, Neural networks for pattern recognition, Multilayer feed-forward neural networks, ANN klasifikatorius, DNN klasifikatorius.
S. Corbet et al., 2020 m. [61]	Šiame straipsnyje nagrinėjamas naujienų socialiniuose tinkluose ir bitkoino grąžos ryšys. Ankstesniai tyrimai rodo, kad makroekonominės naujienos daro įtaką akcijų grąžoms, žaliavų kainoms ir palūkanų normoms. Šio tyrimo tikslas yra ištirti socialinių naujienų ir bitkoino grąžų ryšį ir nustatyti, ar makroekonominės naujienos daro įtaką šios kriptovaliutos grąžoms.	Statistinė laiko eilutės analizė, tiesinės regresijos modeliai, sentimentų analizė, koreliacijos, grafiniai priklausomybių grafikai.
C. Alexander, M. Dakos, 2020 m. [62]	Šio tyrimo tikslas yra išnagrinėti, kaip pasirinkta kriptovaliutų kaina ir jos šaltinis gali paveikti empirinės analizės rezultatus.	AR, GARCH, EGARCH, Markov grandinės

Tęsinys kitame puslapyje

Autorius ir metai	Tyrimo objektas	Matematiniai metodai
E. Akyildirim et al., 2020 m. [63]	Šiame tyrime aiškinamasi, kaip susiję <i>VIX</i> ir <i>VSTOXX</i> indeksų ir bitkoino kainos svyravimas. <i>VIX</i> ir <i>VSTOXX</i> indeksai akcijų rinkoje yra laikomi kaip kintamumo (svyravimo) indeksai, dažniai apibūdinami kaip „baimės indeksai“. Šiame straipsnyje ieškoma ryšio tarp šių rodiklių svyravimo ir bitkoino kainos. Naudoja GARCH(1,1) modelį kaip geriausiai tinkamą rizikos modeliavimui bitkoino atveju. Gaunama, kad kriptovaliutų rinkoje, bitkoino atveju stebimas didesnis volatilumas tais periodais, kai investuotojai jaučia baimę, t.y. <i>VIX</i> ir <i>VSTOXX</i> indeksai yra nuolat kintantys.	GARCH (1,1), DCC-GARCH
Z. Chen et al., 2020 m. [64]	Tyrimo objektas yra bitkoino kainos prognozavimas naudojant mašininių mokymąsi, išbandomi įvairūs matematiniai modeliai, naudojami 5 minutiniai bitkoin duomenys. LDA ir LR metodais gauti geriausi rezultatai 66% modelių tikslumai. Lyginant su mašininio mokymosi metodais naudojant šiuos duomenis, gauti geriausi 65.3% tikslumas taikant SVM algoritimą.	Logistic Regression (LR), Linear Discriminant Analysis (LDA), Random Forest (RF), XGBoost, Quadratic discriminant analysis (QDA), Support Vector Machine (SVM), Long Short-term Memory (LSTM)
S. Gu et al., 2020 m. [65]	Šio tyrimo tikslas yra palyginti skirtingus mašininio mokymosi metodus, siekiant išmatuoti turto rizikos grąžas - išspręsti finansinių produktų kainų modeliavimo problemą. Tyrimas parodo, kad naudojant mašininio mokymosi metodus galima sudaryti modelius, kurie prognozėse teikia informaciją investuotojams, o kai kuriais atvejais tokių prognozių efektyvumas yra dvigubai didesnis nei naudojant regresijos metodus, aprašytus literatūroje. Tyrimo autoriai nustato geriausiai veikiančius metodus (medžius ir neuroninius tinklus).	Simple linear, Robust objective functions, Penalized linear, duomenų dimensijos mažinimo metodai: PCR and PLS, Generalized linear, Boosted regression trees and random forests, Neural networks

Tęsinys kitame puslapyje

Autorius ir metai	Tyrimo objektas	Matematiniai metodai
Y. Liu et al., 2023 m. [66]	Šio straipsnio tikslas yra naudoti mašininio mokymosi modelius siekiant prognozuoti 3703 kriptovaliutų gražas laikotarpiui nuo 2013 iki 2021 metų, taip pat išnagrinėti kriptovaliutų elgesį finansų rinkoje. Autoriai šiuo tyrimu siekia pateikti naujų įžvalgų kriptovaliutų investuotojams ir finansų analitikams, naudoja mašininio mokymosi metodus. Naudoja kriptovaliutų, <i>Google Trends</i> , <i>Effective Federal Funds Rate (EFFR)</i> , nedarbingumo lygio, gamybos lygio, infliacijos ir kitus duomenis.	XGB modelis, SHapley Additive exPlanations (SHAP), LASSO, Ridge, Random Forest (RF), Gradient Boosting (GB), Feedforward Neural Networks (FFNN).

1.5. Literatūros apibendrinimas ir atliekamo tyrimo problematikos išgryninimas


Apibendrinant aukščiau pateiktą literatūrą, galima teigti, kad pastaraisiais dešimtmečiais pasaulinė ekonomika patyrė daugybę iššūkių, kurių įtaka jaučiama ir finansinėse rinkose. Vienas iš svarbiausių pasaulinės ekonomikos pokyčių yra sparčiai auganti tarptautinė prekyba. Ši tendencija susijusi su tarptautinės gamybos grandinės plėtra (dydžiu), kuri reiškia, kad produktai ir paslaugos yra gaminami skirtingose šalyse, o po to eksportuojami į kitas šalis. Šis procesas padidina pasaulinę konkurenciją ir gali turėti įtakos valiutų kursams, finansų rinkoms, o taip pat ir kriptovaliutų vertei. Kitas svarbus pasaulinės ekonomikos pokytis yra demografiniai pokyčiai. Ši tendencija reiškia, kad pasaulinė populiacija sensta, o tai daro įtaką ekonomikos rodikliams ir vartojimo prekių rinkai. Reiškia, kad senėjanti populiacija gali turėti mažesnę perkamąją galią, o tai gali sumažinti paklausą tam tikrose pramonės šakose. Taip pat senėjanti populiacija reiškia didesnę medicinos išlaidų kiekį, o tai daro įtaką sveikatos apsaugos sektoriui. Technologijų plėtra taip pat daro didelę įtaką finansinėms rinkoms, ypač – kriptovaliutų. Čia naudojamos naujausios technologijos, tokios kaip blokų grandinė, išmanieji kontraktai, kad užtikrintų saugumą ir skaidrumą, gali pagerinti kriptovaliutų pirkimo ir pardavimo efektyvumą. Remiantis anksčiau atliktų finansų rinkų tyrimų analize (žr. 4 lent.), matyti, kad dauguma tyrimų buvo grindžiami klasifikavimo metodais arba tiesinės regresijos modeliais. Regresiniai mašininio mokymo metodai finansų rinkų tyrimuose yra taikomi itin retai, o parenkant modelio regresorius, retai įtraukiami kintamųjų ankstiniai (angl. *lag*).

Sugrįžtant prie tyrimo pradžioje išsikeltų uždavinių, remiantis atlikta literatūros analize, savo tyrimą pirmiausia pradėsiu nuo detalios bitkoino kainos laiko eilutės analizės, stilizuotų faktų, siekiant įrodyti, kad ši laiko eilutė yra finansinė laiko eilutė ir yra matomi visi būdingi finansų rinkos požymiai. Tyrime pasirinkau tirti būtent bitkoino laiko eilutę, nes tai yra pagrindinė, pati pirmoji kriptovaliuta, turinti didžiausią kapitalizaciją, apimtį (angl. *volume*). Toliau, kaip išryškinta literatūroje, atlieku išorės veiksnių tyrimą, ieškant šablonų (angl. *patterns*), kurie yra susiję su bitkoino laiko eilute. Galiausiai, atlieku mašininio mokymosi metodais grįstą analizę, kurioje randami svarbiausi regresoriai, turintys reikšmingą įtaką bitkoino kainos pokyčiui.

2. Tyrimo objektas ir metodai

Kai pasirenkama aktuali tema ir nusprendžiama atlikti tyrimą, svarbu atkreipti dėmesį ne tik į tinkamų duomenų tyrimui rinkimą, bet ir į naudojamus metodus bei duomenų modelius, kurie yra būtini atlikti, siekiant gauti patikimus ir reprezentatyvius rezultatus. Analizuojant mokslininkų tyrimus, reikia atidžiai įvertinti jų panaudotus metodus ir technologijas, kad būtų galima patikrinti gautų rezultatų validumą. Be to, reikia atkreipti dėmesį į duomenų transformacijas, pavyzdžiui duomenų valymą, tvarkymą, kurie yra būtini norint pritaikyti duomenis analizei. Tai reiškia, kad svarbu turėti gilesnį supratimą apie duomenų apdorojimo ir analizės metodus, kad būtų galima gauti patikimus ir reprezentatyvius rezultatus, norint sudaryti matematinius modelius. Šiame skyriuje pateikiama apžvalga apie tyrimo metu naudojamus duomenis, metodus, bei pateikiama vienmačio atvejo bitkoino kainos gražos analizė, norint išmodeliuoti laiko eilutės liekanas (angl. *residuals*).

2.1. Tyrimo metodologinė schema



14 Pav.: Tyrimo metodologinė schema

2.2. Duomenų apžvalga

Visi analizėje naudojami duomenys yra surinkti iš „Investing.com“ duomenų bazės. *Investing.com* yra finansų rinkų platforma, teikianti realaus laiko duomenis, kainas, grafikus, naujienas ir analizę apimant daugiau kaip 250 finansinių biržų visame pasaulyje. Platformoje fiksuojama daugiau nei 46 milijonai mėnesinių vartotojų ir daugiau nei 400 milijonų fiksuotų vartotojo sesijų. *Investing.com* yra viena iš trijų didžiausių finansinių svetainių pasaulyje, remiantis *SimilarWeb* ir *Alexa* duomenimis

[67]. Šie duomenys surinkti pagal laiko filtrą, pasirenkant laikotarpį nuo 2010-01-01 iki 2023-04-21. Tyrime naudojamos logaritminės grąžos Y_t skaičiuojamos pagal formulę:

$$Y_t = \log(1 + R_t) = \log\left(\frac{P_t}{P_{t-1}}\right)$$

Čia R_t yra finansinio produkto dieninė aritmetinė grąža, P_t – finansinio produkto dieninė uždarymo kaina.

Analizėje 41 kintamasis – dieninės šių kintamųjų logaritminės grąžos (žr. 5 lent.):

5 lentelė: Tyrimo kintamieji. Šaltinis *Investing.com*

Kintamasis	Pavadinimas	Dažnis	Komentaras
AAPL	Apple Inc.	Daily	<i>Apple</i> yra viena iš populiariausių technologijų įmonių pasaulyje, kuri turi didelę rinkos vertę ir garsėja savo inovatyviais produktais. Finansiniame pasaulyje šios akcijos yra laikomos stabilios ir yra laikomos patikima investicija, nes įmonė dirba pelningai, turi gerą finansinę padėtį.
AEX	AEX Index	Daily	AEX yra pagrindinis Nyderlandų, Amsterdamo akcijų biržos indeksas, kuris apima 25 didžiausių ir likvidžiausių Nyderlandų įmonių akcijas.
AMD	Advanced Micro Devices Inc.	Daily	AMD – technologijų įmonė, specializuojasi mikroprocesorių ir grafinių procesorių gamyboje, konkurencinga dėl savo inovatyvių produktų. Šios akcijos yra populiarus pasirinkimas tarp investuotojų pastaruoju metu, turi didelį augimo potencialą ir naudojasi augančia skaitmeninių prietaisų paklausa.
AMZN	Amazon.com Inc.	Daily	<i>Amazon.com Inc</i> (AMZN) yra viena iš didžiausių internetinės prekybos platformų pasaulyje, kurios akcijos yra paklausios dėl įmonės didelės rinkos vertės, didelio augimo potencialo ir galimybių plėsti verslą įvairiose srityse.

Tęsinys kitame puslapyje

lentelė 5 – tęsinys

Kintamasis	Pavadinimas	Dažnis	Komentaras
AUD_USD	AUD/USD Exchange Rate	Daily	<i>AUD/USD</i> yra valiutų pora, kurioje Australijos doleris yra bazinė valiuta, o JAV doleris - kotiruojamoji valiuta. Pora yra populiarus pasirinkimas tarp investuotojų, kadangi ji atspindi dviejų svarbių pasaulio ekonomikų - Australijos ir JAV - santykį ir yra susijusi su daugybe įvairių sektorių, įskaitant finansų, eksportą ir importą.
BRENT	Brent Crude Oil Price	Daily	Brent naftos kaina yra svarbi investicinė priemonė, turinti įtaką finansų rinkoms, kuomet kalbama apie žaliavas. Didelės naftos kainos gali neigiamai paveikti pasaulio ekonomiką ir padidinti infliacijos riziką, taip pat gali turėti įtakos bendrajai prekių kainų infliacijai.
CAD_USD	CAD/USD Exchange Rate	Daily	Kanados dolerio ir JAV dolerio valiutų pora <i>CAD/USD</i> yra svarbi tarptautinėje prekyboje ir finansų sektoriuje, nes atspindi Kanados ir JAV ekonominį santykį, ši valiutų pora yra populiari investuoti ir yra dažnai naudojama kaip pagrindas daugelyje investavimo strategijų tarp šių šalių investuotojų.
CARBON	EUA Spot Carbon Price	Daily	EUA Spot kainų pokyčiai yra svarbus rodiklis Europos Sąjungos pastangoms sumažinti šiltnamio efektą sukeliančių dujų emisijas. Tai daro poveikį ne tik energetikos ir pramonės sektoriams, bet ir finansų rinkoms. Aukštos EUA Spot kainos gali padidinti investicijų patrauklumą į švariąsias technologijas.
CHF_USD	CHF/USD Exchange Rate	Daily	Šveicarijos franko ir JAV dolerio valiutų pora <i>CHF/USD</i> yra vertinga investicija, nes Šveicarijos bankų sektorius laikomas stabilia ir patikima finansų sistema. Be to, Šveicarijos frankas yra žinomas kaip patikima rezervinė valiuta ir yra svarbus veiksnys tarptautinėje prekyboje.

Tęsinys kitame puslapyje

lentelė 5 – tęsinys

Kintamasis	Pavadinimas	Dažnis	Komentaras
CNY_USD	CNY/USD Exchange Rate	Daily	<i>CNY/USD</i> yra svarbi valiutų pora tarptautinėje prekyboje, atspindinti Kinijos ekonomikos dydį ir reikšmę pasaulio ekonomikai. Kinijos valdžios politika, o taip pat Kinijos pozicija kaip didelės JAV skolos turėtojos, gali turėti poveikį šios valiutos kursui.
COPPER	Copper Price	Daily	Copper Price yra svarbus ekonominis rodiklis, nes varis yra naudojamas įvairiose pramonės šakose įskaitant statybą, elektroniką ir transportą. Kaina nustatoma pagal pasiūlą ir paklausą, taip pat atsižvelgiama į politinius ir ekonominius faktorius. Prekiaujama daugelyje pasaulio biržų, įskaitant LME, Azijos ir Šiaurės Amerikos biržas.
CRUDE	WTI Crude Oil Price	Daily	<i>WTI Crude Oil Price</i> yra žinoma naftos rinkos kaina, prekiaujama daugelyje pasaulio finansų biržų, įskaitant Niujorko prekių biržą (New York Mercantile Exchange, <i>NYMEX</i>), kurioje WTI naftos ateities sandoriai yra parduodami. Tai yra viena iš svarbiausių ir aktyviausių naftos rinkos biržų pasaulyje.
CSI	CSI 300 Index	Daily	CSI 300 indeksas yra akcijų indeksas, kuris apima 300 didžiausių Kinijos bendrovių akcijų, prekiaujamų Šanchajaus ir Šendženo biržose. Tai leidžia investuotojams sekti Kinijos akcijų rinkos būklę, sekti lyderiaujančių bendrovių veiklą.

Tęsinys kitame puslapyje

lentelė 5 – tęsinys

Kintamasis	Pavadinimas	Dažnis	Komentaras
DIA	SPDR Dow Jones Industrial Average ETF Trust (DIA)	Daily	Dow Jones Industrial Average yra vienas iš žymiausių JAV akcijų indeksų, apimantis 30 didžiausių JAV bendrovių akcijas. DIA yra laikomas vienu pagrindiniu JAV ekonomikos rodikliu ir dažnai naudojamas kaip investicinis indikatorius. DIA reikšmė yra įtakota daugybės faktorių, tokių kaip JAV ekonomikos būklė, tarptautinė situacija, JAV bendrovių pelningumas.
DAX	DAX Index	Daily	DAX indeksas yra vienas iš žymiausių Vokietijos akcijų indeksų, kuris apima 30 didžiausių Vokietijos bendrovių akcijas. DAX indeksas yra populiarus investicinis rodiklis, kuris rodo Vokietijos akcijų rinkos tendencijas, prekiaujamas Frankfurto akcijų biržoje.
EUR_USD	EUR/USD Exchange Rate	Daily	<i>EUR/USD</i> yra svarbi valiutų pora, atspindinti Europos Sąjungos ir JAV ekonomikos sąveiką. Ši valiutų pora yra reikšminga tarptautinėje prekyboje ir finansų rinkose. Valiutos kursas gali būti paveiktas ekonomikos tendencijų, pinigų politikos ir geopolitinių įvykių.
FTSE	FTSE 100 Index	Daily	<i>FTSE 100 Index</i> yra vienas iš didžiausių akcijų indeksų Jungtinėje Karalystėje, kuriame yra 100 didžiausių bendrovių, prekiaujančių Londone registruotų įmonių akcijomis. Šis indeksas yra reikšmingas ekonominis rodiklis, rodantis Jungtinės Karalystės akcijų rinkos būklę.
GBP_USD	GBP/USD Exchange Rate	Daily	<i>GBP/USD</i> valiutų pora yra svarbi finansų rinkose, nes atspindi svarbių ekonomikų – Didžiosios Britanijos ir JAV – sąveiką. Kintantis <i>GBP/USD</i> kursas atspindi politinius ir ekonominius pokyčius šiose šalyse (<i>Brexit</i>), todėl jis yra svarbus prekybininkams ir investuotojams, kurie siekia prognozuoti finansų rinkas ir priimti adekvačius sprendimus.

Tęsinys kitame puslapyje

lentelė 5 – tęsinys

Kintamasis	Pavadinimas	Dažnis	Komentaras
GOLD	Gold Price per Ounce	Daily	Auksas yra ilgalaikis saugių investicijų (žaliavų) simbolis, nes jis gali apsaugoti nuo infliacijos ir finansų rinkos nestabilumo. Kaina dažnai kinta pagal pasaulinę politiką ir ekonomikos pokyčius, o prekyba vyksta visose didžiausiose biržose. Tai viena populiariausių investicijų rūšių.
HANG	Hang Seng Index	Daily	Hang Seng Indeksas yra vienas iš pagrindinių Azijos akcijų indeksų, kuris apima 50 didžiausių Honkongo biržoje prekiaujamų bendrovių akcijas. Atspindi Kinijos ekonomikos būklę, sandorius su kitomis šalimis, įvykius tarptautinėje politikoje.
HEATING	Heating Oil Futures Price	Daily	<i>Heating Oil Futures Price</i> yra finansinis instrumentas, kuris leidžia investuotojams spekuliuoti ant naftos rinkos kainų kilimo arba kritimo. Tai ypač aktualu šildymo sezono metu, kai didėja šildymo poreikis ir kaina, o prekybininkai stengiasi prognozuoti ateities rinkos kainų pokyčius ir prisitaikyti prie jų, siekdami maksimalaus pelno iš šios žaliavos.
IXIC	NASDAQ Composite Index	Daily	IXIC NASDAQ Composite Index yra vienas iš žinomiausių technologijų akcijų indeksų pasaulyje, kuris apima daugiau nei 2500 technologinių bendrovių akcijas. Šis indeksas yra labai jautrus naujų technologinių produktų ir paslaugų atsiradimui rinkoje. Indekso reikšmę taip pat gali paveikti tarptautinės situacijos ir ekonomikos tendencijos pasaulyje.
LONDON	London Robusta Coffee Futures	Daily	Londono Robusta kavos ateities sandoriai yra susiję su kavos grūdų kainomis, kuriais yra prekiaujama biržoje. Kavos gamyba nėra vienpusė ir priklauso nuo klimato sąlygų, todėl ši investicija yra rizikinga. Kavos ateities sandoriai prekiaujami Intercontinental Exchange (ICE) biržoje

Tęsinys kitame puslapyje

lentelė 5 – tęsinys

Kintamasis	Pavadinimas	Dažnis	Komentaras
MOEX	MOEX Russia Index	Daily	MOEX Russia Index yra Rusijos vertybinių popierių biržos indeksas, kuriame yra įtrauktos didžiausios ir likvidžiausios Rusijos bendrovių akcijos. Indekso vertė atspindi Rusijos akcijų rinkos būklę ir yra aktualus rodiklis investuotojams, siekiantiems investuoti į Rusijos vertybinius popierius.
MSFT	Microsoft Corporation	Daily	Microsoft Corporation yra viena iš didžiausių ir populiariausių pasaulio technologijų įmonių, kurios produktais ir paslaugomis naudojasi milijonai žmonių visame pasaulyje. Įmonė turi stabilų finansinį pagrindą ir ilgalaikę sėkmę, taip pat daug investuoja į inovacijas, todėl šios akcijos yra populiarus pasirinkimas investuotojams.
NATURAL	Natural Gas Futures Price	Daily	<i>Natural Gas Futures Price</i> yra ateities sandorių kaina, susijusi su gamtinių dujų kaina ateityje. Tai yra finansinis instrumentas, leidžiantis spekuliuoti su dujų kaina ir yra vertinga priemonė energijos gamintojams, kurie nori apsaugoti savo verslą nuo rizikos, dėl kintančių dujų kainų.
NDX	NASDAQ 100 Index	Daily	<i>NASDAQ 100 Index (NDX)</i> yra vienas iš populiariausių technologijų akcijų indeksų, sudarytas iš 100 didžiausių ne finansų sektoriaus bendrovių, kurios yra prekiaujamos NASDAQ biržoje.
NIFTY	NIFTY 50 Index	Daily	<i>NIFTY 50 Index</i> yra Indijos biržos National Stock Exchange (NSE) akcijų indeksas, kuris apima 50 didžiausių ir aktyviausių Indijos bendrovių akcijas. Indija yra sparčiai auganti ekonomika, o NIFTY 50 yra vienas iš pagrindinių Indijos ekonomikos rodiklių, kurio vertinimas gali padėti prognozuoti Indijos akcijų rinką ir ekonominę vystymąsi šalyje.

Tęsinys kitame puslapyje

lentelė 5 – tęsinys

Kintamasis	Pavadinimas	Dažnis	Komentaras
NIKKEI	Nikkei 225 Index	Daily	Nikkei 225 Index yra vienas iš pagrindinių Japonijos akcijų indeksų, apimantis 225 didžiausių Japonijos įmonių akcijas, kurios yra prekiaujamos Tokijo vertybinių popierių biržoje. Šis indeksas yra naudojamas kaip rodiklis Japonijos ekonomikos būklei ir vystymuisi stebėti.
NUS	NYSE TOP US 100	Daily	<i>NYSE TOP US 100</i> yra biržos indeksas, kuris atspindi 100 didžiausių JAV bendrovių vertę, prekiaujamų Niujorko vertybinių popierių biržoje. Šis indeksas yra naudingas investuotojams siekiantiems sekti JAV akcijų rinkos tendencijas ir vertinimų pokyčius. Indekso komponentai yra atrinkti remiantis rinkos kapitalizacija ir prekybos apimtimi.
NVDA	NVIDIA Corporation	Daily	NVIDIA Corporation yra JAV kompanija, kuri yra pasaulinė lyderė vaizdo plokščių ir grafinių procesorių srityje. Tai yra patraukli investicija, atsižvelgiant į didelę produktų paklausą, kurią sukelia vis didesni reikalavimai žaidimų pramonės sektoriaus, dirbtinio intelekto įmonių ir duomenų modeliavimo centrų.
RTSI	RTSI Index	Daily	<i>Russian Trading System Index</i> yra pagrindinis Rusijos akcijų rinkos indeksas, kuris apima didžiausias ir likvidžiausias Rusijos bendroves. Renkantis investuoti į šį indeksą, reikia atsižvelgti į geopolitines rizikas, susijusias su Rusijos politine situacija ir sankcijomis.

Tęsinys kitame puslapyje

lentelė 5 – tęsinys

Kintamasis	Pavadinimas	Dažnis	Komentaras
RUB_USD	RUB/USD Exchange Rate	Daily	<i>RUB/USD</i> valiutų poros kursas yra jautrus politiniams ir ekonominiais veiksniams, ypač kai kalbama apie tarptautinę politiką. Rusijos santykiai su Vakarais ir JAV yra svarbus veiksnys, turintis įtakos <i>RUB/USD</i> kursui. Pavyzdžiui, Rusijos invazija į Ukrainą ir Krymo aneksija išprovokavo JAV ir kitų šalių sankcijas prieš Rusiją, dėl ko Rusijos rublio kursas nukrito žemyn. Karinis konfliktas ir politinė krizė yra pagrindiniai faktoriai šios valiutos staigiamame kainos pokytyje.
S.P	S&P 500 Index	Daily	<i>S&P 500 Index</i> yra JAV akcijų rinkos indeksas, apimantis 500 stambiausių JAV bendrovių akcijas, kuris naudojamas kaip ekonominis rodiklis atspindintis JAV ekonomiką. Šio indekso reikšmę gali paveikti daugybė faktorių, įskaitant bendrą pasaulio ekonominę situaciją, JAV bendrovių pelningumą.
S.P_TSX	S&P/TSX Composite Index	Daily	<i>S&P/TSX Composite Index</i> yra Kanados akcijų rinkos indeksas, apimantis virš 200 didžiausių bendrovių akcijas, prekiaujamas Toronto biržoje. Šis indeksas yra svarbus Kanados ekonomikos rodiklis.
SILVER	Silver Price per Ounce	Daily	<i>Silver price per ounce</i> yra svarbus kintamasis investuotojams, norintiems sekti sidabro vertę rinkoje. Kaip investicija, sidabras gali būti vertingas apsaugai nuo infliacijos ir finansinių rizikų. Antras po aukso pagal svarbumą.
SZSE	SZSE Component Index	Daily	Shenzhen Stock Exchange (SZSE) Component Index yra indeksas, kurio sudėtyje yra daugiau nei tūkstantis įmonių, kurių akcijos prekiaujamos Šendženo biržoje. Šis indeksas yra svarbus finansinis rodiklis, rodantis biržoje prekiaujamų akcijų kainų pokyčius ir atspindintis Kinijos ekonomikos vystymosi rodiklius.

Tęsinys kitame puslapyje


Kintamasis	Pavadinimas	Dažnis	Komentaras
TSLA	Tesla, Inc.	Daily	Inovatyvi elektromobilių, saulės energijos, kosmoso pramonės ir technologijų įrangos bendrovė, kuri per pastaruosius kelis metus tapo labai populiari tarp investuotojų. Bendrovė nuolat plečiasi ir ieško naujų būdų revoliucingai transformuoti automobilių pramonę, taigi ši investicija gali būti potencialiai pelninga, tačiau kainų svyravimai gali būti labai staigūs ir rizikingi.
USCORN	US Corn Futures Price	Daily	<i>US Corn Futures Price</i> yra ateities sandorių kainos, kurias nustato biržos. Žaliava yra susijusi su kukurūzų derliumi JAV. Ši investicija leidžia spekuliuoti su kukurūzų kaina ateityje ir yra svarbi ne tik investuotojams, bet ir žemdirbiams, kurie siekia apsisaugoti nuo kainų svyravimų.
VILNIUS	Vilnius Lithuanian Stock Exchange Index (VILSE)	Daily	Vilniaus vertybinių popierių biržos bendrojo indekso, arba <i>VILSE</i> indekso, vertę sudaro didžiausių Lietuvoje veikiančių bendrovių akcijų kainų pokyčiai. Tai svarbus finansinis rodiklis, kuris rodo Lietuvos ekonomikos būklę ir perspektyvas bei leidžia investuotojams sekti vietinės rinkos pokyčius.

Trūkstatų duomenų analizės šiame tyrime nėra prasmės atlikti, nes kuomet yra kuriami matematiniai mašininio mokymosi metodai, R progaminėje įrangoje atlieku funkciją *merge* ir *complete cases*. Šios funkcijos, panaikina duomenų – laiko eilučių laiko atžvilgiu neatitikimo problemą – panaikina eilutes, kuriose yra stebimas bent vienas kintamasis su NA . Šiame tyrime naudojami kintamieji turi skirtingus laikotarpius, tačiau pagrindinis duomenų pjūvis yra nuo 2010-01-01 iki 2023-04-21. Kadangi tyrimo kintamieji yra žaliavos, akcijos, biržų indeksai ir valiutos, dėl kiekvienos biržos prekiavimo specifikos, pastebimos trūkstamos reikšmės tokiais atvejais: savaitgaliais, šventinėmis dienomis, suplanuoti techniniai uždarymai, nenumatyti atvejai, reguliavimo pasikeitimai trumpuoju periodu. Reikia atkreipti dėmesį, kad investicinių produktų prekybos valandos ir atostogos gali skirtis priklausomai nuo konkrečios biržos ir šalies, kurioje tie produktai prekiaujami.

2.3. Bitkoino laiko eilutės analizė: aprašomoji statistika


Vienas iš šio projekto tikslų yra išnagrinėti bitkoino laiko eilutę, rasti paaiškinamas priežastis galimiems kainos šuoliams ir nukritimams. Šiam tikslui pasiekti, reikia atlikti bitkoino laiko eilutės

analizę. Kalbant apie laiko eilutę finansų rinkoje, yra skiriami du svarbiausi terminai – kaina ir grąža. Visų pirma, šis magistrinis projektas apima 2010–2023 metų laikotarpį. Paveiksle (žr. 15 pav.) matoma bitkoino kainos laiko eilutės pokytis dienomis:




15 Pav.: Bitkoino kainos laiko eilutė 2010–2023 metais

Tam, kad geriau matyti bitkoino kainos pokytį, yra naudinga pažvelgti į dar vieną grafiką, nurodantį bitkoino kainos pokytį logaritmuotą, kad geriau matytųsi tikrasis laiko eilutės augimo trendas (žr. 16 pav.).



16 Pav.: Bitkoino kainos laiko eilutė logaritmuota 2010–2023 metais

Iš abiejų grafikų (pav. 15, pav. 16) matoma, kad ši laiko eilutė per 10 metų periodą paaugo reikšmingai ir nuo 2013 metų, matomi reikšmingi bitkoino kainos pokyčiai. Toliau, tikslinga pažiūrėti, kaip atrodo bitkoino kainos histograma. Čia svarbu, kad finansinio produkto kaina gali būti tik teigiama, arba lygi nuliui, bet niekada neigiama (žr. 17 pav.).



17 Pav.: Bitkoino kainos laiko eilutės histograma

Toliau pateikiama aprašomoji statistika (žr. 6 lent.):

6 lentelė: Aprašomoji statistika: bitkoino kaina


Statistika	Reikšmė	Komentaras
N	4 654	<i>obs.</i>
Min	0,10	<i>USD</i> , 2010-07-18
Max	67 527,90	<i>USD</i> , 2021-08-11
Median	914,00	<i>USD</i>
Mean	8 937,80	<i>USD</i>
Skew	2,01	Asimetriškumas (angl. <i>skewness</i>) yra teigiamas, šiame skirstinyje uodegos dalis yra ilgesnė dešinėje pusėje, t.y. daugiau reikšmių virš vidurkio.
Kurtosis	3,24	Eksesas (angl. <i>kurtosis</i>) yra teigiamas, šiame skirstinyje yra daugiau sunkesnių uodegų (angl. <i>heavy tail</i>) ir smailesnis skirstinio viršūnės pavidas, lyginant su normaliuoju skirstiniu.

Tęsinys kitame puslapyje

lentelė 6 – tęsinys

Statistika	Reikšmė	Komentaras
SE	212,72	Standartinė klaida (angl. <i>standart error</i>) reikšmė 212,72 rodo, kad šiame skirstinyje yra daug kintamumo ir neapibrėžtumo. Stebima duomenų variacija.

Apskaičiavau logaritmines bitkoino kainos grąžas nagrinėtam periodui ir čia pateikiamas grąžų grafikas ir aprašomoji statistika (žr. 18 pav.), (žr. 7 lent.):



18 Pav.: Bitkoino logaritminės grąžos 2010–2023 metais

7 lentelė: Aprašomoji statistika: bitkoino logaritminės grąžos


Statistika	Reikšmė	Komentaras
N	4 654	<i>obs.</i>
Min	-0,85	
Max	1,47	
Median	0,00	
Mean	0,00	
Skew	2,63	Asimetriškumas yra teigiamas, šiame skirstinyje uodegos dalis yra ilgesnė dešinėje pusėje, t.y. daugiau reikšmių virš vidurkio, o pats skirstinys yra laikomas pakreiptas į kairę.

Tęsinys kitame puslapyje

lentelė 7 – tęsinys

Statistika	Reikšmė	Komentaras
Kurtosis	90,98	Eksezas yra teigiamas, šiame skirstinyje yra daugiau sunkesnių uodegų (angl. <i>heavy tail</i>) ir smailesnis skirstinio viršūnės pavidalas, lyginant su normaliuoju skirstiniu.

Taip pat, svarbu pažiūrėti, kaip atrodo bitkoino logaritminių gražų histograma. Čia svarbu, kad finansinio produkto graža gali būti ir teigiama, ir neigiama. Priklausomai nuo skirstinio, vėliau priklausys ir GARCH modelio sudarymas. Kaip matoma histogramoje, skirstinys nėra normalusis, stebimos ilgos uodegos ir gražos daugiausiai yra apie nulį (žr. 19 pav.).



19 Pav.: Bitkoino logaritminių gražų histograma

Apibendrinant bitkoino kainos ir bitkoino gražos tyrimą, galima teigti, kad bitkoino laiko eilutė yra komplikuota analizuoti, nes per 13 metų periodą, bitkoino kaina išaugo drastiškai. Tai dar kartą įrodo, kad ši, nors ir palyginus nauja rinka, yra įdomi analizuoti, sunkiai pritaikomi paprasti statistinės analizės metodai, nes gražų skirstinys nėra normalusis. Stebimos ilgos, sunkios uodegos, kurios negali būti laikomos išskirtimis, nes tai yra šios laiko eilutės specifika – informacija. Be to, bitkoino kainos laiko eilutė yra paveikta daugybės veiksnių, įskaitant makroekonominis veiksnius, visuomenės nuomonės apie bitkoiną, naujienas apie saugumo pažeidimus ir reglamentavimą. Todėl yra labai sunku modeliuoti bitkoino kainą ir gražą į ateitį, nes modeliai gali būti paveikti daugybės faktorių, kuriuos sunku numatyti. Vis dėlto, norint išanalizuoti bitkoino kainos laiko eilutę ir prognozuoti jos elgesį, reikia atsižvelgti į visus susijusius veiksnius ir naudoti adekvatų statistinės analizės metodą, kuris būtų pritaikytas bitkoino gražų skirstiniui, jo modeliavimui. Tik radus tinkamą metodą bus galima suprasti bitkoino kainos svyravimų priežastis ir prognozuoti galimą šios kriptovaliutos kainos kryptį ateityje.

2.4. Bitkoino laiko eilutės analizė: stilizuoti faktai


Prieš pradėdant laiko eilutės analizę GARCH modelio kūrimui, pirmiausia atlikau stilizuotų faktų analizę bitkoino laiko eilutei, norint įrodyti, kad ši laiko eilutė pagal stilizuotus faktus atitinka finansinės laiko eilutės sampratą. Pagal apibrėžimą, kurį pateikia J.Y Campbell [68], stilizuoti faktai yra empirinių stebėjimų savybės, kurios yra pastebimos aukštos rizikos rinkose, ir tam yra keli metodai, patikrinti ar stilizuotas faktas yra būdingas nagrinėjamai eilutei, ar ne. Kaip teigia A.J. McNeil [69], šios pastebėtos savybės yra svarbios norint įvertinti, ar rizikos modelis yra tinkamai sudarytas, siekiant įvertinti kilusią riziką, susijusią su investicijomis.

Keli dažniausiai pateikiami (skirtingi autoriai, skirtingai formuluoja) stilizuotų faktų pavyzdžiai finansinėms laiko eilutėms yra šie:

- SF1:** Finansinės laiko eilutės gražos nėra nepriklausomos ir vienodai paskirsčiusios (angl. *independent and identically distributed*) nors ir egzistuoja nežymi autokoreliacija.
- SF2:** Finansinės laiko eilutės absoliučiosios arba kvadratinės gražos yra autokoreliuotos.
- SF3:** Finansinės laiko eilutės skirstinys yra leptokurtinis (angl. *leptokurtic – power-like tail*). Išskirtys ir ekstremalios reikšmės yra labiau tikėtinos, nei normaliajame skirstinyje.
- SF4:** Finansinės laiko eilutės gražos volatilumas nėra pastovus, atsikartojantis laike.
- SF5:** Finansinės laiko eilutės gražos ekstremalios reikšmės yra stebimos grupėmis panašiam laike (angl. *volatility clustering*). Bitkoino laiko eilutės atveju – stebimi rinkos pakilimo ir nukritimo laikotarpiai (angl. *bull market* ir *bear market*) dažniausiai yra besitęsiantys kurį laiką.
- SF6:** Finansinės laiko eilutės gražos empirinis skirstinys yra pakreiptas į kairę (angl. *skewed to the left*), o tikima grąža yra artima nuliui.


Patikriname, ar egzistuoja aukščiau išvardinti stilizuoti faktai bitkoino gražos laiko eilutei.

- SF1:** Autokoreliacijos funkcija (ACF) yra statistinis metodas, kuris naudojamas matuoti koreliacijoms tarp finansinių laiko eilučių ankstinių (angl. *lags*). Šis metodas gali būti naudojamas, norint nustatyti, ar duomenų rinkinyje yra stebimos koreliacijos tarp laiko intervalų. ACF grafikas R kalboje yra grafikas, kuriame X ašyje yra nurodyti laiko ankstiniai, o Y ašyje yra koreliacijos koeficientai tarp atitinkamų laiko ankstinių. Patikriname ACF grafiką bitkoino gražoms, ir matoma, kad **patvirtinta** – egzistuoja nežymi autokoreliacija (žr. 20 pav.).




20 Pav.: ACF grafikas logaritminēms bitkoino grāžoms

SF2: Patvirtinta, remiantis ACF grafikais (žr. 21 pav.)




21 Pav.: ACF kvadratinėms ir absoliučioms bitkoino logaritminėms grąžoms

SF3: Patvirtinta, remiantis anksčiau pateiktu histogramos grafiku (žr. 19 pav.), *box plot* grafiku (žr. 22 pav.) ir QQ plot grafiku (žr. 23 pav.), kuris patvirtina sunkias uodegas (angl. *heavy tails*) skirstinyje.




22 Pav.: Bitkoino logaritminių grąžų box plot grafikas



23 Pav.: QQ plot grafikas

SF4: Patvirtinta, atsikartoja (žr. 24 pav.)



24 Pav.: Bitkoino absoliučių grąžų volatilumo grupės

SF5: Patvirtinta, remiantis aukščiau pateiktu volatilumo klasterių grafiku (žr. 24 pav.) ir literatūros analizės dalyje aprašytais pasikartojančiais pakilimo ir nukritimo ciklais (angl. *bull market*, *bear market*).

SF6: Patvirtinta, remiantis aprašomosios statistikos (žr. 7 lent.) duomenimis. Grąža yra artima nuliui, skirstinys yra pakreiptas į kairę.

Stilizuotų faktų analizė tik dar kartą patvirtina, kad bitkoino laiko eilutė yra normaliai funkcionuojanti finansinių rinkų laiko eilutė, kuriai yra randami šiai rinkai būdingi bruožai. Bitkoino laiko eilutė yra pavyzdys, kai stilizuotų faktų analizės taikymas padeda atskleisti šios rinkos specifinius bruožus ir svarbias tendencijas. Pavyzdžiui, bitkoino grąžos yra leptokurtinės ir autokoreliuotos, reiškia, kad išskirtys ir ekstremalios reikšmės yra daugiau tikėtinos nei normalioje rinkoje. Be to, bitkoino grąžos volatilumas nėra pastovus ir yra susijęs su rinkos pakilimo ir nukritimo laikotarpiais.

Stilizuotų faktų analizė taip pat parodė, kad bitkoino grąžos yra pakreiptos į kairę, o tikima grąža yra artima nuliui. Tai reiškia, kad bitkoino investicijos turi didelę riziką, bet taip pat gali pasižymėti aukštomis grąžomis. Grįžtant prie tyrimo tikslų, siekiant apibendrinti investuotojų elgseną, analizuojant bitkoino laiko eilutę, svarbu prisiminti, kad tai yra nauja ir vis dar besiformuojanti rinka, kurioje galimi staigūs ir netikėti pokyčiai.

2.5. Matematiniai metodai

2.5.1. GARCH modelis

Prieš pradedant aprašyti GARCH modelį ir jo matematinę išraišką, svarbu paminėti kada prasidėjo tokių modelių kūrimo pradžia. Robert Engle (gim. 1942 m.) sukūrė ARCH (angl. *Autoregressive Conditional Heteroskedasticity*) modelį dar 1980 metais. Jo esminis straipsnis, „Autoregressive

conditional heteroscedasticity with estimates of the variance of United Kingdom inflation“ [70] buvo paskelbtas žurnale *Econometrica* 1982 metais. Šis darbas R. Engle pelnė Nobelio ekonomikos premiją 2003 metais, nes suteikė revoliucingą pagrindą analizuoti ir modeliuoti sunkiai prognozuojamą finansų duomenų volatilumą. Nobelio premijos citata: „Už metodus skirtus analizuoti ekonominės laiko eilutės su kintančiu volatilumu (ARCH)“ (angl. *"for methods of analyzing economic time series with time-varying volatility"*) [71].

Toliau aprašysiu jau patobulintą ARCH modelį – GARCH modelį, kuris yra naudojamas šiame tyrime. GARCH (angl. *Generalized Autoregressive Conditional Heteroskedasticity*) modelis yra išplėstinė ARCH modelio versija. Tai statistinis modelis, kuriuo siekiama modeliuoti ir prognozuoti finansų ar kitų kintančių laiko eilučių savybes, tokias kaip liekanų heteroskedastiškumas arba laiko eilutės volatilumas. GARCH modelis yra sudarytas iš dviejų pagrindinių dalių: autoregresinės dalies (AR) ir sąlyginės heteroskedastiškumo dalies (ARCH). Autoregresinė dalis atspindi modelio gebėjimą atsižvelgti į ankstesnių periodų svyravimus ir jų poveikį dabatinei reikšmei. Sąlyginio heteroskedastiškumo dalis įtraukia praeities paklaidų kvadratų į modelį, kad būtų galima atspėti kintantį svyravimo lygį.

GARCH modelis leidžia nustatyti, ar pasitaikantis svyravimas turi ilgalaikį atminties efektą, t. y. ar praeities laiko momentų pokyčiai turi įtakos dabatinei reikšmei. Taip pat modelis suteikia galimybę įvertinti svyravimo lygio kintamumo intensyvumą, leidžiantį prognozuoti grąžą ir valdyti investicinę riziką. GARCH modelis dažnai naudojamas finansų analizėje, taikant jį prognozuoti ir valdyti riziką, ypač susijusią su akcijų, valiutų arba kitų finansinių instrumentų kainų svyravimais.

GARCH(p, q) modelio bendroji formulė:

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i a_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

čia σ_t^2 yra sąlyginis dispersijos dydis laiku t , ω yra konstanta, α_i yra koeficientai, rodantys kvadratinį liekanų a_{t-i}^2 įtaką su atsilikimu i , β_j yra koeficientai, rodantys sąlyginės dispersijos σ_{t-j}^2 įtaką su atsilikimu j .

Šaltiniai: [72], [73].

2.5.2. Random Forest

Atsitiktiniai miškai (angl. *random forests*) yra populiarus mašininio mokymo metodas, naudojamas tiek klasifikavimui, tiek regresijai. Tai yra prižiūrimo mokymosi (angl. *supervised*) metodas, kuris naudoja daugybę sprendimų medžių (angl. *decision trees*) ir kombinuoja jų rezultatus, kad gautų geriausią galutinį prognozavimo rezultatą.

Kiekvienas sprendimų medis atsitiktiniame miške yra mokomas su skirtingomis duomenų imtimis. Taip sukuriama skirtingi ir nepriklausomi sprendimų medžiai. Kadangi medžiai yra mokomi su atsitiktinėmis imtimis, tai suteikia kiekvienam medžiui skirtingą perspektyvą ir padeda sumažinti persi-

mokymo (angl. *overfitting*) riziką.

Atsitiktiniai miškai turi keletą privalumų, įskaitant gerą prognozavimo tikslumo pasiekimą, efektyvumą su dideliais duomenų rinkiniais ir galimybę įvertinti kintamųjų svarbą prognozėje. Jie taip pat gali būti naudingi mažinant modelio persimokymo problemą ir padidinant modelio stabilumą. Atsitiktiniai miškai yra klasifikavimo ar regresijos metodai, kurie priskiriami „ansamblių“ (angl. *ensemble*) metodams. Vietoje vieno medžio, sudaroma daug sprendimų medžių, pavyzdžiui 100 arba 1000. Norint sukurti medžius, kurie nėra identiški, naudojamas randomizavimas (atsitiktinumas) medžio kūrimo metu. Tinkamai atlikus randomizavimą, atsitiktiniai miškai nėra linkę persimokyti, net jei juose naudojami į persimokymą linkę sprendimų medžiai.

Duota:

- Mokymo duomenų rinkinys: $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$
- Sprendimų medžių skaičius: T
- Atsitiktinai pasirenkamų kintamųjų skaičius kiekviename mazge: m

Algoritmas:

- Už kiekvieną $t = 1$ iki T :
 - Parinkti atsitiktinį "bootstrap" duomenų rinkinį: $\{(x_{i_t}, y_{i_t})\}_{i_t=1}^N$
 - Mokyti sprendimų medį naudojant "bootstrap" duomenų rinkinį:
 - * Kiekviename mazge:
 - Atsitiktinai pasirinkti m kintamuosius iš visų kintamųjų
 - Apskaičiuoti geriausią perskirstymo tašką naudojant šiuos atsitiktinai pasirinktus kintamuosius
 - Išsaugoti mokytą sprendimų medį kaip h_t
- Naujam įvesties x taškui numatyti rezultatą, agreguojant visų sprendimų medžių prognozes:
$$\hat{y} = \frac{1}{T} \sum_{t=1}^T h_t(x)$$

Šaltiniai [74], [75].

Šiame algoritme kiekvienas sprendimų medis yra mokomas naudojant *bootstrap* imtį (atsitiktinį atrinkimą su pakartojimu) iš pradinio mokymo duomenų rinkinio. Kiekviename medžio mazge atsitiktinai pasirenkami tam tikras kintamųjų poaibis, kad būtų nustatytas geriausias perskirstymo taškas. Galutinis rezultatas gaunamas, vidurkinti visų sprendimų medžių prognozes. Atsitiktinių miškų algoritmas regresijos uždaviniams išnaudoja ansamblio mokymosi galią, jungiant kelis sprendimų medžius, kad pagerintų prognozavimo tikslumą ir stabilumą.

2.5.3. XGBoost

XGBoost algoritmas yra metodas, sprendžiantis regresinius uždavinius mašininio mokymo srityje. Šis algoritmas veikia iteratyviai, pridedant naujus regresijos medžius ir tobulinant jų prognozes. XGBoost algoritmas yra populiarus dėl efektyvumo ir gero prognozavimo greičio. Dažnai naudojamas finansinėje analizėje tiriant finansinius laiko eilučių duomenis.

- Inicializavimas:
 - Pradinės numatomosios reikšmės nustatymas kaip tikslinės kintamojo vidurkį arba konstantą, žymimas kaip F_0 .
- Kiekvienam skatinimo ciklui m nuo 1 iki M :
 - Skačiuojami pseudo liekanos r_m , juos randant praeitų numatomųjų reikšmių atžvilgiu išvestinės gradientą nuo nuostolių funkcijos: $r_m = -\nabla_h L(y, \mathbf{F}m - 1)$.
 - Treniruojamas regresijos medis $\mathbf{h}_m$ pagal pseudo liekanas $\mathbf{r}_m$, mažinant nurodytą nuostolių (angl. *loss*) funkciją.
 - Atnaujinama numatomųjų reikšmių prognozė įtraukiant naujo medžio indėlį: $\mathbf{F}m = \mathbf{F}m - 1 + \gamma_m \mathbf{h}_m$, čia γ_m yra mokymo greitis, kuris nustato kiekvieno medžio svarbą.
 - Reguluojamas medžio sudėtingumas taikant mažinimo parametą: $\mathbf{F}m = \mathbf{F}m - 1 + \lambda \gamma_m \mathbf{h}_m$, čia λ yra mažinimo parametras.
- Kartoti antrą žingsnį, kol pasiekiamas norimas skatinimo ciklų skaičius M .
- Galutinė prognozė naujai įvestai reikšmei $\mathbf{x}$ gaunama sumuojant visų medžių prognozes: $\mathbf{F} = \sum_{m=1}^M \gamma_m \mathbf{h}_m$.

Šaltiniai [76], [77].

XGBoost algoritmas siekia mažinti nurodytą nuostolių funkciją (pavyzdžiui, vidutinį kvadratinį nuokrypį) iteratyviai pridedant regresijos medžius prie bendro rezultato. Kiekvienas medis yra konstruojamas taip, kad atitektų nuostolių funkcijos neigiamą gradientą, o numatomosios reikšmės yra atnaujinamos mokymosi greičio ir paklaidos mažinimo parametru, kurie kontroliuoja kiekvieno medžio indėlį ir padeda išvengti persimokymo.

2.5.4. Neural Network

Neuroniniai tinklai mašininiam mokymui yra modeliai, kurie imituoja žmogaus smegenų veikimą. Jie sudaryti iš sąlyginės veikimo vienetų, vadinamų neuronais, kurie yra sujungti tarpusavyje.

Regresinio uždavinio sprendimui per neuroninius tinklus atliekami šie žingsniai:

- Duomenų paruošimas: Paruošiami mokymo duomenys su skaitinėmis įvesties ir norimomis išvesties reikšmėmis.

- Tinklo architektūra: Pasirenkama tinklo architektūra, kurioje yra įvesties sluoksnis, vienas arba daugiau paslėptųjų sluoksnių su aktyvacijos funkcijomis ir išvesties sluoksnis su tinkamomis išvesties funkcijomis.
- Tinklo apmokymas: Inicializuojami tinklo svoriai atsitiktinai ir naudojamas mokymo algoritmas, pavyzdžiui, gradientinio nusileidimo metodas, norint atnaujinti svorius pagal nuostolių funkciją. Tinklas yra mokomas prognozuoti norimą išvesties reikšmę.
- Prognozavimas: Apmokytas tinklas gali būti naudojamas prognozuoti išvesties reikšmes naujiems įvesties duomenims, taikant įvesties reikšmes tinklui ir gaudami išvesties reikšmę pagal tinklo struktūrą.

Tai yra pagrindiniai žingsniai regresinio uždavinio sprendimui per neuroninius tinklus. Svarbu tinkamai parinkti tinklo architektūrą, apmokyti tinklą su pakankamai mokymo duomenų ir tinkamai sukonfigūruoti tinklo hiperparametrus siekiant gauti gerus rezultatus.

Algoritmas:

- Inicializacija:
 - Atsitiktinai arba naudojant tam tikrą pradinių reikšmių nustatymo metodą inicializuoti svorius W ir postūmius b kiekvienam tinklo neuronui.
 - Pasirinkti tinkamą aktyvacijos funkciją, pavyzdžiui, sigmoidinę funkciją arba tiesinės aktyvacijos vienetą (ReLU faktoriizacija).
- Tolimesnė eiga:
 - Skaičiuoti svertinių įvesties reikšmių ir postūmių sumą kiekvienam paslėptosioms sluoksnių neuronams ir išvesties sluoksnio neuronui.
 - aiški aktyvacijos funkciją apdorotiems rezultatams, siekiant įvesti nelinearumą.
 - Kartoti šį procesą kiekvienam sluoksniui, kad informacija būtų persiunčiama pirmyn per tinklą.
- Klaidos skaičiavimas:
 - Skaičiuoti klaidos funkciją, pavyzdžiui, vidutinį kvadratinį nuokrypį (MSE) arba vidutinį absoliutų nuokrypį (MAE), lyginant prognozuotas reikšmes su tikrosiomis tikslinėmis reikšmėmis.
- Atgalinė propagacija:
 - Skaičiuoti gradientą nuo klaidos funkcijos iki prognozuotų išvesties reikšmių.
 - Atnaujinti tinklo svorius ir postūmius, atgalinai perduodant gradientus per sluoksnius.
 - Naudoti optimizavimo algoritmą, pavyzdžiui, gradientinio nuolydžio metodą, iteratyviai atnaujinti svorius ir postūmius.
- Kartoti 2-4 žingsnius:

- Iteratyviai atlikite pirmyninę propagaciją, klaidos skaičiavimą ir atgalinę propagaciją tam tikrą epochų skaičių arba iki konvergavimo.
 - Pakeisti hiperparametrus, pavyzdžiui, mokymo greitį ir reguliavimo stiprumą, norint pagerinti modelio apmokymo procesą.
- Prognozavimas:
 - Kai tinklas yra apmokytas, naudokite jį prognozuoti naujų įvesties duomenų reikšmes vykdydami pirmyninę propagaciją.

Šaltiniai [78], [79], [80].

Neuroninio tinklo algoritmas regresijos uždaviniams siekia išmokyti atitikties tarp nepriklausomųjų kintamųjų ir priklausomojo kintamojo reikšmių, koreguodamas tinklo neuronų svorius ir postūmius. Procesui vykstant iteratyviai mokymui ir optimizavimui, tinklas stengiasi minimalizuoti klaidos funkciją ir pagerinti prognozių tikslumą.

3. Tyrimų rezultatai ir jų aptarimas

3.1. Tyrimo rezultatai

Šiame tyrimo darbe tyrimo objektu yra bitkoino kainos ir generuojamos gražos analizė. Tyrime yra analizuojamas bitkoino kainos ryšys su išoriniais veiksniais, su tikslu išsamiau suprasti šios kriptovaliutos kainų svyravimus bei jų įtaką ekonominei ir socialinei aplinkai. Šiuo tyrimu siekiu įgyti ir įrodyti platesnį supratimą apie tai, kaip išoriniai veiksniai gali paveikti bitkoino kainą ir kaip tai susiję su plačiai suprantamu kontekstu, įtraukiančiu ekonomiką ir visuomenę.

3.1.1. GARCH modelis

Prieš pradėdant kurti bitkoino gražos GARCH modelį, 2.4 skyrelyje, atlikta stilizuotų faktų analizė įrodo, kad ši laiko eilutė yra tinkama modeliuoti GARCH modelį, atlikti šią analizę.

1. Pirmiausia, patikrinu kelis statistinius testus: Šapiro normalumo testą (angl. *Shapiro–Wilk test*, Jarke-Bera normalumo testą (angl. *Jarque Bera test*) ir ARCH efekto testą (angl. *ARCH LM-test*). Visiems testams $\alpha = 0,05$.

Rezultatai (žr. 8 lent.):

8 lentelė: Statistiniai testai

Statistinis testas	p-reikšmė	Komentaras
Shapiro–Wilk test	$p\text{-value} < 2.2e^{-16}$	H_0 hipotezė apie normalųjį skirstinį atmesta.
Jarque Bera test	$p\text{-value} < 2.2e^{-16}$	H_0 hipotezė apie normalųjį skirstinį (skewness and kurtosis) atmesta.
ARCH LM-test	$p\text{-value} < 2.2e^{-16}$	H_0 hipotezė, kad ARCH efektas neegzistuoja atmesta. Reiškia, ARCH efektas yra ir ši laiko eilutė yra tinkama GARCH modeliavimui.

2. Toliau sudariau kelis GARCH modelius, kuriuose palyginami skirtingi skirstinio tipai bitkoino gražos laiko eilutei, atliekama GARCH modelio tinkamumo analizė.

Atsikerpu duomenų laikotarpį nuo 2013-10-09 iki 2023-04-14. Šis periodas yra informatyvus, nes nuo 2013 metų galo, stebimi pokyčiai bitkoino laiko eilutėje, 2010–2013 metų periodo gražos yra neinformatyvios, pasiskirsčiusios apie 0. Imties pabaiga 2023-04-14 yra duomenų rinkimo data šio magistrinio projekto tyrimui atlikti.

Rezultatai (žr. 9 lent.):

9 lentelė: GARCH modeliai

Modelis A	Modelis B
Model = sGARCH garchOrder=c(1,1) armaOrder=c(1,0) distribution.model="norm" (normal distribution) Includes Skew: FALSE Includes Shape: FALSE	Model = sGARCH garchOrder=c(1,1) armaOrder=c(1,0) distribution.model="sged" (skewed generalized error distribution) Includes Skew: TRUE Includes Shape: TRUE
1st test: Weighted Ljung-Box test on Standartized Residuals Lag[1] p-value = $1,45e^{-3}$ Lag[2*(p+q)+(p+q)-1][2] p-value = $1,27e^{-10}$ Lag[4*(p+q)+(p+q)-1][5] p-value = $1,54e^{-5}$ Visi ankstiniai atmeta H_0 hipotezę, reiškia, kad yra logaritminės liekanos yra autokoreliuotos. Weighted Ljung-Box Test on Standardized Squared Residuals Lag[1] p-value = 0,84 Lag[2*(p+q)+(p+q)-1][2] p-value = 0,57 Lag[4*(p+q)+(p+q)-1][5] p-value = 0,70 Visi ankstiniai neatmeta H_0 hipotezės, reiškia, kad yra logaritminės kvadratinės liekanos nėra autokoreliuotos.	1st test: Weighted Ljung-Box test on Standartized Residuals Lag[1] p-value = $1.19e^{-8}$ Lag[2*(p+q)+(p+q)-1][2] p-value = 0 Lag[4*(p+q)+(p+q)-1][5] p-value = 0 Visi ankstiniai atmeta H_0 hipotezę, reiškia, kad yra logaritminės liekanos yra autokoreliuotos. Weighted Ljung-Box Test on Standardized Squared Residuals Lag[1] p-value = 0,86 Lag[2*(p+q)+(p+q)-1][2] p-value = 0,55 Lag[4*(p+q)+(p+q)-1][5] p-value = 0,67 Visi ankstiniai neatmeta H_0 hipotezės, reiškia, kad yra logaritminės kvadratinės liekanos nėra autokoreliuotos.
2nd test: Weighted ARCH LM Test ARCH Lag[3] p-value = 0,21 ARCH Lag[5] p-value = 0,27 ARCH Lag[7] p-value = 0,42 ARCH efekto H_0 hipotezė atmesta visuose ankstiniuose, reiškia ARCH efektas egzistuoja.	2nd test: Weighted ARCH LM Test ARCH Lag[3] p-value = 0,13 ARCH Lag[5] p-value = 0,23 ARCH Lag[7] p-value = 0,38 ARCH efekto H_0 hipotezė atmesta visuose ankstiniuose, reiškia ARCH efektas egzistuoja.

Tęsinys kitame puslapyje

Modelis A	Modelis B
3rd test: Sign Bias Test Sign Bias p-value = 0,19 Negative Sign Bias p-value = 0,45 Positive Sign Bias p-value = 0,08* Joint Effect p-value = 0,32 Matoma, kad prie teigiamų ženklų eilutės yra *, reiškia <i>sGARCH</i> modelis nėra tinkamas, ženklų testo nepraeina.	3rd test: Sign Bias Test Sign Bias p-value = 0,67 Negative Sign Bias p-value = 0,24 Positive Sign Bias p-value = 0,28 Joint Effect p-value = 0,43 Matoma, kad nėra *, reiškia <i>sGARCH</i> modelis yra tinkamas, ženklų testą praeina. Tai reiškia, kad tinkamai išmodeliuojamos tiek teigiamos, tiek neigiamos gražos.
4th test: Adjusted Pearson Goodness-of-Fit Group 20 p-value = $3,59e^{-93}$ Group 30 p-value = $5,39e^{-92}$ Group 40 p-value = $7,53e^{-90}$ Group 50 p-value = $1,49e^{-84}$ Visos H_0 hipotezės atmetos, netinkamas skirstinys.	4th test: Adjusted Pearson Goodness-of-Fit Group 20 p-value = 0,02 Group 30 p-value = 0,01 Group 40 p-value = 0,10 Group 50 p-value = 0,08 Trečio grupavimo metu H_0 hipotezė neatmesta, skirstinys pagal duomenis parinktas tinkamai ir <i>ssged</i> skirstinys atspindi bitkoino logaritminių gražų skirstinį.
Išvada: netinkamas GARCH modelis	Išvada: Tinkamas GARCH modelis. Gauti modelio koeficientai: $\alpha = 0,169746$ $\beta = 0,892399$ $\mu = 0,000080$ $\omega = 0,000004$ $skew = 0,9909661$ $shape = 0,8703572$

Gauto GARCH modelio formulė:

$$\begin{aligned}
 Y_t &= 0,000080 - 0,057232Y_{t-1} + a_t \\
 \sigma_t^2 &= 0,000004 + 0,169746a_{t-1}^2 + 0,892399\sigma_{t-1}^2 \\
 a_t &= \sigma_t \varepsilon_t
 \end{aligned}$$

GARCH modelio liekanų skirstinys:

$$\varepsilon_t \sim \text{SkewedGeneralizedErrorDistribution}(0; 1; 0,8703572; 0,9909661)$$

3. Tolimesniame tyrime naudosiu GARCH modeliu sumodeliuotas liekanas, kaip priklausomąjį kintamąjį Y sprendžiant regresinį uždavinį, ieškant išorinių faktorių įtakos bitkoino kainai. Šios

liekanos tyrime bus žymimos *sged_res*.

3.1.2. Bitkoino gražos ir išorinių veiksnių gražų koreliacinė analizė


Finansų rinkose, koreliacija gali būti tarp akcijų ar kitų finansinių instrumentų kainos, o taip pat tarp jų gražų. Mano tyrimo atveju, tikrinu koreliacijas tarp finansinių produktų gražų. Koreliacija yra svarbus statistinis matas rizikos valdymo požiūriu, nes tai gali padėti įvertinti, kaip susijusios skirtingos investicijos ir kaip jos veikia viena kitos atžvilgiu.

Norint įvertinti koreliaciją tarp finansinių laiko eilučių gražų, galima naudoti Pearson koreliacijos koeficientą. Šis koeficientas matuoja tiesinį ryšį tarp dviejų kintamųjų ir svyruoja nuo -1 iki 1. Reikšmė -1 rodo, kad yra visiškai neigiamas tiesinis ryšys (vieno kintamojo reikšmei augant, kito reikšmė krenta), o reikšmė 1 – kad yra visiškai teigiamas tiesinis ryšys (abu kintamieji auga tiesiškai priklausomai). Reikšmė 0 rodo, kad koreliacijos nėra – tiesinis ryšys neegzistuoja.

Tyrime esančių kintamųjų koreliacinė analizė pateikta žemiau (žr. 25 pav.).

Išvalgos apie tyrimo kintamųjų koreliaciją:

- Nėra žymių koreliacijų tarp finansinių produktų logaritminių gražų.
- GARCH modelio liekanos stipriai koreliuoja su bitkoino graža – tai logiška, bet absoliučiai neinformatyvu.
- GARCH modelio liekanų stipriausios koreliacijos su šių finansinių priemonių logaritminėmis gražomis:
 - *ixic* koreliacija 0,14813
 - *ndx* koreliacija 0,14299
 - *s.p* koreliacija 0,13342
 - *dia* koreliacija 0,12341
 - *msft* koreliacija 0,11987
 - *nus* koreliacija 0,11382
 - *aex* koreliacija 0,10056
 - *amzn* koreliacija 0,09229



25 Pav.: Koreliacijų matrica

Po koreliacinės analizės, toliau sudaromi mašininio mokymosi modeliai. Visų pirma, sudariau kiekvieno kintamojo ankstinius (angl. *lag*), kiekvienam kintamajam po 7 ankstinius. Ankstiniai yra kuriami su tikslu išsiaiškinti, kiek informacijos kiekvienas kintamasis turi savo istorijoje, ankstesniuose stebėjimuose. Tyrime naudoju 7 ankstinius, tam kad matytųsi savaitės ankstiniai.

3.1.3. Random Forest

Random Forest (atsitiktiniai miškai) yra galingas mašininio mokymosi algoritmas, naudojamas tiek klasifikacijos, tiek regresijos uždaviniams spręsti. Algoritmas veikia kurdamas daugybę sprendimų medžių ir jungiant jų prognozes į vieną. Kiekvienas sprendimų medis mokomas atskirai, naudojant atsitiktinę duomenų imtį ir atsitiktinę požymių imtį. Kiekvienas medis generuoja prognozes remdamasis savo mokymo duomenimis.

Siekiant modeliuoti GARCH modelio liekanomis sudarytas bitkoino grąžą, kuriu modelį, kuris sprendžia regresinį uždavinį. Modelio parametrai: naudojamų miškų skaičius 600, kintamųjų kiekis naudojamas kiekvieno medžio apmokymo metu 20, ($ntry=600$, $mtry=20$), modelio duomenys: visi kintamieji ir jų ankstiniai, išskyrus bitkoiną ir bitkoino ankstinius.

Modelio rezultatai

Modelio formuluotė (R kalboje):

```
pirmas.rf <- randomForest(sged_res ~ ., data=finaldata, ntree = 600, mtry = 20, keep.forest = FALSE,
```

importance = TRUE)

Modelis regresijos išraiška:

Modelis_RF $\sim$ RandomForest(sged_res $\sim$ X, parametrai) , čia X – visi kintamieji ir jų ankstiniai, išskyrus bitkoiną ir bitkoino ankstinius, naudojamų miškų skaičius 600, kintamųjų kiekis naudojamas kiekvieno medžio apmokymo metu 20.

Modelio tikslumas:

Mean of squared residuals: 0,004118029

% Var explained: 5,02

RF (Random Forest) algoritme %IncMSE reiškia "Procentinį padidėjimą vidutinės kvadratinės paklaidos" (angl. *Percent Increase in Mean Squared Error*). Tai yra svarbumo matas, kuris parodo, kiek padidėja vidutinės kvadratinės paklaidos metrika (MSE), kai tam tikras kintamasis yra atsitiktinai įtraukiamas į modelį arba išmetamas iš modelio.

Kai modelis yra mokomas su Random Forest algoritmu, kiekvienam požymiui yra skaičiuojamas jo svarbumas prognozės tikslumui. %IncMSE parodo, kiek vidutinio kvadratinio paklaidos metrika padidėja, kai tam tikras požymis yra pašalinamas iš modelio. Didelis %IncMSE rodiklis reiškia, kad šis požymis turi didelę įtaką prognozėms, o mažas rodiklis reiškia, kad šio požymio pašalinimas neturi didelės įtakos prognozėms.

Šis svarbumo matas leidžia identifikuoti, kurie požymiai yra labiausiai svarbūs modeliui ir turi didelę įtaką prognozėms. Tai svarbu, norint suprasti, kokie išorės faktoriai įtakoja modelio veikimą ir kokie požymiai yra informatyvūs prognozėms daryti, modeliuoti bitkoino grąžai.

Svarbiausi kintamieji pagal %IncMSE yra šie:

- *ndx* %IncMSE 5,89
- *ixic* %IncMSE 5,55
- *london_lag3* %IncMSE 4,09
- *s.p* %IncMSE 3,96
- *s.p_lag2* %IncMSE 3,68
- *dia* %IncMSE 3,67
- *aex_lag2* %IncMSE 3,54
- *nus* %IncMSE 3,52
- *nvda* %IncMSE 3,25
- *copper* %IncMSE 3,14
- *ndx_lag2* %IncMSE 3,11

- *copper_lag3* %IncMSE 3,08
- *aud_usd_lag2* %IncMSE 3,01
- *msft_lag1* %IncMSE 2,99
- *nus_lag4* %IncMSE 2,95

Toliau, tą patį modelį prasukau tik su šiais, svarbiausiais 15 kintamųjų.

Rezultatai:

Mean of squared residuals: 0,00422619

% Var explained: 4,67

- *ndx* %IncMSE 6,52
- *ixic* %IncMSE 7,12
- *london_lag3* %IncMSE 0,97
- *s.p* %IncMSE 4,78
- *s.p_lag2* %IncMSE 7,28
- *dia* %IncMSE 2,47
- *aex_lag2* %IncMSE 4,56
- *nus* %IncMSE 4,31
- *nvda* %IncMSE 4,33
- *copper* %IncMSE 6,34
- *ndx_lag2* %IncMSE 1,69
- *copper_lag3* %IncMSE 1,12
- *aud_usd_lag2* %IncMSE 1,17
- *msft_lag1* %IncMSE 1,05
- *nus_lag4* %IncMSE 1,30

Toliau, tą patį modelį prasukau tik su 5 svarbiausiais kintamaisiais.

Rezultatai:

Mean of squared residuals: 0,004330127

% Var explained: 3,22

- *ndx* %IncMSE 5,98
- *ixic* %IncMSE 5,87
- *s.p* %IncMSE 17,83
- *s.p_lag2* %IncMSE 13,31
- *ndx_lag2* %IncMSE 13,93

Matoma, kad modelio rezultatai nėra tikslūs prognozavimui, tačiau išsiskiria pagrindiniai 15 regresorių, reikšmingų bitkoino grąžai modeliuoti. *Random Forest* algoritmo rezultatai palyginami 3.2 skyrelyje.

3.1.4. XGBoost

Toliau, tokiu pačiu principu sprendžiau regresinį uždavinį, panaudodama *XGBoost* algoritimą. Duomenų imtis modelyje naudojama ta pati, kaip ir 3.1.3 skyrelyje.

Modelio rezultatai

Modelio formuluoė (R kalboje):

```
dtrain <- xgb.DMatrix(data = as.matrix(new_data[, selected_variables]), label = new_data$sged_res)

parametrai <- list( objective = "reg squarederror", nrounds = 800, eta = 0.1, max_depth = 20, sub-
sample = 0.8, colsample_bytree = 0.8)

xgb_model <- xgboost(params = parametrai, data = dtrain, nrounds = params$nrounds)
```

Modelis regresijos išraiška:

Modelis_XGB ~ XGBoost(sged_res ~ X, parametrai) , čia *X* – visi kintamieji ir jų ankstiniai, išskyrus bitkoiną ir bitkoino ankstinius, naudojamų miškų skaičius 800, kintamųjų kiekis naudojamas kiekvieno medžio apmokymo metu 20.

Modelio tikslumas:

Mean of squared residuals: 0,0001870408

% Var explained: 7,46

Svarbiausi kintamieji pagal %IncMSE yra šie:

- *sged_res_lag4* %IncMSE 14,41
- *london_lag5* %IncMSE 6,96
- *aapl* %IncMSE 6,18
- *sged_res_lag2* %IncMSE 5,49

- *london_lag1* %IncMSE 5,28
- *carbon_lag1* %IncMSE 3,20
- *sged_res_lag1* %IncMSE 2,69
- *aex* %IncMSE 1,74
- *london_lag3* %IncMSE 1,34
- *london_lag4* %IncMSE 1,21
- *ixic* %IncMSE 0,95
- *tsla_lag7* %IncMSE 0,93
- *sged_res_lag3* %IncMSE 0,88
- *carbon* %IncMSE 0,85
- *sged_res_lag7* %IncMSE 0,82

Tai yra geresni rezultatai, nei *Random Forest* algoritmo atveju. Matoma, kad bitkoino grąžų ankstiniai turi vis didesnę svarbą modelio rezultatui. Toliau – tęsiu modelio analizę su 5 svarbiausiais kintamaisiais pagal %IncMSE rodiklį.

Rezultatai:

Modelio tikslumas:

Mean of squared residuals: 0,005567457

% Var explained: 8,91

- *sged_res_lag4* %IncMSE 38,08
- *london_lag5* %IncMSE 18,45
- *sged_res_lag2* %IncMSE 16,65
- *london_lag1* %IncMSE 13,86
- *aapl* %IncMSE 12,80

Matoma, kad modelio rezultatai nėra tinkami regresiniam prognozavimui, tačiau išsiskiria pagrindiniai regresoriai, kurie gali turėti įtaką bitkoino grąžai modeliuoti. Šiame algoritme didesnę įtaką turi bitkoino grąžų ankstiniai. *XGBoost* algoritmo rezultatai palyginami 3.2 skyrelyje.

3.1.5. Neural Network

Galiausiai, tokiu pačiu principu sprendžiau regresinį uždavinį, panaudodama *Neural Network* algoritmą. Duomenų imtis modelyje naudojama ta pati, kaip ir 3.1.3 skyrelyje.

Modelio rezultatai

Modelio formuluotė (R kalboje):

```
nn_model <- neuralnet(formula, data = new_data, hidden = c(5, 3), linear.output = TRUE)
```

Modelis regresijos išraiška:

Modelis_NN ~ NeuralNet(sged_res ~ X, parametrai) , čia X – visi kintamieji ir jų ankstiniai, išskyrus bitkoiną ir bitkoino ankstinius, naudojamų pasleptų neuronų sluoksnis 2, kiekviename sluoksnyje paslepiant po 5 ir 3 neuronus atitinkamai.

Modelio tikslumas:

Mean of squared residuals: 0,000258997

% Var explained: 4,23

Svarbiausi kintamieji pagal *weights* yra šie:

- *sged_res_lag3* weights 11,23
- *ixic* weights 9,63
- *tsla_lag7* weights 8,12
- *london_lag3* weights 8,05
- *sged_res_lag1* weights 7,02
- *sged_res_lag2* weights 6,58
- *aapl* weights 6,23
- *silver_lag7* weights 6,12
- *dia_lag2* weights 5,48
- *london_lag4* weights 4,49
- *crude* weights 4,18
- *carbon_lag7* weights 3,17
- *sged_res_lag5* weights 3,02
- *carbon* weights 2,11

- *sged_res_lag7* weights 2,05

Šio modelio rezultatai, lyginant su prieš tai sudarytais modeliais – kitokie. *Neural Network* algoritmo rezultatas yra prastas, tačiau stebima tai, kad šiame algoritme vis daugiau įtakos turi kintamųjų ankstiniai – labiausiai bitkoino kainos grąžų ankstiniai. Tai yra indikacija, kad ankstiniai atneša daug informacijos iš savęs ir yra reikšmingi šiame modeliavime. *Neural Network* algoritmo rezultatai palyginami su kitais algoritmais 3.2 skyrelyje.

3.2. Matematinų modelių rezultatų palyginimas

Norėdama palyginti sudarytų modelių rezultatus ir nustatyti geriausius bei svarbiausius kintamuosius modelio atrankoje, šiuos modelius lyginsiu pagal šias metrikas *% Var explained* – modeliams ir *%IncMSE* – svarbiausiems kintamiesiems (*RF*, ir *XGBoost* modeliams), ir *weights Neural Network* modeliui. Tikslas – rasti geriausius modelius, atitinkančius baigiamojo projekto paskutinį uždavinį – panaudojant didžiųjų duomenų mokslo metodus sudaryti kelis bitkoino grąžos priklausomumo regresinius matematinius modelius, juos palyginti, rasti geriausią modelį bei aptarti jo rezultatus.

Modelių palyginimas pateikiamas lentelėje (žr. 10 lent.).

10 lentelė: Didžiųjų duomenų mokslo modelių regresijos uždaviniui spręsti palyginimas

Matematinis modelis	Rezultatai	Komentaras
Random Forest	<i>% Var explained</i> 5,02	Pirmasis <i>RF</i> mašininio mokymosi algoritmas buvo atliktas parenkant visus kintamuosius ir visus jų ankstinius, išskyrus bitkoiną ir bitkoino ankstinius. Šiame algoritme gauti svarbiausi kintamieji yra šie: <i>ndx</i> , <i>ixic</i> , <i>london_lag3</i> , <i>s.p</i> , <i>s.p_lag2</i> , <i>dia</i> , <i>aex_lag2</i> , <i>nus</i> , <i>nvda</i> , <i>copper</i> , <i>ndx_lag2</i> , <i>copper_lag3</i> , <i>aud_usd_lag2</i> , <i>msft_lag1</i> , <i>nus_lag4</i> . Šių kintamųjų tikslios <i>%IncMSE</i> reikšmės aprašytos 3.1.3 skyrelyje.

Tęsinys kitame puslapyje

Matematinis modelis	Rezultatai	Komentaras
Random Forest	<i>% Var explained 4,67</i>	Antrasis <i>RF</i> mašininio mokymosi algoritmas buvo atliktas parenkant svarbiausius 15 kintamųjų pagal pirmąjį <i>RF</i> modelį. Šiame algoritme naudoti kintamieji yra šie: <i>ndx</i> , <i>ixic</i> , <i>london_lag3</i> , <i>s.p</i> , <i>s.p_lag2</i> , <i>dia</i> , <i>aex_lag2</i> , <i>nus</i> , <i>nvda</i> , <i>copper</i> , <i>ndx_lag2</i> , <i>copper_lag3</i> , <i>aud_usd_lag2</i> , <i>msft_lag1</i> , <i>nus_lag4</i> . Šių kintamųjų tikslios <i>%IncMSE</i> reikšmės aprašytos 3.1.3 skyrelyje, svarbiausi iš jų pagal <i>%IncMSE</i> reikšmes buvo šie penki kintamieji: <i>ndx</i> , <i>ixic</i> , <i>s.p</i> , <i>s.p_lag2</i> , <i>ndx_lag2</i> .
Random Forest	<i>% Var explained 3,22</i>	Galiausiai, tą patį <i>RF</i> algoritmą atlikau ant svarbiausių 5 kintamųjų: <i>ndx</i> , <i>ixic</i> , <i>s.p</i> , <i>s.p_lag2</i> , <i>ndx_lag2</i> . Šių kintamųjų tikslios <i>%IncMSE</i> reikšmės aprašytos 3.1.3 skyrelyje. Apibendrinant <i>RF</i> modelius, aiškiai matyti, kad kintamųjų mažinimas pradiniam duomenų padavimo žingsnyje blogina <i>RF</i> algoritmo rezultatus. Kita vertus – mažiau kintamųjų reiškia mažesnę riziką modelio persimokymui.

Tęsinys kitame puslapyje

Matematinis modelis	Rezultatai	Komentaras
XGBoost	<i>% Var explained 7,46</i>	Pirmasis <i>XGBoost</i> mašininio mokymosi algoritmas buvo atliktas parenkant visus kintamuosius ir visus jų ankstinius, išskyrus bitkoiną ir bitkoino ankstinius. Šiame algoritme gauti svarbiausi kintamieji yra šie 15: <i>sged_res_lag4</i> , <i>london_lag5</i> , <i>aapl</i> , <i>sged_res_lag2</i> , <i>london_lag1</i> , <i>carbon_lag1</i> , <i>sged_res_lag1</i> , <i>aex</i> , <i>london_lag3</i> , <i>london_lag4</i> , <i>ixic</i> , <i>tsla_lag7</i> , <i>sged_res_lag3</i> , <i>carbon</i> , <i>sged_res_lag7</i> . Šių kintamųjų tikslios <i>%IncMSE</i> reikšmės aprašytos 3.1.4 skyrelyje.
XGBoost	<i>% Var explained 8,91</i>	Antrasis <i>XGBoost</i> mašininio mokymosi algoritmas buvo atliktas parenkant svarbiausius 5 kintamuosius pagal pirmąjį <i>XGBoost</i> modelį. Šiame algoritme naudoti kintamieji yra šie: <i>sged_res_lag4</i> , <i>london_lag5</i> , <i>sged_res_lag2</i> , <i>london_lag1</i> , <i>aapl</i> . Šių kintamųjų tikslios <i>%IncMSE</i> reikšmės aprašytos 3.1.4 skyrelyje. Apibendrinant <i>XGBoost</i> modelius, aiškiai matyti, kad kintamųjų mažinimas pradiniam duomenų padavimo žingsnyje pagerina <i>XGBoost</i> algoritmo rezultatus.

Tęsinys kitame puslapyje

lentelė 10 – tęsinys

Matematinis modelis	Rezultatai	Komentaras
Neural Network	% Var explained 4,23	Atlikus modeliavimą neuroninių tinklų algoritmu gaunu šiuos svarbiausius kintamuosius pagal <i>weights</i> : <i>sged_res_lag3</i> , <i>ixic</i> , <i>tsla_lag7</i> , <i>london_lag3</i> , <i>sged_res_lag1</i> , <i>sged_res_lag2</i> , <i>aapl</i> , <i>silver_lag7</i> , <i>dia_lag2</i> , <i>london_lag4</i> , <i>crude</i> , <i>carbon_lag7</i> , <i>sged_res_lag5</i> , <i>carbon</i> , <i>sged_res_lag7</i> . Šių kintamųjų tikslios <i>weights</i> reikšmės aprašytos 3.1.5 skyrelyje. Čia įdomu tai, kad bitkoino gražos ankstiniai turi reikšmingą įtaką modelio rezultatams.

XGBoost yra labai galinga ir plačiai naudojamas mašininio mokymosi algoritmas, kuris pasižymi aukštu spėjimo tikslumu. Šis modelis yra labai efektyvus dėl savo spartaus gradientinio kritimo optimizavimo metodo, kuris padeda geriau modeliuoti ir prognozuoti duomenis. *XGBoost* yra populiarus pasirinkimas, kai siekiama išgauti maksimalų spėjimo tikslumą. Šio tyrimo atveju, šis algoritmas generuoja geriausius rezultatus

Random Forest yra kita labai dažnai naudojama mašininio mokymosi technika. Šis algoritmas veikia jungdamas daug medžių modelių, kurie veikia kaip grupė. Ši kolektyvinė struktūra leidžia *Random Forest* modeliui efektyviai valdyti permokytas reikšmes ir sumažinti perprastinimo riziką. Todėl *Random Forest* taip pat yra geras pasirinkimas prognozuojant bitkoino kainos gražą.

Neural Network – neuroninių tinklų tipo modelis, kuris gali išmokti sudėtingas duomenų savybes ir atlikti sudėtingas prognozes. Tačiau rezultatai gali skirtis priklausomai nuo tinklo architektūros, naudojamų parametrų ir mokymo proceso. Šis tyrimas parodė, kad šiuo konkrečiu atveju *Neural Network* modelis pasirodė prasčiau nei *XGBoost* ir *Random Forest*. Tai gali būti dėl to, kad kitos modelių technikos buvo veiksmingesnės prognozuojant bitkoino kainos gražą turimiems duomenims ir tyrimo sąlygoms.

Svarbu prisiminti, kad šie rezultatai gali būti labai specifiniai dėl duomenų ir nustatytų modelio parametrų. Norint gauti tiksliausius prognozavimo rezultatus, būtina tinkamai pritaikyti modelį konkrečioms situacijoms, tinkamai parinkti parametrus ir įvertinti tinklo architektūrą.

Vis dėlto, šis atliktas tyrimas ir gauti rezultatai parodo, kad *XGBoost* ir *Random Forest* yra geri pasirinkimai regresiniam uždaviniui spręsti, kai norima prognozuoti bitkoino kainos gražą. Nors šie modeliai ir negeneruoja didelių skaičių kai kalbama apie dispersijos paaiškinamumą, tačiau šie algoritmai yra pirminė indikacija apie prognozavimą, tačiau svarbu visada atlikti tinkamą modelio parinki-

mą ir pritaikymą konkrečiai situacijai. Tolimesnis šio tyrimo tikslas galėtų būti modelių treniravimo, apmokymo uždavinys, tačiau magistrinio darbo kontekste, tai galėtų būti formuluojama kaip kitas magistrinis projektas.

Todėl apibendrinant galima teigti, kad geriausiai veikiantis šiam tyrimui išbandytas algoritmas ir jo parametrai yra *XGBoost* ir reikšmingiausi kintamieji šiam regresiniam bitkoino kainos gražos modeliavimo uždaviniui yra *sged_res_lag4*, *london_lag5*, *sged_res_lag2*, *london_lag1*, *aapl*.

3.3. Tyrimo trūkumai

Tyrime naudojami kintamieji yra pasirinkti galvojant apie jų potencialią sąsają su bitkoino kaina. Tai gali būti kintamieji, kurie yra žinomi kaip svarbūs kriptovaliutų rinkoje arba kurie gali būti susiję su išorinių rinkų veiksmų įtaka bitkoino kainai. Kitaip tariant – tai yra prielaidos, kurias aš, kaip duomenų analitikė, apsvarsčiau ir pritaikiau, kai rinkau reikalingus duomenis šiam tyrimui atlikti.

Pasaulyje nuolatos keičiasi išorės faktoriai, kurie gali tapti svarbūs bitkoino kainos pokyčiui. Šiame tyrime, naudojami jau įvykusių įvykių duomenys, kurie yra susiję su pokyčiais išorės rinkoje. Todėl drąsiai galima teigti, kad šis tyrimas yra praeities įvykių apžvalga, nesistengiant prognozuoti, kur investuotojai ateityje turėtų padėti savo pinigus, siekdami pelno. Priešingai – šis tyrimas parodo, kur investuotojai jau padėjo pinigus, ir koks ryšys yra stebimas su bitkoino kaina.

Svarbu pažymėti, kad pasirinkti kintamieji nebūtinai turi pilną informaciją arba tiesioginę koreliaciją su bitkoino kaina. Iš ties sunku identifikuoti koreliacijas tarp kintamųjų logaritminių gražų, nes kartais, tiesinis ryšys tiesiog neegzistuoja, o koreliacija tiria būtent tai. Kita vertus, šis tyrimas yra orientuotas į tai siekiant rasti, ar šie kintamieji gali būti reikšmingi prognozuojant ar paaiškinant bitkoino kainos pokyčius, nors jų savybės ir ryšiai gali būti sudėtingi ar neviseškai suprantami.

Dauguma matematinio mašininio mokymosi metodų, tokių kaip *Random Forest*, *XGBoost* ir *Neural Network*, turi specifinę logiką ir skaičiavimo algoritmus, kurie gali būti taikomi analizuojant duomenis ir modeliuojant ryšius tarp kintamųjų. Šie metodai gali naudoti skirtingus duomenų dalijimo būdus, atrankos metodus ir parametrus, kurie gali turėti įtakos rezultatams.

Šiame tyrime tiriami dieniniai bitkoino duomenys. Duomenys nėra agreguojami stambesniu lygmeniu (savaitiniu, mėnesiniu) siekiant rasti ryšį tarp dieninių kainos pokyčių, nes ši rinka yra labai kintanti – volatili ir duomenų agregavimas gali privesti prie svarbios informacijos praradimo – didesnio bendrumo prarandant tikslumą.

Analitinės technikos įtaka rezultatų interpretavimui gali būti svarbi, nes skirtingi metodai gali gauti skirtingus rezultatus ar pabrėžti skirtingus kintamuosius kaip svarbius. Interpretuojant rezultatus, svarbu atsižvelgti į naudojamų metodų veikimo principus ir suvokti, kad jie gali turėti savo specifinių privalumų ir specifinių ribojimų.

Šis tyrimas buvo atliktas naudojant *R Studio* programinę įrangą. Programinės įrangos veikimo parametrai taip pat gali būti viena iš priežasčių, kodėl gauti rezultatai yra tokie, kokie yra. Pavyzdžiui, tam šios programinės įrangos funkcijos gali turėti išankstinius nustatymus, kurie gali būti tinkami daugumai scenarijų, bet ne visada tinkami šiam tyrimui. Šie nustatymai gali apimti duomenų apdorojimo

metodiką, modelio parinkimą, optimizavimo strategijas ir kita. Keičiant šiuos nustatymus, gali būti gauti skirtingi rezultatai. Taip pat svarbu atsižvelgti į programinės įrangos versiją ir įdiegtus paketus. Paketų versijos gali skirtis pagal funkcionalumą ir aprašytus algoritmus. Savo tyrime naudočiau tyrimo atlikimo metu esančią naujausią *R Studio* versiją *2023.03.0-daily+82.pro2*. Tai gali reikšti, kad dar naujesni algoritmai arba patobulinimai ateityje gali būti reikšmingi šio tyrimo rezultatų tikslumui ir patikimumui.

Be to, verta paminėti, kad visi šie metodai yra tik priemonės duomenų analizei, ir jų rezultatai neturėtų būti traktuojami kaip absoliuti tiesa arba vienintelis teisingas atsakymas. Tyrimo rezultatai turėtų būti vertinami kritiškai, atsižvelgiant į naudojamų metodų galimybes, duomenų kokybę, pasirinktus kintamuosius ir kitus veiksnius, kurie gali turėti įtakos rezultatų patikimumui.

Išvados

Tyrimo išvados, pagal uždavinius:

- 1 užd.** išnagrinėti bitkoino laiko eilutę, rasti paaiškinamas priežastis galimiems kainos šuoliams ir nukritimams; įvertinti kainos augimo ar kainos kritimo tendencijas.

Išvados šiam uždavinui:

- Stilizuotų faktų analizė parodo, kad bitkoino laiko eilutė yra leptokurtinė (angl. *leptocurtic*) finansinė laiko eilutė, kurią yra sunku modeliuoti, stebimas didelis kintamumas (angl. *volatility*) ir heteroskedastiškumas.
- Bull market: Manoma, kad vienas iš ryškesnių pakilimo periodų buvo nuo 2013 metų pradžios iki 2014 metų pabaigos, kai bitkoino kaina smarkiai kilo. Taip pat galima išskirti kainos kilimą nuo 2020 metų spalio iki 2021 metų kovo, kai bitkoino kaina taip pat ženkliai paaugo.
- Bear market: Ryškesnis nukritimo periodas pastebėtas nuo 2021 metų lapkričio pradžios iki 2022 metų sausio mėnesio, kai bitkoino kaina smarkiai sumažėjo. Taip pat galima išskirti dar vieną nukritimo periodą – nuo 2022 metų balandžio iki 2022 metų liepos, kai kaina taip pat patyrė ženklių nuosmukį.

- 2 užd.** atlikti išorinių veiksnių analizę, surasti veiksnius, turinčius reikšmingą įtaką bitkoino kainos svyravimams.

Išvados šiam uždavinui:

- Tyrimo rezultatai parodo, kad bitkoino kainai didelę įtaką turi išorės veiksniai, tokie kaip ekonominės sąlygos ir geopolitiniai veiksniai.
- Išoriniai veiksniai, tokiu kaip reguliavimo priemonės ir teisinis aplinkos pokytis, turi ryškų poveikį bitkoino kainų svyravimams.
- Apžvelgus tyrimo duomenis, matyti, kad pasaulinės finansų rinkos tendencijos taip pat turėjo įtakos bitkoino kainoms.
- Tyrimas atskleidžia, kad socialinės medijos ir visuomenės nuomonės taip pat gali paveikti bitkoino kainų pokytį.
- Išvalgos iš šio tyrimo rodo, kad sėkmingas bitkoino kainos prognozavimas privalo atsižvelgti į išorinius veiksnius ir jų potencialų poveikį kriptovaliutų rinkai. Čia svarbu paminėti, kad ateities prognozėms sudaryti, reikia suvokti, kad yra veiksniai, kurių neįmanoma numatyti, nes jie dar niekada nevyko, arba anksčiau nebuvo reikšmingi.

- 3 užd.** panaudojant didžiųjų duomenų mokslo metodus sudaryti kelis bitkoino gražos priklausomumo regresinius matematinius modelius, juos palyginti, rasti geriausią modelį bei aptarti jo rezultatus.

Išvados šiam uždavinui:

- Esama duomenų priklausomybė laike išmodeliuota ARMA-GARCH modeliu su atsitiktine komponente, turinčia *Skewed Generalized Error Distribution* (sged) skirstinį. Tuomet regresinis modelis sudaromas šio modelio liekanoms, siekiant identifikuoti galimą poveikį iš išorės. Toliau duomenų šokuose, kurie lieka nuo GARCH modelio ieškoma poveikio iš aplinkos, darant prielaidą, kad būtent išorės poveikis nulėmė tą šoką duomenyse.
- Atlikus matematinį modeliavimą remiantis trimis mašininio mokymosi metodais, geriausi rezultatai bitkoino kainos gražos regresniam uždaviniui spręsti gauti naudojant *XGBoost* algoritmą.
- Pagal geriausio šiame tyrime gauto modelio rezultatus, reikšmingiausi išorės kintamieji yra šie: *sged_res_lag4*, *london_lag5*, *sged_res_lag2*, *london_lag1*, *aapl*, t.y. GARCH modelio liekanų 2 ir 4 ankstiniai, Londono Robusta kavos ateities sanodrių 1 ir 5 ankstiniai, bei įmonės *Apple* akcijos.
- Reikšmingą įtaką visiems modeliams ir jų rezultatams turi kintamųjų ankstiniai.
- Tolimesnė mašininio mokymosi tyrimo analizės dalis gali tapti idėja kito magistrinio baigiamojo projekto tyrimui, siekiant dar labiau išstbulinti modelių parametrus, kad regresijos uždavinio rezultatai būtų dar tikslesni, pavyzdžiui ieškoti senesnių ankstinių nei viena savaitė.

Literatūra

- [1] Tanya Kaushal. Labor shortage: 'You've got to start thinking that robots can do some of these jobs,' Expert says. Prieiga per internetą: <https://uk.news.yahoo.com/labor-shortage-robots-jobs-193116161.html>.
- [2] Anna Wise. Three-quarters of UK business struck by labour shortages. Prieiga per internetą: <https://www.bloomberg.com/news/articles/2022-10-10/three-quarters-of-uk-business-struck-by-labour-shortages-survey?leadSource=uverify20wall>.
- [3] Lietuvos statistikos departamentas. Statistikos departamentas atsigręžia į didžiuosius duomenis. Prieiga per internetą: <https://www.vz.lt/verslo-valdymas/2022/11/29/statistikos-departamentas-atsigrezia-i-didziuosius-duomenis>.
- [4] Robert Sher. Building a KPI mindset for growth. Prieiga per internetą: <https://www.forbes.com/sites/robertsher/2022/09/27/building-a-kpi-mindset-for-growth/?sh=62dd75c755f7>.
- [5] Bloomberg UK dashboard. The 12 global economic indicators to watch. Prieiga per internetą: <https://www.bloomberg.com/graphics/world-economic-indicators-dashboard/?leadSource=uverify20wall>.
- [6] Nicholas Graetz Joseph Friedman, Hunter York. Measuring and forecasting progress towards the education-related SDG targets. *Nature*, 580(184):636–639, 2020.
- [7] Dalius Simėnas. SEB strategas apie infliaciją, palūkanas ir kada sprogsta kainų burbulai. Prieiga per internetą: <https://www.vz.lt/finansai-apskaita/2021/02/03/seb-strategas-apie-infliacija-palukanas-ir-kada-sprogsta-kainu-burbulai>.
- [8] Agnė Škultinaitė. Vakarai nebeslepia – Rusijos pradėto karo sąskaitas apmokame visi. Prieiga per internetą: <https://www.vz.lt/verslo-aplinka/2022/09/01/vakarai-nebeslepia--rusijos-pradeto-karo-saskaitas-apmokame-visi>.
- [9] Justinas Gapšys. Volstritas kalba: auksas, euras, bitkoinas, trumpalaikės jav obligacijos. Prieiga per internetą: <https://www.vz.lt/rinkos/2023/04/16/volstritas-kalba-auksas-euras-bitkoinas-trumpalaikes-jav-obligacijos>.
- [10] Gerwin AW Griffioen. Technical analysis in financial markets. 2003.
- [11] Mohammad Omar Farooq and Md Hasib Reza. Dow Jones islamic market US index: applying technical analysis from a comparative perspective. *International Journal of Islamic and Middle Eastern Finance and Management*, 7(4):395–420, 2014.
- [12] Xi Chen, Yang Ha Cho, Yiwei Dou, and Baruch Lev. Fundamental analysis of detailed financial data: a machine learning approach. *Journal of Accounting Research*, 60(2):467–515, 2022.

- [13] Ruey S Tsay. *Analysis of financial time series*. John Wiley & sons, 2005.
- [14] Tome Almeida Borges and Rui Ferreira Neves. Ensemble of machine learning algorithms for cryptocurrency investment with different data resampling methods. *Applied Soft Computing*, 90: 106187, 2020.
- [15] Nor Azizah Hitam and Amelia Ritahani Ismail. Comparative performance of machine learning algorithms for cryptocurrency forecasting. *Ind. J. Electr. Eng. Comput. Sci*, 11(3):1121–1128, 2018.
- [16] Franco Valencia, Alfonso Gómez-Espinosa, and Benjamín Valdés-Aguirre. Price movement prediction of cryptocurrencies using sentiment analysis and machine learning. *Entropy*, 21(6): 589, 2019.
- [17] Emre Şaşmaz and F Boray Tek. Tweet sentiment analysis for cryptocurrencies. In *2021 6th International Conference on Computer Science and Engineering (UBMK)*, pages 613–618. IEEE, 2021.
- [18] Arti Jain, Shashank Tripathi, Harsh Dhar Dwivedi, and Pranav Saxena. Forecasting price of cryptocurrencies using tweets sentiment analysis. In *2018 eleventh international conference on contemporary computing (IC3)*, pages 1–7. IEEE, 2018.
- [19] Wee Seng Wong, Dennis Saerbeck, and Dante Delgado Silva. Cryptocurrency: A new investment opportunity? an investigation of the hedging capability of cryptocurrencies and their influence on stock, bond and gold portfolios. *An Investigation of the Hedging Capability of Cryptocurrencies and Their Influence on Stock, Bond and Gold Portfolios (January 29, 2018)*, 2018.
- [20] Simona Andreea Apostu, Mirela Panait, László Vasa, Constanta Mihaescu, and Zbysław Dobrowolski. NFTs and cryptocurrencies.the metamorphosis of the economy under the sign of blockchain: a time series approach. *Mathematics*, 10(17), 2022. ISSN 2227-7390. doi: 10.3390/math10173218. URL <https://www.mdpi.com/2227-7390/10/17/3218>.
- [21] Syed Abdul Rehman Khan, Zhang Yu, Salman Sarwat, Danish Iqbal Godil, Sumeela Amin, and Sobia Shujaat. The role of block chain technology in circular economy practices to improve organisational performance. *International Journal of Logistics Research and Applications*, 25 (4-5):605–622, 2022. doi: 10.1080/13675567.2021.1872512. URL <https://doi.org/10.1080/13675567.2021.1872512>.
- [22] Maxine Berg. In pursuit of luxury: global history and British consumer goods in the eighteenth century. *Past & present*, (182):85–142, 2004.
- [23] Grant McCracken. The history of consumption: a literature review and consumer guide. *Journal of Consumer Policy*, 10(2):139–166, 1987.
- [24] John Brewer and Roy Porter. *Consumption and the World of Goods*. Routledge, 2013.
- [25] Susan Strasser. The alien past: Consumer culture in historical perspective. *Journal of Consumer Policy*, 26(4):375–393, 2003.

- [26] Luis Bonilla-Molina. COVID-19 on route of the fourth industrial revolution. *Postdigital Science and Education*, 2:562–568, 2020.
- [27] Ludvík Eger, Lenka Komárková, Dana Egerová, and Michal Mičík. The effect of COVID-19 on consumer shopping behaviour: Generational cohort perspective. *Journal of Retailing and Consumer Services*, 61:102542, 2021.
- [28] COVID-19: how consumer behavior will be changed. Prieiga per internetą: <https://www.accenture.com/us-en/insights/consumer-goods-services/coronavirus-consumer-behavior-research>.
- [29] Yadong Liu, Paritosh Sharma, Vipin Jain, Avanish Shukla, Malik Shahzad Shabbir, Mosab I Tabash, and Chanchal Chawla. The relationship among oil prices volatility, inflation rate, and sustainable economic growth: Evidence from top oil importer and exporter countries. *Resources Policy*, 77:102674, 2022.
- [30] Phil Molyneux, Alessio Reghezza, John Thornton, and Ru Xie. Did negative interest rates improve bank lending? *Journal of Financial Services Research*, 57:51–68, 2020.
- [31] Jens Eisenshmidt and Frank Smets. Negative interest rates: Lessons from the euro area. *Series on Central Banking Analysis and Economic Policies no. 26*, 2019.
- [32] Pamela Peterson Drake. The gold-stock market relationship during covid-19. *Finance research letters*, 44:102111, 2022.
- [33] Margherita Bottero, Camelia Minoiu, José-Luis Peydró, Andrea Polo, Andrea F Presbitero, and Enrico Sette. Expansionary yet different: credit supply and real effects of negative interest rate policy. *Journal of Financial Economics*, 146(2):754–778, 2022.
- [34] Gili Yen and Cheng-few Lee. Efficient market hypothesis (EMH): past, present and future. *Review of Pacific Basin Financial Markets and Policies*, 11(02):305–329, 2008.
- [35] Remigijus Leipus and Rimas Norvaiša. Finansų rinkos teorijų pagrindai. *Pinigų studijos*, 4: 5–28, 2003.
- [36] Meilutė Jasienė. Visuotinė lietuvių enciklopedija. Prieiga per internetą: <https://www.vle.lt/straipsnis/akciju-indeksas/>.
- [37] Peter Temin. The great recession & the great depression. *Daedalus*, 139(4):115–124, 2010.
- [38] Sofia Pappa, Nikolaos Athanasiou, Nikolaos Sakkas, Stavros Patrinos, Elpitha Sakka, Zafeiria Barmparessou, Stamatoula Tsikrika, Andreas Adraktas, Athanasia Pataka, Ilias Migdalīs, et al. From recession to depression? Prevalence and correlates of depression, anxiety, traumatic stress and burnout in healthcare workers during the COVID-19 pandemic in Greece: A multi-center, cross-sectional study. *International journal of environmental research and public health*, 18(5): 2390, 2021.
- [39] Ryan Farrell. An analysis of the cryptocurrency industry. 2015.

- [40] Coryanne Hicks. Different types of cryptocurrencies. Prieiga per internetą: <https://www.forbes.com/advisor/investing/cryptocurrency/different-types-of-cryptocurrencies>.
- [41] Yuanyuan Zhang, Stephen Chan, Jeffrey Chu, and Hana Sulieman. On the market efficiency and liquidity of high-frequency cryptocurrencies in a bull and bear market. *Journal of Risk and Financial Management*, 13(1):8, 2020.
- [42] Vasileios Kallinterakis and Ying Wang. Do investors herd in cryptocurrencies—and why? *Research in International Business and Finance*, 50:240–245, 2019.
- [43] Victor Fabulosa. 7 most influential people in crypto. Prieiga per internetą: <https://dailycoin.com/7-most-influential-people-in-crypto>.
- [44] Vildana Hajric Hannah Miller and Olga Kharif. Winklevoss twins lend 100 million to their Gemini crypto platform. Prieiga per internetą: <https://www.bloomberg.com/news/articles/2023-04-10/winklevoss-twins-lend-100-million-to-gemini-crypto-exchange>.
- [45] Jadvyga Čiburienė. Visuotinė lietuvių enciklopedija. Prieiga per internetą: <https://www.vle.lt/straipsnis/spekuliacija/>.
- [46] Rajeev Dhir. Pump-and-dump: definition, how the scheme is illegal, and types. Prieiga per internetą: <https://www.investopedia.com/terms/p/pumpanddump.asp>.
- [47] Lennart Ante. How Elon Musk’s Twitter activity moves cryptocurrency markets. *Technological Forecasting and Social Change*, 186:122112, 2023. ISSN 0040-1625. doi: <https://doi.org/10.1016/j.techfore.2022.122112>. URL <https://www.sciencedirect.com/science/article/pii/S0040162522006333>.
- [48] Evelyn Cheng. Staten Island-based ‘CabbageTech’ charged with bitcoin-related fraud after promising 300 percent returns in a week. Prieiga per internetą: <https://www.cnn.com/2018/01/19/us-regulator-charges-cabbagetech-with-bitcoin-related-fraud.html>.
- [49] Stafford C Baum. Cryptocurrency fraud: A look into the frontier of fraud. *Georgia Southern University. Honors College Theses*, 2018.
- [50] Paulius Viluckas. „Fintech“ bendrovių Lietuvoje pernai padaugėjo 13%, pritrauktos rekordinės investicijos. Prieiga per internetą: <https://www.vz.lt/inovacijos/technologijos/2022/04/01/fintech-bendroviu-lietuvoje-pernai-padaugejo-13-pritrauktos-investicijos>.
- [51] BNS. „Payserai LT“ – 100 tūkst. eurų bauda už neištaisytus pažeidimus. Prieiga per internetą: <https://www.15min.lt/verslas/naujiena/bendroves/payserai-lt-100-tukst-euru-bauda-uz-neistaisytus-pazeidimus-663-1929580>.
- [52] Shobit Seth. The 6 most private cryptocurrencies. Prieiga per internetą: <https://www.investopedia.com/tech/five-most-private-cryptocurrencies/>.
- [53] Andreas Vlachos, Klitos Christodoulou, and Elias Iosif. An algorithmic blockchain readiness index. *Multidisciplinary Digital Publishing Institute Proceedings*, 28(1):4, 2019.

- [54] Birton Cowden and Jintong Tang. Institutional entrepreneurial orientation: Beyond setting the rules of the game for blockchain technology. *Technological Forecasting and Social Change*, 180:121734, 2022. ISSN 0040-1625. doi: <https://doi.org/10.1016/j.techfore.2022.121734>. URL <https://www.sciencedirect.com/science/article/pii/S0040162522002608>.
- [55] Ani Petrosyan. Distribution of malware attack vectors worldwide from 2018 to 2022. Prieiga per internetą: <https://www.statista.com/statistics/1238997/malware-attacks-vectors/>.
- [56] Raynor de Best. Total value of cryptocurrency lost to and recovered from theft and other attacks between march 2020 and february 2022. Prieiga per internetą: <https://www.statista.com/statistics/1285057/crypto-theft-size/>.
- [57] Daniel B Nelson. Conditional heteroskedasticity in asset returns: A new approach. *Econometrica: Journal of the econometric society*, pages 347–370, 1991.
- [58] Nashirah Abu Bakar and Sofian Rosbi. Autoregressive integrated moving average (ARIMA) model for forecasting cryptocurrency exchange rate in high volatility environment: A new insight of bitcoin transaction. *International Journal of Advanced Engineering Research and Science*, 4 (11):130–137, 2017.
- [59] Roman Matkovskyy. Centralized and decentralized bitcoin markets: Euro vs USD vs GBP. *The Quarterly Review of Economics and Finance*, 71:270–279, 2019.
- [60] Xiao Zhong and David Enke. Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation*, 5(1):1–20, 2019.
- [61] Shaen Corbet, Charles Larkin, Brian M.Lucey, Andrew Meegan, and Larisa Yarovaya. The impact of macroeconomic news on bitcoin returns. *The European Journal of Finance*, 26(14): 1396–1416, 2020. doi: 10.1080/1351847X.2020.1737168. URL <https://doi.org/10.1080/1351847X.2020.1737168>.
- [62] C. Alexander and M. Dakos. A critical investigation of cryptocurrency data and analysis. *Quantitative Finance*, 20(2):173–188, 2020. doi: 10.1080/14697688.2019.1641347. URL <https://doi.org/10.1080/14697688.2019.1641347>.
- [63] Erdinc Akyildirim, Shaen Corbet, Brian Lucey, Ahmet Sensoy, and Larisa Yarovaya. The relationship between implied volatility and cryptocurrency returns. *Finance Research Letters*, 33:101212, 2020. ISSN 1544-6123. doi: <https://doi.org/10.1016/j.frl.2019.06.010>. URL <https://www.sciencedirect.com/science/article/pii/S1544612319303381>.
- [64] Zheshi Chen, Chunhong Li, and Wenjun Sun. Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365:112395, 2020. ISSN 0377-0427. doi: <https://doi.org/10.1016/j.cam.2019.112395>. URL <https://www.sciencedirect.com/science/article/pii/S037704271930398X>.
- [65] Shihao Gu, Bryan Kelly, and Dacheng Xiu. Empirical asset pricing via machine learning. *The Review of Financial Studies*, 33(5):2223–2273, 2020.

- [66] Yujun Liu, Zhongfei Li, Ramzi Nekhili, and Jahangir Sultan. Forecasting cryptocurrency returns with machine learning. *Research in International Business and Finance*, 64:101905, 2023.
- [67] Investing.com. About. Prieiga per internetą: <https://www.investing.com/about-us/>.
- [68] John Y Campbell. Asset prices, consumption, and the business cycle. *Handbook of macroeconomics*, 1:1231–1303, 1999.
- [69] Valerie Chavez-Demoulin*, Anthony C Davison, and Alexander J McNeil. Estimating value-at-risk: a point process approach. *Quantitative Finance*, 5(2):227–234, 2005.
- [70] Robert F Engle. Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the econometric society*, pages 987–1007, 1982.
- [71] Robert Engle. For methods of analyzing economic time series with time-varying volatility (ARCH). 1982.
- [72] Manuela Braione and Nicolas K Scholtes. Forecasting value-at-risk under different distributional assumptions. *Econometrics*, 4(1):3, 2016.
- [73] IM Md Ghani and HA Rahim. Modeling and forecasting of volatility using arma-garch: case study on malaysia natural rubber prices. In *IOP Conference Series: Materials Science and Engineering*, volume 548, page 012023. IOP Publishing, 2019.
- [74] Yanli Liu, Yourong Wang, and Jian Zhang. New machine learning algorithm: Random forest. In *Information Computing and Applications: Third International Conference, ICICA 2012, Chengde, China, September 14-16, 2012. Proceedings 3*, pages 246–252. Springer, 2012.
- [75] Cran R project. Package ‘randomForest’. Prieiga per internetą: <https://cran.r-project.org/web/packages/randomForest/randomForest.pdf>, .
- [76] Santhanam Ramraj, Nishant Uzir, R Sunil, and Shatadeep Banerjee. Experimenting xgboost algorithm for prediction and classification of different datasets. *International Journal of Control Theory and Applications*, 9(40):651–662, 2016.
- [77] Cran R project. Package ‘xgboost’. Prieiga per internetą: <https://cran.r-project.org/web/packages/xgboost/xgboost.pdf>, .
- [78] Donald F Specht et al. A general regression neural network. *IEEE transactions on neural networks*, 2(6):568–576, 1991.
- [79] Tin-Yau Kwok and Dit-Yan Yeung. Constructive algorithms for structure learning in feedforward neural networks for regression problems. *IEEE transactions on neural networks*, 8(3): 630–645, 1997.
- [80] Cran R project. Package ‘neuralnet’. Prieiga per internetą: <https://cran.r-project.org/web/packages/neuralnet/neuralnet.pdf>, .