



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Kriptovaliutų tarpusavio priklausomybių tyrimas globalių krizių metu

Baigiamasis magistro studijų projektas

Edvinas Lisauskas

Projekto autorius

Doc. dr. Audrius Kabašinskas

Vadovas

Doc. dr. Aušrinė Lakšutienė

Vadovė

Kaunas, 2023



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Kripto valiutų tarpusavio priklausomybių tyrimas globalių krizių metu

Baigiamasis magistro studijų projektas

Didžiųjų verslo duomenų analitika (6213AX001)

Edvinas Lisauskas

Projekto autorius

Doc. dr. Audrius Kabašinskas

Vadovas

Doc. dr. Aušrinė Lakšutienė

Vadovė

Doc. dr. Mantas Landauskas

Recenzentas

Doc. dr. Lina Sinevičienė

Recenzentė

Kaunas, 2023



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Edvinas Lisauskas

Kripto valiutų tarpusavio priklausomybių tyrimas globalių krizių metu

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

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

Edvinas Lisauskas

Patvirtinta elektroniniu būdu

Lisauskas, Edvinas. Kriptovaliutų tarpusavio priklausomybių tyrimas globalių krizių metu. Magistro studijų baigiamasis projektas, vadovas doc. dr. Audrius Kabašinskas, vadovė doc. dr. Aušrinė Lakštutienė; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

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

Reikšminiai žodžiai: kriptovaliutos, koreliacinė analizė, tarpusavio priklausomybių analizė, COVID-19.

Kaunas, 2023. 52 p.

Santrauka

Kriptovaliutų tematika ir siekis jas pažinti bei suprasti yra neatsiejama šių dienų aktualija. Mokslo ir finansų sektorių atstovai siekia giliau, šia santykinai naują technologiją, suprasti ir pritaikyti. Mokslinėje literatūroje galime rasti ne vieną bandymą analizuoti kriptovaliutų tarpusavio priklausomybes siekiant surasti tendencijas ir lyderiaujančius žetonus. Atradus sąsajas galima konstruoti diversifikuotą investicinį portfelį, kuris sumažintu finansinę riziką. Dėl santykinai jaunos kriptovaliutų rinkos struktūros sąsajos tarp žetonų yra kintančios. Norint kriziniais periodais patirti minimalius nuostolius, reikia išanalizuoti kaip šios sąsajos kinta globalių krizių metu ir ar galime panaudoti dalį žetonų kaip apsidraudimo priemonę. Todėl šiame darbe ir buvo nagrinėjami kriptovaliutų tarpusavio ryšiai ir jų dinamika skirtingais periodais, kurie apėmė tokias krizes kaip COVID-19 pandemija.

Kriptovaliutų tarpusavio priklausomybių kriziniais laikotarpiais problematika buvo aprašyta pirmoje dalyje atlikus mokslinės literatūros analizę. Antroje dalyje buvo sudaryta metodiką, kaip išanalizuoti pasirinktus duomenis ir kokios savybės joms yra būdingos bei kaip atlikti koreliacinę, impulso atsako, Grangerio priežastingumo, kintamumo plitimo analizes. Trečioje dalyje buvo pateikti gauti rezultatai, kurie parodo sustiprėjusius koreliacinius ryšius COVID-19 pandemijos pradžios laikotarpyje ir duomenų imties laikotarpio pabaigoje. Minimalių medžių metodas parodė kintančias sąsajas ir dominuojančius žetonus skirtingais laikotarpiais, kai tuo tarpu impulso atsako ir Grangerio priežastingumo analizė parodė kryptinius ryšius prieš ir po pandeminio laikotarpio. Kintamumo plitimo analizė sudarė bendrą vaizdą kaip kriptovaliutų sistemoje persiduoda kintamumas ir jo ženklų padidėjimą per virtualių valiutų rinkos krizinius periodus bei COVID-19 pandemiją.

Lisauskas, Edvinas. Study of Cryptocurrency Interdependencies during Global Crises. Master's Final Degree Project, assoc. prof. Audrius Kabašinskas, assoc. prof. Aušrinė Lakštutienė; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology.

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

Keywords: cryptocurrency, correlation analysis, interdependencies, COVID-19.

Kaunas, 2023. 52 p.

Summary

Cryptocurrencies, and the quest to know and understand them, are a hot topic these days. The scientific and financial sectors are seeking to understand and apply this relatively new technology in greater depth. In the scientific literature, we can find a number of attempts to analyse the interdependencies between cryptocurrencies in order to find trends and leading tokens. The discovery of correlations can lead to the construction of a diversified investment portfolio that minimises financial risk. Due to the relatively young structure of the cryptocurrency market, the correlations between tokens are volatile. In order to minimise losses during crisis periods, it is necessary to analyse how these linkages change during global crises and whether we can use some of the tokens as a hedging instrument. Therefore, this work has examined the interconnections between cryptocurrencies and their dynamics during different periods, which included crises such as the COVID-19 pandemic.

The issue of cryptocurrency interdependencies during crisis periods was described in the first part of the paper through a literature review. In the second part, a methodology was developed to analyse the selected data and the characteristics they exhibit, as well as how to perform correlation, impulse response, Granger causality, and volatility spillover analyses. In the third part, the results obtained were presented, which show an increased correlation between the start of the COVID-19 pandemic and the end of the data sample period. The minimum tree approach showed changing correlations and dominant tokens in different time periods, while impulse response and Granger causality analyses showed directional relationships in the pre- and post-pandemic period. The volatility propagation analysis provided an overall picture of how volatility is propagated in the cryptocurrency system and the increase in its tokens during the crisis periods of the virtual currency market and the COVID-19 pandemic.

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Įvadas	9
1. Kriptovaliutų rinkos mokslinės literatūros analizė	11
1.1. Kriptovaliutų raida	11
1.2. Kriptovaliutų išskirtinumas finansų rinkoje	14
1.3. COVID-19 pandemijos įtaka finansų rinkoje	20
1.4. Kriptovaliutų rinkos mokslinės literatūros analizės apibendrinimas	22
2. Kriptovaliutų tarpusavio priklausomybių nustatymo kriziniu laikotarpiu vertinimo metodika	23
2.1. Tyrimo eiga	23
2.2. Duomenų rinkinio ir naudojamos programinės įrangos apžvalga	24
2.3. Bendroji aprašomoji statistika	24
2.4. Stilizuoti faktai	25
2.5. Koreliacinė analizė	27
2.6. Mažiausiai besidriekiančio medžio metodas	28
2.7. Duomenų stacionarumo patikrinimas ir Grangerio priežastingumo testas	30
2.8. Kintamumo plitimas	31
3. Kriptovaliutų tarpusavio priklausomybių nustatymo kriziniu laikotarpiu tyrimo rezultatai	33
3.1. Duomenų rinkinio analizė	33
3.2. Stilizuotų faktų patikra	35
3.3. Koreliacinė analizė	37
3.4. Minimaliai besidriekiančio medžio metodo pritaikymo rezultatai	40
3.5. Duomenų stacionarumo, IRF ir Grangerio priežastingumo testo rezultatai	41
3.6. Kintamumo plitimo analizės rezultatai	46
Išvados	48
Literatūros sąrašas	50
Priedai	53
1 priedas. Viso laikotarpio kriptovaliutų Grangerio priežastingumo testo grafikas	53
2 priedas. Kryžminio poveikio matrica visam laikotarpiui	53

Lentelių sąrašas

1 lentelė. Mokslininkų kriptovaliutų rinkos tyrimui naudoti metodai ir apžvelgta ekonominė tematika	22
2 lentelė. Ljung-Box testo rezultatai	36
3 lentelė. Shapiro-Wilk testo rezultatai.....	36
4 lentelė. ADF testo rezultatai.....	41

Paveikslų sąrašas

1 pav. NTL, APL ir MOL metrikų rezultatų grafikai iš Ho ir kt. (2020) tyrimo	19
2 pav. Tyrimo eiga	23
3 pav. Ryšio stiprumas vertinant pagal koreliacijos koeficiento vertes	27
4 pav. Normalizuotų kriptovaliutų kainų grafikas	33
5 pav. Logaritminių dieninių kriptovaliutų grąžų grafikas	34
6 pav. Logaritminių grąžų aprašomoji statistika	34
7 pav. Logaritminių grąžų vidurkio, standartinio nuokrypio, eksceso ir asimetrijos rezultatai	35
8 pav. Logaritminių grąžų Bitcoin ir Ethereum autokoreliacijų tyrimo grafinis pavyzdys	35
9 pav. Kintamumo klasterių susidarymas kriptovaliutose	36
10 pav. Q-Q grafikas	37
11 pav. Spirmano koreliacijos koeficientų matrica	37
12 pav. Netiesinės koreliacijos koeficientų matrica	38
13 pav. Slenkantis Spirmano koreliacijos koeficientas tarp Bitcoin ir likusių kriptovaliutų	38
14 pav. Slenkantis Spirmano koreliacijos koeficientas tarp Ripple ir likusių kriptovaliutų	39
15 pav. Slenkantis Spirmano koreliacijos koeficientas tarp Filecoin ir likusių kriptovaliutų	39
16 pav. MST metodu gauti medžiai 4 skirtingais laikotarpiais	40
17 pav. Maksimalaus ryšio ir liekanų koeficiento kitimas laike	41
18 pav. IRF impulsų rezultatai prieš pandeminiame laikotarpyje	42
19 pav. Stipriausi Bitcoin ir Ethereum IRF impulsai prieš pandeminį laikotarpį	42
20 pav. FEVD įtaka Litecoin ir Binance coin žetonams	43
21 pav. Prieš pandeminis kriptovaliutų Grangerio priežastingumo testo grafikas	43
22 pav. IRF impulsų rezultatai po pandeminiame laikotarpyje	44
23 pav. Stipriausi Bitcoin ir Ethereum IRF impulsai po pandeminiame laikotarpyje	44
24 pav. FEVD įtaka Filecoin ir Binance Coin žetonams	44
25 pav. Po pandeminis kriptovaliutų Grangerio priežastingumo testo grafikas	45
26 pav. Kryžminio poveikio matricos atvaizdavimas (kairėje prie COVID-19 pandemiją, o dešinėje – po)	45
27 pav. Kintamumo plitimo (angl. <i>volatility spillover</i>) lentelė	46
28 pav. Kintamumo plitimo (angl. <i>volatility spillover</i>) indekso grafikas	47

Ivadas

Kriptovaliutų tematika ir siekis jas pažinti bei suprasti yra neatsiejama šių dienų aktualija. Mokslo ir finansų sektorių atstovai siekia gyčiau, šia santykinai naują technologiją, suprasti ir pritaikyti. Nors didelė dalis mokslinėje literatūroje esančių straipsnių ir metodų yra siekiant prognozuoti kainos dinamiką, tačiau nemaža dalis tyrimų apima lyginimą su kitomis turto klasėmis arba pačių kriptovaliutų tarpusavio priklausomybių analizę. Galime surasti ne vieną straipsnį (Liu ir Tsyvinski, 2020, Baur ir kt. 2018, Kurka 2019), kuriame yra lyginamos kriptovaliutos su kitomis turto klasėmis, tokiomis kaip akcijos, tradicinės valiutos, brangiaisiais metalais, tačiau didelė dalis šių tyrimų prieina vieną ir tą pačią išvadą, kad kriptovaliutų negalime priskirti nei vienai iš šių turto klasių. Siekiant išsiaiškinti kodėl jos tokios skirtingos reikia grįžti prie pačių kriptovaliutų savybių ir tarpusavio priklausomybių analizės. Mokslinėje literatūroje galima pastebėti skirtingus priėjimus nagrinėjant tarpusavio priklausomybės. Dalis tyrimų remiasi koreliacinėmis matricomis ir šioms matricoms pritaikytais metodais, tokiais kaip atsitiktinių matricų teorija su minimalaus medžio metodu (Stosic ir kt., 2018, Chaudhari ir kt. 2020, Gavin ir kt. 2021), kiti tyrėjai mano, kad tiesinių priklausomybių nepakanka ir reikėtų papildomai įvertinti ir netiesines priklausomybes, kaip abipusės informacijos analizę (Kitanovskis ir kt., 2022), dar viena dalis tyrėjų mėgina paaiškinti kriptovaliutų elgesį Grangerio priežastingumo testu (Kim ir kt., 2021) bei kitais metodais. Tačiau pastebėta, kad skirtingais laikotarpiais kriptovaliutų tarpusavio priklausomybės yra kintančios. Jos gali stiprėti, silpnėti, netgi keistis. Rinkos lyderiaujančias kriptovaliutas gali pakeisti santykinai nauji, greitai išpopuliarėję žetonai (Ho ir kt., 2020). Išanalizavus tarpusavio priklausomybių mokslinius tyrimus ir sekant sparčią dinamiką pasauliniuose įvykiuose buvo iškeltas savaime kylantis klausimas: **kaip kriptovaliutos tarpusavyje elgiasi per globalius pasaulinius sukrėtimus?**

Tyrimo objektas: Kriptovaliutų tarpusavio priklausomybė kriziniu laikotarpiu.

Pagrindinis tyrimo tikslas yra ištirti kriptovaliutų tarpusavio priklausomybes kriziniu laikotarpiu pritaikant koreliacinę analizę, identifikuoti egzistuojančius ryšius tarp kriptovaliutų panaudojant Grangerio priežastingumo bei kintamumo plitimo analizes ir visai tai atlikti skirtingais laikotarpiais.

Darbo uždaviniai:

1. Ištirti mokslinėje literatūroje naudojamas kriptovaliutų sąsajų nustatymo metodus, apžvelgti gautus tyrėjų rezultatus;
2. Sudaryti tarpusavio ryšių tyrimo metodiką, kurią būtų galima pritaikyti skirtingo laikotarpio duomenims;
3. Atlikti pasirinktų duomenų analizę, panaudojant aprašomąją statistiką ir stilizuotų faktų patikrą siekiant atrasti rinkos struktūros sąsajas;
4. Atlikti tiesinių ir netiesinių koreliacijų analizę, sudaryti koreliacines matricas ir jas pritaikyti minimalių medžių metodei;
5. Skirtingiems laikotarpiams pritaikyti impulso atsako funkcijas, išanalizuoti Grangerio priežastingumą ir surasti ryšius tarp kriptovaliutų;
6. Atlikti kintamumo plitimo analizę siekiant nustatyti kiek pačioje kriptovaliutų sistemoje persiduoda kintamumas tarp žetonų.

Kripto valiutų tarpusavio priklausomybių kriziniais laikotarpiais problematika buvo aprašyta pirmoje dalyje atlikus mokslinės literatūros analizę. Antroje dalyje buvo sudaryta metodiką, kaip išanalizuoti pasirinktus duomenis ir kokios savybės joms yra būdingos bei kaip atlikti koreliacinę, impulso atsako, Grangerio priežastingumo, kintamumo plitimo analizes. Trečioje dalyje buvo pateikti gauti rezultatai, kurie parodo koreliacinius ryšius ir kaip jie kinta skirtingais laikotarpiais, kokių laikotarpiu kokia kriptovaliuta yra dominuojanti, impulso atsako ir Grangerio priežastingumo analizė parodė kryptinius ryšius bei kintamumo plitimo analizė sudarė bendrą vaizdą kaip sistemoje persiduoda kintamumas. Tyrimo pabaigoje pateiktos apibendrinančios išvados.

1. Kriptovaliutų rinkos mokslinės literatūros analizė

Šiuolaikiniame pasaulyje galime sutikti daugybę inovatyvių atsiskaitymo už paslaugas ir prekes būdų, tokių kaip: atsiskaitymai išmaniuoju įrenginiu (telefonu), internetu ar net skaitmeninėmis kortelėmis bei virtualiomis pinigineis. Tokių atsiskaitymo būdų galime sutikti naudojantis šiomis platformomis: PayPal, Apple Pay, Google Wallet, BitPay bei kitos. Nors ir didžioji daugumą atsiskaitymų vyksta tradicine valiuta (Euras, Doleris ir pan.), tačiau didėjantis susidomėjimas ir rinkos suteikiamos galimybės skatina naudotis ir atkreipti dėmesį į greitesnį, lankstesnį ir inovatyvesnį atsiskaitymo būdą skaitmenine valiuta – kriptovaliutomis.

Priežasčių ieškoti ir kurti alternatyvias valiutas ar atsiskaitymo būdus galime rasti tikrai ne vieną. Remiantis Chuen ir kt. (2015) galime išskirti kelias esmines priežastis:

1. Technologinis pažangumas – skaitmenizacijos procesui greitėjant ir vis labiau remiantis skaitmeninėmis bei technologinėmis priemonėmis tampa lengviau pritaikyti skaitmeninių valiutų panaudojimą kasdienėse operacijose.
2. Efektyvumas – dabartinė finansų sistema yra per mažai efektyvi ir per brangi.
3. Finansinė nepriklausomybė – kai kurios skaitmeninės valiutos, tokios kaip kriptovaliutos, turi ypatingą bruožą, kad jų nevaldo jokia centrinė institucija, todėl vyriausybės nelabai gali manipuliuoti ar apriboti jas.

Įvertinus šias priežastis bei faktą, kad šias laikais sukurti ir paleisti į rinką naujas alternatyvias valiutas, tokias kaip kriptovaliutos, yra nesudėtinga, dėl ko jų kiekis sparčiai didėja. Tačiau didžioji dalis naujai sukurtų kriptovaliutų po išleidimo nesulaukia pakankamai didelio susidomėjimo ir neįsitvirtina rinkoje. Todėl šiame darbe buvo pasirinkta nagrinėti tik pagrindines ir santykinai senas kriptovaliutas. Norint tinkamai suprasti tarpusavio ryšius ir jų priežastis, reikia panagrinėti, kas yra kriptovaliutos, kaip jos veikia ir iš kur jos kilo.

1.1. Kriptovaliutų raida

Kriptovaliutų užuomazgas ir bandymus sukurti skaitmenines valiutas galime pastebėti jau 1990 metais įmonės DigiCash, Inc sukurtoje eCash sistemoje, kuri buvo sukurta remiantis šios sistemos autorių moksliniais straipsniais Chaum (1983), Chaum ir kiti (1992). Šioje sistemoje buvo naudojami kriptografiniai protokolai, kurie užkertą kelią atlikus vieną mokėjimą užskaityti kaip kelis apmokėjimus (angl. *double-spending*), bei pati sistema suteikdavo anonimiškumą jos naudotojams, kas ir buvo pagrindinis šios sistemos tikslas. Nors ši idėja ir sulaukė didelio susidomėjimo savo laiku ir suteikė pagrindą vystyti šiuolaikinėms kriptovaliutomis, 1998 metais įmonė paskelbė bankrotą. Sekantis mėginimas kurti skaitmenines valiutas buvo 1999 – 2000 metais. Tai buvo skaitmeninė aukso valiuta e-Gold, kurios valiuta buvo tiesiogiai susijusi su auksu. Tačiau šis skaitmeninės valiutos tipas neprigijo taip pat, dėl savo tiesioginio ryšio su auksu, negalėjimo užtikrinti skaidrių mokėjimų ir sulaukė didelio spaudimo iš finansų priežiūros institucijų dėl pinigų plovimo prevencijos nebuvimo. Tačiau ši skaitmeninė valiuta (mokėjimų tipas) davė pagrindą ir užuomazgas šiuolaikiniams internetiniams atsiskaitymams.

Po 2008 metų finansinės krizės susidomėjimas kriptovaliutomis vėl atgijo. Pirmasis šiuolaikinių kriptovaliutų pradininkas buvo Satoshi Nakamoto, kuris 2008 pristatė Bitcoin idėją. Satoshi ištaisė prieš tai buvusius mėginimus kurti kriptovaliutas ir sukūrė Bitcoin, kuris sulaukė didelio

susidomėjimo ir pasisekimo. Bitcoin pagrindiniai tikslai yra šie: atsiskaitymai tarp klientų vyktų tiesiai vienas su kitu be trečiųjų šalių tarpininkavimo, tokių kaip bankas, bei pačių klientų apsauga, siekiant, kad mokėjimas įvyktų tinkamai, t.y. gavėjas gautu tokią sumą kokią išsiuntė siuntėjas. Naujai sukurtos sistemos (Bitcoin) pagrindiniai privalumai ir jų paaiškinimai pateikiami žemiau:

- Panaudojant Blockchain technologiją, klientai darydami pavedimus vieni su kitais yra apsaugoti nuo neteisingo arba daugkartinio pervedimo užskaitymo. Pagrindinė problema kriptovaliutuose yra užtikrinti atlikto pavedimo teisingumą. Lyginant su tradicinėmis finansinėmis priemonėmis, tokiomis kaip bankinis pervedimas, atsiranda trečioji šalis, kuri garantuoja ir užtikrina, kad atliekamas sandoris (pavedimas) bus atliktas tam kam reikia ir tokio dydžio, kokį nurodė siuntėjas. Tačiau, kai sistema yra decentralizuota ir anoniminiai klientai siunčia pavedimus tiesiogiai vienas kitam, reikėjo sugalvoti sistemą, kuri užtikrintų atlikto pervedimo teisingumą. Tam buvo panaudotas *Proof of Work* metodas ir sukurtas vienas iš esminių Bitcoino inovacijų – *Blockchain* technologija. Pagal Miller (2016) *Blockchain* tai yra tarsi vieša knyga, kurioje yra aprašyti atlikti sandoriai. Atliekant sandorį (transakciją) yra prijungiamas naujas blokas prie prieš tai buvusių transakcijų blokų grandinės ir tada siekiama transakciją validuoti. Kad tai atlikti, Satoshi pasirinko *Proof of Work* metodą, kurį galime paaiškinti taip: kiti sistemos dalyviai (ne siuntėjas ir gavėjas) gali, atlikdami sudėtingus matematinius uždavinius, patvirtinti mokėjimo autentiškumą ir už atliktą darbą gauti atlygį. Taip sistema pati save patvirtina ir neleidžia atlikti neteisingų transakcijų. Jeigu būtų norima įrašyti į blokų grandinę neteisingą transakciją, reikėtų iš naujo validuoti visus blokus grandinėje, kas būtų neracionalu ir nepelninga. Taip pati sistema save apsaugo nuo galimų operacijų klastojimo bei leidžia veikti sistemai, dėl tvirtintojų gaunamo pelno už validuotas operacijas. Ši nauja technologija buvo pagrindinė inovacija, kuri paskatino ateityje kurtis kitoms kriptovaliutoms.
- Klientai išlaiko anonimiškumą atlikdami operacijas. Nors atsekti kiek konkretus klientas operacijų yra atlikęs galima nesunkiai, tačiau konkrečių asmenų atsekti nėra lengva arba yra neįmanoma. Siuntėjas norėdamas atlikti pervedimą gavėjui jį patalpina į *Blockchain* tinklą. Kad pervedimą galėtų patalpinti į *Blockchain* ir tvirtintojai galėtų patvirtinti transakciją siuntėjas užšifruoja pervedimo informacija su savo viešuoju raktu ir pasirašo su savo asmeniniu raktu. Taip pervedimas įgauna unikalią formą su šia informacija: kokį kiekį, kas ir kam siunčia. Siuntėjas pasirašydamas transakciją su savo asmeniu raktu patvirtina, kad siuntėjas nori atlikti operaciją. Taip yra matoma informacija iš kokios piniginės kam siunčia kokią dalį Bitcoino, tačiau kadangi informacija yra užšifruota, nėra žinomi konkretūs siuntėjai.
- Globalumas. Šia sistema gali naudotis neribotas kiekis žmonių ir ją gauti ir siųsti gali kiekvienas pasaulyje. Tai yra rimtas privalumas, nes atlikti pavedimus galima visame pasaulyje ir tokiu pačiu greičiu. Atliekant tradicinių valiutų pervedimą tarp skirtingų valstybių galima užtrukti ženkliai ilgiau.
- Patikimumas. Pati sistema iš savęs yra patikima, nes tiesiog nėra galimybių suklastoti ar kažkaip kitaip iškraipyti pervedimo duomenis. Pačio Bitcoin savininką gali pakeisti tik pats savininkas. Atlikus pervedimą, nėra galimybės sustabdyti ar atgauti Bitcoin atgal.

Nors ši skaitmeninė valiuta turi daug naujovių ir privalumų, tačiau Qaroush ir kt. (2022) išskiria šios trūkumus:

- Piniginėse laikomų Bitcoinų saugumas. Įsigijus Bitcoin susiduriama su problema, kur šią valiutą saugoti. Galima saugoti savo kompiuteryje arba internetinėse piniginėse, tačiau pametus asmeninį raktą arba sugedus saugyklai, kurioje laikote Bitcoin, prie jų daugiau nebebus galimybės prieiti ir jie bus prarasti visam laikui – nėra būdo atstatyti prarastus Bitcoin.
- Decentralizavimo pavojus. Nors kriptovaliutų pagrindinis privalumas yra decentralizacija, kuri suteikia galimybę išvengti priežiūros iš reguliuojančių institucijų reikalavimų, tačiau šios kontrolės nebuvimas gali sukelti rimtus pavojus sistemos naudotojams. Galime įvardinti šios pagrindinius pavojus: naujos technologijos neiširtos galimybės ir spragos; didžiųjų investuotojų dirbtinė kainų manipuliacija, apsaugos ir atsekamumo nebuvimas pačiam vartotojui (siuntėjui atlikus transakciją už paslaugas arba prekęs, gavėjas gali nesuteikti paslaugų arba neduoti prekių už kurias gavo pinigus).
- *Proof of work*. Nors tai ir būtina sąlyga užtikrinanti Bitcoin veikimą, tačiau tai yra taip pat ir didelis sistemos trūkumas, dėl didelių ir didėjančių elektros energijos sąnaudų atlikti transakcijos validavimą.

Rinkai supratęs ir išnagrinėjęs Bitcoin privalumus prasidėjo kriptovaliutų bumai. Nors išleidus Bitcoin 2009 didelio populiarumo iškart nesulaukė, tačiau jau 2014 – 2015 metais kriptovaliutų skaičius siekė virš 500. Investuotojai ir vystytojai suprato galimybes ir šio įrankio potencialą. Kūrėjai pradėjo kurti įvairiausių tipų kriptovaliutas su skirtingomis idėjomis bei atlikdami tam tikras modifikacijas, tokias kaip: šifravimo būdo pakeitimas, transakcijos užtikrinimo metodo pakeitimas, tačiau didžioji dalis kriptovaliutų išliko naudojančios *Blockchain* technologiją. Todėl apsibrėžiame, kas yra kriptovaliuta:

Kriptovaliuta – tai skaitmeninė ar virtuali valiuta, kuri yra apsaugota kriptografija ir jos veikimas paremtas decentralizuotais tinklais, kurie naudoja *blockchain* technologiją. Ši technologija leidžia atlikti internetinius mokėjimus tiesiai iš siuntėjo gavėjui be finansinių institucijų įsikišimo.

2009 metais išleidus Bitcoin net 2 metus buvo vienintelė kriptovaliuta ir tik 2011 metais pradėjo kurtis kitos alternatyvos Bitcoin, tokios kaip: Litecoin, Namecoin, Peercon. Net iki 2013 metų vidurio vis dar buvo 7 kriptovaliutos. Tačiau didėjant visuomenės ir investuotojų susidomėjimui kriptovaliutomis jų skaičius pradėjo augti kartais. Jau 2014 metais atsirado virš 500 kriptovaliutų, iš kurių keletas senųjų lyderių išliko pirmose pozicijose pagal rinkos kapitalizaciją, tokios kriptovaliutos kaip Bitcoin (rinkos kapitalizacija 5,13 mlrd. Dolerių), Litecoin (rinkos kapitalizacija 122,63 mln. Dolerių). Didėjant kriptovaliutų rinkos kapitalizacijai ir įgaunant vis daugiau dėmesio iš visuomenės ir investuotojų kriptovaliutų kapitalizaciją augo bei jų kūrėsi vis daugiau. Šiai dienai galime suskaičiuoti virš 20000 skirtingų kriptovaliutų, tačiau didžioji dalis yra bevertė ir praktiškai neturinti apyvartos. Bendra kriptovaliutų rinkos kapitalizacija rašant šį darbą siekia virš 1 trilijono dolerių, o praityje, vertinant kilimo laikotarpius, galime pastebėti, kad siekė bendra rinkos kapitalizacija arti 3 trilijonų dolerių. Šie skaičiai parodo, kad kriptovaliutos šiuolaikiniame pasaulyje sudaro didelę svarbą finansų rinkoje.

Vertinant akademinio pasaulio susidomėjimą kriptovaliutomis galime panagrinėti gerai žinomas mokslinių publikacijų duomenų bazines, tokias kaip ScienceDirect bei Scopus. Įvedus į paieškos laukelį „cryptocurrency“ galime pastebėti, kad kiekvienais metais yra didėjantis mokslinių

publikacijų skaičius. Įvertinant kriptovaliutų kapitalizacijos dydį ir akademinio pasaulio susidomėjimo augimą, galima pastebėti, kad kriptovaliutų tematiką yra aktuali ir dominanti.

1.2. Kriptovaliutų išskirtinumas finansų rinkoje

Didėjantis kriptovaliutų susidomėjimas paskatino mokslo ir finansų srities atstovus pradėti nagrinėti šio naujo darinio panašumus į mums žinomas turtų klases, tokias kaip: tradicinės valiutos, brangieji metalai, akcijos. Siekiant suprasti kriptovaliutų elgesį rinkoje Liu ir Tsyvinski (2020) pasirinko lyginti kriptovaliutas su akcijomis, tradicinėmis valiutomis bei brangiaisiais metalais. Buvo pasirinktos 3 didžiausios kriptovaliutos (Bitcoin, Ripple, Ethereum) ir pradėta nagrinėti kriptovaliutų grąžų charakteristikos. Atlikus aprašomąją statistiką buvo pastebėta, kad grąžų vidurkis ir standartinis nuokrypis ženkliai didesnis už tradicinės turto klases. Buvo pastebėta, kad kriptovaliutos turi daug didesnę tikimybę patirti staigų nuosmukį žemyn, bei taip pat ir susidurti su staigiu grąžos kilimu. Pirmoje dalyje autoriai mėgino lyginti kriptovaliutas su akcijų birža, tirdami, ar kriptovaliutų rinkos grąžą kompensuoja rizikos veiksniai kylantys iš akcijų rinkos. Tačiau nustatyta, kad akcijų rinkos rizikos veiksnių poveikis yra labai mažas kriptovaliutomis. Antroje dalyje, autoriai lygino šias kriptovaliutas su pagrindinėmis tradicinėmis valiutomis, tokiomis kaip Eurais, Svarais, Australijos doleris, Kanados doleris. Nors ir buvo pastebėtas didelis panašumas tarp tradicinių valiutų, tačiau tarp kriptovaliutų ir tradicinių valiutų reikšmingo ryšio nepavyko rasti. Trečioje dalyje, mėginant surasti sąsajas tarp kriptovaliutų ir brangiųjų metalų, tokių kaip Auksas, Platina, sidabras. Nevertinant Ethereum ryšio su auksu, kiti ryšiai tarp šių turto klasių nebuvo reikšmingi. Ketvirtoje dalyje, autoriai lygino kriptovaliutų elgesį su makroekonominiais faktoriais, kaip didėjantis vartojimas, didėjančios gyventojų pajamos, tačiau nebuvo pastebėtas statistiškai svarbus ryšys. Taigi autoriams atlikus palyginimą buvo padaryta išvada, kad nors kriptovaliutas galime įvertinti paprastomis finansinėmis priemonėmis, tačiau ši turto klasė skiriasi iš esmės nuo tradicinių turto klasių. Buvo pastebėta, kad nors kriptovaliutos ir neturi aiškių sąsajų su tradicinėmis turto klasėmis, jas įtakoja jų pačių pagreitis ir investuotojų dėmesys. Nagrinėjant buvo nustatyta, kad dabartinės kriptovaliutų grąžos daro statistiškai reikšmingą poveikį sekančių kelių dienų grąžoms bei standartiniams nuokrypiams. Taip pat stebint investuotojų susidomėjimą Google paieškoje, tyrėjai pastebėjo, kad padidėjęs teigiamas susidomėjimas kriptovaliutomis internete daro įtaką kainos padidėjimui, tačiau analogiškai išaugus neigiamoms naujienoms, kriptovaliutų grąžos pradėdavo mažėti. Apibendrinant, kriptovaliutų grąžos turi mažą tradicinių turto klasių įtaką, tačiau turi aiškų ryšį su skelbiamomis naujienomis internete ir žiniasklaidoje.

Analogiškų tyrimų mokslinėje literatūroje galime surasti ne vieną. Nagrinėjant Josef Kurka (2019) tyrimą buvo gautas analogiškas, prieš tai nagrinėtam straipsniui, atsakymas, kad ryšiai tarp tradicinių turto klasių yra nereikšmingi ir kriptovaliutos, tokios kaip Bitcoin, gali būti diversifikatorius arba apsidraudimo priemonę formuojant portfelį. Tačiau reikėtų atkreipti dėmesį, kad kriptovaliutomis būdingi dideli svyravimai ir nepastovumas. Šie svyravimai dažnu atveju būna susiję su pačia kriptovaliutų rinka ir nebūtinai sutampa su visa finansų rinka. Taip pat skaitant Baur ir kt. (2018) tyrimą, matome analogiškas išvadas anksčiau aptartiems straipsniams - Bitcoin grąžos yra labai skirtingos lyginant su tradicinėmis turto klasėmis vertinant sunkmečio ir finansinio stabilumo laikotarpius. Autorius pastebi, kad didžioji dalis Bitcoino yra laikoma kaip investicija ir nenaudojama pagal paskirtį, dėl ko ši valiuta yra naudojama kaip spekuliatyvi priemonė.

Nagrinėjant plačiau ir naujesnius straipsnius, buvo pastebėta, kad nors ir sąsajų su tradicinėmis turto klasėmis yra sunku įžvelgti ir rasti, tačiau tai galima panaudoti balansuojant finansinių portfelių rizikas. Long ir kt. (2022) atliktame tyrime pastebėjo, kad tarp WTI naftos, Comex aukso ir kriptovaliutų ilgame laikotarpyje galime pastebėti neigiamą kintančią koreliaciją. Tai mums parodo, kad plačiau nagrinėjant šią sritį ir pritaikius tinkamus matematinius modelius galime atrasti galimybių, kaip pridėti kriptovaliutas į savo finansinius portfelius kaip dar vieną rimtą turto klasę, siekiant sumažinti portfelio rizikos dydį.

Apibendrinant išnagrinėtus straipsnius, galime teigti, kad kriptovaliutos nepriklausomo nei vienai tradicinei turto klasei pagal savo savybes ir jas reikėtų vertinti kaip atskirą turto klasę. Tačiau tai mums suteikia puikias galimybes diversifikuoti savo finansinius portfelius siekiant sumažinti rizikos dydį.

Kriptovaliutų tarpusavio priklausomybės

Didžioji dalis kriptovaliutų turi savitas savybes, kurios padaro jas išskirtines iš kitų turto klasių. Pagal Zhang ir kt. (2018) atlikta stilizuotų faktų analizę 8 didžiausioms kapitalizaciją turinčioms kriptovaliutomos buvo pastebėti kriptovaliutomoms būdingi požymiai, tokie kaip:

- Tikimybiniai kriptovaliutų gražų skirstiniai yra su „sunkiomis uodegomis“ - parodo, kad yra didesnė tikimybė gauti ekstremalias vertes.
- Susidaro kintamumo klasteriai (angl. *Volatility clusters*) – tai parodo, kad po didelio kainų kitimo seka kitas didelis kainų kitimas.
- Dėsninga koreliacija (angl. *power-law correlation*) tarp kainos ir apimtys – tai parodo, kad kintant kainai, ženkliai didėja ir pačios kriptovaliutų suprečiau jamas kiekis.

Tai parodo šios turto klasės išskirtinumą, bei sukuria norą nagrinėti šią klasę plačiau.

Nagrinėjant plačiau kriptovaliutų elgesį, galime išanalizuoti Stosic ir kt. (2018) tyrimą, kuris nagrinėja kolektyvinį kriptovaliutų kainų elgesį. Tyrime yra nagrinėjamos net 119 kriptovaliutų laiko eilutės periode nuo 2016-08-26 iki 2018-01-18. Šis kriptovaliutų skaičius buvo pasirinktas padarius prielaidas, kad kriptovaliutos turi būti iš 400 didžiausių kapitalizaciją turinčių kriptovaliutų, bei būtų jomis prekiaujama daugiau negu 500 dienų. Pirmoje tyrimo dalyje buvo nagrinėjamos pasirinktų kriptovaliutų kryžminės ir dalinės kryžminės koreliacijos. Sudarius kryžminių koreliacijų matricas buvo pastebėta, kad didžioji dalis kriptovaliutų reikšmingai viena kita veikia, kas parodo kolektyvinį elgesį šioje rinkoje. Atkreiptinas dėmesys, kad nedidelė dalis kriptovaliutų parodė neigiamą koreliacijos koeficientą su didžiąją dalimi kitų kriptovaliutų, pavyzdžiui Tether žetonas. Panagrinėjus giliau, galime pastebėti, kad šios kriptovaliutos yra susietos su tradicinėmis valiutomis. Tokios kriptovaliutos turi atskirą savo pavadinimą – *stablecoin*. Antroje dalyje kryžminių koreliacijų matricai buvo pritaikyta atsitiktinių matricų teorija. Atlikus skaičiavimus buvo pastebėta, kad didžiausia tikrinė reikšmė ir ją atitinkantis tikrinis vektorius rodo visos rinkos įtaką visoms kriptovaliutomis, kas parodo kriptovaliutų tarpusavio susietumą. Trečioje tyrimo dalyje pritaikomas mažiausiai besidriekiančio medžio metodas (angl. *Minimal Spanning Tree* (MST)). Pritaikius šį metodą galima analizuoti kolektyvinį elgesį kriptovaliutų rinkoje. Atlikus tyrėjams skaičiavimus buvo sudaryti net 5 kriptovaliutų klasteriai, kas parodo, kad tinklas natūraliai dalijasi į grupes su tankiomis vidinėmis jungtimis ir retesnėmis jungtimis tarp pačių grupių. Tai parodo, kad nors ir kriptovaliutos yra stipriai susijusios vienos su kita, tačiau rinkos struktūroje

formuojasi skirtingą elgseną turinčios grupės. Susidarę klasteriai paneigia mitą, kad dominuojantis rinkoje Bitcoin daro įtaką visai kriptovaliutų rinkai.

Analogišką tyrimą atlikę Chaudhari ir kt. (2020), taip pat nustatė kolektyvinį kriptovaliutų elgesį. Tyrimui buvo pasirinkti 2 skirtingi duomenų rinkiniai: pirmasis sudarytas iš 150 skirtingų kriptovaliutų, kurių kainų istorija siekia 150 stebėjimų ir antrasis rinkinys su 59 kriptovaliutom bei 300 dienų stebėjimais. Kaip ir anksčiau aprašytame tyrime, autoriai sudarė kryžminių koreliacijų matricas ir pritaikė atsitiktinių matricų teoriją bei pritaikė MST metodą. Žvelgiant į sudarytos kryžminių koreliacijų matricos rezultatus, galima pastebėti, kad didžioji dalis kriptovaliutų tarpusavyje koreliuoja vidutiniškai arba stipriai, tačiau buvo pastebėta, kad dalis kriptovaliutų nekoreliuoja su didžiąją dalimi kriptovaliutų arba keletas imties narių net turi neigiamas koreliacijas su kitais imties nariais, tokios kriptovaliutos buvo Iconomi ir Zcoin. Pritaikius atsitiktinių matricų teoriją ir MST metodą tyrėjai iš antrojo duomenų rinkinio sudarė kriptovaliutų klasterius. Šiame bandyme buvo gauti net 8 klasteriai. Tai parodo kolektyvinį rinkos elgesį ir paneigia mitą, kad pagrindinės kriptovaliutos įtakoja visą rinką vienodai. Taip pat buvo pastebėta, kad laikui bėgant (padalinus 300 stebėjimų po 150 ir nagrinėjant atskirai) susidaro toks pats skaičius kolektyvinių grupių, tačiau tik nedidelė dalis grupių narių išlieka tie patys. Tai parodo, kad kriptovaliutų bendruomenės (klasteriai) nėra pastovios bėgant laikui. Autoriai tai aiškina, kad taip gali būti dėl to, kad konkrečių kriptovaliutų populiarumas ir kapitalizacijos dydis yra labai kintantis, dėl visuomenės kintančio dėmesio skirtingoms kriptovaliutom.

Gavin ir kt. (2021) atliktame tyrime buvo pritaikyti tokie patys metodai kaip ir anksčiau aprašytuose tyrimuose, tik papildomai buvo įtraukta nauja Louvain kriptovaliutų grupių nustatymo metodika. Tyrimui autoriai pasirinko 146 ir 50 kriptovaliutų duomenų rinkinius, su kuriais atliko kryžminių koreliacijų nagrinėjimą, pritaikė atsitiktinių matricų teoriją bei MST metodą. Naujai pritaikytas Louvain metodas, sukurtas Blondel ir kt. (2008), yra euristinis metodas, pagal kurį grupės kuriamos remiantis moduliškumo optimizavimu. Newman (2016) moduliškumą apibūdina kaip naudos funkciją, t.y. tinklo susiskirstymo į grupes kokybės matą. Kiekvienam skaidiniui priskiriama modulinė vertė, kuri parodo ryšių grupių viduje tankį, lyginant su ryšiais tarp grupių. Louvain metodas sukuria bendruomenes jungdamas mazgus į vieno dydžio bendruomenę. Taikant šį metodą „iš apačios į viršų“, klasteriai nuosekliai sujungiami su kitais klasteriais, kurie duoda didžiausią moduliškumo prieaugį. Pritaikius šį metodą kartu su MST didesniams kriptovaliutų duomenų rinkiniui buvo gauti rezultatai, kad 7 iš 11 klasteriuose dominuojančių (daugiausia jungčių turinčių) kriptovaliutų yra priklausančios top dvidešimtukui pagal rinkos kapitalizaciją. Tai mums parodo, kad dominuojančios kriptovaliutos aplink save kuria klasterius iš kitų smulkesnių kriptovaliutų. Mokslininkams nagrinėjant plačiau, buvo pasirinktas mažesnis duomenų rinkinys ir tikrinama ar dominuojančios kriptovaliutos išlieka tokios pačios skirtingais laiko periodais. Tyrimas parodė, kad dalis kriptovaliutų išlieka visais periodais klasterio lyderiu, tokios kriptovaliutos kaip Bitcoin ir Ethereum, o kitais laiko intervalais lyderius pakeičia kiti rinkos lyderiai, kurie priklauso taip pat top dvidešimtukui pagal rinkos kapitalizaciją. Šis tyrimas parodė, kad kriptovaliutų rinkoje formuojasi klasteriai, kurių didžiąją dalimi klasterio branduolys yra gerai žinomos ir didžiausias rinkos kapitalizacijas turinčios kriptovaliutos, aplink kurias buriuojasi smulkesnės, mažiau žinomos valiutos.

Tiriant kriptovaliutų tarpusavio ryšius ir klasterių susidarius, Kitanovskii ir kt. (2022) siūlo šiek tiek kitokį priėjimą ir vertinimo metodiką. Autorius teigia, kad tiesinių priklausomybių, nagrinėjant

šia rinką, nepakanka bei kartu nagrinėjant tiesines koreliacijas reikėtų atsižvelgti ir į netiesines priklausomybes. Autoriai tyrimui pasirinko 2019-2021 metus ir 215 kriptovaliutų. Kaip mums gerai žinoma, šis laikotarpis apima ir mūsų visų gyvenimus pakeitusią COVID-19 pandemiją. Tyrėjai pasirinko nagrinėti kriptovaliutas naudoti korelacijų analizę, kuri parodo tiesines priklausomybes bei abipusės informacijos analizę (angl. *Mutual Information Analysis* (MIA)), kuri parodo netiesinius ryšius bei geriau atspindi priklausomybės nepastovioje aplinkoje. Pastebėta, kad vertinant tą patį laikotarpį ir tas pačias valiutas didelė dalis kriptovaliutų tiesiškai nekoreliuoja viena su kita, tačiau MIA parodo stiprius ryšius. Pritaikius atsitiktinių matricių teoriją kartu su Louvain metodų buvo sudaryti pasirinktų valiutų klasteriai tiesinėms ir netiesinėms priklausomybėms. Iš tyrimo grafikų galima pastebėti, kad klasterių struktūra šiek tiek skiriasi, tačiau klasterių skaičius išlieka panašus ir siekia apie 8. Tai ir vėl parodo, kad kriptovaliutų rinkoje nėra visiškai vienos dominuojančios kriptovaliutos, o yra bent jau keletas. Sekančioje dalyje tyrimo autoriai siekė sudaryti investicinius portfelius, kurie būtų diversifikuoti, t.y. parinkti portfelio komponentus iš skirtingų klasterių. Tam buvo pasirinkti 2 metodai: pagrindinių komponentų analizė (*principal component analysis* (PCA)) ir centriškumo laipsnio analizė (angl. *centrality degree* (C_D)). Pagrindinių komponentų analizė naudojama kriptovaliutų klasterių analizei, siekiant apibūdinti kiekvienos kriptovaliutos kintamumą, o centriškumo laipsnio analizė yra mazgo lygio matas, kuri apskaičiuojamas kaip artimų mazgų skaičiaus santykis su bendru klasterio mazgų skaičiumi. Išdalinus duomenų rinkinį į mokymosi ir bandymo imtis buvo gauti rezultatai, kad šis portfelis buvo sudarytas ganėtinai sėkmingai ir pasirinktam duomenų rinkiniui ir laikotarpiui parodė, kad portfelis gali būti pelningas. Tai mums parodo, kad kriptovaliutų tarpusavio ryšių nustatymas ir supratimas gali būti naudingas sudarant investicinius portfelius.

Iš kitos perspektyvos į kriptovaliutų rinką mėgino pažiūrėti Kim ir kt. (2021). Savo atliktame tyrime jie naudojo Grangerio priežastingumo analizę, kuri yra naudojama norint surasti abipusius ryšius ir norint išsiaiškinti kiek kintamieji turi įtakos nuspėjant vienas kito ateities reikšmes. Autoriai tyrimui pasirinko 8 didžiausių kriptovaliutų (Bitcoin, Ethereum, Ripple, Bitcoin cash, Litecoin, EOS, Binance coin, Stellar) pagal kapitalizaciją kainų laiko eilutes laikotarpyje 2017-06-23 – 2019-11-28. Atliekant tyrimą buvo sudalinti duomenys į 8 skirtingus kvantilinius intervalus ir priežastingumo analizė atliekama kiekvienam intervalui atskirai. Atlikus tyrimą pastebėta tai: iš pasirinktų kriptovaliutų nėra nei vienos visiškai nepriklausomos kriptovaliutos pagal kvantilinį priežastingumo testą; stipresnis priežastingumo ryšys egzistuoja prie viršutinių kvantilių, negu prie žemų; Bitcoin ir Ethereum turi didesnį priežastingumą mažesnėms kriptovaliutoms aukštesnių kvantilių intervale. Šis tyrimas parodo, kad reikšmingas priežastingumo ryšys yra aukštame kvantilių intervale, dėl ko investuotojams yra sudėtinga apsidrausti nuo rizikos kriptovaliutų rinkoje.

Priklausomybių tarp kriptovaliutų tyrimui Briola ir kt. (2022) pasirinko nagrinėti aukšto dažnio duomenų imtis. Tyrėjai pasirinko 25 kriptovaliutų kainas laikotarpyje 2021-01-01 – 2022-02-28. Ši duomenų rinkinį sudarė skirtingo dažnio stebėjimai: kas 15 sekundžių, 1, 15, 60 minučių ir 4, 24 valandos. Kiekvienam skirtingo dažnio duomenų rinkiniui autoriai paskaičiavo logaritmines grąžas ir jas normalizavo. Savo darbe tyrėjai pasirinko naudoti MST metodą bei plokštuminę maksimaliai filtruotų grafų analizę (angl. *Planar Maximally Filtered Graph* (PMFG)). MST yra galingas metodas, leidžiantis užfiksuoti reikšmingus ryšius sudėtingą sistemą apibūdinančioje tinklo struktūroje. Tačiau pagrindinis šio metodo apribojimas yra, kad būtina turi būti gaunamas medis. Dėl šios savybės neįmanoma atvaizduoti ryšių tarp daugiau nei dviejų kintamųjų, kurių dinamika stipriai koreliuoja. Siekiant išlaikyti geras MST savybės ir kartu pridėti papildomų ryšių autoriai,


autoriai pasirinko adaptuoti MST kartu su PMFG. Papildomai modifikavus PMFG metodą tyrėjai gavo šios įdomius rezultatus:

- Kriptovaliutų rinkai yra būdingas *Epps* efektas. Pagal Toth(2007) tai reiškia, kai empirinė koreliacija tarp dviejų skirtingų kriptovaliutų grąžų mažėja didėjant duomenų dažniui.
- Koreliaciniai ryšiai tarp kriptovaliutų didėja einant iš aukštesnio dažnio link žemesnio.
- Naudojant MST metodą gauta, kad Ethereum kriptovaliuta yra dominuojanti ir ji turi daugiausia ryšių su kitomis kriptovaliutomis. Tai parodo didėjančią svarbą ir įtaką šios kriptovaliutos, nes šiam tyrimui buvo naudoti ganėtinai nauji duomenys.
- Naudojant modifikuotą PMFG metodą gauta, kad visuose dažnio intervaluose Ethereum išlieka daugiausiai ryšių turinti kriptovaliuta, tačiau keičiant dažnio intervalą panašiai ryšių užmezga tokios kriptovaliutos kaip Bitcoin ir Litecoinin.

Apibendrinant tyrimo rezultatus, galima pastebėti, kad kriptovaliutų tarpusavio ryšio nustatymui nereikėtų naudoti labai aukšto dažnio duomenų rinkinius, siekiant išvengti *Epps* efekto. Taip pat, Ethereum valiuta užima vis svarbesnį vaidmenį kriptovaliutų rinkoje.

Tirti kriptovaliutų priklausomybės skirtingais laiko intervalais gali būti naudinga, siekiant surasti lyderiaujančias kriptovaliutas. Tokį priėjimą prie šios rinkos analizės padarė Ho ir kt. (2020). Tyrimo autoriai pasirinko nagrinėti kriptovaliutų tarpusavio priklausomybės laikotarpyje nuo 2013 iki 2020 metų vidurio skaičiavimas imant 180 dienų laiko intervalus ir jos slenkant per vieną dieną. Imant tokį didelį laikotarpį tyrėjai vis įtraukdavo naujų kriptovaliutų, kurios buvo sukurtos vėliau, negu senieji žetonai, tokie kaip Bitcoin ar Ethereum. Buvo pritaikytos anksčiau aprašytos metodikos, tokios kaip kryžminių korelacių matricos ir mažiausiai besidriekiančio medžio metodas (MST). Buvo pritaikytos net penkios centriškumo metodikos, kurios parodo svarbias ir įtankingas kriptovaliutas visoje struktūroje. Pirmoje dalyje autoriai atliko kryžminės korelacijos koeficiento pasiskirstymo analizę pagal keturis rodiklius, t.y. vidurkį, dispersiją, asimetriją (angl. *skewness*) ir ekscesą (angl. *kurtosis*). Iš šių statistikų tyrėjai gavo ganėtinai įdomius rezultatus. Kriptovaliutų eros pradžioje 2013-2014 metais tarpusavio korelacijos koeficientai buvo vidutiniame arba aukštame lygyje (0,6-0,8). Tai galima paaiškinti mažų kriptovaliutų skaičiaus buvimu ir didelę įtaką tuometinėje kriptovaliutų rinkoje turinčio Bitcoin vaidmeniu (tuo metu net 80% visos rinkos kapitalizacijos turėjo ši valiuta). Nuo 2014 iki 2017 kriptovaliutų tarpusavio korelacijos koeficiento vidurkis buvo labai mažas ir siekė 0-0,2. Tokį drastišką pasikeitimą galima paaiškinti staigiu kriptovaliutų kūrimosi bumu, bei sukurtų kriptovaliutų paskirties įvairove. Nuo 2017 metų galima pastebėti, kad kriptovaliutų tarpusavio korelacijos vėl pradeda augti. Tokį neįprastą elgesį galima būtų paaiškinti didžiuoju kriptovaliutų kainų kritimu. 2018 metų rugsėjį kriptovaliutos krito 80% nuo 2018 metų sausio aukščiausio lygio. Ši griūtis buvo didesnė nei Dot-com burbulo. Tai mums parodo, kad per staigių kainų kritimų žemyn periodus, kriptovaliutos pradeda stipriai koreliuoti viena su kita ir visa rinka tampa panaši, kas apsunkina investuotojams sumažinti rizikas savo finansiniuose portfeliuose. Taip pat, COVID-19 laikotarpiu buvo pastebėta didėjantis kryžminių korelacių koeficiento didėjimas tarp kriptovaliutų. Pastebėta, kad nors kriziniu laikotarpiu kriptovaliutos stipriau koreliuoja viena su kita, tačiau variaciją išauga stipriai taip pat, ypač išaugo COVID-19 laikotarpiu. Antroje tyrimo dalyje autoriai pritaiko MST metodą prieš tai aprašytoms kryžminėms korelacijoms. Tyrėjai pasirinko nagrinėti kelis šio metodo parametrus, tokius kaip: normalizuotą medžio ilgį (angl. *normalized tree lenght* (NTL)), kuris naudojamas išmatuoti vidutinį tinklo atstumą; vidutinį kelio ilgį (angl. *average path lenght* (APL)), kuris naudojamas nustatyti tinklo tankumą; vidutinį užimamą sluoksnį (angl. *mean occupation layer*

(MOL)), kuris yra naudojamas apibūdinti mazgų paplitimą tinkle. Apačioje pateiktas tyrėjų gautų rezultatų grafikas, visiems 3 parametrų.



1 pav. NTL, APL ir MOL metrikų rezultatų grafikai iš Ho ir kt. (2020) tyrimo

Trumpai apžvelkime gautus tyrėjų rezultatus. Žvelgianti į normalizuoto medžio ilgio (NTL) grafiką, galime pastebėti, kad per kriptovaliutų krizę 2018 ir COVID-19 epidemijai prasidėjus, šio rodiklio įvertis sumažėjo ženkliai, lyginant su prieš tai buvusiu laikotarpiu. Mažėjančios NTL reikšmės rodo stiprėjantį koreliacinį ryši kriptovaliutų rinkoje. Iš grafiko galime teigti, kad kriptovaliutų rinkoje kriziniais laikotarpiais (finansiniais ar epideminiais) būdingas didėjantis koreliacinis ryšys, dėl to kriptovaliutos tampa jautresnės rinkos kainos pokyčiams. Tą patį galima pastebėti ir vertybinių popierių rinkoje. Nagrinėjant antrąjį ir trečiąjį grafikus, galima pastebėti augantį MOL rodiklį ir nuo 2016 metų ženkliai didėjančius svyravimus trečiame grafike. Tai parodo, kad kriptovaliutų rinka tampa vis mažiau kompaktiškas ir pastebimas mažėjantis mazgų tankis. MOL grafike tyrėjai pastebi, kad per 2016 metų Bitfinex įsilaužimą (buvo pavogta apie 120 000 Bitcoin žetonų) ir bendrą kriptovaliutų rinkos nuosmukį 2018 metais, MOL rodiklis pasiekia labai žemas vertes. Ekonominė tokio elgesio interpretaciją galima būtų aiškinti taip, kad per rinkos krizę kriptovaliutų grąžą turėtų lemti bendrieji veiksniai, o ne konkrečių bendrovių ar pramonės šakų veiksniai. Tankesnis tinklas rodo bendrųjų veiksmių svarbos didėjimą. Maža MOL reikšmė kriziniu metu reiškia, kad kainų nepastovumui ir kitai informacijai perduoti reikia mažiau tarpinių kriptovaliutų perduodant iš centrinio mazgo į kitus mazgus, kai didelės MOL reikšmės atspindi smulkesnę rinkos struktūrą.

Kitoje tyrimo dalyje autoriai pritaikė centriškumo matavimus minimaliai besidriekenčio medžio metodui (MST), siekiant nustatyti, kurio metu, kuri kriptovaliuta buvo dominuojanti rinkoje. Gautus rezultatus galima paaiškinti padalinus tiriamąjį laikotarpį į 3 etapus. Pagal tyrėjus nuo 2013 iki 2016 metų dominuojančios valiutos buvo Bitcoin, Litecoin, Ripple, Dogecoin, nes tuo metu pagrindinė kriptovaliutų paskirtis buvo transakciniai atsiskaitymai, o šių kriptovaliutų pagrindinė paskirtis tokia ir yra. Nuo 2016 iki 2017 metų dominuojančių kriptovaliutų pozicijos stipriai pasikeitė ir išryškėjo tokios kriptovaliutos kaip Siacon, BitShares, Factom. Šį pokytį galima paaiškinti rinkoje pasikeitusiu požiūriu į padidėjusiu kriptovaliutų pritaikomumo galimybėmis. Anksčiau išvardintos kriptovaliutos pasižymi tuo, kad jų pagrindė paskirtis nėra atlikti ar užtikrinti transakcijas, tačiau suteikia galimybes panaudoti jas ir kitur, kaip pavyzdžiui, sukurti decentralizuota duomenų keitimosi tinklą, panaudojant savo laisvą kompiuterio saugyklos vietą arba sukurti decentralizuotą

duomenų bazę, kuri užtikrintų elektroninių duomenų autentiškumą. Šie inovatyvūs sprendiniai sulaukė didelio susidomėjo, dėl ko tikėtina šias valiutas ir padarė lyderėmis. Trečiame etape (nuo 2017 metų) matome, kad senieji rinkos lyderiai grįžo, tačiau tarp jų atsirado naujų rinką formuojančių kriptovaliutų. Vienas iš pavyzdžių Ethereum, kuris vertinamajame laikotarpyje rinkoje turėjo didesnę įtaką nei Bitcoin. Papildomai tarp lyderių atsirado naujų, panašių į Ethereum technologiją, kriptovaliutų, tokios kaip Cardano, Neo, kurios pasižymi kartu su Ethereum naujesniu, efektyvesniu veikimu, naudojant išmaniąsias sutartis (angl. *smart contracts*). Tai leidžia efektyviau ir pigiau atlikti pervedimų patvirtinimą ar kitus su veikimu susijusias operacijas. COVID-19 epidemijos pradžios laikotarpyje galime įžvelgti, kad į lyderių pozicijas įsirašė mažos ir mažiau žinomos valiutos, tokios kaip Quantum coin ir Binance coin. Tačiau šį iškilimą galima labai nesunkiai paaiškinti. Quantum coin kūrėjai skyrė dideli dėmesį karantino metu uždarytiems namuose žmonėms ir taip rengė jiems įvairius renginius, tuo tarpu Binance coin kūrėjai skyrė 5 milijonų dolerių paramą medikams, dėl ko šis žetonas trumpai buvo stipriai išpopuliarėjęs. Tai mums dar kartelį parodo, kad visuomenės dėmesys turi reikšmingą įtaką formuojant kriptovaliutų rinkos struktūrą.

1.3. COVID-19 pandemijos įtaka finansų rinkoje

COVID-19 pandemija ir po jos sekęs visuomenės uždarymas turėjo didelę neigiamą įtaką žmonėms, įvairioms institucijoms ir ypač finansų rinkai (Akhtaruzzaman ir kt. (2021)). Pasaulinių akcijų indeksų rinkos kapitalizacija smarkiai krito, dėl ko išaugo rizika ir kintamumas. Didelį smūgį patyrė ne vien vertybinių popierių rinka, tačiau ir valiutų ar kriptovaliutų rinkos. Globalūs judėjimo apribojimai stipriai sumažino naftos poreikį, kurio pasekoje naftos ateities sandorių vertės buvo kritusios net iki neigiamų reikšmių. Tuo tarpu aukso kainos, pandemijos pradžioje, pasiekė visų laikų aukštumas. Noman ir kt. (2023) tai aiškina investuotojų siekiu ieškant stabilios investicijos neramumu laikais bei norint sumažinti savo portfelio nuvertėjimą, dėl kitų turto klasių vertės mažėjimo.

Panagrinėkime literatūroje aprašytus mokslinius darbus susijusius su kriptovaliutų tarpusavio elgesiu COVID-19 laikotarpiu. Pagal Mnif ir kt. (2020) atliktą tyrimą autoriai analizavo penkių didelių kriptovaliutų priklausomybes prieš ir po COVID-19 laikotarpį. Pastebėta, kad lyginant didžiąsias valiutas, Bitcoin pasirodė labiausiai efektyvus kriptovaliutų rinkoje prieš pandemiją, kai po pandemijos Ethereum efektyvumas padidėjo. Rinkos efektyvumas – tai laipsnis, kurio rinkos kainos atspindi visą turimą svarbią informaciją. Kitų kriptovaliutų rinkos efektyvumas paaugo, lyginant su prieš pandeminiu laikotarpiu.

Pagal Youssef ir kt. (2022) COVID-19 laikotarpio pradžioje buvo pastebėtas bandos elgesys kriptovaliutų rinkoje. Tyrimo autoriai pasirinkę 47 didžiausios kapitalizacijos turinčias kriptovaliutas tyrė laikotarpius prieš ir po COVID-19. Atlikę skaičiavimus tyrėjai nustatė, kad kriziniu laikotarpiu kriptovaliutoms būdingas „bandos“ elgesio modelis, kurį galima paaiškinti didele dalimi nepatyrusių investuotojų skaičiumi ir rinkos lyderių (investuotojų) rodomu pavyzdžiu, siekiant sumažinti nuostolius didelio neaiškumo laikotarpiu. Papildomai tyrėjai pastebėjo, kad „bandos“ elgesiui didelę įtaką darė naujienos apie COVID-19 socialinėse medijose ir žiniasklaidose. Pastebėta, kad didėjant rinkos nepastovumui ir panikai, žiniasklaidos dėmesys didina „bandos“ elgesį.

Pagal Assaf ir kt. (2023) atliktą tyrimą, tyrėjai pastebėjo, kad per COVID-19 laikotarpį galima įžvelgti kriptovaliutų didesnę koreliaciją su JAV biržų indeksais, auksu ar VIX indeksu. Šiam tyrimui autoriai pasirinko nagrinėti 4 pagrindines kriptovaliutas (Bitcoin, Ethereum, Ripple, Litecoin) ir kintamumo indeksą (VIX), aukso ir S&P500 kainas. Ištirti tarpusavio ryšius autoriai naudojo koreliacinę analizę ir *Shannon* entropijos perdavimo matą. Iš atlikto tyrimo buvo gautos išvados ir informacijos srautų dinamikos kitimo tendencijos, kurios parodo kaip turto klasės įtakoja kitas turto klases. Pastebėta išaugusi priklausomybė tarp kriptovaliutų ir S&P500 bei VIX indekso per COVID-19 laikotarpį. Atitinkamai galima pastebėti, kad COVID-19 pandemijos pradžioje S&P500 indeksas buvo dominuojantis informacijos srauto siuntėjas visoms 4 kriptovaliutomis. Didėjantis informacijos srautas tarp visų tyrime nagrinėtų turto klasių parodo mažas diversifikavimo ir apsidraudimo (angl. *hedge*) galimybes tarp šių turto klasių kriziniu metu. Pastebėba, kad kriziniais laikotarpiais kriptovaliutos pasižymi padidėjusiu nestabilumu ir nereguliarumu, dėl ko investavimas tokiais periodais į virtualias valiutas tampa rizikingesnis.

Umar ir kt. (2023) savo tyrime nagrinėjo sąsajas tarp ekonominės politikos neapibrėžtumo indekso (EPU) ir kriptovaliutų grąžų prieš ir po pandeminiame laikotarpyje. Papildomai buvo nagrinėjami skirtingi kvantiliai, kad būtų plačiau apžvelgti rezultatai. Iš tyrimo rezultatų pastebėta, kad ryšiai tarp apatinių kvantilių yra reikšmingai teigiami, o tarp viršutinių kvantilių galima pastebėti reikšmingai neigiamus ryšius. Tai parodo, kad kriptovaliutų sistemoje, kriptovaliutos elgiasi ganėtinai skirtingai ir neužtenka nagrinėti tik kelias didžiausias kriptovaliutas, siekiant aprašyti ir suprasti visą virtualių valiutų rinką. Tyrėjams atskirus duomenis į prieš ir po pandeminius laikotarpius buvo gauti įdomūs rezultatai. Kriptovaliutomis daroma EPU indekso įtaka buvo teigiama prieš COVID-19 ir tapo neigiama po pandemijos pradžios. Tai reiškia, kad kriptovaliutos buvo geresnės apsidraudimo (angl. *hedge*) priemonės prieš pandemiją ir nebėra tinkamos po pandemijos pradžios. Apibendrinant tyrimą, galima teigti, kad po COVID-19 pandemijos pradžios pradėjo elgtis panašiau į tradicinės turto klases, nei lyginant prieš pandemiją laikotarpį. Tai apsunkina investuotojų siekį pritaikyti kriptovaliutas siekiant sumažinti portfelio rizikos matą tarp įvairių turto klasių.

Akhtaruzzaman ir kt. (2022) savo tyrime vertino kriptovaliutų sisteminę riziką pasinaudodami CoVaR (angl. *Conditional Value-at-Risk*) modeliu siekiant nustatyti užkrato (angl. *contagion*) indekso (SCI) dydį ir nustatyti kintamumo plitimo efektą (angl. *volatility spillover*) visai sistemai. Tyrime pastebėta, kad užkrato indeksas pasiekia didžiausias reikšmes per COVID-19 periodą, kas parodo pandemijos nulemtą užkrato plitimo įrodymus. Taip pat tai parodo, kad per pandemiją padidėjo tarp kriptovaliutų tarpusavio ryšiai, kurie išryškina didesnę sisteminio užkrato plitimo kanalų skaičių. Tai padidina sisteminę riziką. Tyrimo metu pastebėta, kad Bitcoin išliko visu laikotarpiu ganėtinai stabilus ir mažiau paveikiamas sistemos. Taip pat Dogecoin, Zcash ir Decred per pandemiją parodė žemas SCI vertes, kas parodo, kad šios valiutos yra mažiau pažeidžiamos šokų kriptovaliutų sistemoje. Apibendrinant tyrimą, investuotojai siekiantys sumažinti sisteminę riziką, turėtų išnagrinėti kriptovaliutas ir diversifikuoti savo portfelius su mažiau sistemos veikiamomis valiutomis.

Išnagrinėjus literatūrą, galima apibendrinti kaip COVID-19 paveikė virtualias valiutas: kriptovaliutų tarpusavio ryšiai susistiprėjo pandemijos pradžioje ir šio laikotarpiu kriptovaliutomis buvo būdingas „bandos“ elgesys, pradėjo didėti kriptovaliutų panašumas su tradicinėmis turto klasėmis ir sumažėjo diversifikavimo galimybės tarp skirtingų turto klasių.

1.4. Kriptovaliutų rinkos mokslinės literatūros analizės apibendrinimas

1 lentelė. Mokslininkų kriptovaliutų rinkos tyrimui naudoti metodai ir apžvelgta ekonominė tematika

Nr.	Tyrimai	Tarpusavio ryšių nustatymo metodai			Ekonominė tematika		
		Koreliacija	MST	Granger	Diversifikavimas	Ryšiai tarp kitų turto klasių	COVID-19 tematika
1	Noman ir kt. (2023)				+	+	+
2	Assaf ir kt. (2023)	+			+	+	+
3	Briola ir kt. (2022)	+	+				
4	Stosic ir kt. (2018)	+	+		+		
5	Kitanovski ir kt. (2022)	+	+		+		+
6	Diebold ir kt. (2012)				+	+	
7	Chaudhari ir kt. (2020)	+	+		+		
8	Mudassar ir kt. (2019)					+	
9	Liu ir Tsyvinski (2020)	+			+	+	
10	Gavin ir Crane (2021)	+	+		+		+
11	Kurka (2019)					+	
12	Ho ir kt. (2020)	+	+		+		+
13	Akhtaruzzaman ir kt. (2022)				+	+	+
14	Kim ir kt. (2021)			+			
15	Youssef ir kt. (2022)						+
16	Umar ir kt. (2023)					+	+
17	Giudici ir kt. (2020)	+	+		+		
18	Zhanga ir kt. (2018)	+					
19	Long ir kt. (2022)				+	+	+
20	Qaroush ir kt. (2022)				+	+	+
21	Barcilar ir kt. (2017)			+		+	

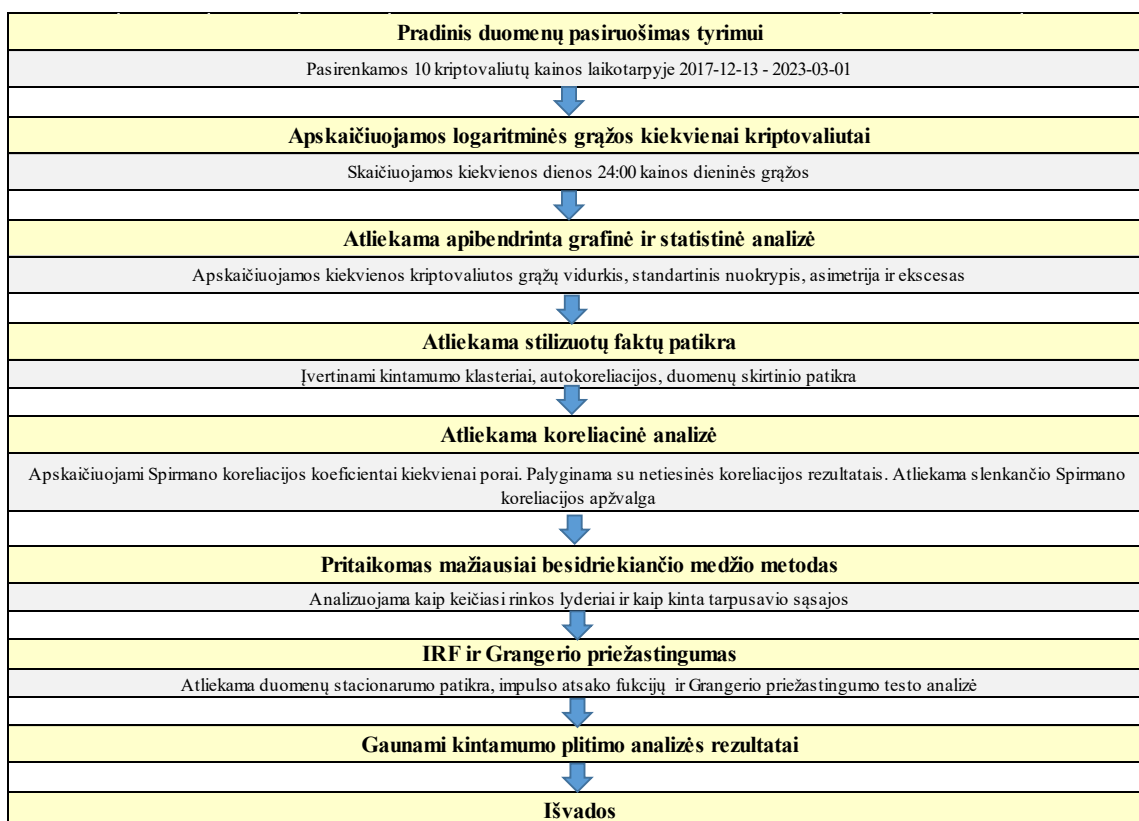
Išnagrinėjus mokslinę literatūrą buvo sudaryta apibendrinanti 1 lentelė, kurioje pateikti pagrindiniai nagrinėti tyrimai ir juose apžvelgta tarpusavio ryšių nustatymo metodika bei ekonominės pusės interpretacija ir pritaikymas. Matome, kad tarpusavio ryšių nustatymui dažnu atveju buvo atliekama įvairi koreliacinė analizė bei koreliacinėms matricoms pritaikomas minimalaus medžio metodas (MST). Nedidelė dalis straipsnių naudojo Grangerio priežastingumo analizę, kuri parodo įtakos stiprumą ir kryptį tarp kriptovaliutų. Likę tyrimai naudoja GARCH metodus tirti tarpusavio ryšius. Pagrindinis tyrimų uždavinys yra investicinio portfelio sudarymas ir diversifikavimas. Tam atlikti tyrėjai naudoja anksčiau paminėtus metodus ištirti priklausomybes tarp kriptovaliutų arba kitų turto klasių skirtingais periodais. Naujesnių tyrimų dažna tematika susijusi su COVID-19 poveikiu visai kriptovaliutų sistemai ir kaip pasikeitė tarpusavio ryšiai bei kokiomis kriptovaliutomis reikėtų remtis siekiant sumažinti investicinio portfelio riziką. Apžvelgus mokslinę literatūrą ir jų taikomus metodus, buvo pasirinkta atlikti kriptovaliutų tarpusavio priklausomybių tyrimą skirtingais laiko periodais, į kurios įeina įvairūs globalūs sukrėtimai. Tam atlikti buvo pasirinkta įvairi koreliacinė analizė, pritaikytas minimalių medžių metodas, atliktas impulso atsako bei Grangerio priežastingumo testas. Papildomai įvertintas kintamumo plitimo indeksas visam pasirinktam duomenų laikotarpiui. Tai buvo atlikta siekiant įvairiapusiškai įvertinti kriptovaliutų tarpusavio priklausomybes ir kaip jos pasikeičia tiek įvykus globaliems sukrėtimams, tiek tik kriptovaliutų sistemai būdingomis krizėmis.

2. Kriptovaliutų tarpusavio priklausomybių nustatymo kriziniu laikotarpiu vertinimo metodika

Šiame skyriuje yra detalai aprašytos metodikos ir tyrimo eiga siekiant: aprašyti naudota duomenų rinkinį, jų dydį, atlikti šių duomenų detalią analizę, atlikti tarpusavio koreliacinių ryšių analizę bei pritaikyti minimaliai besidriekenčio medžio (MST) metodiką nustatant ryšius tarp kriptovaliutų įvairiais laiko periodais. Papildomai aprašyta impulsų atsako funkcijos ir Grangerio priežastingumo analizė bei kintamumo plitimo įvertinimo metodikos.

2.1. Tyrimo eiga

Tyrimo eigos schema pateikta 2 pav. Prieš pradedant tyrimą buvo pasirinktos 20 didžiausią kapitalizaciją turinčios kriptovaliutos. Siekiant turėti vienodo ilgio duomenų eilutes buvo paliktos 10 kriptovaliutų, kurių duomenų laikotarpis siekia virš 5 metų. Kiekvienos kriptovaliutos duomenų eilutės buvo perdarytos į dienes logaritmines grąžas. Taip buvo gauti stacionarūs duomenys, Pirmoje dalyje buvo atliekama apibendrintos statistikos analizė su stilizuotų faktų patikra. Gavus rezultatus, buvo pastebėtos kriptovaliutoms būdingos savybės. Atliekant koreliacinę analizę, buvo pasirinktas Spirmano koreliacijos koeficientas, dėl duomenų nenormalumo. Spirmano koreliacijos koeficientai buvo palyginti su netiesinių koreliacijų koeficientu – rezultatai buvo panašūs. Papildomai atlikta slenkančio Spirmano koreliacijos tarp kriptovaliutų porų analizė, Koreliacinėms matricoms buvo pritaikytas mažiausiai besidriekenčio medžio metodas ir nustatytos kintančios tiesinės priklausomybės. Patikrinus duomenų stacionarumą ir pritaikius impulso atsako funkcijas gauta, kokie kryptiniai ryšiai egzistuoja ir kokia daroma įtaka daro viena kitai kriptovaliutos. Šie skaičiavimai atlikti skirtingais periodais, siekiant įvertinti globalių krizių įtaką. Galiausiai atlikta kintamumo plitimo analizė ir parašytos apibendrinančios išvados.



2 pav. Tyrimo eiga

2.2. Duomenų rinkinio ir naudojamos programinės įrangos apžvalga

Išnagrinėjus literatūrą ir mokslinius straipsnius pastebėta, kad dažniausiai skaičiavimai yra atliekami pasirinkus logaritmines grąžas. Priklausomai nuo tiriamojo darbo tematikos galima pasirinkti įvairaus dažnio duomenys, nes kriptovaliutų kainos dinamiką kinta kas kelias sekundes ir prekyba vyksta kiekvieną dieną. Tačiau šiame darbe buvo pasirinkta nagrinėti kiekvienos dienos uždarymo kainų logaritmines grąžas. 1 formulė parodo, kaip galime tai apskaičiuoti :

$$r_i^t = \log P_i^t - \log P_i^{t-1}; \quad (1)$$

Čia:

P_i^t – konkrečios kriptovaliutos(*i*) laiku(*t*) kaina

Darbo pradžioje buvo pasirinktos 20 didžiausios kapitalizacijos turinčios kriptovaliutos, tačiau įvertinus skirtingą egzistavimo laiką ir atmetus kriptovaliutas, kurios yra prištos prie tradicinių valiutų (angl. *stablecoin*), pasilikta nagrinėti 10 kriptovaliutų. Pasirinktos kriptovaliutos yra šios: Bitcoin (BTC), Ethereum (ETH), Litecoin (LTC), Binance coin (BNB), Bitcoin Cash (BCH), Cardano (ADA), Ripple (XRP), Dogecoin (DOGE), , Chainlink (LINK), Filecoin (FIL). Kriptovaliutų analizuojamas laikotarpis nuo 2017-12-13 iki 2023-03-01. Iš viso gauta 19040 kiekvienos dienos uždarymo kainų stebėjimų. Duomenys paimti iš *yahoo! Finance*.

Šiam darbui atlikti buvo naudojamos Microsoft office ir R programinė įranga. Microsoft excel pasitarnavo nupiešiant dalį grafikų ir atliekant paprastus skaičiavimus, o R buvo naudojama kaip pagrindinė programa analizuoti kriptovaliutas. Įvairūs R programinės įrangos papildiniai buvo panaudoti atliekant skaičiavimus. Pagrindiniai naudoti R papildiniai aprašyti žemiau:

- *quantmod* – nagrinėjamų duomenų atsisiuntimui ir peržiūrai;
- *xts* – laiko eilučių analizei;
- *PerformanceAnalytics* – ekonometrinis įrankis analizuoti laiko eilučių našumui ir rizikoms;
- *Plyr* – duomenų sutvarkymui;
- *Zoo* – duomenų atvaizdavimui;
- *Matrix*, *matrixcalc* – matricų sudarymui ir jų skaičiavimams;
- *Glasso* – kavariacinių matricų įvertinimui;
- *Corrplot* – koreliacijų atvaizdavimui;
- *Spillover* – kintamumo kitimo analizei.

Bei kiti mažiau panaudoti, tačiau reikalingi papildiniai, užtikrinantys sklandų skaičiavimų atlikimą R programinėje įrangoje.

2.3. Bendroji aprašomoji statistika

Norint dirbti su duomenimis, reikalinga susipažinti su jais ir nustatyti bendruosius parametrus apie juos. Pagrindiniai duomenų rinkinio rodikliai gali būti nustatyti skaičiuojant vidurkį, standartinį

nuokrypį, asimetriją ir ekscesą. Žemiau pateiktos formulės ir paaiškinimai ką kiekvienas rodiklis reiškia:

$$\bar{r} = \frac{\sum_i^n r_i}{n}; \quad (2)$$

Čia:

r_i – i – tosios kriptovaliutos dieninė kainų graža;

n – apskaičiuotų dieninių gražų skaičius

Ši formulė ir skaičiavimas parodo pasirinktos kriptovaliutos imties vidurkį.

$$\sigma = \sqrt{\frac{\sum_i^n |r_i - \bar{r}|^2}{n}}; \quad (3)$$

Pasinaudojus 3 formule galima apskaičiuoti standartinį nuokrypį, kuris parodo kiek plačiai duomenys yra išsiskaidę aplink vidurkį.

$$Sk = \frac{\sum_i^n |r_i - \bar{r}|^3}{(n - 1) * \sigma^3}; \quad (4)$$

Apskaičiavus asimetriją naudojant 4 formulę galime pasakyti, kiek duomenų skirstinys yra pasislinkęs į kairę arba dešinę nuo vidurkio. Normaliai pasiskirsčius duomenims asimetrija artima 0.

$$Kurt = n * \frac{\sum_i^n |r_i - \bar{r}|^4}{\sum_i^n |r_i - \bar{r}|^2}; \quad (5)$$

Ekscesą galima apskaičiuoti pasinaudojus 5 formule. Ekscesas parodo, kiek imtyje duomenų yra susitelkę skirstinių kraštuose – uodegose. Didelis ekscesas kainų gražose reiškia, kad duomenų imtyje yra daug didelių kainų svyravimų ir ekstremalių reikšmių. Normaliai pasiskirsčiusiems duomenims ekscesas yra artimas 3.

Atlikus paprasčiausią aprašomąją statistiką pasirinktiems duomenims, galime susidaryti bendrą vaizdą apie juos.

2.4. Stilizuoti faktai

Papildomai atliekami stilizuoti statistinės kriptovaliutų gražos savybių įvertinimai. Jie padeda labiau suprasti duomenis su kuriais yra dirbama. Nors pagal Cont (2001) stilizuotų faktų galime atrasti virš 10, šiame darbe buvo pasirinkta nagrinėti tik 3 iš jų. Žemiau aprašoma kokie stilizuoti faktai pasirinkti ir kaip jie įvertinami:

Kintamumo klasteriai. Yra pastebėta, kad dideli kainų pokyčiai seka po didelių kainų pokyčių, o maži kainų pokyčiai eina po mažų kainų pokyčių (Zhanga ir kt. (2018)). Ši savybė būdinga finansų rinkoje. Norint patikrinti ar kriptovaliutoms galioja ši savybė taip pat, atliekama kintamumo klasterių vizualinė patikra. Pasirinkus kiekvienos kriptovaliutos grąžų imtis yra išrūšiuojama pagal dydį ir pasirenkamos pirmosios 200 absoliučių reikšmių. Nubraižomas grafikas, kaip šios reikšmės pasiskirsčiusios per laikotarpį. Jeigu matoma, kad tam tikrais intervalais vertės yra ženkliai sutankėjusios, galime įtarti, kad duomenims yra būdingi kintamumo klasteriai.

Autokoreliacijos. Tai matematinis tam tikros laiko eilutės ir jos vėluojančios versijos panašumo laipsnis. Tai yra tarsi koreliaciją tarp dviejų laiko eilučių tik ta pati laiko eilutė naudojama du kartus: vieną kartą pradinė forma ir kitą kartą pastumta per tam tikrą laiko tarpą. Autokoreliacija parodo ryšį tarp kintamojo ir jo praeities verčių. Autokoreliacijos gali sukelti problemų, siekiant pritaikyti prognozavimo metodus, todėl nagrinėjant laiko eilutes, reikėtų pasitikrinti ar turimai laiko eilutei būdinga autokoreliacija. Tai galima padaryti atlikus Ljung-Box testą. Šiame teste keliamos šios hipotezės:

H_0 : Duomenys yra nepriklausomai pasiskirstę

H_a : Duomenys nėra nepriklausomai pasiskirstę, jiems būdinga nuoseklioji koreliacija

Patikrinti hipotezes yra skaičiuojama Q statistika:

$$Q = n(n + 2) \sum_{k=1}^h \frac{\widehat{\rho_k^2}}{n - k}; \quad (6)$$

Čia:

$\widehat{\rho_k^2}$ – imties autokoreliacija

k – vėlavimas

h – vėlavimų skaičius, kuris buvo skaičiuojamas

Reikšmingumo lygmeniui nustatyti yra lyginama:

$$Q > X_{1-\alpha, h}^2; \quad (7)$$

Čia:

$X_{1-\alpha, h}^2$ – $(1 - \alpha)$ kvantilis chi – kvadrato pasiskirtymo su h laisvės laipsniu

Norint pritaikyti duomenis prognozavimo modeliams turėtume neatmesti nulinės hipotezės.

Duomenų skirstinio normalumo patikra.

Analizuojant laiko eilutes, reikia nustatyti koks yra duomenų pasiskirstymas imtyje. Siekiama turėti duomenų imtį, kurioje būtų duomenys normaliai pasiskirstę. Toks duomenų tipas yra tinkamas daugeliui prognozavimo modelių ir palengviną darbą tyrėjams. Siekiant patikrinti ar duomenys yra normaliai pasiskirstę, galima pasinaudoti Shapiro-Wilk testu, kuris tikrina šias hipotezes:

H_0 : Duomenys priklauso normaliajam skirstiniui

H_a : Duomenys nepriklauso normaliajam skirstiniui

Hipotezei patikrinti yra skaičiuojamas Shapiro-Wilk testo parametras, su kurio pagalba galima patikrinti reikšmingumo lygmenį:

$$W = \frac{(\sum_{i=1}^n \alpha_i x_{(i)})^2}{\sum_{i=1}^n (x_i - \hat{x})^2}; \quad (8)$$

Čia:

$\hat{x}$ – imties vidurkis

Patikrinus ar duomenys yra normaliai pasiskirstę papildomai atliekamas „sunkių uodegų“ patikrinimas nupiešiant Q-Q grafiką. Tai grafikas, kurio pagalba galima palyginti kelių duomenų rinkinių skirstinius. Dažniausiai šis grafikas naudojamas palyginti turimą duomenų imtį su normaliuoju skirstiniu. Jeigu visi duomenys yra vienoje linijoje, tada skirstiniai yra vienodi, tačiau jeigu galuose matome ženklus nukrypimus nuo tiesios linijos galime įtarti, kad duomenys yra su „sunkiomis uodegomis“. Tai reiškia, kad yra ženklus skaičius ekstremalių verčių.

2.5. Koreliacinė analizė

Pasirinktoms kriptovaliutoms atliekama koreliacinė analizė, kuri parodo tiesinį arba netiesinį ryšį tarp kintamųjų. Sudaromos koreliacinės matricos yra apskaičiuojami koreliacijos koeficientai, kurie parodo tarpusavio priklausomybių dydį. Kadangi duomenys netenkina normaliai pasiskirsčiusių duomenų prielaidos, buvo pasirinkta skaičiuoti Spirmano (angl. *Spearman*) koreliacijos koeficientai. Šį koeficientą galima apskaičiuoti pasinaudojant šia formule:

$$r_s = 1 - \frac{6 \sum_{i=1}^n D_i^2}{n^3 - n}; \quad (9)$$

Čia:

D_i^2 = visų porų skirtumų kvadratų suma

Koreliacijos stiprumas yra vertinimas skalėje nuo -1 iki 1. Reikšmės nuo -1 iki 0 indikuoja, kad tarp pasirinktų kintamųjų egzistuoja neigiamas ryšys, t.y. vieno kintamojo reikšmėms didėjant kito kintamojo reikšmės mažėja. Gavus Spirmano koeficiento reikšmę lygią 0, tai parodo, kad nėra priklausomybės tarp pasirinktų kintamųjų. Reikšmės nuo 0 iki 1 rodo, kad tarp kintamųjų yra teigiamas ryšys. Spirmano koreliacijos koeficientas buvo pasirinktas, nes jis gali būti taikomas neturint normaliai pasiskirsčiusių duomenų ir jis apibūdina ryšį tarp kintamųjų monotoniškumo prasme, t.y. didėjant vienam kintamajam, didėja ir kitas kintamasis. Apačioje pateiktas koreliacinio koeficiento dydžio įvertinimas.

Neigiamos reikšmės	Aprašymas	Teigiamos reikšmės
0.00	Ryšio nėra	0.00
-0.19 – -0.01	Labai silpnas ryšys	0.01 – 0.19
-0.39 – -0.20	Silpnas ryšys	0.20 – 0.39
-0.69 – -0.40	Vidutinis ryšys	0.40 – 0.69
-0.89 – -0.70	Stiprus ryšys	0.70 – 0.89
-0.90 – -1.00	Labai stiprus ryšys	0.90 – 1.00

3 pav. Ryšio stiprumas vertinant pagal koreliacijos koeficiento vertes

Papildomai buvo pasirinkta apskaičiuoti netiesinių koreliacijų koeficientus siekiant įvertinti skirtumą tarp tiesinių ir netiesinių ryšių. Tam buvo pasirinktas *nIcor* R programinės įrangos paketas, kuris netiesinėms koreliacijoms apskaičiuoti naudoja adaptyviąją erdvinę atranką, t.y. duomenų rinkinys yra dalinamas į mažesnius duomenų masyvūs ir jiems skaičiuojamos tiesinės koreliacijos. Šis netiesinių koreliacijų analizavimo metodas turi tik teigiamas koreliacijos koeficiento vertes.

Dydžių interpretavimui galime pasinaudoti 6 pav. Apskaičiavus tiesinių ir netiesinių koreliacijų koeficientų vertes buvo pastebėta, kad abu metodai duoda praktiškai tokius pačius įverčius. Toliau nagrinėti kriptovaliutas buvo pasirinkta tiesinėmis Spirmano koreliacijomis.

Koreliacijos koeficientai laikui bėgant kinta. Kad galėtume įvertinti kaip kriptovaliutų ryšiai kito skirtingu laiko intervalu buvo nupiešti slenkančių koreliacijų grafikai iš kurių galima pastebėti, kurio metu tarpusavio ryšiai buvo didžiausi arba mažiausi. Slenkančios koreliacijos koeficientai yra apskaičiuojami naudojant Spirmano metodą, tačiau ne visam duomenų rinkiniui, o dalinant duomenų rinkinį į tam tikro laiko intervalus ir skaičiuojant koeficiento dydį tuo laiko intervalu bei keičiant intervalus per vieną poziciją į priekį. Šiame tyrime laiko intervalas buvo pasirinktas 120 dienų.

2.6. Mažiausiai besidriekiančio medžio metodas

Mažiausiai besidriekiančio medžio (angl. *minimal spanning tree*) (MST) metodas suteikia puikią galimybę atvaizduoti ryšius tarp kriptovaliutų dieninių kainų grąžų laiko eilučių. Šis metodas pasitelkia koreliacijų matricą, kuri yra gaunama iš atsitiktinių matricų teorijos (angl. *random matrix theory* (RMT)). Ši teorija yra plačiai naudojama kvantinėje mechanikoje, nagrinėjant bevielį ryšį bei ekonomikoje ar finansuose. Šiuo metodu koreliacinėse matricose galima išskirti svarų signalą ir panaikinti triukšmą, kuris gadina galutinius rezultatus. Šis algoritmas tikrina nulinę hipotezę, kad tikrinės koreliacinės matricos reikšmės yra lygios tikrinėms atsitiktinei Wišarto (angl. Wishart) matricai, kuri apsirašo taip:

$$R = \frac{1}{T} AA^T; \quad (10)$$

Čia:

A – $N \times T$ matrica, kur N laiko eilučių skaičius, o T laiko eilutės ilgis

Matricos A elementai yra atsitiktiniai kintamieji, kurių vidurkis lygus nuliui, o dispersija – vienetinė.

Marchenko ir kt. (1967) įrodė, kad kai $N \rightarrow \infty$, $T \rightarrow \infty$ ir santykis $Q = \frac{T}{N} \geq 1$ yra fiksuotas, imties tikrinių reikšmių tankis konverguoja į:

$$f(\lambda) = \frac{T}{2\pi} \frac{\sqrt{(\lambda_+ - \lambda)(\lambda - \lambda_-)}}{\lambda}; \quad (11)$$

Kur, $\lambda \in (\lambda_-, \lambda_+)$,

$$\lambda_{\pm} = 1 + \frac{1}{Q} \pm 2\sqrt{\frac{1}{Q}}; \quad (12)$$

Taigi, atlikus singuliariųjų reiškių dekompoziciją pagal atsitiktinių matricų teoriją (RMT) sukurama filtruota koreliacinė matrica.

Apskaičiavus kriptovaliutų logaritmines grąžas pagal (1) formulę galima sudaryti koreliacinę matricą C , kurios dydis yra 10×10 (nes nagrinėjama 10 kriptovaliutų). Atsitiktinių matricų metodas išfiltruoją šią matricą ir gauname naują koreliacinę C^* matricą, kuri atrodo taip:

$$C^* = V\Lambda V^T, \text{ kur} \quad (13)$$

$$\Lambda = \begin{cases} 0 & \lambda_i < \lambda_+ \\ \lambda_+ & \lambda_i \geq \lambda_+ \end{cases} \quad (14)$$

Čia:

Λ – matrica tikrinių vektorių, kurie yra susiję su tikrinėmis reikšmėmis didesnėmis nei λ_+

Gavus koreliacinę matricą C^* galima pritaikyti minimaliai besidriekiančio medžio metodą, kuris vaizdingiau ir paprasčiau pateikia ryšius tarp kriptovaliutų. Pradžioje reikia apskaičiuoti Euklido atstumus tarp kiekvieno koreliacinės matricos porų ir šie atstumai patalpinami į atstumų matricą D , tai galima atlikti pagal šią formulę:

$$d_{ij} = \sqrt{2 - 2c_{ij}^*}; \quad (15)$$

Čia:

c_{ij}^* – C^* matricos ij elementas

d_{ij} – D matricos ij elementas

Minimaliai besidriekiančio medžio metodas sugeba sumažinti ryšius tarp kriptovaliutų nuo $\frac{N(N-1)}{2}$

iki $N - 1$ priskiriant kiekvieną mazgą prie artimiausio kaimyno.

Siekiant paaiškinti kaip kinta kriptovaliutų tarpusavio priklausomybės per laiką, papildomai panaudotas Spelta ir kt. (2012) pasiūlytas liekanų koeficientas (angl. *Residuality coefficient*), kuris palyginą santykinį jungčių stiprumą:

$$R = \frac{\sum_{d_{i,j} > L} d_{i,j}^{-1}}{\sum_{d_{i,j} \leq L} d_{i,j}^{-1}}; \quad (16)$$

Čia:

L – didžiausia slenkstinė vertė, užtikrinanti MST ryšį

Kai liekanų koeficientas didėja, tai didėja ir sąsajų skaičius tarp kriptovaliutų (tinklas retėja), kai koeficientas mažėja, ryšių skaičius mažėja taip pat.

Tinklo centriškumui apskaičiuoti buvo pasirinktas Bonacich (2007) pasiūlytas tikrinio vektoriaus centriškumo matas, kuris vertina kiekvieno mazgo svarbą tinkle, priskirdamas santykinis balus visiems tinklo mazgams . Šis parametras apskaičiuojamas pagal (17) formulę:

$$x_i = \frac{1}{\lambda} \sum_{j=1}^N \widehat{d_{i,j}} x_j; \quad (17)$$

Čia:

x_j – santykinis balas mazgui j

$\widehat{d_{i,j}}$ – elementas iš priklausomybių matricos $\widehat{D}$

Kadangi tinklas pagrįstas atstumais tarp dieniniu logaritminių kriptovaliutų grąžų, tai kuo didesnis su mazgu siejamas centriškumo matas, tuo labiau šis mazgas skiriasi nuo kitų tinkle mazgų.

2.7. Duomenų stacionarumo patikrinimas ir Grangerio priežastingumo testas

Logaritminių grąžų stacionarumui patikrinti buvo pasirinktas ADF testas. Išplėstas Dikio Fulerio (angl. *Augmented Dickey-Fuller*) testo rezultatas gali padėti nustatyti ar duomenys yra stacionarūs ar turi „trendą“. Šis testas tikrina šias hipotezes:

H_0 : y_t procesas turi vienetinę šaknį

H_a : y_t procesas yra stacionarus

Hipotezei patikrinti naudojama (18) formulė:

$$y_t = \alpha y_{t-1} + \sum_{i=2}^i \beta \Delta y_{t-i+1} + w_t; \quad (18)$$

Atlikus testą logaritminių grąžų laiko eilutėms kiekvienai kriptovaliutai, buvo gauta, kad visi duomenys yra stacionarūs ir duomenų nereikia diferencijuoti integruojant.

Turint stacionarius duomenis galima atlikti IRF analizę. Ortogonalizuotos impulso atsako funkcijos apskaičiuojamos pagal šią formulę:

$$IRF_{ij}(l) = \frac{\partial y_{j,t+l}}{\partial \zeta_{it}}; \quad (19)$$

Gauti impulsai parodo koks egzistuoja kryptinis ryšys tarp kriptovaliutų. Pasirinkus 24 dienų prognozės periodą, galima atvaizduoti kaip impulsas keičiasi per 24 dienų laikotarpį. FEVD komponentas k laikotarpiui nustatomas pagal šią formulę:

$$y_{ij}(k) = \frac{\sum_{l=0}^k IRF_{ij}^2(l)}{\sum_{i=1}^K \sum_{l=0}^k IRF_{ij}^2(l)}; \quad (20)$$

Grangerio priežastingumo testas buvo naudojamas siekiant nustatyti teigiamus ir neigiamus ryšius tarp kriptovaliutų. Taip pat šis testas parodo ar viena kriptovaliuta turi įtakos nuspėjant kitos kriptovaliutos ateities reikšmes.

Grangerio priežastingumo analizė buvo atlikta su 3 skirtingomis duomenų imtimis:

1. Nagrinėjami ryšiai nuo duomenų imties pradžios iki 2020-03-01 (Covid-19 pandemijos pradžios).
2. Nagrinėjami ryšiai nuo 2020-03-01 iki duomenų imties pabaigos (Covid-19 pandemijos laikotarpis).
3. Nagrinėjami ryšiai visam laikotarpiui.

Grangerio priežastingumo testas naudoja kintamųjų tiesinį autoregresinį modelį, kurį galima aprašyti šiomis formulėmis:

$$x_1 = \sum_{j=1}^p A_{11,j} X_{1(t-j)} + \sum_{j=1}^p A_{12,j} X_{2(t-j)} + E_{1(t)}; \quad (21)$$

$$x_2 = \sum_{j=1}^p A_{21,j} X_{1(t-j)} + \sum_{j=1}^p A_{22,j} X_{2(t-j)} + E_{2(t)}; \quad (22)$$

Čia:

p – maksimalus vėlinimų skaičius

Matrica A – modelių koeficientų sumos su įvertintu vėlinimu

E – prognozavimo paklaidos

Tada apskaičiuojama F-statistika pagal šią formulę:

$$F = \frac{\frac{RSS_i - RSS_{i+1}}{p_2 - p_1}}{\frac{RSS_{i+1}}{n - p_2}}; \quad (23)$$

Čia:

RSS_i – modelio kvadratų paklaidų suma.

Pasinaudojant Grangerio priežastingumo analize, galima sudaryti vizualius grafikus su ryšiais tarp kriptovaliutų bei matyti kuri kriptovaliuta veikia stipriau viena kitą ir koks tai yra ryšio tipas – neigiamas ar teigiamas.

2.8. Kintamumo plitimas

Toliau panagrinėkime kintamumo plitimą (angl. *volatility spillover*) tarp kriptovaliutų. Mudassar ir kt. (2019) kintamumo plitimą apibrėžiamas kaip nestabilumo perdavimą iš vienos rinkos į kitą. Tai atsiranda, kai kainos pokytis vienoje rinkoje daro vėluojantį poveikį kainos pokyčiui kitoje rinkoje. Šis dėsniumas yra paplitęs finansų rinkoje. Tokių rinkų įvertinimą pasiūlė Diebold ir kt. (2009, 2012). Savo darbuose jie vertino kaip įtakoja vienos rinkos kitas ir kaip kinta kintamumo indeksas skirtingais laikotarpiais. Savo darbe pastebėjo, kad galima pastebėti aiškius kintamumo padidėjimus pasaulinių ar finansinių sukrėtimų metu. Toliau bus aprašyta metodika, kurią taikė tyrėjai, bei pasirinkus šia metodika bus analizuojamos kriptovaliutų tarpusavio ryšiai ir kintamumo plitimas skirtingais laikotarpiais. Norint nustatyti šių plitimų (angl. *spillovers*) matą, skaičiavimai atliekami pasinaudojant žemiau pateiktomis formulėmis:

$$\Theta_{ij}^g(H) = \frac{\sum_{h=0}^{H-1} (e_i' A_h \Sigma e_j)^2}{\sum_{h=0}^{H-1} e_i' A_h \Sigma A_h' e_j}; \quad (24)$$

$$\tilde{\Theta}_{ij}^g(H) = \frac{\Theta_{ij}^g(H)}{\sum_{j=1}^N \Theta_{ij}^g(H)} \quad (25)$$

$$S^g(H) = \frac{\sum_{i,j=1, i \neq j}^N \tilde{\Theta}_{ij}^g(H)}{N} * 100 \quad (26)$$

Pilnutinis kintamumo plitimo koeficientas apskaičiuojamas pagal 26 formulę.


Skaičiavimams atlikti buvo panaudotas R programinės įrangos „*spillover*“ paketu. Šis paketas sukurtas remiantis Diebold ir kt. (2009, 2012) atliktais skaičiavimais. Panaudojus šį paketą buvo gautos kintamumo plitimo lentelė, kur galima matyti kiek įtakoja viena kriptovaliuta kitą ir kaip bendras visos imties (10 kriptovaliutų) kintamumo kitimo rodiklis kito skirtingais laikotarpiais. Taip pat pastebėta, kad globalių sukrėtimų metu šis rodiklis staigiai padidėja.

3. Kriptovaliutų tarpusavio priklausomybių nustatymo kriziniu laikotarpiu tyrimo rezultatai

Šiame skyriuje aprašomi gauti rezultatai tiriant kriptovaliutų tarpusavio priklausomybes kriziniais laikotarpiais. Pradžioje yra išnagrinėjami pasirinkti duomenys, jų tipas bei savybės, atliekama koreliacinė analizė, bei pritaikomas mažiausiai besidriekiančio medžio metodas. Toliau yra pritaikomi IRF, Grangerio priežastingumo testas, kintamumo plitimo metodai ir aprašomi gauti rezultatai.

3.1. Duomenų rinkinio analizė

Buvo pasirinktos 20 didžiausios kapitalizacijos kriptovaliutos iki 2023-03-01 metu. Dėl skirtingo žetonų gyvavimo laiko ir pašalinus stabiliuosius žetonus (angl. *stablecoin*) duomenų imtis liko iš 10 kriptovaliutų. Nagrinėjamas laikotarpis yra nuo 2017-12-13 iki 2023-03-01. Kaip žinoma į šį laikotarpį patenka ir tokie pasauliniai įvykiai kaip: COVID-19 pandemija bei prasidėjęs karas Ukrainoje. Taip pat nemažai įvykių susiję su pačia kriptovaliutų sistema, tokie kaip: kriptovaliutų keitimosi platformų įsilaužimas (BITPoint), jų bankrutavimas (FTX), keletas kilimo ir kritimo bangų, pritaikomos reguliuotojų griežtinamos priemonės. Apačioje pateiktas pasirinkto laikotarpio visų žetonų normalizuotų kainų grafikas. Normalizavimui pasirinktas min-max metodas. Duomenys paimti iš *Yahoo! Finance*.



4 pav. Normalizuotų kriptovaliutų kainų grafikas


Iš grafiko galime pastebėti, kad kainų dinamiką per vertinamąjį laikotarpį yra ganėtinai didelė. Laikotarpio pradžioje galima pastebėti aukštas kainas, tačiau jos greitai sumažėjo ir net keletą metų laikėsi ties ganėtinai žemomis vertėmis. Laikotarpis nuo 2020 metų pabaigos iki 2022 metų pabaigos pasižymi aukščiausiomis laikotarpio kainomis. Šį staigų šuolį 2020 metų pabaigoje galima būtų paaiškinti keliais ekonominiais aspektais:

- COVID-19 pandemijos pradžioje susidaręs didelis neapibrėžtumas ir baimė, kuri paskatino finansų institucijas ir investuotojus ieškoti alternatyvių investavimo galimybių;
- Žemos palūkanų normos. Euribor palūkanų norma net iki 2022 metų vidurio siekė rekordines žemumas ir buvo net minusinė vertė, dėl ko investuotojai galėjo pigiai skolintis ir investuoti į platesnę gamą finansinių priemonių.
- COVID-19 pandemijos pradžioje, kai kurių valstybių (tokių kaip JAV). gyventojams išdalintų skatinamųjų čekių panaudojimas investicijoms į finansų sektorių. *Yahoo! Finance*

atlikta apklausa ir tyrimas parodė, kad net 15% JAV gyventojų gautus pinigus už skatinamąjį čekį investavo į finansų rinką ir net pusę iš jų specifiškai į kriptovaliutas. Tai parodo, kad COVID-19 pandemijos pradžioje susidaręs didžiulis neapibrėžtumas ir vyriausybės vykdoma pinigų leidimo politika, sudarė galimybes gyventojams investuoti neplanuotai gautas pajamas į ne pirmo būtinumo prekes ar paslaugas, tokias kaip investicijas į finansų rinką.

Dėl šių ir dar daugelio priežasčių šiame laikotarpyje susidarė puikios galimybės akcijų ir kriptovaliutų rinkoms stipriai augti. Nuo 2022 metų matome kainų kritimą, kuris prasidėjo dėl didelės infliacijos ir brangstančių palūkanų normos. Šį kainų kritimą galima pastebėti ir kitose finansų rinkose, tokiose kaip akcijų birža.

Tiriant finansų rinkos laiko eilutes įprastai yra nagrinėjamos ne pačios kainos, o dieninės logaritminės grąžos. Šiame darbe buvo taip pat apskaičiuotos šios grąžos. Apačioje matome grafiką, kaip kinta logaritminės grąžos per visą laikotarpį.



5 pav. Logaritminių dieninių kriptovaliutų grąžų grafikas

Iš grafiko galima pastebėti, kad didžiosios kriptovaliutos, tokios kaip Bitcoin arba Ethereum svyruoja aplink 0 nedidele amplitude, tuo tarpu tokios kriptovaliutos kaip Filecoin ir Dogecoin turi stiprių išsišokimų tiek į neigiamą, tiek į teigiamą pusę. Apačioje pateikiama bendroji aprašomoji logaritminių grąžų imties statistika.

Index	Bitcoin	Ethereum	Litecoin	Binance Coin	Bitcoin cash
Min. :2017-12-14	Min. : -0.4647302	Min. : -0.5507317	Min. : -0.4490616	Min. : -0.543084	Min. : -0.5613476
1st Qu.:2019-04-03	1st Qu.: -0.0156273	1st Qu.: -0.0215681	1st Qu.: -0.0256172	1st Qu.: -0.021152	1st Qu.: -0.0255421
Median :2020-07-22	Median : 0.0009689	Median : 0.0007964	Median : -0.0000133	Median : 0.001014	Median : -0.0008902
Mean :2020-07-22	Mean : 0.0001919	Mean : 0.0004525	Mean : -0.0005936	Mean : 0.002464	Mean : -0.0013040
3rd Qu.:2021-11-10	3rd Qu.: 0.0171852	3rd Qu.: 0.0262725	3rd Qu.: 0.0255697	3rd Qu.: 0.026912	3rd Qu.: 0.0244664
Max. :2023-03-01	Max. : 0.1718206	Max. : 0.2306952	Max. : 0.2905937	Max. : 0.529218	Max. : 0.4208142
Cardano	Ripple	Dogecoin	Chainlink	Filecoin	
Min. : -0.5036382	Min. : -0.5505025	Min. : -0.515118	Min. : -0.614577	Min. : -0.6046051	
1st Qu.: -0.0292039	1st Qu.: -0.0232540	1st Qu.: -0.024627	1st Qu.: -0.033899	1st Qu.: -0.0393208	
Median : -0.0001697	Median : -0.0009916	Median : -0.001120	Median : 0.001226	Median : -0.0025248	
Mean : 0.0005185	Mean : 0.0001075	Mean : 0.001286	Mean : 0.001764	Mean : -0.0002422	
3rd Qu.: 0.0277964	3rd Qu.: 0.0205941	3rd Qu.: 0.019563	3rd Qu.: 0.036283	3rd Qu.: 0.0360012	
Max. : 0.6395773	Max. : 0.6068853	Max. : 0.800000	Max. : 0.480615	Max. : 0.7692101	

6 pav. Logaritminių grąžų aprašomoji statistika

Iš 9 paveikslo galime pastebėti, kad visų kriptovaliutų logaritminių gražų vidurkiai yra artimi nuliui. Taip pat matome, kad gražos svyruoja nuo -0,615 iki 0,8, tačiau 25% ir 75% kvantiliai parodo, kad didžioji dalis gražų yra pasiskirsčiusios tarp -0,034 ir 0,036.


Apskaičiavus standartinį nuokrypį, asimetriją ir ekscesą, matoma, kad logaritminės gražos yra ganėtinai asimetriškos: 5 kriptovaliutos yra pasislinkusios į neigiamą pusę ir likusios 5 pasislinkusios į teigiamą pusę. Vertinant ekscesą galima pasakyti, kad yra ženkliai didesnis nei normaliojo skirstinio, kas indikuoja, kad duomenų imtys turi „sunkias uodegas“.

	vidurkis	stand. nuokrypis	Ekscesas	Asimetrija
Bitcoin	0.0001919307	0.03915298	12.627031	-1.0180774
Ethereum	0.0004525283	0.05042851	9.979085	-1.0071075
Litecoin	-0.0005935564	0.05288705	7.473629	-0.5844572
Binance Coin	0.0024641072	0.05781976	15.599501	0.3823547
Bitcoin cash	-0.0013040444	0.06136918	11.319158	-0.2065273
Cardano	0.0005184652	0.06231048	13.612111	0.9837661
Ripple	-0.0001074918	0.06198431	17.182982	0.7439721
Dogecoin	0.0012859216	0.07116017	23.358905	1.9064334
Chainlink	0.0017639746	0.06923192	7.492892	-0.1269735
Filecoin	-0.0002421756	0.09429420	9.884899	0.5656488

7 pav. Logaritminių gražų vidurkio, standartinio nuokrypio, eksceso ir asimetrijos rezultatai

3.2. Stilizuotų faktų patikra

Plačiau nagrinėjant pasirinktų laiko eilučių logaritmines gražas buvo atliekama papildomą statistinę analizę. Autokoreliacijos vienas iš būdų patikrinti, kiek praeities kainos daro įtaką kriptovaliutų ateities kainoms. Tam patikrinti buvo lyginamos kriptovaliutos logaritminių gražų laiko eilutė su ta pačia laiko eilute tik pritaikant skirtingą dienų vėlinimo skaičių. Grafinis rezultatų pavyzdys pateiktas 8 paveiksle.



8 pav. Logaritminių gražų Bitcoin ir Ethereum autokoreliacijų tyrimo grafinis pavyzdys


Siekiant išsiaiškinti kriptovaliutų autokoreliacijos reikšmingumą buvo pritaikytas Ljung-Box testas su 50 dienų vėlinimo intervalu. Gauti rezultatai pateikti 2 lentelėje:

2 lentelė. Ljung-Box testo rezultatai

	Bitcoin	Ethereum	Litecoin	Binance coin	Bitcoin cash	Cardano	Ripple	Dogecoin	Chainlink	Filecoin
Ljung-Box testo p vertės	0,101	0,241	0,374	0,001	0,487	0,008	0,001	0,001	0,137	0,001

Iš rezultatų lentelės galime teigti, kad pasirinkus 95% reikšmingumo lygmenį galime atmesti šio testo nulinę hipotezę apie autokoreliacijų nebuvimą šioms 5 kriptovaliutoms: Binance coin, Cardano, Ripple, Dogecoin, Filecoin. Šios kriptovaliutos bent viename iš 50 vėlavimo langų parodė autokoreliaciją. Likusios kriptovaliutos neparodė reikšmingo autokoreliacijos buvimo.

Sekančiam stilizuotam faktui yra piešiamos 200 absoliučių didžiausių dieninių gražų kriptovaliutai. Iš šio grafiko galime įžvelgti kintamumo klasterius, kurie parodo, kad po didelio kainų kitimo seką kitas didelis kainų kitimas.



9 pav. Kintamumo klasterių susidarymas kriptovaliutose


Iš 9 paveikslo galime įtarti, kad pasirinktoms kriptovaliutoms yra būdingi kintamumo klasteriai. Matome, kad 9 iš 10 kriptovaliutų kintamumo klasteriai gauti panašiais laikotarpiais: 2018 metų pradžioje per kainų kilimą ir kritimą bei 2021 metų pradžioje, per kainų augimo piką. Tai parodo kriptovaliutų kintamumo panašumus. Tačiau Filecoin ganėtinai išsiskyrė iš kitų pasirinktų kriptovaliutų – šios kriptovaliutos ekstremalių verčių klasteris susidarė per pandemijos pradžią 2020 metų pirmoje pusėje.

Toliau buvo patikrinta ar pasirinktų kriptovaliutų duomenų skirstiniai yra pasiskirstę normaliai. Tam buvo atliktas Shapiro-Wilk testas ir šio testo rezultatai pateikti 3 lentelėje:

3 lentelė. Shapiro-Wilk testo rezultatai

	Bitcoin	Ethereum	Litecoin	Binance coin	Bitcoin cash	Cardano	Ripple	Dogecoin	Chainlink	Filecoin
Shapiro-Wilk testo p vertės	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001

Iš gautų rezultatų matome, kad visoms kriptovaliutoms testo p vertės yra mažesnės negu 0,001, dėl ko galime teigti, kad su 95% reikšmingumo lygmeniu galime atmesti nuline šio testo hipotezę, kad duomenys yra pasiskirstę pagal normalųjį skirstinį. Papildomai duomenims yra nupiešiamas Q-Q grafikas, kuriame galime palyginti turimus duomenis su normaliuoju skirstiniu.




10 pav. Q-Q grafikas

Iš grafiko taip pat galime pastebėti, kad duomenys nėra normaliai pasiskirstę ir jiems būdingos „sunkios uodegos“, dėl didelio skaičiaus ekstremalių verčių.

Apibendrinant gautus rezultatus, galime teigti, kad kriptovaliutų logaritminių grąžų vidurkiai yra artimi nuliui, puse kriptovaliutų pasižymi autokoreliacinėmis savybėmis, joms būdingi kintamumo klasteriai bei kriptovaliutų grąžos nėra normaliai pasiskirsčiusios ir turi „sunkias uodegas“. Šie rezultatai sutampa su literatūroje nagrinėtais moksliniais straipsniais.

3.3. Koreliacinė analizė

Vienas iš paprasčiausių kriptovaliutų tarpusavio ryšių nustatymo metodų yra koreliacinė analizė. Jai atlikti buvo pasirinkta apskaičiuoti Spirmano tiesinės koreliacijos koeficientus. 11 paveiksle pateikti Spirmano koeficientų reikšmės kiekvienai kriptovaliutų porai visam imties laikotarpiui.



11 pav. Spirmano koreliacijos koeficientų matrica


Iš apskaičiuotų koeficientų matricos galime pastebėti, kad tarp kriptovaliutų egzistuoja ganėtinai stiprus tiesinis ryšys. Tarp didžiausių žetonų, tokių kaip: Bitcoin, Ethereum, Litecoin ir Bitcoin cash - matome stiprų teigiamą koreliacinį ryšį, kuris siekia nuo 0,75 iki 0,83. Tarp Binance Coin, Chainlink, Ripple, Cardano ir Dogecoin gautas vidutinis teigiamas koreliacinis ryšys, kuris siekia nuo 0,42 iki 0,67. Tik vienas Filecoin žetonas parodė silpną teigiamą ryšį tarp kitų žetonų ir siekė nuo 0,25 iki 0,35. Vertinant susidariusią dendogramą galime išskirti 2 aiškius klasterius, kur viename klasteryje yra Filecoin su Dogecoin, o kitame klasteryje yra likusios 8 kriptovaliutos. Tarp likusių 8 kriptovaliutų galime įžvelgti mažiau ryškius 2 klasterius, kuriuose viename yra stiprų koreliacinį ryšį turinčios kriptovaliutos, o likusiame – vidutinį koreliacijos koeficientą turintys žetonai.

Siekiant patikrinti ar tarp kriptovaliutų porų egzistuoja netiesiniai koreliaciniai ryšiai buvo apskaičiuoti netiesinės koreliacijos koeficientai. Gauta, kad netiesinės koreliacijos koeficientai yra labai artimi Spirmano koreliacijos koeficientams ir visiškai sutampa su Pirsono (angl. *Pearson*) koreliacijos koeficientais, dėl ko galima teigti, kad netiesiniai ryšiai yra nereikšmingi. Gauti rezultatai pateikti 12 paveiksle.

	Bitcoin	Ethereum	Litecoin	Binance Coin	Bitcoin cash	Cardano	Ripple	Dogecoin	Chainlink	Filecoin
Bitcoin	1.0000000	0.8236801	0.8043038	0.6781364	0.7546097	0.6703929	0.5890613	0.5240769	0.6040736	0.3463498
Ethereum	0.8236801	1.0000000	0.8293339	0.6756748	0.7802230	0.7252241	0.6478141	0.5061906	0.6788688	0.3373554
Litecoin	0.8043038	0.8293339	1.0000000	0.6672788	0.7969352	0.6826082	0.6380674	0.5305007	0.6289977	0.3244983
Binance Coin	0.6781364	0.6756748	0.6672788	1.0000000	0.5998518	0.5826098	0.5243562	0.4197290	0.5493705	0.2839756
Bitcoin cash	0.7546097	0.7802230	0.7969352	0.5998518	1.0000000	0.6634431	0.6234835	0.5127338	0.5881268	0.3109723
Cardano	0.6703929	0.7252241	0.6826082	0.5826098	0.6634431	1.0000000	0.6586538	0.4919594	0.6027642	0.3102510
Ripple	0.5890613	0.6478141	0.6380674	0.5243562	0.6234835	0.6586538	1.0000000	0.4332715	0.5377694	0.2591712
Dogecoin	0.5240769	0.5061906	0.5305007	0.4197290	0.5127338	0.4919594	0.4332715	1.0000000	0.4274569	0.2459064
Chainlink	0.6040736	0.6788688	0.6289977	0.5493705	0.5881268	0.6027642	0.5377694	0.4274569	1.0000000	0.2838491
Filecoin	0.3463498	0.3373554	0.3244983	0.2839756	0.3109723	0.3102510	0.2591712	0.2459064	0.2838491	1.0000000

12 pav. Netiesinės koreliacijos koeficientų matrica

Prieš tai apskaičiuoti Spirmano koreliacijos koeficientai buvo visam laikotarpiui, tačiau imant skirtingus laiko intervalus, koreliacijos koeficientas kinta, todėl norint pažvelgti kaip kinta koreliacijos koeficientai, buvo nubraižyti slenkančios Spirmano koreliacijos koeficiento grafikai. Pasirinktas koreliacijos koeficiento skaičiuojamasis intervalas 120 dienų. 13 paveiksle pasirinktas Bitcoin žetonas iš stiprių korelacių turinčio klasterio.




13 pav. Slenkantis Spirmano koreliacijos koeficientas tarp Bitcoin ir likusių kriptovaliutų

Iš grafiko galima pastebėti įdomius rezultatus. Pirma, Bitcoin ir likusių kriptovaliutų koreliacijos per visą laikotarpį išlieka ganėtinai stiprios, neskaitant Chainlink ir Filecoin. Antra, COVID-19 pandemijos pradžioje 9 iš 10 kriptovaliutų Spirmano koreliacijos koeficientas pasiekė 0,8 ir didesnes vertes. Tai parodo, kad kriptovaliutų tarpusavio priklausomybės tapo stiprios arba labai stiprios ir tuo periodu šių žetonų grąžos elgseni labai panašiai. Trečia, pastebėta, kad iš pasirinktų žetonų labai

išsiskiria Filecoin. Pandemijos pradžioje ši kriptovaliuta nekoreliavo arba pasiekė net silpną neigiamą koreliacinį ryšį. Tai galima būtų paaiškinti šios kriptovaliutos išskirtinumu nuo kitų, t.y. šios kriptovaliutos pagrindinė paskirtis yra ne decentralizuotas transakcijų atlikimas, o decentralizuotas duomenų saugojimas.


Toliau pasirenkama kriptovaliuta iš vidutinio koreliacijos koeficiento klasterio – Ripple.



14 pav. Slenkantis Spirmano koreliacijos koeficientas tarp Ripple ir likusių kriptovaliutų

Iš šio grafiko galime pastebėti taip pat, kad koreliacijos koeficientai tarp 9 iš 10 kriptovaliutų per pandemijos pradžią išaugo iki 0,8 ir didesnių verčių. Panašų rezultatą gavome ir 16 paveiksle. Įdomu pastebėti ir tai, kad Ripple žetono ir kitų kriptovaliutų tarpusavio ryšis 2021 metų pradžioje staigiai krito. Tai galima paaiškinti JAV vertybinių popierių ir biržos komisijos iškeltai bylai prieš šią kriptovaliutą ir jos kūrėjus. Rinka sureagavo stipriai ir šio žetono vertė per nedidelį laiko tarpą nukrito ženkliai, kai tuo metu bendrai kriptovaliutų rinkoje vyko kainų augimas.

Kadangi iš 13 ir 14 paveikslo matome Filecoin skirtingą elgesį nuo kitų žetonų, šiam žetonui sudaromas slenkančios koreliacijos grafikas taip pat.




15 pav. Slenkantis Spirmano koreliacijos koeficientas tarp Filecoin ir likusių kriptovaliutų

Iš grafiko galima pastebėti, kad Filecoin su kitais žetonais skirtingais laikotarpiais išlaiko ganėtinai panašų koreliacinį ryšį. Laikotarpio pabaigoje galima pastebėti, kad visų pasirinktų kriptovaliutų priklausomybės pasiekė aukštą lygį. Atkreiptinas dėmesys, kad 2022 metų pabaigoje galime įžvelgti staigų tiesinio ryšio sumažėjimą. Tai galima būtų paaiškinti kriptovaliutų rinką sukrėtusiu įvykiu – FTX kriptovaliutų keityklos bankrotu, kuria sukėlė FTX žetono likvidumo krizė.

Apibendrinant kriptovaliutų koreliacinę analizę galime teigti, kad tarp pasirinktų kriptovaliutų yra ganėtinai stipri tarpusavio priklausomybė, netiesinės priklausomybės nėra reikšmingos, o per COVID-19 pandemijos pradžią pastebėtas ženkliai sustiprėjęs tarpusavio ryšys tarp 9 iš 10 kriptovaliutų. Filecoin išsiskiria maža koreliacijos koeficiento verte ir savo elgesiu per vertinamąjį laikotarpį. Iš šių rezultatų galima investuotojams pasiūlyti rinktis įvairesnių paskirčių kriptovaliutų siekiant diversifikuoti savo investicinį portfelį.

3.4. Minimaliai besidriekiančio medžio metodo pritaikymo rezultatai

Siekiant vaizdžiau atvaizduoti kriptovaliutų tarpusavio ryšių stiprumus buvo pasirinktas minimaliai besidriekiančio medžio (MST) metodas. Šiam metodui yra reikalingos koreliacinės matricos, kurios gaunamos iš atsitiktinių matricų teorijos (RMT). Kad išfiltruoti koreliacinę matricą, buvo pasirinktas duomenų rinkinys su 10 kriptovaliutų logaritminių grąžų vertėmis padalintomis į persidengiančius „langus“, kurių dydis yra 120 dienų ir jie yra pastumiami kas 7 dienas. Taip buvo gauti 255 keturių mėnesių duomenų rinkinukai. Kiekvienas duomenų rinkinukas buvo padalintas į 113 dienų įvertinimo ir 7 dienų patvirtinimo imtis. Apibendrinant buvo sudarytos 255 koreliacijų matricos tarp 10 kriptovaliutų. Šios matricos buvo išfiltruotos naudojant RMT metodą ir pritaikytos MST metodui. Tokiu būdu galime sudaryti medžio grafiką kiekviename iš 255 duomenų rinkinukų ir pažiūrėti kurios kriptovaliutos buvo dominuojančios ir turinčios daugiausiai ryšių su kitais žetonais. Apačioje pateikiami 4 grafikai skirtingais laikotarpiais.




16 pav. MST metodu gauti medžiai 4 skirtingais laikotarpiais

Iš grafikų galime pastebėti, kad duomenų rinkinio pirmaisiais 4 mėnesiais susidarė 2 klasteriai, kurių branduoliai buvo Bitcoin ir Ethereum, tai galima nesunkiai paaiškinti, nes tuo metu tai buvo dominuojančios ir didelę rinkos dalį užimančios valiutos. Sekantis grafikas vaizduoja laikotarpį, kai aktyviai prasidėjo COVID-19 pandemija. Įdomu, tai kad susidarė vienas klasteris su pagrindine dominuojančia kriptovaliuta – Ethereum. Kitas grafikas atvaizduoja 2021 metų pradžios kriptovaliutų kilimo bumą, įdomu tai, kad šiuo laikotarpiu susidarė net 3 klasteriai, kurių branduolius sudarė Bitcoin Cash, Litecoin, Ethereum. Paskutinis grafikas atvaizduoja periodą, apimančią Ukrainoje prasidėjusio karo pradžią. Šiuo laikotarpiu galime pastebėti, kad susidarė 2

klasteriai iš Litecoin ir Ethereum. Iš šių grafikų galime pastebėti, kad kriptovaliutų tarpusavio priklausomybės laikui bėgant kinta, tačiau Ethereum žetonas visose laikotarpuose pasirodė kaip daugiausia ryšių turinti kriptovaliuta.

Toliau sudaromas grafikas kuriame atvaizduojamas dvi metrikos: maksimalaus ryšio, kuris parodo maksimalų atstumą tarp 2 susikirtimo taškų ir liekanų koeficiento, kuris parodo santykį tarp ryšių, kurie buvo atmesti ir palikti MST metodo.



17 pav. Maksimalaus ryšio ir liekanų koeficiento kitimas laike

Iš grafiko matome, kad maksimalaus ryšio koeficientas 2018 metų viduryje ir nuo 2019 metų iki 2021 metų pradžios yra ganėtinai aukštame lygyje. Tai parodo, kad koreliacijos tarp kriptovaliutų gražų elgėsi ganėtinai skirtingai. Tačiau matome, kad nuo 2021 metų vidurio šio koeficiento vertės nukrito, kas parodo kad kriptovaliutų gražos pradėjo labiau koreliuoti. Vertinant liekanų koeficientą, galima pastebėti, kad laikotarpio pradžioje iki 2021 metų vidurio jis laikėsi ganėtinai stabiliai, tačiau po 2021 metų vidurio matome staigų augimą trumpu periodu, tai parodo, kad tarp kriptovaliutų atsirado daugiau sąsajų, kas įtakoja ir padidėjusi sinchroniškumą tarp kriptovaliutų gražų.

3.5. Duomenų stacionarumo, IRF ir Grangerio priežastingumo testo rezultatai

Norint pritaikyti Grangerio priežastingumo analizę duomenims, laiko eilutės turi būti stacionarios. Logaritminių gražų patikrai buvo pasirinktas išplėstas Dikio Fulerio testas (ADF). Testo rezultatai pateikti 4 lentelėje.

4 lentelė. ADF testo rezultatai

	Bitcoin	Ethereum	Litecoin	Binance coin	Bitcoin cash	Cardano	Ripple	Dogecoin	Chainlink	Filecoin
ADF testo p vertės	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01

Iš gautų rezultatų matome, kad visoms kriptovaliutoms testo p vertės yra mažesnės negu 0,01, dėl ko galime teigti, kad su 95% pasiklovimo lygmeniu galime atmesti nuline šio testo hipotezę, kad

laiko eilutės turi vienetinę šaknį ir yra nestacionarios. Gavome, kad kriptovaliutų dieninės logaritminės grąžų eilutės yra stacionarios ir gali būti naudojamos IRF ir Grangerio analizei.

Toliau tiriant duomenis buvo panaudoti atsako fukcijų impulsų (IRF), FEVD ir priežastingumo ryšių nustatymo metodai. Siekiant įvertinti skirtingus laikotarpius, duomenys buvo padalinti į 3 dalis: iki COVID-19 pandemijos (nuo 2017-12-14 iki 2020-03-01), po pandeminį laikotarpį (nuo 2020-03-01 iki 2023-03-01) ir visai duomenų imčiai.


Apačioje pateiktame paveiksle galime pamatyti gautus prieš pandeminius IRF rezultatus, kurie parodo egzistuojančius ryšius tarp kriptovaliutų. Šis paveikslas parodo, kaip sureaguotų kriptovaliutų poros įvykus staigiam kainų pokyčiui, t.y. parodo kuris žetonas daro įtaką kuriam žetonui.

Bitcoin	-	Ethereum	Ethereum	>	Litecoin	Litecoin	<	Binance Coin	Binance Coin	-	Bitcoin Cash	Bitcoin Cash	>	Cardano
Bitcoin	>	Litecoin	Ethereum	<	Binance Coin	Litecoin	-	Bitcoin Cash	Binance Coin	<	Cardano	Bitcoin Cash	<	Ripple
Bitcoin	<	Binance Coin	Ethereum	-	Bitcoin Cash	Litecoin	-	Cardano	Binance Coin	<	Ripple	Bitcoin Cash	>	Dogecoin
Bitcoin	>	Bitcoin Cash	Ethereum	>	Cardano	Litecoin	>	Ripple	Binance Coin	<	Dogecoin	Bitcoin Cash	<	Chainlink
Bitcoin	-	Cardano	Ethereum	<	Ripple	Litecoin	<	Dogecoin	Binance Coin	<	Chainlink	Bitcoin Cash	>	Filecoin
Bitcoin	<	Ripple	Ethereum	<	Dogecoin	Litecoin	<	Chainlink	Binance Coin	>	Filecoin	Bitcoin Cash	-	Binance Coin
Bitcoin	<	Dogecoin	Ethereum	<	Chainlink	Litecoin	>	Filecoin	Binance Coin	<	Litecoin	Bitcoin Cash	-	Litecoin
Bitcoin	-	Chainlink	Ethereum	>	Filecoin	Litecoin	<	Ethereum	Binance Coin	<	Ethereum	Bitcoin Cash	-	Ethereum
Bitcoin	>	Filecoin	Ethereum	-	Bitcoin	Litecoin	<	Bitcoin	Binance Coin	<	Bitcoin	Bitcoin Cash	<	Bitcoin
Cardano	<	Ripple	Ripple	<	Dogecoin	Dogecoin	>	Chainlink	Chainlink	>	Filecoin	Filecoin	<	Bitcoin
Cardano	<	Dogecoin	Ripple	>	Chainlink	Dogecoin	>	Filecoin	Chainlink	<	Dogecoin	Filecoin	<	Ethereum
Cardano	>	Chainlink	Ripple	>	Filecoin	Dogecoin	<	Ripple	Chainlink	<	Ripple	Filecoin	<	Litecoin
Cardano	>	Filecoin	Ripple	<	Cardano	Dogecoin	<	Cardano	Chainlink	<	Cardano	Filecoin	<	Binance Coin
Cardano	<	Bitcoin Cash	Ripple	>	Bitcoin Cash	Dogecoin	<	Bitcoin Cash	Chainlink	<	Bitcoin Cash	Filecoin	<	Bitcoin Cash
Cardano	<	Binance Coin	Ripple	>	Binance Coin	Dogecoin	>	Binance Coin	Chainlink	>	Binance Coin	Filecoin	<	Cardano
Cardano	-	Litecoin	Ripple	<	Litecoin	Dogecoin	<	Litecoin	Chainlink	<	Litecoin	Filecoin	<	Ripple
Cardano	<	Ethereum	Ripple	<	Ethereum	Dogecoin	<	Ethereum	Chainlink	>	Ethereum	Filecoin	<	Dogecoin
Cardano	-	Bitcoin	Ripple	<	Bitcoin	Dogecoin	<	Bitcoin	Chainlink	-	Bitcoin	Filecoin	<	Chainlink

18 pav. IRF impulsų rezultatai prieš pandeminiame laikotarpyje

Iš 18 paveikslo galime pastebėti, kad ryšių tarp kriptovaliutų yra daug, tačiau didžioji dalis ryšių yra vienus pusius. Atkreiptinas dėmesys, kad Bitcoin nėra veikiamas vienus pusiuskai nei vienos kitos kriptovaliutos. Taip pat, įdomu tai, kad Filecoin yra veikiamas vienus pusiuskai visų kitų kriptovaliutų ir neveikia jokios kriptovaliutos pats.


Nors ir matome, kad ryšių tarp žetonų yra labai daug, tačiau pamėginkime grafiškai atrinkti stipriausius signalus siuntusius bei stipriausią įtaką dariusias kriptovaliutas. Apačioje pateiktas keletas atvaizduotų IRF grafikų.



19 pav. Stipriausi Bitcoin ir Ethereum IRF impulsai prieš pandeminį laikotarpį


Iš grafiko galime teigti, kad su 90 proc. pasiklovimo lygmeniu, Ethereum logaritminei grāžai padidėjus 1 proc., per pirmas dvi diena tai turės neigiamos įtakos Litecoin. Taip pat galime teigti, kad su 90 proc. pasiklovimo lygmeniu, Bitcoin logaritminei grāžai padidėjus 1 proc., 3 diena Binance Coin padidės apie 0,5 proc.

Papildomai atliekama FEVD (angl. *forecast error variance decomposition*) analizė, iš kurios galime pasakyti, kad vertinant Litecoin ir Binance coin prognozuojamą paklaidos dispersiją ateityje apie 70 proc. ir 40 proc. pokyčio būtų galima paaikškinti remiantis atitinkamai Ethereum ir Bitcoin duomenimis. Kas parodo šių kriptovaliutų didelę įtaką.



20 pav. FEVD įtaka Litecoin ir Binance coin žetonams

Pritaikius Grangerio priežastingumo testo analizę kriptovaliutų duomenis prieš pandeminiam laikotarpiui, parodė teigiamą arba neigiamą žetonų įtaką. Pagal išdėstymą galime matyti, kad visos kriptovaliutos yra glaudžiai susijusios ir sunku aiškiai išvelgti kiekvieną ryšį, tačiau svarbiausi būtų tokie pastebėjimai: Filecoin gauna iš visų kitų kriptovaliutų tik teigiamą ryšį, Bitcoin ir Ethereum siunčia neigiamą signalą praktiškai toms pačios kriptovaliutoms, t.y. Binance Coin, Ripple, Dogecoin, Litecoin. Chainlink siunčia ir gauna tik teigiamus signalus.



21 pav. Prieš pandeminiis kriptovaliutų Grangerio priežastingumo testo grafikas

Įvertinti po pandeminiu laikotarpiu vyraujančius tarpusavio ryšius tarp kriptovaliutų atliekami analogiški skaičiavimai ir analizės kaip prieš pandemini laikotarpį.


Apačioje pateiktame paveiksle galime pamatyti gautus po pandeminius IRF rezultatus.

Bitcoin < Ethereum	Ethereum - Litecoin	Litecoin > Binance Coin	Binance Coin < Bitcoin Cash	Bitcoin Cash > Cardano
Bitcoin - Litecoin	Ethereum > Binance Coin	Litecoin < Bitcoin Cash	Binance Coin < Cardano	Bitcoin Cash < Ripple
Bitcoin < Binance Coin	Ethereum < Bitcoin Cash	Litecoin > Cardano	Binance Coin < Ripple	Bitcoin Cash < Dogecoin
Bitcoin > Bitcoin Cash	Ethereum < Cardano	Litecoin < Ripple	Binance Coin < Dogecoin	Bitcoin Cash > Chainlink
Bitcoin > Cardano	Ethereum < Ripple	Litecoin > Dogecoin	Binance Coin < Chainlink	Bitcoin Cash > Filecoin
Bitcoin < Ripple	Ethereum < Dogecoin	Litecoin < Chainlink	Binance Coin > Filecoin	Bitcoin Cash < Binance Coin
Bitcoin < Dogecoin	Ethereum < Chainlink	Litecoin > Filecoin	Binance Coin < Litecoin	Bitcoin Cash < Litecoin
Bitcoin < Chainlink	Ethereum > Filecoin	Litecoin - Ethereum	Binance Coin < Ethereum	Bitcoin Cash < Ethereum
Bitcoin > Filecoin	Ethereum < Bitcoin	Litecoin - Bitcoin	Binance Coin > Bitcoin	Bitcoin Cash < Bitcoin
Cardano > Ripple	Ripple < Dogecoin	Dogecoin < Chainlink	Chainlink > Filecoin	Filecoin < Bitcoin
Cardano < Dogecoin	Ripple < Chainlink	Dogecoin < Filecoin	Chainlink > Dogecoin	Filecoin < Ethereum
Cardano < Chainlink	Ripple - Filecoin	Dogecoin < Ripple	Chainlink > Ripple	Filecoin < Litecoin
Cardano > Filecoin	Ripple < Cardano	Dogecoin < Cardano	Chainlink > Cardano	Filecoin < Binance Coin
Cardano < Bitcoin Cash	Ripple < Bitcoin Cash	Dogecoin < Bitcoin Cash	Chainlink < Bitcoin Cash	Filecoin < Bitcoin Cash
Cardano < Binance Coin	Ripple < Binance Coin	Dogecoin < Binance Coin	Chainlink < Binance Coin	Filecoin < Cardano
Cardano < Litecoin	Ripple < Litecoin	Dogecoin < Litecoin	Chainlink > Litecoin	Filecoin - Ripple
Cardano < Ethereum	Ripple < Ethereum	Dogecoin > Ethereum	Chainlink > Ethereum	Filecoin > Dogecoin
Cardano < Bitcoin	Ripple > Bitcoin	Dogecoin > Bitcoin	Chainlink > Bitcoin	Filecoin < Chainlink

22 pav. IRF impulsų rezultatai po pandeminio laikotarpio


Iš 22 paveikslo galime pastebėti, kad padaugėjo dvipusių tarpusavio ryšių ir pasikeitė lyderių pozicijos bei, kad Bitcoin tapo veikiamas kitų kriptovaliutų. Taip pat matome, kad Chainlink tapo duominuojanti kriptovaliuta, kuri daro įtaką beveik visoms kitoms tyrime naudotoms kriptovaliutoms. Filecoin liko stipriai įtakojamas kitų žetonų. Pastebėtina, kad Bitcoin cash neturi vienos įtakos iš kito žetono.

Taip pat nupiešiami IRF grafikai, kurie atvaizduoti 26 paveiksle. Iš šių grafikų galime teigti, kad su 90 proc. pasiklovimo lygmeniu, Bitcoin logaritminei grąžai padidėjus 1 proc., 7 dieną Filecoin sumažės apie 1 proc. Taip pat galime teigti, kad su 90 proc. pasiklovimo lygmeniu, Ethereum logaritminei grąžai padidėjus 1 proc., 6 dieną Filecoin sumažės apie 1 proc.



23 pav. Stipriausi Bitcoin ir Ethereum IRF impulsai po pandeminio laikotarpio


Atlikus FEVD analizę kitam laikotarpiui, buvo gauti grafikai, iš kurių galime pasakyti, kad vertinant Filecoin ir Binance coin prognozuojamą paklaidos dispersiją ateityje apie 20 proc. ir 60 proc. pokyčio būtų galima paaiškinti remiantis atitinkamai Bitcoin ir Ethereum duomenimis. Kas parodo sumažėjusią Bitcoin, tačiau išlikusia Ethereum didelę įtaką.



24 pav. FEVD įtaka Filecoin ir Binance Coin žetonams

Turint atsako impulso analizės rezultatus galima sudaryti kryžminio poveikio (angl. *cross-impact*) matricą. Iš šios matricos galime nupiešti grafiką, kuriame būtų suskirstytos grafiko dalys į keturias veiksmų grupes ir kiekviena kriptovaliuta būtų patalpinta į jai būdingo elgesio dalį. Šias veiksmų grupes galima apibūdinti taip:

- 26 paveiksle galime pamatyti šios grafikus ir kaip keitėsi kriptovaliutų pozicijos skirtingais laikotarpiais, kairėje pateiktas grafikas yra laikotarpiui iki COVID-19 pandemijos, o dešinėje po.



45

laikotarpiu matome lyderiaujančių kriptovaliutų pasikeitimą, t.y. Bitcoin ir Ethereum savo pozicijas užleido Chainlink ir Litecoin. Nors Ethereum ir išliko tarp stiprių ir aktyvių veiksmų ribos, tačiau Bitcoin matome sumažėjusia įtaką. Atkreiptinas dėmesys, kad abejais periodais Filecoin išliko prie pasyvių veiksmų dalies. Tokį lyderiaujančių žetonų pokytį vien COVID-19 pandemijai nereikėtų priskirti. Papildomai prie to prisidėjo ir su Bitcoin efektyvumu keliama klausimai, rinkos kapitalizacijos struktūros pokytis, didėjantis susidomėjimas kitomis, ne vien senosiomis kriptovaliutomis.

Papildomai atlikus visos duomenų imties IRF ir Grangerio priežastingumo testą gavome rezultatus panašius į prieš COVID-19 pandemijos pradžios laikotarpį. Išanalizavus ryšius galime pastebėti, kad tarpusavio ryšių yra įvairių ir dvipusių, tik Chainlink nėra įtakojamas ir nedaro įtakos Bitcoin ir Ethereum. Vertinant kryžminio poveikio matricą visam laikotarpiui, galima pastebėti, kad aktyvios kriptovaliutos yra Bitcoin Cash, Ethereum bei Litecoin. Įtakojamos kriptovaliutos išliko Filecoin, Cardano ir Dogecoin. Rezultatai pateikti 1 Priede.

3.6. Kintamumo plitimo analizės rezultatai

Kitas įdomus būdas patikrinti kaip tarpusavyje elgiasi kriptovaliutos skirtingu laiko momentu yra kintamumo plitimo analizė (angl. *volatility spillover*). Šis metodas yra įprastai taikomas vertinti kaip vienos turto klasės padidėjusi dispersija persiduoda kitai turto klasei. Šiame darbe buvo nagrinėjama, kaip vienos kriptovaliutos padidėjusi dispersija persiduoda kitai bei kaip bendras kintamumo plitimo indeksas kinta laike. Pritaikius vektorinį autoregresijos modelį normalizuotiems duomenis pagal 26 formulę ir apskaičiavus kintamumo koeficientus sudaroma kintamumo plitimo koeficientų lentelė. Ji pateikta 27 paveiksle.

	Bitcoin	Ethereum	Litecoin	Binance.Coin	Bitcoin.cash	Cardano	Ripple	Dogecoin	Chainlink	Filecoin	C. from others
Bitcoin	19.730722	13.613500	12.897176	9.267762	11.805197	9.922911	7.512335	5.520515	7.350038	2.379844	80.26928
Ethereum	12.798386	18.571053	12.857828	8.797328	11.555800	11.071944	8.581916	4.894262	8.631994	2.239488	81.42895
Litecoin	12.362369	13.189567	18.951280	8.605129	12.531487	10.362206	8.670904	5.559808	7.664541	2.102708	81.04872
Binance.Coin	11.635571	11.755670	11.403377	24.832603	9.430529	9.141104	7.750571	4.371470	7.607240	2.071867	75.16740
Bitcoin.cash	12.155595	12.655208	13.471344	7.783781	20.420945	10.037936	8.272681	5.782870	7.287618	2.132022	79.57906
Cardano	10.817002	12.802771	11.733961	7.727495	10.467445	21.428536	9.611913	5.070836	8.254652	2.085389	78.57146
Ripple	9.364826	11.400410	11.361146	7.592645	10.025693	11.183741	24.595402	5.205655	7.478021	1.792462	75.40460
Dogecoin	9.465009	8.938351	9.855103	5.728646	9.425530	7.978069	7.082975	33.453751	6.218036	1.854529	66.54625
Chainlink	9.660182	12.074709	10.557992	7.874229	9.348125	9.894494	7.775747	4.807798	25.750065	2.256659	74.24993
Filecoin	6.454100	6.570659	6.125498	4.681263	5.715401	5.367952	3.967182	2.925228	4.691991	53.500727	46.49927
C. to others (spillover)	94.713039	103.000845	100.263424	68.058279	90.305207	84.960355	69.226226	44.138440	65.184131	18.914969	73.87649
C. to others including own	114.443761	121.571898	119.214704	92.890882	110.726152	106.388891	93.821628	77.592192	90.934196	72.415695	1000.00000

27 pav. Kintamumo plitimo (angl. *volatility spillover*) lentelė

Lentelę galima būtų paaiškinti taip: lentelės ij-asis įrašas yra įvertintas indėlis į i nario prognozės klaidos dispersiją, atsirandanti dėl pasikeitimų j naryje. Paskutiniame stulpelyje pateikiamas atitinkamo nario suminis indėlis į to nario prognozės klaidos dispersiją. Priešpaskutinėje eilutėje pateikiamas atitinkamo nario suminis indėlis į kitų narių prognozės klaidos dispersiją. Santykis tarp paskutinio stulpelio ir paskutinės eilutės sumų yra bendras sistemos kintamumo plitimo indeksas. Šis indeksas parodo kintamumo šokų išplitimo visoje sistemoje indėlį į bendrą prognozės klaidos dispersiją. Interpretuoti rezultatus galima taip, pavyzdžiui: pasikeitimas Bitcoin grąžose yra atsakingas už 12,36 proc. paklaidos dispersijos prognozuojant Litecoin grąžas. Iš lentelės galima pastebėti, kad įtaką paklaidos dispersijai tarp kriptovaliutų yra ganėtinai panaši, o suminės vertės yra ganėtinai didelės. Apskaičiavę bendrą kintamumo plitimo indeksą gavome, kad jis siekia net 73,88 proc. Kas parodo, kad vidutiniškai tarp pasirinktų kriptovaliutų net 73,88 proc. kintamumo prognozės paklaida kyla iš kintamumo plitimo. Tai mums parodo, kad kriptovaliutos turi didelę įtaką viena kitai.

Panagrinėkime, kaip bendrasis kintamumo plitimo indeksas keičiasi per vertinamąjį laikotarpį.



28 pav. Kintamumo plitimo (angl. *volatility spillover*) indekso grafikas

Vertinant kintamumo plitimo indeksą vertinamuoju laikotarpiu galime matyti, kaip kinta prognozės dispersijos paklaidos ir kaip persiduoda tai visai sistema. Grafike pažymėti 4 taškai, kuriuose yra matomas staigus kintamumo plitimo indekso augimas. Kiekvieną iš šių taškų galima susisiekti su globaliais įvykiais:

- Taškas nr. 1 – JAV vertybinių popierių ir biržos komisijos neigiamos nuomonės išsakymas apie kriptovaliutas. Bitcoin ir Ethereum nepriskyrimas prie vertybinių popierių.
- Taškas nr. 2 – COVID-19 pandemijos pradžia.
- Taškas nr. 3 – Kinijos centrinis bankas uždraudė visus atsiskaitymus kriptovaliutomis. Kadangi Kinija užėmė didelę dalį Kriptovaliutų kasimo rinkos, tai stipriai atsiliepė visai kriptovaliutų rinkai.
- Taškas nr. 4 – Rusijos pradėtas karas Ukrainoje.

Šie įvykiai paskatino išaugti kintamumui tarp pasirinktų 10 kriptovaliutų.

Apibendrinant matome, kad kriptovaliutos yra veikiamos pasaulinių įvykių, tačiau stipriau yra veikiamos veiksnių susijusių su pačių kriptovaliutų sistema, negu su globaliais įvykiais. Tai parodo savitas savybės, būdingas išskirtinai virtualių valiutų rinkai. Lyginant gautus rezultatus su mokslinėje literatūroje išnagrinėtais tyrimais galima išvelgti rezultatų panašumus. Vertinant koreliacines priklausomybes, buvo gautos aukštos koreliacijos koeficiento vertės tarp kriptovaliutų. COVID-19 laikotarpiu pastebėta dar labiau sustiprėjęs tiesinis ryšys, kas sutampa su Stosic ir kt. (2018), Chaudhari ir kt. (2020) tyrimu rezultatais, kurie teigia apie kriptovaliutų kolektyvinę elgesį. Vertinant minimalių medžių rezultatus, pastebėta, kad kriptovaliutos skirtingais laikotarpiais pasižymi skirtingais dominuojančiais žetonais, kas parodo dar jauną ir kintančią šios turto klasės pobūdį. Panašūs rezultatai buvo gauti ir nagrinėtuose Gavin ir kt. (2021), Kim ir kt. (2021) tyrimuose. Išanalizavus kriptovaliutų tarpusavio priklausomybes prieš ir po COVID-19 pandemijos matome, kad dominuojančių ir darančių įtaką kriptovaliutų pozicijos keičiasi. Matome stiprėjantį Ethereum žetono poziciją ir silpnėjantį Bitcoin. Šie rezultatai taip pat sutampa su Mnif ir kt. (2020) tyrimo rezultatais. Siekiant sudaryti investicinius portfelius investuotojams reikėtų atkreipti dėmesį, kad tam tikros kriptovaliutos nors ir gali būti naudojamos mažinant portfelio riziką kriziniais periodais, tačiau šiai turto klasei yra būdingas didelis kintamumas ir yra stipriai veikiamos vidinių šios rinkos krizių, dėl ko galima patirti daugiau žalos negu naudos.

Išvados

1. Mokslinės literatūros analizė parodė, kad tyrėjai aktyviai ieško sąsajų tarp egzistuojančių turto klasių ir priklausomybių pačioje kriptovaliutų struktūroje. Dažnu atveju tyrėjai pasitelkia atsitiktinių matricų teoriją su minimalių medžių metodu analizuoti kriptovaliutų koreliacines matricas. Ši analizė parodo būdingas tiesines priklausomybes tarp pačių kriptovaliutų. Siekiant suprasti ryšių kryptingumą ir stiprumą, tyrėjai pritaiko impulsų atsako bei Grangerio priežastimo testus. Skirtingo dažnio duomenys ir skirtingiems laikotarpiams pritaikyti šie metodai padeda dar geriau suprasti tiesines ir kryptines priklausomybes. Tokie tyrimai padeda geriau suprasti rinkos struktūrą ir sudaro galimybes diversifikuoti investicinius portfelius.
2. Sudarant tyrimo metodiką buvo pasiremta analogiškų tyrimų metodikomis bei jų kombinacijomis. Buvo sudaryta metodika, siekiant atlikti duomenų aprašomąją analizę, stilizuotų faktų patikrą, korelacių analizę, ją papildant atsitiktinių matricų teorija ir minimalių medžių metodu, impulso atsako su Grangerio priežastingumo testu bei kintamumo plitimo apžvalga. Šie metodai pritaikyti skirtingais laikotarpiais parodė kriptovaliutų rinkos struktūros dinamiką kriziniais periodais.
3. Duomenų rinkinio konvertavimas į logaritmines grąžas ir šių grąžų analizė parodė, kad kriptovaliutų grąžų vidurkis yra artimas nuliui, duomenys pasižymi asimetrija ir ekscesas yra net kelis kartus didesnis lyginant su normaliuoju skirstiniu. Kriptovaliutų grąžos neatitinka normaliojo skirstinio bei būdingos sunkios uodegos. Taip pat, šiuose duomenyse galime išvelgti kintamumo klasterius, kurie 9 iš 10 kriptovaliutų susidaro panašiu laikotarpiu. Autokoreliacijos testo rezultatai parodė, kad 5 iš 10 kriptovaliutų pasižymi autokoreliacinėmis savybėmis.
4. Atliktos tiesinės ir netiesinės koreliacijos analizės parodė, kad rezultatai yra labai panašūs, kas parodo dominuojantį tiesinį ryšį. Atlikus Spirmano koreliacijos koeficiento skaičiavimus gavome, kad galime išskirti 3 kriptovaliutų klasterius, kurioms būdingas silpnas, vidutinis ir stiprus tiesinis ryšys. Aukštais Spirmano koreliacijos koeficientais pasižymėjo Bitcoin, Bitcoin cash, Ethereum ir Litecoin, kai patį silpniausią koreliacinį ryšį su kitomis pasirinktomis kriptovaliutomis parodė Filecoin. Slenkančios Spirmano koreliacijos koeficiento analizė parodė, kad 9 iš 10 kriptovaliutų tiesiniai ryšiai stipriai sustiprėjo ir susitelkė ties 0,80 – 0,85 vertė ties COVID-19 pandemijos pradžios laikotarpiu. Tai mums parodo, kad kriptovaliutomis, kaip ir akcijų biržai, yra būdingas „bandos“ elgesys kriziniu laikotarpiu. Filecoin parodė išskirtinį elgesį ir net neigiamą koreliacijos koeficientą pandemijos pradžioje. Minimalių medžių metodas parodė kintančią rinkos struktūrą su besikeičiančiais rinkos lyderiais, tačiau didžiąją dalimi Ethereum išliko centrine figūra. Taip pat, šis metodas parodė, kad laikotarpio pabaigoje kriptovaliutų grąžos ėmė stipriau koreliuoti.
5. Pritaikius impulso atsako ir Grangerio priežastingumo testą prieš ir po COVID-19 pandemijos pastebėta, kad rinkos lyderiai ir įtakos kryptys pasikeitė. Prieš COVID-19 pandemiją matome didelę neigiamą ir teigiamą įtaką senųjų kriptovaliutų, tokių kaip Bitcoin ir Ethereum. Po pandeminiame laikotarpyje matome pasikeitusias lyderių pozicijas, kurias užėmė Ethereum ir Chainlink. Įdomu tai, kad Bitcoin tapo labiau įtakojamas kitų kriptovaliutų negu pats darytų įtaką kitiems. Tai galima paaiškinti mažu Bitcoin efektyvumu ir didėjančiu investuotojų susidomėjimu naujomis, universalesnėmis ir efektyvesnėmis kriptovaliutomis.
6. Atlikus kintamumo plitimo analizę galima pastebėti, kad įvairiais kriziniais laikotarpiais kintamumo perdavimas tiek visai sistemai, tiek kitoms kriptovaliutomis padidėja. Galima pastebėti ženklius kintamumo plitimo indekso padidėjimus šiais laikotarpiais: 2018 metų viduryje JAV vertybinių popierių ir biržos neigiamos nuomonės išsakymo apie kriptovaliutas

viešojoje erdvėje, COVID-19 pandemijos pradžioje, Kinijos kriptovaliutų uždraudimo 2021 metų laikotarpyje bei labai neženklų padidėjimą Rusijos ir Ukrainos karo pradžioje. Tai mums parodo, kad kriptovaliutų sistemai ir jų kainos dinamikai turi didelę įtaką įvykiai susiję su pačia kriptovaliutų sistema bei turėjo didelę įtaką COVID-19 pandemija. Tačiau taip pat galime pamatyti, kad karas Ukrainoje nors ir atsiliepė akcijų rinkai, tačiau mažai paveikė kriptovaliutų rinką.

Literatūros sąrašas


1. Abu Hanifa Md Noman, Muhammad Mahmudul Karim, Mohammad Kabir Hassan, Muhammad Asif Khan, Sajeda Pervin (2023). COVID-19 pandemic and the dynamics of major investable assets: What gives shelter to investors? *International Review of Economics & Finance*, 86, 14-30. <https://doi.org/10.1016/j.iref.2023.03.003>
2. Alessandro Spelta, Tanya Araújo (2012). The topology of cross-border exposures: Beyond the minimal spanning tree approach. *Physica A: Statistical Mechanics and its Applications* 391(22), 5572-5583. <https://doi.org/10.1016/j.physa.2012.05.071>.
3. Ata Assaf, Khaled Mokni, Manel Youssef (2023). COVID-19 and information flow between cryptocurrencies, and conventional financial assets. *The Quarterly Review of Economics and Finance* 89, 73-81. <https://doi.org/10.1016/j.qref.2023.02.010>.
4. Barcilar, M., Bouri, E., Gupta, R. & Roubaud, D. (2017). Can volume predict Bitcoin return and volatility? A quantiles-based approach. *Economic Modelling*, 64, 74-81. <http://dx.doi.org/10.1016/j.econmod.2017.03.019>
5. Bence Tóth, János Kertész (2007). On the origin of the Epps effect. *Physica A: Statistical Mechanics and its Applications*, 383(1), 54-58. <https://doi.org/10.1016/j.physa.2007.04.111>.
6. Briola A, Aste T (2022). Dependency Structures in Cryptocurrency Market from High to Low Frequency. *Entropy*, 24(11):1548. <https://doi.org/10.3390/e24111548>
7. Chaum, D. (1983). Blind Signatures for Untraceable Payments. *Springer Science*, 199-203. https://doi.org/10.1007/978-1-4757-0602-4_18
8. Chaum, D. (1992). Achieving Electronic Privacy. *Scientific American*, 267, 96-101. <http://dx.doi.org/10.1038/scientificamerican0892-96>
9. Darko Stosic, Dusan Stosic, Teresa B. Ludermit, Tatijana Stosic (2018). Collective behavior of cryptocurrency price changes. *Physica A: Statistical Mechanics and its Applications*, 507, 499-509. <https://doi.org/10.1016/j.physa.2018.05.050>.
10. Dimitar Kitanovski, Miroslav Mirchev, Ivan Chorbev, and Igor Mishkovski (2022). Cryptocurrency Portfolio Diversification Using Network Community Detection. 30th Telecommunications Forum (TELFOR), 1-4. doi: 10.1109/TELFOR56187.2022.9983742
11. Francis X. Diebold, Kamil Yilmaz (2009). Measuring Financial Asset Return and Volatility Spillovers, with Application to Global Equity Markets. *The Economic Journal* 119(534), 158-171. <https://doi.org/10.1111/j.1468-0297.2008.02208.x>
12. Francis X. Diebold, Kamil Yilmaz (2012). Better to give than to receive: Predictive directional measurement of volatility spillovers. *International Journal of Forecasting* 28(1), 57-66. <https://doi.org/10.1016/j.ijforecast.2011.02.006>.
13. Handbook of Digital Currency. David LEE Kuo Chuen. Academic press, (2015). <https://doi.org/10.1016/C2014-0-01905-3>
14. Harshal Chaudhari, Martin Crane (2020). Cross-correlation dynamics and community structures of cryptocurrencies. *Journal of Computational Science*, 44, 101130. <https://doi.org/10.1016/j.jocs.2020.101130>.
15. Hasan, Mudassar, Ahmad, Muhammad, Naeem, Muhammad Abubakr, Naseem, Muhammad, Rehman, Ramiz. (2019). Examining the Spillover Effect between the KSE100 and the S&P500 Indexes*. *Universidad & Empresa*. 21. 175-195. [10.12804/revistas.urosario.edu.co/empresa/a.6472](https://doi.org/10.12804/revistas.urosario.edu.co/empresa/a.6472).

16. Yukun Liu, Aleh Tsyvinski (2020). Risks and Returns of Cryptocurrency. *The Review of Financial Studies*, 34(6), 2689-2727. <https://doi.org/10.1093/rfs/hhaa113>
17. J.P. Onnela, A. Chakraborti, K. Kaski, J. Kertesz, A. Kanto (2003). Dynamics of market correlations: Taxonomy and portfolio analysis. *Physical Review E*, 65(5), 1-13. <https://doi.org/10.48550/arXiv.cond-mat/0302546>
18. Jenna Gavin, Martin Crane (2021). Community Detection in Cryptocurrencies with Potential Applications to Portfolio Diversification. Preprint, 1-14. Prieiga per internetą: <https://arxiv.org/pdf/2108.09763.pdf>
19. Josef Kurka (2019). Do cryptocurrencies and traditional asset classes influence each other? *Finance Research Letters*, 31, 38-46. <https://doi.org/10.1016/j.frl.2019.04.018>.
20. Kin-Hon Ho, Wai-Han Chiu, Chin Li (2020). A Network Analysis of the Cryptocurrency Market. 2020 IEEE Symposium Series on Computational Intelligence (SSCI), 2178-2185. doi: 10.1109/SSCI47803.2020.9308282.
21. M. E. J. Newman (2016). Community detection in networks: Modularity optimization and maximum likelihood are equivalent. *Phys. Rev. E* 94, 052315, 1-8. <https://doi.org/10.48550/arXiv.1606.02319>
22. Md Akhtaruzzaman, Sabri Boubaker, Ahmet Sensoy (2021). Financial contagion during COVID-19 crisis. *Finance Research Letters*, 38, 1-20. <https://doi.org/10.1016/j.frl.2020.101604>
23. Md Akhtaruzzaman, Sabri Boubaker, Duc Khuong Nguyen, Molla Ramizur Rahman (2022). Systemic risk-sharing framework of cryptocurrencies in the COVID-19 crisis. *Finance Research Letters* 47(B), 1-6. <https://doi.org/10.1016/j.frl.2022.102787>
24. Myeong Jun Kim, Nguyen Phuc Canh, Sung Y. Park (2021). Causal relationship among cryptocurrencies: A conditional quantile approach. *Finance Research Letters*, 42, 1-8. <https://doi.org/10.1016/j.frl.2020.101879>
25. Mouna Youssef, Sami Sobhi Waked (2022). Herding behavior in the cryptocurrency market during COVID-19 pandemic: The role of media coverage. *The North American Journal of Economics and Finance*, 62, 1-10. <https://doi.org/10.1016/j.najef.2022.101752>
26. Muhammad Umar, Fakhar Shahzad, Irfan Ullah, Tong Fanghua (2023). A comparative analysis of cryptocurrency returns and economic policy uncertainty pre- and post-Covid-19. *Research in International Business and Finance* 65, 1-17. <https://doi.org/10.1016/j.ribaf.2023.101965>
27. Paolo Giudici, Paolo Pagnottoni, Gloria Polinesi (2020). Network models to enhance automated cryptocurrency portfolio management. *Artificial Intelligence in Finance* 3, 1-30. <https://doi.org/10.3389/frai.2020.00022>
28. Phillip Bonacich (2007). Some unique properties of eigenvector centrality. *Social Networks* 29(4), 555-564. <https://doi.org/10.1016/j.socnet.2007.04.002>
29. Preston Miller (2016). Digital Forensics, Chapter 1 – The cryptocurrency enigma. Syngress, 1-25. <https://doi.org/10.1016/B978-0-12-804526-8.00001-0>.
30. Rama Cont (2001). Empirical properties of asset returns: stylized facts and statistical issues. *Quantitative Finance*, 1, 223-236. <https://doi.org/10.1080/713665670>
31. Satoshi Nakamoto (2008). Bitcoin: A Peer-to-Peer Electronic Cash System. 1-9. Prieiga per internetą: <https://bitcoin.org/bitcoin.pdf>
32. Shangrong Jiang, Xuerong Li, Shouyang Wang (2021). Exploring evolution trends in cryptocurrency study: From underlying technology to economic applications. *Finance Research Letters*, 38, 1-8. <https://doi.org/10.1016/j.frl.2020.101532>

33. Vincent D. Blondel, Jean-Loup Guillaume, Renaud Lambiotte, Etienne Lefebvre (2008). Fast unfolding of communities in large networks. *Journal of Statistical Mechanics Theory and Experiment* 2008(10), 1-12. <https://doi.org/10.48550/arXiv.0803.0476>
34. Wei Zhanga, Pengfei Wanga, Xiao Li and Dehua Shen (2018). Some stylized facts of the cryptocurrency market. *Applied economics*, 50(50), 5950-5965. <https://doi.org/10.1080/00036846.2018.1488076>
35. Wen Long, Maohua Wang, Man Guo (2022). The asset allocation utility of digital cryptocurrency. *Procedia Computer Science*, 214, 1174-1181. <https://doi.org/10.1016/j.procs.2022.11.293>.
36. Zaer Qaroush, Shadi Zakarneh, Ammar Dawabsheh (2022). Cryptocurrencies Advantages and Disadvantages: A Review. *International Journal of Applied Sciences and Smart Technologies*, 4(1), 1-20. DOI:10.24071/ijasst.v4i1.4610

Priedai

1 priedas. Viso laikotarpio kriptovaliutų Grangerio priežastingumo testo grafikas



2 priedas. Kryžminio poveikio matrica visam laikotarpiui

