

Utilizarea momentelor statistice în selecția portofoliilor de criptomonede. O abordare bazată pe analiza cluster

Stuparu Alexandru Cătălin

Facultatea de Finanțe, Asigurări, Bănci și Burse de Valori,
program de studii universitare de licență, anul III
stuparualexandru18@stud.ase.ro

Coordonatorul lucrării

Prof. univ. dr. Andreea Maria Stoian

1. Introducere

Din momentul în care Bitcoin, prima criptomonedă a fost creată și lansată pe piață, investitorii au văzut în aceasta o bună alternativă de a-și plasa capitalurile, bineînțeles, pentru a obține rentabilități superioare celor deja existente pe piața financiară „tradițională”. Apărută în mijlocul uneia dintre cele mai mari crize financiare la nivel mondial, în anul 2008, această criptomonedă avea rolul de a completa sistemul bancar, nici de cum de a-l înlocui. Se dorea revoluționarea acestui sistem, și așa îngenunchiat de consecințele nefaste ale crizei financiare, așa că investițiile în Bitcoin au devenit rapid foarte populare în rândul investitorilor. Acest lucru a condus rapid și la crearea unor noi criptomonede, multe dintre acestea bazându-se exclusiv pe tehnologia folosită la crearea Bitcoin-ului. Spre deosebire de investițiile în valori mobiliare tradiționale, ce au la bază o „casă de compensare” ce protejează investitorii în cazul falimentului intermediarului, investitorii de criptomonede nu se bucură de astfel de reglementări, de aceea spunem că sistemul de validare a tranzacțiilor este unul descentralizat (A.F. Bariviera, M.J. Basgall, W. Hasperue, M. Naiouf, 2017).

Când vorbim despre criptomonede, vorbim implicit și despre tehnologie. Tehnologia este responsabilă pentru apariția criptomonedelor, și nu numai. Cele mai multe criptomonede au la bază tehnologia numită blockchain. Dar ce presupune această tehnologie? Menționăm pentru început că blockchain-ul nu a condus doar la apariția criptomonedelor, ci este o tehnologie prezentă în multe alte domenii de activitate din economie. Așadar, blockchain-ul este o rețea cibernetică în care sunt înregistrate la nesfârșit toate tranzacțiile efectuate pe această piață a criptomonedelor. Este o tehnologie care oferă transparență, fiecare operator de pe piață având acces la informații în mod simultan, deoarece, fiecare criptomonedă ce are la bază această tehnologie știm exact când a creată, cui a fost vândută, și cine o deține în momentul actual. Nu dorim să intrăm în termeni foarte sofisticăți specifici limbajelor de programare, așa că ne vom limita la o comparație între această rețea cibernetică și sistemul bancar, tocmai pentru a înțelege cu exactitate fenomenul. O mare parte a populației depune banii la bancă, într-un depozit, într-un cont de economii sau în alte asemenea produse oferite de sistemul bancar. În vremurile prezente, această metodă de păstrare a averii pare să nu mai fie așa de atractivă datorită condițiilor economice. Observăm că dobânzile oferite sunt tot mai mici, sau chiar negative în unele țări și că inflația este în creștere. Blockchain-ul are la bază același raționament, de a depozita banii într-un portofel electronic, din care sunt efectuate tranzacțiile personale cu criptomonede. Spre deosebire de sistemul bancar, care percepe comisioane destul de mari pentru faptul că depunem banii la bancă și efectuăm tranzacții din acel depozit, păstrarea banilor în astfel de portofele electronice nu antrenează comisioane atât de mari. Un mare avantaj al blockchain-ului este transparența și siguranța, fiind o rețea puternic criptată, așadar, nu se pot introduce tranzacții noi fără ca participanții ceilalți să afle. Alte criptomonede importante în

termeni de capitalizare bursieră, ce au la bază tehnologia blockchain sunt Ethereum, Litecoin și XRP, dar cu toate acestea, Bitcoin reprezintă peste 80% din întreaga capitalizare a pieței de criptomonede.

Piața criptomonedelor posedă o caracteristică esențială ce o diferențiază de restul piețelor financiare, aceasta fiind volatilitatea foarte mare. Piața criptomonedelor poate crește semnificativ pe parcursul unei perioade scurte de timp, dar poate suferi imediat și un declin substanțial. De aceea, nu de puține ori, auzim investitori de criptomonede spunând „nu investi decât banii pe care ești pregătit să-i pierzi”. Cu toate acestea, criptomonedele au captat intens atenția investitorilor, dornici de a obține profituri rapide pe fondul speculației, proces numit „day trading”. Este esențial de spus că, spre deosebire de prețul altor active financiare tranzacționate pe piețele reglementate, prețul criptomonedelor reacționează foarte rapid la noile informații apărute în piață. Spre exemplu, la data scrierii acestui articol, prețul Bitcoin a fost influențat semnificativ de anunțul CEO-ului Tesla, Elon Musk. Acesta a anunțat că a cumpărat Bitcoin în valoare de 1,5 mld. USD, și că va accepta plata în Bitcoin pentru mașinile ce urmează a fi vândute. Acest anunț a generat un boom pe piața criptomonedelor, prețul Bitcoin-ului depășind chiar valoarea de 58.000 USD, iar rentabilitățile zilnice fiind și de 50%. Similar Bitcoin-ului, și prețul altor criptomonede importante cum ar fi Ethereum și XRP, s-a situat pe același trend ascendent. Vedem cum un singur om poate influența o întreagă piață. Poate suna surprinzător sau chiar aberant, dar este un adevăr ce domină această piață, iar argumentul este simplu: Bitcoin-ul (sau orice altă criptomonedă) nu este o monedă susținută și reglementată de autoritățile ce implementează politicile monetare în diferite state (în speță Băncile Centrale), și prețul acesteia nu reacționează neapărat în același sens cu ciclul economic, spre deosebire de monedele tradiționale (USD, JPY, CNY, CHF, etc.). Prin urmare, prețul Bitcoin-ului are la bază „încrederea” pe care investitorii o au în criptomoneda respectivă. Deci, dacă tot mai mulți investitori vor avea încredere în criptomonedă, prețul acesteia va crește, respectiv, lipsa încrederii duce la vânzări masive, și implicit la scăderea prețului. Iar cu cât investitorii sunt mai importanți din punct de vedere al sumei investite în criptomonede sau al reputației în general, prețul criptomonedei reacționează mai mult.

Criptomonedele nu au fost privite cu ochi buni, mai ales de specialiștii ce activează în sectorul bancar. Aceștia le considerau a fi doar o categorie de instrumente speculative ce nu oferă siguranță. Bineînțeles, opiniile în această privință au fost împărțite, dar este cert că siguranța este un aspect important de luat în calcul în decizia de plasare a banilor într-o astfel de piață. Am asistat în trecut la diverse atacuri cibernetice ce au destabilizat unele dintre cele mai mari platforme electronice de tranzacționare cu criptomonede, ceea ce aduce o reticență printre investitori când vine vorba despre astfel de instrumente financiare. Dar, făcând referire la perioada actuală, vedem că Bitcoin-ul și tot mai multe criptomonede se bucură de noi reglementări, venite atât din rândul instituțiilor de credit, cât și din partea marilor companii. Totuși, puțini investitori cunosc în mod cert beneficiile rezultate din includerea criptomonedelor în propriul portofoliu de active financiare sau chiar din buna gestiune a unui portofoliu de criptomonede.

2. Stadiul actual al cunoașterii

Numeroase studii au avut menirea de a explica impactul introducerii monedelor virtuale într-un portofoliu de active financiare format din acțiuni, obligațiuni sau indici bursieri. Spre exemplu, Dyhrberg (2016), utilizând o model de tip GARCH asimetric a ajuns la concluzia că Bitcoin-ul poate fi introdus într-un portofoliu de active tradiționale ca instrument de acoperire împotriva riscului, comportându-se într-o anumită măsură la fel ca și aurul (cel puțin în perioadele de recesiune economică, prețul aurului are tendința de a crește). Argumentele în acest sens au la bază caracteristicile asemănătoare dintre Bitcoin și aur: rezerva este finită, volatilitatea prețurilor este ridicată, iar oferta nu poate fi controlată de guvern. De asemenea,

rezultatul aceluiași cercetător relevă faptul că Bitcoin poate fi folosit și pentru acoperirea riscului împotriva deprecierei dolarului american, însă numai pe termen scurt.

Datorită faptului că succesul Bitcoin a generat dezvoltarea multor alte criptomonede, constatăm că pe această piață există unele similitudini în privința modului în care se comportă prețul acestor noi instrumente financiare la diverse șocuri ce au la bază, în special informațiile ce apar în piață. Altfel spus, dacă o informație pune Bitcoin-ul într-o lumină nefavorabilă ce va avea ca efect scăderea prețului, o serie de alte criptomonede vor reacționa în același fel. De aici poate interveni nevoia de grupare (en. clustering) a acestor criptomonede, în funcție de anumite criterii, scopul fiind identificarea comportamentului colectiv al criptomonedelor, ce poate ajuta investitorul la o bună optimizare a portofoliului. Această grupare se poate face în funcție de momentele statistice ale distribuției de probabilitate a randamentelor acestor monede virtuale.

Teoria piețelor eficiente (EMH) este un concept fundamental aplicat în finanțe atunci când vine vorba despre testarea eficienței informaționale. Conform definiției date de Eugene Fama (1970) „o piață este eficientă din punct de vedere informațional dacă reflectă pe deplin toate informațiile disponibile”. Dar, dacă o piață ar fi eficientă din punct de vedere informațional, toate plasamentele investitorilor ar fi canalizate doar către acele active ce vor genera cele mai mari rentabilități, acest lucru generând oportunități de arbitraj în timp real. În practică vedem că nu toate investițiile sunt profitabile, unele active fiind atractive pentru o perioadă limitată de timp. Exact același raționament este aplicat și în cazul pieței monedelor virtuale. Dacă ar exista eficiență informațională, investitorii ar alege doar acele criptomonede ce vor aduce rentabilități așteptate cât mai mari, acționând în sensul cumpărării și deținerii acestora (en. buy and hold), împiedicându-se tranzacționarea. Dar, constatăm că asemenea activelor tradiționale, monedele virtuale sunt atractive pentru o perioadă limitată de timp, datorită noilor informații ce apar în piață, deci nici piața criptomonedelor nu este eficientă din punct de vedere informațional.

Studiile empirice efectuate pentru o mare varietate a activelor financiare tradiționale, tranzacționate pe piețe diferite, și pentru perioade de timp diferite, au relatat faptul că rentabilitățile acestora posedă anumite proprietăți statistice comune de tipul tendințelor generale sau a regularităților. Literatura de specialitate a denumit aceste proprietăți „fapte stilizate” (en. Stylized facts), acestea fiind în general greu de expus cu ajutorul unui anumit proces stocastic, sau a unui anumit model parametricⁱ. Fără a restrânge generalitatea, cele mai cunoscute fapte stilizate ce caracterizează varietatea claselor de active tradiționale sunt: absența autocorelațiilor, distribuția de probabilitate a randamentelor asimetrică, cozi „groase” ale distribuției randamentelor și „volatilitatea grupată” (en. volatility clustering).

Dar oare, criptomonedele posedă aceleași fapte stilizate ca în cazul activelor financiare tradiționale? Este important de precizat de la început că literatura de specialitate nu este foarte vastă în această privință. Un studiu interesant ce vizează această problemă aparține cercetătorilor C.R. da Canuha și R. da Sliva (2020), aceștia analizând faptele stilizate pentru Bitcoin, utilizând date zilnice ce vizează perioada aprilie 2013-februarie 2019. Studiul lor a arătat că distribuția randamentelor Bitcoin nu urmează o lege normală, este asimetrică, leptocurtică și prezintă cozi „groase” pentru date cu frecvență ridicată. Este important de menționat că distribuția randamentelor Bitcoin este mult mai „înaltă” decât distribuția randamentelor activelor tradiționale, în general. De asemenea, cei doi cercetători au arătat că randamentele Bitcoin prezintă o volatilitate ce tinde să se grupeze în timp, iar corelația dintre volum și volatilitate este întotdeauna pozitivă.

Un alt studiu relevant în acest sens aparține lui T. Takaiishi (2018), acesta, utilizând date intraday pentru rentabilitățile Bitcoin, pentru un minut, vizând perioada ianuarie 2014-decembrie 2016, a demonstrat că distribuția de probabilitate a randamentelor Bitcoin este leptocurtică, dar pentru perioade îndelungate de timp și eșantioane mari de date, există o tendință de revenire a coeficientului de aplatizare la valori apropiate de cele pentru legea normală de distribuție. Același cercetător a relevat faptul că pentru date intraday, coeficientul

de asimetrie este unul negativ, dar pentru date săptămânale, acesta tinde la 0 (valoare caracteristică distribuției normale).

J.Y. Song, W. Chang, J.W. Song (2019), au elaborat un studiu care a urmărit formarea clusterelor de criptomonede, utilizând date intraday, pe ore, pentru 76 de criptomonede, pe parcursul perioadei decembrie 2017 - martie 2018. Aceștia au aplicat un filtru denumit Bitcoin-Ethereum având rolul de a elimina influențele liniare ale acestor două criptomonede asupra celorlalte. Înainte de aplicarea acestei metode de filtrare a randamentelor, rezultatele indicau faptul că piața monedelor virtuale putea fi împărțită în două cluster, unul format din criptomonede cu aceleași caracteristici cu Bitcoin, iar al doilea format din criptomonede ce posedă caracteristici comune cu Ethereum. După aplicarea metodei filtrării randamentelor, se constată formarea a 6 cluster omogene de criptomonede, unele având caracteristici comune înainte de a fi instituită reglementarea acestora în unele state, iar altele având caracteristici comune după perioada de reglementareⁱⁱ.

Prin lucrarea de față ne propunem extinderea literaturii de specialitate care vizează domeniul investițiilor în monede digitale. În acest sens, dorim să demonstrăm că monedele digitale pot constitui alternative viabile de investire mai ales în perioadele „tulburi”, ce pot oferi o rata de remunerare superioară celei specifice pieței valorilor mobiliare, bineînțeles, presupunând că un investitor își asumă pe deplin riscurile caracteristice acestor tipuri de investiții. Putem spune că aceste noi tipuri de active financiare sunt preferate în mai mare măsură de către investitorii ce manifestă o preferință ridicată față de risc (investitori riscofili).

Considerăm că investițiile în criptomonede, și implicit gestionarea portofoliilor compuse din astfel de instrumente reprezintă subiecte ce nu au fost pe deplin fructificate și dezbătute în literatura de specialitate existentă în prezent, dar care, la momentul actual captează interesul a tot mai mulți cercetători, practicieni, și studenți. Lucrarea noastră vine în completarea literaturii de specialitate referitoare la gestiunea portofoliilor de criptomonede, utilizând momentele statistice și analiza de tip cluster. Prin urmare, scopul lucrării îl reprezintă identificarea unor comportamente/caracteristici similare ale criptomonedelor, și gruparea acestora în funcție de aceste comportamente/caracteristici.

O mare parte a cercetătorilor preocupați de analiza seriilor de timp financiare pun accent pe sursele de informații pentru a lua decizii, în special când vine vorba despre managementul portofoliilor de active. Totuși, informațiile pot fi înșelătoare dacă provin din surse incerte. De altfel, unii cercetători (vezi, Schumaker și Chen, 2009), chiar au relatat faptul că este dificil a se previziona prețurile acțiunilor apelând la informații provenite din articole de presă sau știri din mass-media. Din această perspectivă putem constata că în cazul monedelor virtuale, estimarea prețurilor devine și mai problematică. Prin urmare, în managementul unui portofoliu compus din criptomonede, este necesar să avem acel reper de care ne putem folosi pentru a selecta ce monede virtuale vor face parte dintr-un anumit portofoliu. Iar cum elementul esențial când vine vorba despre portofolii este diversificareaⁱⁱⁱ, selecția trebuie realizată ținând cont de caracteristicile fiecărei criptomonede. Așa cum spuneam mai sus, succesul timpuriu al Bitcoin a condus la apariția unor alte monede virtuale, ce au la bază aceeași tehnologie utilizată pentru „minarea” Bitcoin, deci sunt definite de aceleași caracteristici ca și principala criptomonedă din lume. Identificarea unor grupuri de criptomonede cu caracteristici diferite de cele ale Bitcoin și includerea acestora într-un portofoliu poate reprezenta o formă de diversificare, reducând pierderea în cazul unui eventual șoc negativ.

3.Date și metodologia utilizată

Pentru realizarea studiului nostru, vom utiliza prețurile zilnice de închidere ale primelor 20 de criptomonede în funcție de capitalizarea bursieră a acestora, vizând întreaga perioadă a anului 2020 (01.01.2020 – 31.12.2020). Deoarece accesibilitatea datelor pentru monedele virtuale nu este foarte facilă, existând mari discrepanțe între diferite platforme de tranzacționare

în ceea ce privește identificarea datelor pentru anumite criptomonede care să corespundă perioadei specificate anterior, sau posibilitatea de descărcare a acestora, menționăm că aceste 20 de criptomonede sunt și cele pentru care am identificat date disponibile, complete pentru întreaga perioadă selectată. Pentru identificare monedelor virtuale în funcție de capitalizarea bursieră, am utilizat platforma electronică de tranzacționare CoinMarketCap^{iv}, iar pentru descărcarea prețurilor am utilizat site-ul Yahoo Finance^v. Am considerat capitalizarea bursieră ca fiind un criteriu relevant în selecția criptomonedelor, deoarece, pe lângă faptul că exprimă dimensiunea relativă a unei criptomonede, poate reprezenta un indicator al performanței și popularității pe termen lung al criptomonedei respective, investitorii manifestând interes permanent de-a lungul timpului pentru acestea. Fără a restrânge generalitatea, este posibil ca aceste 20 de monede virtuale să fie mai puțin volatile decât restul monedelor virtuale, dar, bineînțeles, mai volatile decât activele mobiliare tradiționale. În tabelul 1, puteți regăsi cele 20 de monede virtuale cu care vom opera în realizarea studiului.

Tabel 1. Criptomonedele utilizate în elaborarea studiului

1. Bitcoin	11. NEM
2. Ethereum	12. Monero
3. Cardano	13. EOS
4. Binance coin	14. Tron
5. Tether	15. IOTA
6. XRP	16. VeChain
7. Chainlink	17. Dash
8. Litecoin	18. Decred
9. Stellar	19. Zcash
10. Dogecoin	20. Ethereum classic

Sursa: <https://coinmarketcap.com/>.

Analiza noastră va fi împărțită în 3 secțiuni. În prima parte, vom calcula rentabilitățile zilnice ale fiecărei criptomonede, pentru întreaga perioadă avută în vedere. Menționăm că rentabilitățile zilnice vor fi calculate în sistem logaritm, după formula: $r_t = \ln(P_t) - \ln(P_{t-1}) = \ln\left(\frac{P_t}{P_{t-1}}\right)$, unde P_t reprezintă prețul înregistrat de criptomoneda respectivă în ziua curentă, iar P_{t-1} reprezintă prețul înregistrat cu un lag (o zi) în urmă. În acest fel vom obține seriile de rentabilități zilnice pentru fiecare dintre cele 20 de criptomonede, specificate anterior. Apoi vom realiza histograma randamentelor, care ne va oferi informații cu privire la repartizarea seriei de rentabilități pentru fiecare criptomonedă. Aceste informații vizează în special primele 4 momente ale seriei de rentabilități (media, abaterea medie pătratică, skewness și kurtosis). Momentele de ordin superior, skewness și kurtosis ne vor oferi indicii cu privire la repartitia seriei de rentabilități, facilitându-ne comparația dintre distribuția rentabilităților și legea normală de distribuție. Totodată, ne vor ajuta în evidențierea faptelor empirice stilizate, prezente în rândul rentabilităților zilnice ale criptomonedelor. Spre exemplu, vom vedea că în cazul unui exces de kurtosis^{vi}, distribuția va prezenta cozi groase, deci vor exista multe valori depărtate de medie (en. outliers). Vom încheia prima parte a studiului cu identificarea eventualelor autocorelații existente la nivelul rentabilităților și cu testarea normalității seriilor de date.

În a doua parte a studiului nostru vom aplica analiza cluster, având ca scop gruparea criptomonedelor în diferite grupuri ce au caracteristici comune, bazându-ne pe proprietățile statistice identificate anterior. Astfel, un cluster de criptomonede va conține observații care au cea mai mare similitudine. Pentru a realiza analiza de tip cluster, studiile evidențiază două metode principale: k-means clustering și gruparea ierarhică (en. hierarchical clustering). Prima dintre ele se utilizează când se cunoaște în prealabil un anumit număr de cluster ce se dorește

a fi obținut, iar a doua metodă se folosește atunci când se dorește obținerea unui număr optim de clustere. Noi ne vom axa pe prima metodă (K-means clustering), dorind să aplicăm modele de partiții cu două, trei și patru clustere, pentru fiecare moment statistic în funcție de care vom face gruparea. Pentru realizarea analizei cluster vom utiliza R software, un program statistic de analiză a datelor și în același timp, unul dintre cele mai uzuale limbaje de programare.

Algoritmul k-means presupune calcularea centrului pentru fiecare cluster ce se dorește a fi obținut, urmând apoi a se grupa observațiile în clustere pe baza distanței dintre acestea, alocându-se fiecare observație în jurul centrului cel mai apropiat. Dacă se dorește schimbarea numărului de clustere, centrul fiecărui cluster va fi actualizat iar observațiile vor fi redistribuite.

În ultima parte a studiului punem accent pe caracteristicile grupurilor de criptomonede obținute, identificarea numărului optim de clustere și reprezentarea grafică a fiecărui cluster. Încheiem prin a specifica principalele concluzii întreprinse în urma studiului, și câteva direcții viitoare de extindere a acestei analize.

4. Rezultate și interpretări

4.1. Evidențierea faptelor empirice stilizate specifice seriilor de randamente

Prima parte a rezultatelor studiului nostru se focusează pe evidențierea faptelor empirice stilizate ce caracterizează seria prețurilor și a randamentelor monedelor digitale. În acest sens, în cele ce urmează vom pune accent pe analiza staționarității seriilor de randamente, pe analiza statisticilor descriptive calculate pe baza acestora, pe testarea normalității seriilor de randamente și pe analiza posibilelor autocorelații prezente la nivelul prețurilor, randamentelor și a randamentelor la pătrat (utilizate în analiza noastră ca și proxy pentru volatilitate).

Începem, așadar cu analiza staționarității seriilor de randamente ale criptomonedelor, utilizând două metode: metoda grafică și teste specifice pentru prezența rădăcinii unitate. Prima metodă se fundamentează prin analiza graficelor aferente evoluției randamentelor, în cazul nostru, a evoluției pe întreaga durată a anului 2020. Putem observa în cadrul [setului de grafice 1](#) din anexa lucrării, graficele evoluției randamentelor zilnice pentru fiecare dintre cele 20 de criptomonede. Observăm că randamentele par a fi staționare întrucât urmează un proces de revenire la medie (en. mean reverting). Această afirmație ne este întărită de testele parametrice de staționaritate, respectiv testele ADF (Augmented Dickey Fuller) și PP (Phillips-Peron). Aceste două teste sunt cele mai utilizate pentru testarea staționarității unei serii de date. Ipoteza nulă (H_0) a ambelor teste se referă la prezența rădăcinii unitare în seria de date, sau altfel spus la faptul că seria randamentelor nu este staționară, iar faptul că seria este staționară reprezintă ipoteza alternativă. Testul ADF pornește de la un proces stohastic autoregresiv de ordin 1 (AR(1)), iar testul PP nu include în ecuația de estimare diferențele valorilor trecute ale seriei, estimarea ecuației realizându-se prin metoda celor mai mici pătrate (OLS). Utilizând software-ul econometric Eviews, testăm staționaritatea seriilor de randamente, folosind opțiunile level și intercept, deoarece observăm din graficele expuse anterior că randamentele fluctuează mai mult sau mai puțin în jurul valorii medii ale acestora. De asemenea, menționăm că în cazul testului ADF, se ține cont de numărul de lag-uri utilizate pentru a calcula valorile critice ale testului. În cazul nostru, am ales ca numărul de lag-uri să fie egal cu 14, deoarece această valoare reprezintă intervalul de timp a două săptămâni de tranzacționare, un interval relevant pentru testarea staționarității seriilor de timp financiare. Rezultatele celor două teste sunt expuse în [tabelul 1](#) din anexa lucrării.

Cele două teste, fiind similare, remarcăm faptul că valorile t-statistic sunt aproximativ egale, cu o mică ajustare, în cazul testului PP pentru a se înlătura eventualele erori. Observăm că probabilitatea asociată fiecărui test este 0,0000 nivel inferior chiar și pentru pragul de semnificație de 1%, ceea ce ne conduce la respingerea ipotezei nule a celor două teste, prin urmare, seriile randamentelor monedelor digitale sunt staționare.

Continuăm evidențierea faptelor empirice stilizate cu statisticile descriptive calculate utilizând randamentele celor 20 de criptomonede avute în vedere în elaborarea studiului. Astfel, în cazul statisticilor descriptive, subliniem în special cele 4 momente ale distribuțiilor de rentabilități aferente monedelor digitale (media, abaterea medie pătratică, skewness și kurtosis). Evidențiem în [tabelul 2](#) din anexa lucrării aceste patru momente, precum și mediana distribuției, punctele de maxim și cele de minim. Observăm că cele mai mari rentabilități medii aparțin criptomonedelor NEM (0,51%), Chainlink (0,45%) și Ethereum (0,44%), Bitcoin-ul ocupând abia poziția 5 în această ierarhie cu o rentabilitate medie de aproximativ 0,37%. În subsolul clasamentului regăsim Tether (0,00%), EOS (0,00%) și Ethereum Classic (0,05%).

Remarcăm că variabilitatea rentabilităților (diferența dintre rentabilitatea zilnică maximă și cea minimă) este foarte mare și preponderent negativă aproape pentru fiecare criptomonedă, ceea ce ne întărește convingerea că această piață a monedelor digitale este foarte volatilă.

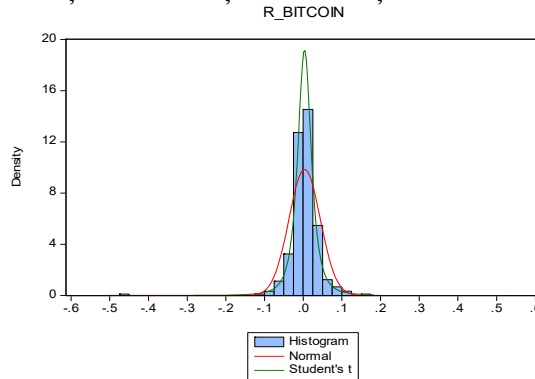
În cazul abaterii medii pătratice, care poate fi considerat un indicator al riscului (deoarece, cu cât abaterea medie pătratică este mai mare, cu atât intervalul de variație a randamentelor este mai mare), observăm că valorile cele mai mari nu corespund întotdeauna criptomonedelor care au și cea mai mare rentabilitate medie, așa cum ar fi normal. În topul criptomonedelor cu cel mai mare risc se află VeChain (6,95%), Chainlink (6,91%) și Zcash (6,05%). Cele mai mici abateri medii pătratice regăsim în cazul Tether (0,56%), Bitcoin (4,04%) și în cazul Monero (4,90%). Trebuie menționat faptul că aceste criptomonede cu cel mai mic risc se află peste cele ce au cel mai mare risc în ceea ce privește capitalizarea bursieră. Mai exact, sunt criptomonedele cele mai preferate de investitori, cele ce oferă cea mai mare încredere. Cu cât o criptomonedă se bucură de o mai mare încredere din partea investitorilor, cu atât riscul acesteia va fi mai mic.

Momentele de ordin superior (skewness și kurtosis) oferă informații suplimentare investitorilor (mai ales a investitorilor pe termen scurt) în ceea ce privește distribuția randamentelor activelor financiare, deoarece iau în considerare extremele setului de date, și nu se concentrează doar la analiza mediei. Într-o distribuție asimetrică, valorile indicatorilor tendinței centrale (media și mediana) sunt diferite, iar în acest caz, un model care să prezică performanța viitoare va fi mai puțin precis. Analizând momentele de ordin superior, observăm că valorile acestora diferă într-o mare măsură de valorile caracteristice unei legi normale de distribuție. Indicatorul skewness este în mare parte negativ (excepție fac Tether, Stellar, Dogecoin și NEM, cu valori apropiate de 0), ceea ce ne indică faptul că distribuția randamentelor este alungită spre stânga, deci, rentabilitatea efectivă pentru majoritatea criptomonedelor este probabil a fi mai mică decât rentabilitatea lor normală. Pentru criptomonedele care sunt exceptate, raționamentul este exact invers: rentabilitatea lor efectivă este probabil a fi mai mare decât rentabilitatea normală, iar forma distribuției este alungită spre dreapta. Indicatorul kurtosis are un nivel superior valorii ce caracterizează distribuția normală, pentru fiecare dintre cele 20 de criptomonede analizate. În acest caz, distribuțiile randamentelor aferente fiecărei criptomonede au o formă mai înaltă și ascuțită decât în cazul distribuției normale, așadar, probabilitatea valorilor din jurul mediei este mai mare decât pentru distribuția normală. Acest nivel al indicatorului ne sugerează faptul că distribuțiile prezintă „cozi groase”, deci este mult mai probabil a se înregistra valori extreme ale rentabilităților, mai mari decât în cazul distribuției normale. Până în acest moment remarcăm că două dintre cele mai întâlnite fapte empirice stilizate și anume distribuția asimetrică și prezența „cozilor groase” ale distribuțiilor aferente seriilor de rentabilități financiare, sunt prezente și în cazul criptomonedelor.

În ceea ce privește ipoteza normalității seriilor de randamente financiare, recurgem la testarea acesteia utilizând două metode, asemenea testării staționarității: metoda grafică și teste specifice. În cazul metodei grafice vom efectua analiza graficului Quantile-Quantile (Q-Q) precum și comparația dintre distribuția randamentelor și legea normală de distribuție. Având deja un prim indiciu referitor la faptul că distribuțiile randamentelor monedelor digitale nu se

identifică cu o distribuție normală, provenit din valorile momentelor statistice de ordin superior analizate mai sus, concluzia ne este întărită de graficele Q-Q, unde putem observa că în cazul tuturor criptomonedelor, relația dintre seria cuantilelor empirice (reprezentate cu albastru) și cea aferentă cuantilelor teoretice (caracteristică distribuției normale, reprezentate cu roșu) nu este una liniară, prin urmare, randamentele nu provin dintr-o distribuție normală. Graficele Q-Q pentru toate criptomonedele analizate pot fi vizualizate în cadrul [setului de grafice 2](#) din anexa lucrării. Observăm din [setul de grafice 3](#), expus în anexa lucrării că distribuția normală nu este adecvată pentru modelarea randamentelor monedelor digitale. Deoarece randamentele criptomonedelor urmează o distribuție leptocurtică, o distribuție Student-T sau GED (Generalized Error Distribution) ar fi mult mai adecvată pentru a modela randamentele criptomonedelor. Exemplificăm în graficul 1 de mai jos, comparația dintre distribuția efectivă a randamentelor, distribuția normală și distribuția Student-T pentru cea mai cunoscută criptomonedă din lume, și anume Bitcoin, pentru restul criptomonedelor, rezultatele fiind similare.

Figura 1. **Comparație între aproximarea distribuției randamentelor bitcoin cu o distribuție normală și o distribuție Student-T**



Sursa: Prelucrare proprie a datelor utilizând Eviews.

În cele din urmă, testele specifice de normalitate Lilliefors, Anderson-Darling și Jarque-Bera, ne conduc la respingerea ipotezei nule, deci seria de date aferentă randamentelor criptomonedelor nu provine dintr-o distribuție normală, întrucât probabilitatea asociată fiecăruia dintre cele trei teste este inferioară pragului de 5%, prin urmare, testele statistice aplicate pentru predicția prețurilor criptomonedelor nu sunt relevante. În [tabelul 3](#) din anexă sunt expuse rezultatele celor trei teste de normalitate aplicate pentru seria randamentelor aferente fiecărei criptomonede.

În finalul primei părți referitoare la evidențierea faptelor empirice stilizate prezente în rândul criptomonedelor, vom efectua analiza autocorelațiilor prezente în cadrul seriei de prețuri, de randamente și de randamente ridicate la pătrat (ca și variabilă proxy pentru volatilitate). Ne vom ajuta de funcția Correlogram din Eviews, și vom efectua testarea celor trei serii de date menționate anterior, folosind opțiunea level, și luând în calcul 14 lag-uri (două săptămâni de tranzacționare). Funcția de autocorelație calculată utilizând opțiunile anterior menționate, are următoarea formă:

$$\rho_k = \frac{\sum_{t=k+1}^n \frac{(X_t - \bar{X})(X_{t-k} - \bar{X})}{n-k}}{\sum_{t=1}^n \frac{(X_t - \bar{X})^2}{n}}$$
, unde ρ_k reprezintă coeficientul de corelație de

ordinul k , n reprezintă numărul de observații aferent seriei X_t , iar \bar{X} desemnează media seriei X_t . Decizia privind respingerea sau, după caz, acceptarea fenomenului de autocorelație o vom fundamenta pe baza Q-statistic și a probabilității asociate acestuia. Ipoteza nulă a acestui test se referă la respingerea fenomenului de autocorelație până la nivelul lag-ului k , iar ipoteză alternativă se referă la existența fenomenului de autocorelație până la lag-ul k .

În privința seriei de prețuri pentru fiecare criptomonedă, observăm că funcția de autocorelație descrește lent de la un lag la celălalt, iar funcția de autocorelație parțială scade brusc după primul lag, ceea ce ne întărește convingerea că seriile de timp aferente prețurilor criptomonedelor sunt nestaționare. Observăm că probabilitatea asociată Q-statistic este inferioară nivelului de semnificație de 5%, pentru fiecare dintre cele 14 lag-uri luate în calcul, deci, în rândul prețurilor criptomonedelor nu există autocorelație. Rezultatele privind valorile funcției de autocorelație la nivelul prețurilor, a statisticii Q și a probabilității asociate acesteia pot fi vizualizate în [tabelul 4](#) din anexa lucrării.

În cazul seriilor de randamente financiare, observăm că nu putem vorbi despre o absență deplină a autocorelațiilor pentru toate criptomonedele avute în vedere. Pentru cele mai cunoscute criptomonede, Bitcoin și Ethereum, randamentele sunt necorelate pentru toate cele 14 lag-uri. Identificăm de asemenea lipsa autocorelațiilor între randamente în cazul Binance Coin și Tether, în timp ce pentru Cardano, a treia criptomonedă în funcție de capitalizarea de piață, observăm o necorelare până la lag-ul 8, după care, lag-urile de la 9 la 14 prezintă autocorelare, deoarece probabilitatea asociată Q-statistic depășește nivelul de relevanță de 5%. Totuși, dacă am fi mai permisivi, și am considera ca și nivel de semnificație pragul de 10%, observăm că și în cazul Cardano putem considera că randamentele nu sunt corelate. Alte criptomonede cu randamente necorelate pentru cele 14 lag-uri sunt Monero, EOS, Iota și VeChain. Restul criptomonedelor prezintă fie randamente corelate pentru toate cele 14 lag-uri (XRP, Chainlink, Dogecoin, NEM, Dash și Zcash), fie randamente corelate pentru primele lag-uri, iar apoi o necorelare a acestora (Litecoin, Stellar, Tron, Decred și Zcash). Specificăm totuși că dacă avem în vedere un prag de semnificație de 10%, criptomonedele cu randamente corelate s-ar reduce. Toate rezultatele privind autocorelația randamentelor sunt prezentate în [tabelul 5](#) din anexa lucrării.

În privința seriilor de rentabilități ridicate la pătrat, observăm că există o mai mare tendință de existență a autocorelației între observații, decât în cazul randamentelor propriu-zise. Bitcoin și Ethereum, care aveau randamente caracterizate de absența autocorelațiilor, au devenit dominate de autocorelație, pentru fiecare dintre cele 14 lag-uri. Chainlink, Litecoin, Monero, EOS, Tron, VeChain, Decred și Zcash sunt alte criptomonede ce prezintă autocorelație a seriei de randamente la pătrat, pentru fiecare lag avut în vedere. De asemenea, identificăm și criptomonede ale căror randamente la pătrat sunt lipsite de autocorelație, cum ar fi Tether, XRP (excepție ultimul lag), Stellar, Dogecoin, NEM (excepție lag 3), Dash (excepție lag 3) și Ethereum Classic (excepție lag-uri 12, 13, 14). Dar, în concluzie, fenomenul de autocorelație este mult mai prezent în cazul randamentelor ridicate la pătrat, decât în cazul randamentelor simple. Prezentăm rezultatele testului de autocorelație a randamentelor la pătrat în [tabelul 6](#) din anexa lucrării.

Așadar, în urma analizei efectuate anterior, randamentele criptomonedelor relevă anumite fapte empirice stilizate identificate și în rândul activelor financiare tradiționale, conform lui R. Cont (2001). Astfel, am evidențiat că distribuțiile rentabilităților sunt asimetrice și prezintă „cozi groase”, seriile de rentabilități sunt staționare în nivel și nu pot fi modelate de o lege normală, iar, cu unele excepții rentabilitățile sunt marcate de absența autocorelației. Seriile de date aferente prețurilor criptomonedelor sunt nestaționare în nivel, și nu prezintă autocorelație. Seriile de date aferente randamentelor ridicate la pătrat sunt în general mult mai corelate față de seriile de rentabilități propriu-zise.

4.2. Analiza de tip cluster

În această secțiune vom aborda analiza cluster, cu scopul de a grupa cele 20 de criptomonede în grupuri omogene, în funcție de caracteristicile similare sau după caz, diferite ale celor 4 momente statistice specifice seriilor de randamente financiare. În acest sens, pentru fiecare dintre cele 4 momente statistice vom aplica algoritmul k-means clustering. Pentru

început să recurgem la o succintă prezentare a analizei de tip cluster, pentru a înțelege considerentele generale.


Mai presus de orice, analiza cluster este o formă de analiză a seriilor de date, serii care conțin în special un număr mare de observații. Prin analiza cluster se dorește împărțirea acestor observații în grupuri ce posedă caracteristici comune. Mai exact, în cadrul unui grup se dorește ca observațiile să aibă un grad ridicat de similaritate, dar să difere semnificativ de observațiile ce aparțin celorlalte grupuri. Este un instrument util în analiza seriilor de timp financiare, putând fundamenta decizii cu privire la selecția instrumentelor ce vor fi introduse în portofoliu, pe baza anumitor criterii. Totuși, această analiză are și unele dezavantaje în privința alegerii celor mai bune metode de clustering ce vor fi utilizate pentru un anumit set de date. În activitatea practică se recomandă utilizarea a cât mai multe metode, deoarece fiecare metodă are specificul ei și oferă o anumită informație calitativă, prin urmare, nu există un singur rezultat corect ce ar putea fi obținut în urma analizei.

Pentru a realiza această grupare, utilizăm software-ul statistic RStudio, atât un mediu destinat activităților de analiză și reprezentare statistică a datelor, cât și un veritabil limbaj de programare.

4.2.1. Gruparea criptomonedelor în funcție de media rentabilității zilnice.

Începem cu gruparea criptomonedelor în funcție de media rentabilității zilnice. Aplicăm algoritmul k-means, care grupează observațiile în într-un anumit număr de clustere specificat de analyst. Noi vom aborda pe rând modele de clusterizare cu două, trei și respectiv patru clustere, apoi vom vedea ce model este mai robust, din perspectiva numărului optim de clustere. Având în vedere că aplicăm algoritmul pentru o singură variabilă (și anume, media rentabilităților), nu este nevoie să standardizăm această variabilă, întrucât observațiile au aceeași unitate de măsură, deci sunt comparabile. Măsurăm apoi gradul de similaritate sau disimilaritate al observațiilor utilizând distanța euclidiană, o măsură a distanței între două puncte. Obținem astfel matricea de (di)similaritate, a cărei reprezentări o putem vizualiza în graficul de mai jos.

Figura 2. **Reprezentarea matricii de (di)similaritate a criptomonedelor în funcție de medie.**



Sursa: Prelucrarea proprie a datelor utilizând RStudio.

Menționăm că cifrele ce se regăsesc pe abscisă și pe ordonată reprezintă rank-urile asociate criptomonedelor în funcție de capitalizarea lor de piață, pe care le puteți consulta în tabelul 1 din prezenta lucrare. Matricea de mai sus ilustrează care criptomonede au cele mai mari disimilarități (chenarele cu roșu) și care criptomonede sunt relativ similare (chenarele cu turcoaz). Spre exemplu, criptomonedele Cardano, Ethereum, Chainlink și Dogecoin sunt foarte diferite de Tether, EOS, XRP și Ethereum Classic. Nu este surprinzător, deoarece dacă vizualizăm mediile randamentelor acestor criptomonede vom vedea că cele din primul grup au

medii zilnice ale rentabilităților relativ mari, în timp ce criptomonedele din al doilea grup au cele mai mici medii. În mod evident, primul grup de criptomonede va face parte dintr-un cluster, iar al doilea grup, din alt cluster.

După rularea fiecărui model de partiție k-means obținem gruparea criptomonedelor în funcție de media rentabilității zilnice pe două, trei, respectiv patru cluster. Fiecare cluster astfel format va avea un centru, în cazul nostru, o anumită rentabilitate zilnică care va fi comună criptomonedelor ce fac parte din clusterul respectiv. Ilustrăm în tabelul de mai jos, centrele clusterelor pentru fiecare partiție.

Tabel 2. Centrele clusterelor pentru fiecare partiție k-means în funcție de medie.

	Cluster	Centrele clusterelor
Partiție 2 cluster	1	0,38%
	2	0,14%
Partiție 3 cluster	1	0,24%
	2	0,02%
	3	0,43%
Partiție 4 cluster	1	0,32%
	2	0,21%
	3	0,02%
	4	0,46%

Sursa: Prelucrare proprie a datelor utilizând RStudio.

Observăm că în cazul partiției cu două cluster, primul cluster va conține criptomonede ale căror rentabilități medii zilnice se vor situa în jurul valorii de 0,38%, în timp ce al doilea cluster va cuprinde criptomonede cu rentabilități medii zilnice mai mici, de doar 0,14%. Bineînțeles, criptomonedele „vedetă” se vor situa în primul cluster, și vor avea cele mai mari rentabilități medii. În cazul partiției cu trei, respectiv patru cluster, remarcăm că există câte un cluster ce va conține criptomonede cu rentabilități medii aproape infime, aceste fiind Tether (0,0009%), XRP (0,00338%), EOS (0,0058%) și Ethereum Classic (0,0529%). Criptomonedele cele mai profitabile se vor situa în clusterul al cărui centru va avea valoarea de 0,43%, respectiv 0,46%, acestea fiind Ethereum (0,4420%), Cardano (0,4289%), Chainlink (0,4573%) și NEM (0,5113%). Rezultatele complete ale grupării criptomonedelor în funcție de primul moment statistic al distribuției rentabilităților pot fi vizualizate în [tabelul 7](#) din anexa lucrării. În special, partițiile cu trei și patru cluster le putem asocia cu o grupare în funcție de quartilele distribuției randamentelor. Prima quartilă poate reprezenta un cluster ce conține criptomonedele cu cele mai mici rentabilități, criptomonedele cu randamentele medii cuprinse între quartila 1 și quartila 2 pot forma un alt cluster, la fel și cele cu randamentele medii cuprinse între quartila 2 și 3, iar în final, se poate forma un cluster ce va conține criptomonedele ale căror randamente medii sunt superioare quartilei 3.

Putem măsura calitatea unei partiții k-means, cu ajutorul următoarei formule a variației totale intra-cluster: $\frac{BSS}{TSS} * 100$, unde BSS reprezintă suma pătratelor distanțelor interclase și TSS reprezintă sumă totală a pătratelor. Cu cât acest procent este mai mare, cu atât partiția este mai bună și mai stabilă. Reprezentăm în tabelul următor, coeficienții de calitate a partiției criptomonedelor în funcție de media rentabilității zilnice.


Tabel 3. Coeficienții de calitate a partiției k-means în funcție de medie

	<i>Calitatea partiției k-means</i>
<i>Partiție 2 clustere</i>	65,20%
<i>Partiție 3 clustere</i>	90,50%
<i>Partiție 4 clustere</i>	96,30%

Sursa: Prelucrare proprie a datelor utilizând RStudio.

Observăm că pe măsură ce numărul de clustere din fiecare partiție crește, calitatea partiției crește, sau partiție devine mai „fină”. Poate fi considerat un rezultat general valabil, pentru că vom remarca același rezultat și în cazul grupării criptomonedelor în funcție de celelalte momente statistice. Totuși o partiție mai fină nu înseamnă că va conține și numărul optim de clustere. Pentru a determina numărul optim de clustere, vom apela la o metodă foarte cunoscută în analiza cluster, și în data science, în general, și anume metoda siluetei medii. Această metodă determină calitatea unui cluster în sensul că măsoară cât de bine este fixat fiecare element (în cazul nostru, criptomonedă) de clusterul său. În programul informatic RStudio, calculăm silueta medie pentru valori $k=\{1;2;3;4\}$, clusterul optim fiind cel ce maximizează silueta, pentru cele patru valori a lui k . Observăm din graficul de mai jos că 4 este numărul optim de clustere ce maximizează silueta.

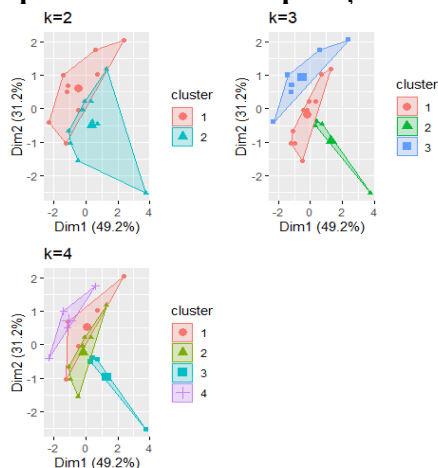
Figura 3. Numărul optim de clustere obținute în funcție de medie



Sursa: Prelucrare proprie a datelor utilizând RStudio.

În final, pentru o mai bună vizualizare a celor trei partiții a criptomonedelor în funcție de rentabilitatea medie a acestora, propunem următorul grafic:

Figura 4. Analiza comparativă a celor trei partiții în funcție de medie




Sursa: Prelucrare proprie a datelor utilizând RStudio.

Putem distinge în graficul de mai sus o reprezentare în plan a punctelor ce compun fiecare cluster, în funcție de partiția aleasă. Punctele mai mari reprezintă centrele clusterelor iar punctele aflate în apropierea centrelor reprezintă criptomonedele cele mai apropiate de centru.

4.2.2. Gruparea criptomonedelor în funcție de abaterea medie pătratică

Aplicând aceeași procedură ca în cazul grupării criptomonedelor în funcție de media rentabilității zilnice, pentru gruparea în funcție de abaterea medie pătratică, începem prin a măsura similaritatea/disimilaritatea criptomonedelor utilizând reprezentarea matricei de (di)similaritate. O putem observa în graficul următor.

Figura 5. Reprezentarea matricei de (di)similaritate a criptomonedelor în funcție de abaterea medie pătratică



Sursa: Prelucrare proprie a datelor utilizând RStudio.

După cum putem observa, există o singură disimilaritate foarte evidentă între criptomoneda Tether și restul criptomonedelor (suprafața cu roșu). Putem remarca din tabelul 2 din anexă, că Tether are cea mai mică abatere medie pătratică (0,562%) dintre toate criptomonedele și de aceea o putem considera cea mai puțin riscantă. De asemenea este important de remarcat că această disimilaritate a criptomonedei Tether este mai intensă în apropierea originii graficului, unde se află Chainlink și Vechain, de altfel, acestea fiind cele mai riscante criptomonede, cu o abatere medie pătratică de 6,915%, respectiv 6,959%. Se pot defini la prima vedere, două

clustere, unul care să conțină o singură criptomonedă, și anume Tether, iar altul care să conțină restul criptomonedelor.

Vom aplica din nou cele trei modele de partiție k-means, cu două, trei, respectiv patru clustere și vom identifica centrele fiecărui cluster, din cadrul fiecărei partiții. Rezultatele sunt disponibile în următorul tabel:

Tabel 4. Centrele clusterelor pentru fiecare partiție k-means în funcție de abaterea medie pătratică

	Cluster	Centrele clusterelor
<i>Partiție 2 clustere</i>	1	5,69%
	2	0,56%
<i>Partiție 3 clustere</i>	1	5,19%
	2	6,25%
	3	0,56%
<i>Partiție 4 clustere</i>	1	0,56%
	2	4,05%
	3	5,31%
	4	6,25%

Sursa: prelucrare proprie a datelor utilizând RStudio.

În cadrul fiecărei partiții remarcăm existența unui cluster al cărui centru este de 0,56%. Acest cluster este format în fiecare caz doar dintr-o singură criptomonedă, aceea fiind Tether, deoarece este singura ce dispune de o asemenea valoare a riscului. Cele mai riscante criptomonede sunt cele ce vor aparține clusterului al cărui centru este de 6,25%. Acestea sunt Cardano (5,969%), XRP (6,233%), Chainlink (6,914%), Stellar (5,985%), NEM (6,057%), Iota (6,022%), VeChain (6,959%), Dash (6,057%) și Zcash (6,033%). Deci, o majoritate covârșitoare a criptomonedelor (aproape jumătate) fac parte din clusterul cel mai riscant. Bitcoin și Ethereum, cele mai cunoscute criptomonede aparțin aceluiași cluster în cadrul partiției cu trei clustere (clusterul cu centrul de 5,19%), apoi sunt divizate în cadrul partiției cu patru clustere (Bitcoin aparține clusterului cu centrul de 4,05%, iar Ethereum, celui cu centru de 5,31%). Rezultatele complete privind componentele fiecărui cluster în funcție de partiție sunt disponibile în cadrul [tabelului 8](#) din anexa lucrării.

Calitatea partiției k-means crește cu cât numărul de clustere crește, la fel ca în cazul grupării în funcție de medie. Totuși, spre deosebire de gruparea în funcție de medie, gruparea în funcție de abaterea medie pătratică are o calitate mai bună în cadrul partiției cu două și trei clustere. Partiția cu patru clustere în cazul grupării după abaterea medie pătratică are o calitate inferioară grupării în funcție de medie. Rezultatele pot fi observate în următorul tabel.


Tabel 5. Coeficienții de calitate a partiției k-means în funcție de abaterea medie pătratică

	Calitatea partiției k-means
<i>Partiție 2 clustere</i>	74,80%
<i>Partiție 3 clustere</i>	90,80%
<i>Partiție 4 clustere</i>	95,10%

Sursa: Prelucrare proprie a datelor utilizând RStudio.

Pentru testarea robusteții partițiilor aplicăm din nou metoda siluetei medii pentru a determina numărul optim de clustere. Putem observa din graficul următor că partiția cu două clustere este cea care maximizează silueta medie.

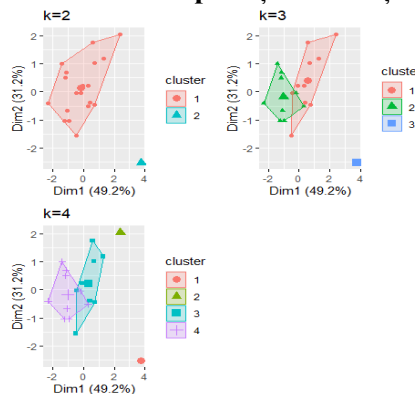
Figura 6. Numărul optim de clustere obținut în funcție de abaterea medie pătratică.



Sursa: Prelucrare proprie a datelor utilizând RStudio.

Vizualizarea celor trei partiții sub formă grafică este expusă în următorul grafic:

Figura 7. Analiza comparativă a celor trei partiții în funcție de abaterea standard




Sursa: Prelucrare proprie a datelor utilizând RStudio.

Din reprezentarea anterioară iese foarte clar în evidență faptul că în cazul partiției cu două, și respectiv trei clustere, vom avea câte un cluster cu un singur element, iar în cazul partiției cu patru clustere, vor exista două clustere cu un singur element. Din această cauză, se consideră relevantă gruparea criptomonedelor în doar două clustere.

4.2.3. Gruparea criptomonedelor în funcție de skewness.

Ajungem și la gruparea criptomonedelor în funcție de momentele de ordin superior ale distribuției randamentelor, și, prima data ne vom ocupa de gruparea în funcție de coeficientul de asimetrie al distribuției (skewness). Măsurarea gradului de similaritate al criptomonedelor în funcție de acest coeficient o vom realiza cu ajutorul reprezentării matricei de (di)similaritate, calculată pe baza distanței euclidiene, ca și în cazurile grupărilor anterioare. În graficul următor poate fi vizualizată matricea de (di)similaritate, în funcție de skewness.

Figura 8. Reprezentarea matricei de (di)similaritate a criptomonedelor în funcție de skewness.



Sursa: Prelucrare proprie a datelor utilizând RStudio.

Cele mai mari disimilarități sunt produse între criptomonedele ca au un cel mai mare skewness negativ (Bitcoin, Binance Coin, Ethereum, Monero și EOS) și cele care au un skewness pozitiv (Dogecoin, Dash, Stellar Tether și NEM). Cu cât ne îndepărtăm de originea graficului, disimilaritatea scade, astfel că, acele criptomonede cu skewness pozitiv pot forma un cluster cu criptomonedele cu skewness negativ, dar apropiate de valoarea 0 (Litecoin, XRP, Chainlink, Cardano și Dogecoin).

Aplicăm din nou cele trei partiții cu două, trei, respectiv patru clusterse în funcție de skewness, iar rezultatele vor fi sintetizate în tabelul 6. Remarcăm în cazul fiecărei partiții că există un cluster distinct cu centrul de 0,34, care va cuprinde doar acele criptomonede ce au un skewness pozitiv, mai exact, va cuprinde doar acele criptomonede a căror rentabilitate efectivă va fi probabil superioară rentabilității normale. De asemenea distingem un cluster cu centrul de -3,41 în cadrul partițiilor cu două și trei clusterse, care va cuprinde criptomonedele cu cel mai mare skewness negativ, adică, criptomonedele care au cea mai mică probabilitate de a înregistra rentabilități efective mari: Bitcoin, Ethereum, Binance coin și Monero. Acestea vor fi preferate în mod special de către investitorii iubitori de risc. Rezultatele complete privind gruparea criptomonedelor în funcție de skewness sunt prezentate în [tabelul 9](#) din anexa lucrării.

Tabel 6. Centrele clusterelor pentru fiecare partiție k-means în funcție de skewness.

	Cluster	Centrele clusterelor
Partiție 2 clusterse	1	0,34
	2	-2,27
Partiție 3 clusterse	1	-1,86
	2	0,34
	3	-3,41
Partiție 4 clusterse	1	-2,20
	2	0,34
	3	-3,41
	4	-1,57

Sursa: Prelucrare proprie a datelor utilizând RStudio.


La fel ca în cazul grupării în funcție de primele două momente statistice, și în cazul grupării criptomonedelor în funcție de skewness, calitatea unei partiții crește dacă numărul clusterelor ce compun partiția respectivă crește. Partiția cu două clusterse are o calitate mai slabă comparativ cu aceeași partiție obținută din gruparea în funcție de abaterea medie pătratică. În rest, partițiile cu două și trei clusterse sunt superioare calitativ. Rezultatele sunt sintetizate în următorul tabel.

Tabel 7: Coeficienții de calitate a partiției k-means în funcție de skewness.

	<i>Calitatea partiției k-means</i>
<i>Partiție 2 clustere</i>	72,90%
<i>Partiție 3 clustere</i>	92,90%
<i>Partiție 4 clustere</i>	96,00%

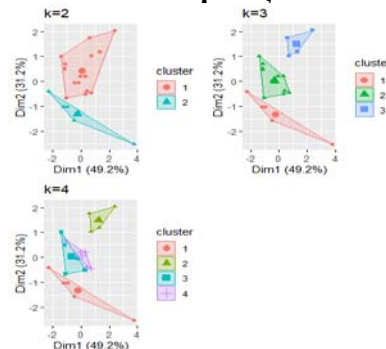
Sursa: Prelucrare proprie a datelor utilizând RStudio.

Identificarea numărului optim de clustere aferent partițiilor în funcție de skewness va fi efectuată tot prin metoda siluetei medii. Conform rezultatelor din graficul de mai jos, 3 clustere maximizează silueta medie.

Figura 9. Numărul optim de clustere obținut în funcție de skewness

Sursa: Prelucrare proprie a datelor utilizând RStudio.

În finalul acestei subsecțiuni, putem vizualiza reprezentarea grafică a celor trei partiții de criptomonede în funcție de skewness în următorul grafic:

Figura 10. Analiza comparativă a celor trei partiții în funcție de skewness

Sursa: Prelucrare proprie a datelor utilizând RStudio.

Putem remarca planurile formate de fiecare cluster în cadrul celor 3 partiții k-means și se asemenea, centrele clusterelor, evidențiate de simboluri mai mari.

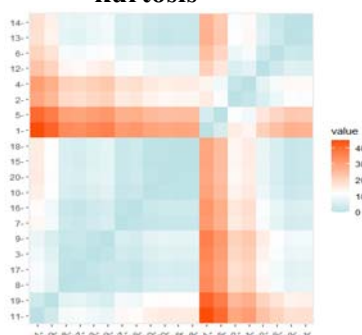
4.2.4. Gruparea criptomonedelor în funcție de kurtosis

Ajungem și la ultimul moment statistic în funcție de care vom realiza gruparea celor 20 de criptomonede. Am sesizat până în acest moment că fiecare criptomonedă în parte are indicatorul kurtosis superior nivelului de 3, caracteristic distribuției normale. Prin urmare, în cazul fiecărei criptomonede există o mai mare probabilitate de a se înregistra valori extreme ale rentabilităților

zilnice. Prin urmare, banda de variație a rentabilităților va fi mult mai largă decât în cazul distribuției normale. Așa că, în cadrul acestei subsecțiuni vom grupa criptomonedele în funcție de al patrulea moment statistic și vom determina în cazul căror criptomonede, probabilitatea de a se înregistra valori anormale ale rentabilităților va fi mai mică.

Ca și până acum, începem prin a calcula și reprezenta grafic matricea distanțelor criptomonedelor în funcție de kurtosis, utilizând distanța euclidiană. Rezultatele sunt expuse în graficul de mai jos.

Figura 11. **Reprezentarea matricei de (di)similaritate a criptomonedelor în funcție de kurtosis**



Sursa: Prelucrare proprie a datelor utilizând RStudio.

Se poate observa că două criptomonede, și anume Bitcoin și Tether au un grad ridicat de disimilaritate cu un grup destul de consistent, format din aproximativ 12 criptomonede. Dacă ne întoarcem în tabelul aferent statisticilor descriptive ale criptomonedelor vom vedea că Bitcoin și Tether au cel mai mare nivel al indicatorului kurtosis, 52,8577 și respectiv 48,5093. Deci, în cadrul acestor două criptomonede este mult mai probabil a se înregistra valori extreme ale rentabilităților față de cele restul criptomonedelor. Bineînțeles, nu doar făcând referire la cele două criptomonede cu cel mai mare kurtosis, ci la nivelul agregat al celor 20 de criptomonede, identificarea unei strategii de tranzacționare pe termen lung, devine aproape imposibilă.

În continuare, vom aplica aceleași trei partiții k-means (cu două, trei și respectiv, patru cluster), ca și în cazul grupării în funcție de primele trei momente statistice. Rezultatele care prezintă partițiile și centrul fiecărui cluster se regăsesc în următorul tabel.

Tabel 8. **Centrele clusterelor pentru fiecare partiție k-means în funcție de kurtosis**

	Cluster	Centrele clusterelor
Partiție 2 cluster	1	44,38
	2	21,11
Partiție 3 cluster	1	44,38
	2	24,76
	3	15,03
Partiție 4 cluster	1	50,68
	2	15,03
	3	23,97
	4	35,98

Sursa: Prelucrare proprie a datelor utilizând RStudio.

În cadrul fiecărei partiții putem distinge un cluster ce va conține criptomonedele cu cele mai mari valori ale indicatorului kurtosis. Putem observa în cazul acestui cluster, centrul său va crește în funcție de partiție, iar acest fapt conduce la scăderea numărului de criptomonede ce

vor face parte din clusterul respectiv. Spre exemplu în cazul partiției cu două cluster și a celei cu trei cluster, criptomonede ce vor face parte din clusterul 1 vor fi Bitcoin (52,8577), Ethereum (37,1914), Binance coin (38,9428) și Tether (48,5093), dar în cazul partiției cu patru cluster, din clusterul 1 vor mai face parte doar Bitcoin și Tether. Clusterelor ce conțin criptomonedele cu cea mai mică valoare a indicatorului kurtosis sunt mai evidente în cazul partiției cu trei și respectiv patru cluster. Aceste criptomonede ce fac parte din aceste cluster sunt Cardano (17,4865), Litecoin (18,1961), Stellar (16,2886), NEM (8,0209), Dash (18,8627) și Zcash (11,3170). Pentru aceste criptomonede este mai probabil ca rentabilitățile să fluctueze într-o bandă de variație mai îngustă. În [tabelul 10](#) din anexă pot fi vizualizate rezultatele grupării criptomonedelor pe fiecare cluster în funcție de kurtosis.

Similar rezultatelor grupării criptomonedelor în funcție de primele trei momente statistice, calitatea partițiilor crește cu cât numărul clusterelor este mai mare. Coeficienții de calitate pentru fiecare partiție pot fi vizualizați în următorul tabel:

Tabel 9. Coeficienții de calitate a partiției k-means în funcție de kurtosis.


	<i>Calitatea partiției k-means</i>
<i>Partiție 2 cluster</i>	70,50%
<i>Partiție 3 cluster</i>	85,00%
<i>Partiție 4 cluster</i>	92,60%

Sursa: Prelucrare proprie a datelor utilizând RStudio.

De remarcat este că acești coeficienți de calitate a partițiilor în funcție de kurtosis sunt inferiori celor pentru partițiile în funcție de skewness sau în funcție de abaterea medie pătratică.

Pentru calculul numărului optim de cluster în cazul partițiilor k-means, utilizăm metoda siluetei medii, care măsoară cât de bine este fixat fiecare element de clusterul său. Conform următorului grafic, numărul optim de cluster în cazul grupării în funcție de kurtosis este 2.

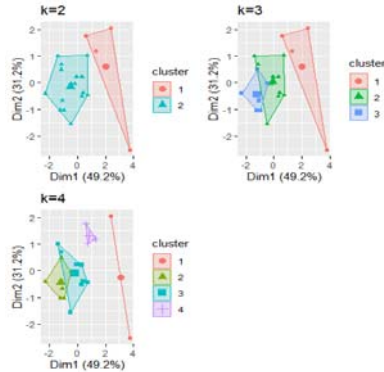
Figura 12. Numărul optim de cluster obținut în funcție de kurtosis



Sursa: Prelucrare proprie a datelor utilizând RStudio.

În final, reprezentarea celor trei partiții k-means în funcție de kurtosis este disponibilă în graficul de mai jos. În cazul partiției cu patru cluster, clusterul format din cele două criptomonede cu valori mari ale indicatorului kurtosis este reprezentat sub forma unei drepte iar punctul din mijloc reprezintă centrul său.

Figura 13. Analiza comparativă a celor trei partiții în funcție de kurtosis



Sursa: Prelucrare proprie a datelor utilizând RStudio.

5. Concluzii

Studiul nostru are menirea de a contribui la extinderea literaturii de specialitate în ceea ce privește analiza pieței monedelor digitale. Date fiind noile reglementări de care se bucură această piață și popularitatea tot mai mare a criptomonedelor în rândul marilor investitori, considerăm aceste noi instrumente financiare ca putând fi folosite drept instrumente de rezervă, mai ales în perioadele de contracție sau recesiune economică.

Analiza a fost realizată utilizând prețurile zilnice ale primelor 20 de criptomonede în funcție de capitalizarea bursieră, pe întreaga perioadă a anului 2020. Constatăm că în rândul seriilor de rentabilități ale acestor criptomonede există unele proprietăți statistice comune, asemeni activelor financiare tradiționale, denumite fapte empirice stilizate. Prețurile și rentabilitățile urmează dinamici foarte diferite. Seria prețurilor este nestaționară în nivel în timp ce seria rentabilităților urmează un proces de revenire la medie, deci este staționară. Fiind o piață foarte volatilă mediile rentabilităților zilnice sunt mai mari decât în cazul activelor financiare tradiționale, dar și riscul este mult mai mare, iar amplitudinea rentabilităților zilnice este foarte mare.

Distribuțiile rentabilităților monedelor digitale sunt asimetrice, multe dintre ele având un coeficient de asimetrie negativ și cu mici excepții, pozitiv. De asemenea, distribuțiile sunt leptocurtice, având un coeficient de aplatizare mai mare decât valoarea caracteristică legii normale. Deci, seriile de rentabilități nu se pot identifica cu o lege normală de distribuție și atunci aplicarea unei strategii de tranzacționare devine aproape imposibil de aplicat și de asemeni, testele statistice pentru previziunea cursurilor nu sunt eficiente. Prețurile criptomonedelor nu sunt autocorelate pentru niciunul dintre cele 14 lag-uri pentru care am efectuat testele. Cu excepția XRP, Chainlink, Dogecoin, NEM, Dash și Zcash, seriile de randamente sunt caracterizate în general de absența autocorelațiilor pentru toate cele 14 lag-uri. În rândul seriilor de randamente ridicare la pătrat (proxy pentru volatilitate), identificăm o mai mare tendință de autocorelare.

În cadrul analizei cluster, am utilizat algoritmul k-means și am grupat cele 20 de criptomonede în funcție de fiecare dintre primele patru momente statistice ale distribuției rentabilităților. Pentru fiecare grupare am utilizat partiții cu două, trei și patru cluster. În cadrul fiecărei partiții identificăm cel puțin un cluster care conține criptomonedele cele mai riscante. Acestea vor fi preferate într-o mai mare măsură de către investitorii riscofili. Este de menționat că nu toate criptomonedele care fac parte din clusterul cu cele mai mari rentabilități zilnice se identifică cu cele care fac parte din clusterul cu cel mai mare risc (excepție NEM și Chainlink). Astfel, un investitor își poate optimiza portofoliul de criptomonede pentru a reduce eventuala pierdere prin selecția criptomonedelor atât care fac parte din clusterul cel mai riscant, cât și din clusterul cu cel mai mic risc. Dat fiind faptul că distribuțiile criptomonedelor sunt asimetrice, un model care să prezică randamentele viitoare este inefficient. În acest caz, un investitor își poate optimiza portofoliul alegând criptomonedele din clusterul cu centrul cel mai apropiat de

0. De asemenea, toate criptomondele prezintă exces de kurtosis, ceea ce se asociază cu faptul că un investitor va experimenta valori extreme ale randamentelor, fie ele pozitive sau negative. Pentru ca aceste valori extreme să fluctueze într-o bandă de variație cât mai îngustă, investitorul trebuie să selecteze criptomondele din clusterul cu centrul cel mai apropiat de valoarea 3.

Dorim ca pe viitor să extindem această analiză și să recurgem la aplicarea mai multor algoritmi de grupare asupra unui număr mai mare de criptomonede. În limita în care accesibilitatea informațiilor ne va permite, dorim să utilizăm cu precădere date cu frecvență intra-day, deoarece aceste date pot facilita și mai bine identificarea caracteristicilor comune ale criptomonedelor, din perspectiva unui investitor pe termen scurt.

Mulțumiri.

Lucrarea de față a fost elaborată în cadrul competiției de proiecte de cercetare studențești, cu tema „Digitalizarea: oportunități și provocări financiare”, finanțată de către Academia de Studii Economice București și implementată în cadrul Centrului de Cercetări financiar-monetare (CEFIMO) al Facultății de Finanțe, Asigurări, Bănci și Burse de Valori. Mulțumiri distinse se acordă doamnei prof. univ. dr. Andreea-Maria Stoian pentru tot sprijinul logistic acordat în elaborarea lucrării. Acordăm mulțumiri speciale doamnei prof. univ. dr. Denisa Bănulescu-Radu (University of Orleans) și doamnei lect. univ. dr. Alina Grigore Sima, pentru împărtășirea noțiunilor din domeniul econometriei financiare, respectiv pentru prezentarea teoriei legate de piețele bursiere, într-o manieră adaptată cu precădere spre partea practică. Dorim totodată să mulțumim conducerii și colectivului de profesori din cadrul Facultății de Finanțe, Asigurări, Bănci și Burse de Valori.

Note.

ⁱ Pentru mai multe detalii privind problematica faptelor stilizate vezi: R. Cont, „Empirical properties of asset returns: stylized facts and statistical issues”, *Quantitative finance*, Vol. 1, pp. 223-236, 2001.

ⁱⁱ Pentru mai multe informații privind analiza de tip cluster a criptomonedelor, vezi: J.Y. Song, W. Chang, J.W. Song, „Cluster analysis on the structure of the cryptocurrency market via Bitcoin-Ethereum filtering”, *Physica A: Statistical Mechanics and its applications*, Vol. 527, 2019.

ⁱⁱⁱ H. M. Markowitz, „Portfolio Selection”, *The Journal of Finance*, Vol. 7, nr. 1, pp. 77-91, 1952.

^{iv} <https://coinmarketcap.com/>

^v <https://finance.yahoo.com/cryptocurrencies?.tsrc=fin-srch>

^{vi} Excesul de kurtosis este definit de literatura de specialitate ca fiind o măsură ce compară coeficientul kurtosis al unei distribuții de serii de date cu cel al unei legi normale de distribuție.

Bibliografie

Bariviera, A.F., Basgall, M.J., Hasperue, W., Naiouf, M. (2017), *Some stylized facts of bitcoin market*, Physica A: Statistical Mechanics and its applications, Vol. 484, pp. 82-90.

CoinMarketCap: <https://coinmarketcap.com/>

da Cahuna, C.R., da Silva, R. (2020), *Relevant stylized facts about bitcoin: Fluctuations, first return probability and natural phenomena*, Physica A: Statistical Mechanics and its applications, Vol. 550.

Dragotă, V. Și colectiv (2009), *Gestiunea portofoliului de valori mobiliare*, Ediția a doua, Editura Economică, București.

Dyhrberg, A.H. (2016), *Hedging capabilities of bitcoin. It is the virtual gold?*, Finance research letters, Vol. 16, pp. 139-144.

Fama, E. (1970), *Efficient Capital Market: A Review of Theory and Empirical Work*, Journal of Finance, pp. 34-105.

Investopedia: <https://www.investopedia.com/>

Schumaker, R.P., Chen, H. (2009), *A quantitative stock prediction system based on financial news*, Information processing and management, Vol. 45, Issue 5, pp. 571-583.


Stancu, S. (2020), *Data Science în mediul R: Teorie și Aplicații*, Colecția Cibernetică, Editura ASE, București.


Takaishi, T. (2018), *Statistical properties and multifractality of bitcoin*, Physica A: Statistical Mechanics and its applications, Vol. 506, pp. 507-519.

Yahoo Finance: <https://finance.yahoo.com/cryptocurrencies?.tsrc=fin-srch>

ANEXE

Setul de grafice 1: Graficele aferente evoluției randamentelor pentru fiecare criptomonedă.





Sursa: Prelucrare proprie a datelor utilizând Eviews.

Tabel 1. Testarea staționarității seriilor de randamente.

Criptomoneda	Augumented Dickey-Fuller		Phillips-Perron	
	Adj. t-stat.	Prob.	Adj. t-stat.	Prob.
Bitcoin	-21,2523	0,0000***	-21,1137	0,0000***
Ethereum	-21,2953	0,0000***	-21,1611	0,0000***
Cardano	-21,3363	0,0000***	-21,1781	0,0000***
Binance coin	-21,0658	0,0000***	-20,9553	0,0000***
Tether	-12,4466	0,0000***	-120,7904	0,0001***
XRP	-20,1408	0,0000***	-20,1483	0,0000***
Chainlink	-20,4256	0,0000***	-20,3672	0,0000***
Litecoin	-20,8806	0,0000***	-20,8131	0,0000***
Stellar	-20,6034	0,0000***	-20,5341	0,0000***
Dogecoin	-19,2215	0,0000***	-19,4166	0,0000***
NEM	-20,8691	0,0000***	-20,7878	0,0000***
Monero	-22,6952	0,0000***	-22,3872	0,0000***
EOS	-22,5751	0,0000***	-22,4213	0,0000***
Tron	-20,8977	0,0000***	-20,8960	0,0000***
IOTA	-20,8402	0,0000***	-20,9930	0,0000***
VeChain	-20,8967	0,0000***	-20,7854	0,0000***
Dash	-17,9485	0,0000***	-17,9372	0,0000***
Decred	-21,1100	0,0000***	-21,0675	0,0000***
Zcash	-19,6486	0,0000***	-19,6371	0,0000***
Ethereum classic	-20,7154	0,0000***	-20,6567	0,0000***

***Semnificativ pentru un prag de semnificație de 1%

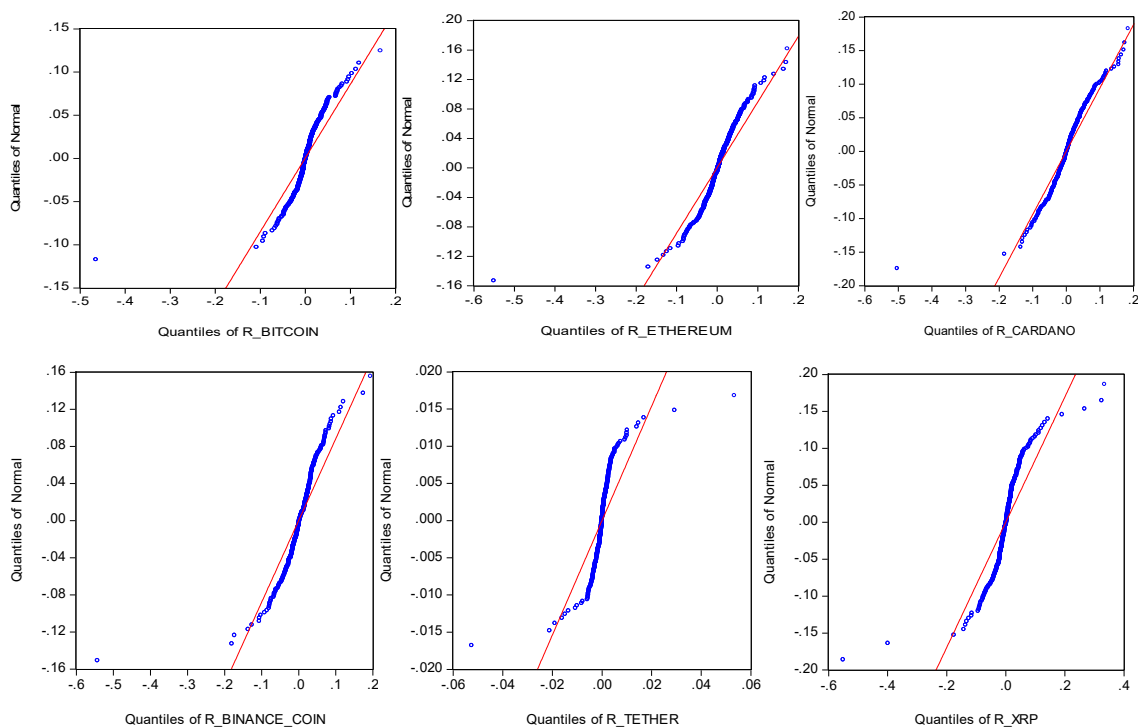
Sursa: Prelucrare proprie a datelor

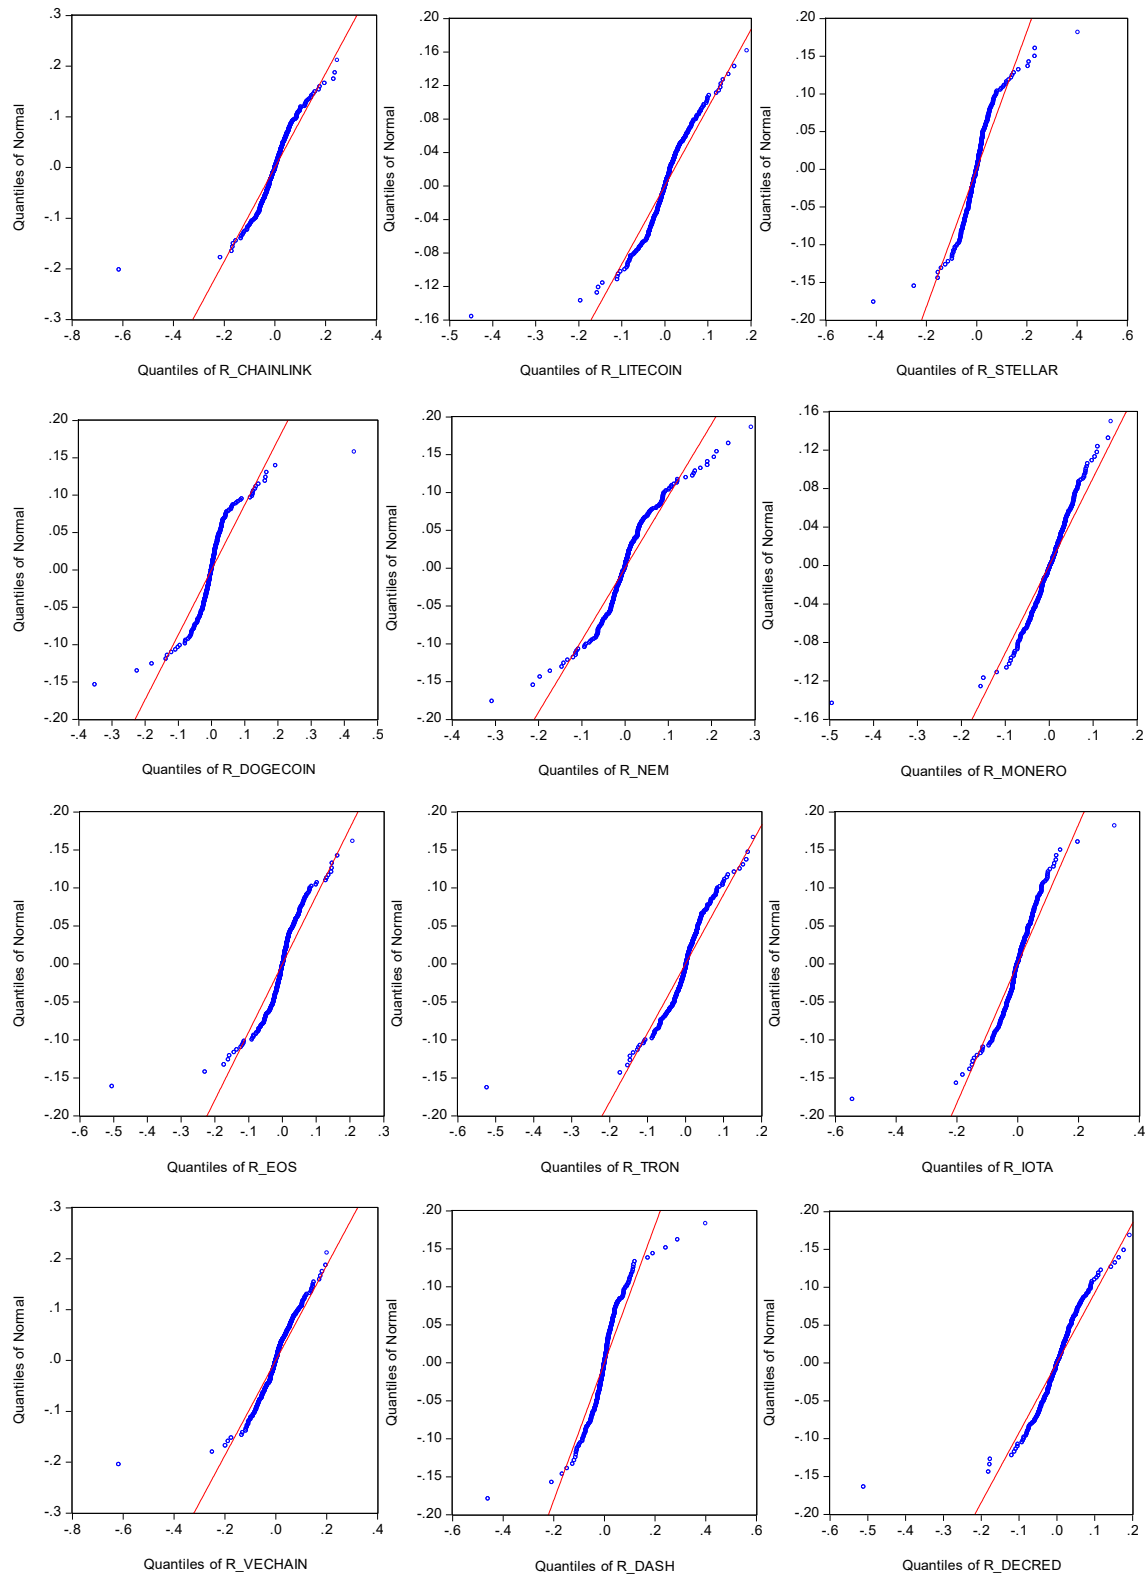
Tabel 2: Statisticile descriptive aferente seriilor de randamente ale criptomonedelor.

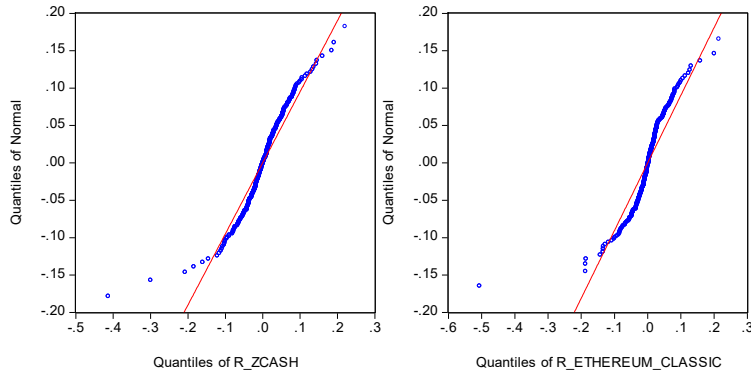
	Mean	Median	Maximum	Minimum	Std. dev.	Skewness	Kurtosis
Bitcoin	0,3732%	0,2664%	16,7104%	-46,4700%	4,0400%	-4,0346	52,8577
Ethereum	0,4400%	0,5100%	17,3452%	-55,0700%	5,2600%	-3,1827	37,1914
Cardano	0,4289%	0,4268%	18,3800%	-50,3638%	5,9600%	-1,4986	17,4865
Binance coin	0,2374%	0,3736%	19,3514%	-54,3084%	5,1267%	-3,44091	38,94275
Tether	0,0000%	0,0000%	5,3300%	-5,2500%	0,5600%	0,2848	48,5092
XRP	0,0338%	0,1859%	33,4399%	-55,0500%	6,2330%	-1,6358	28,4975
Chainlink	0,4573%	0,4995%	24,6300%	-61,4500%	6,9100%	-1,7155	21,2303
Litecoin	0,2882%	0,2629%	19,0930%	-44,9062%	5,3070%	-1,6668	18,1961
Stellar	0,2781%	0,3245%	40,3300%	-40,9900%	5,9800%	0,2617	16,2886
Dogecoin	0,2269%	0,1162%	42,9900%	-35,1300%	5,2100%	0,8072	22,9584
NEM	0,5100%	0,1600%	29,1800%	-30,7800%	6,0500%	0,2857	8,0209
Monero	0,3200%	0,6300%	14,0700%	-49,4200%	4,9000%	-2,9844	31,8177
EOS	0,0000%	0,1500%	20,8300%	-50,4200%	5,3900%	-2,3524	25,6371
Tron	0,1700%	0,3100%	17,8700%	-52,3100%	5,5000%	-2,4134	26,1011
IOTA	0,1700%	0,1000%	31,9100%	-54,3500%	6,0200%	-1,8381	23,4389
VeChain	0,3300%	0,3220%	20,1000%	-61,7200%	6,9500%	-1,9242	20,5117
Dash	0,2200%	0,2700%	39,9600%	-45,9300%	6,0500%	-0,0737	18,8626
Decred	0,2300%	0,3600%	19,2900%	-51,0800%	5,5500%	-2,1311	23,5468
Zcash	0,1900%	0,2200%	22,0200%	-41,2900%	6,0300%	-1,0915	11,3170
Ethereum classic	0,0520%	0,2270%	21,4100%	-50,6300%	5,5200%	-2,1964	23,8138

Sursa: Prelucrare proprie a datelor.

Setul de grafice 2: Graficele Q-Q aferente randamentelor fiecărei criptomonede.

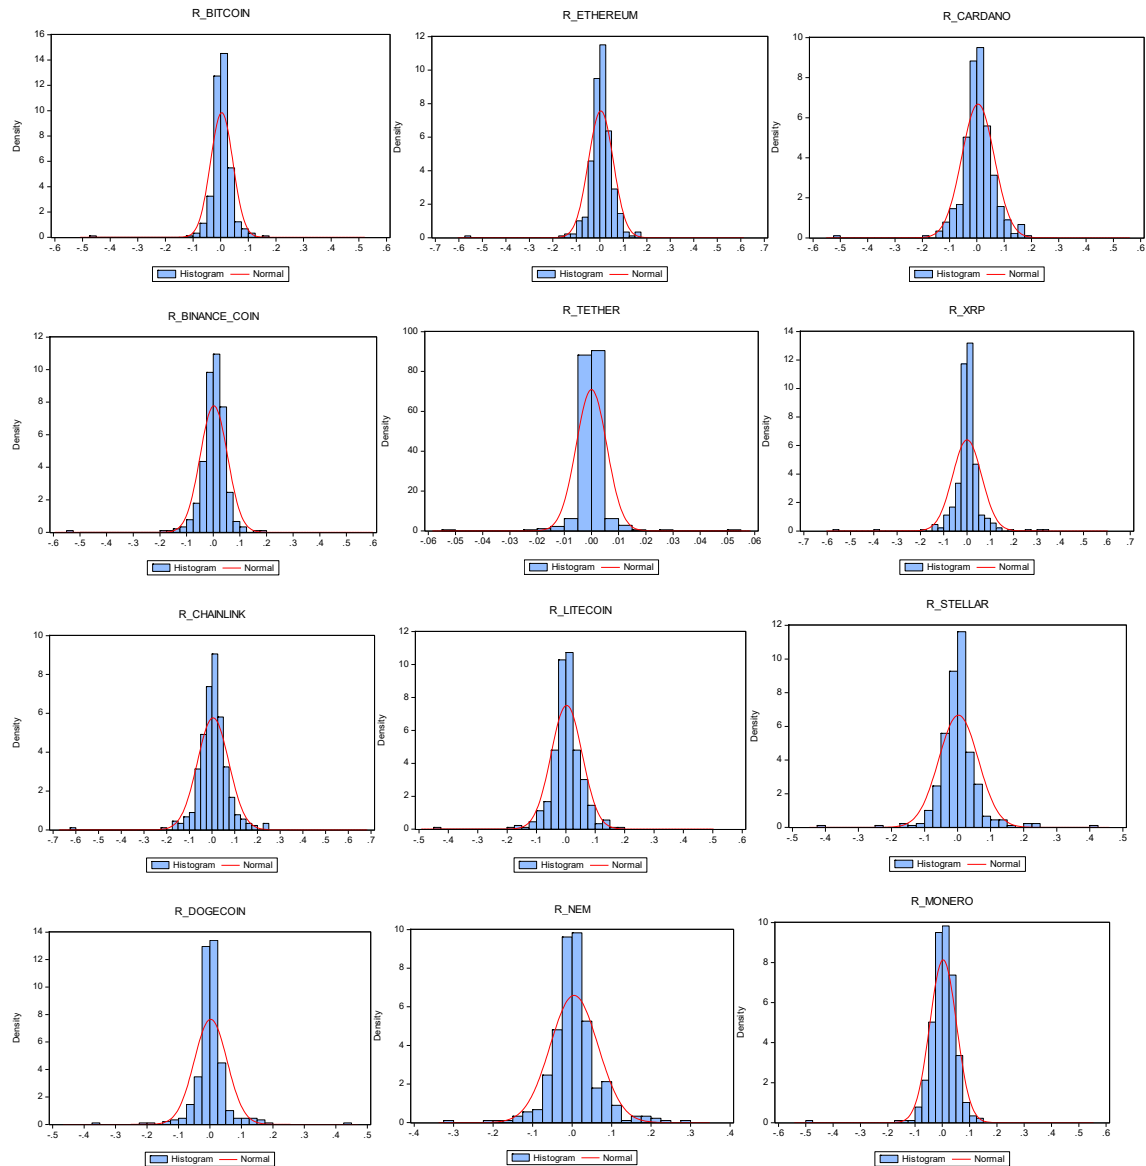


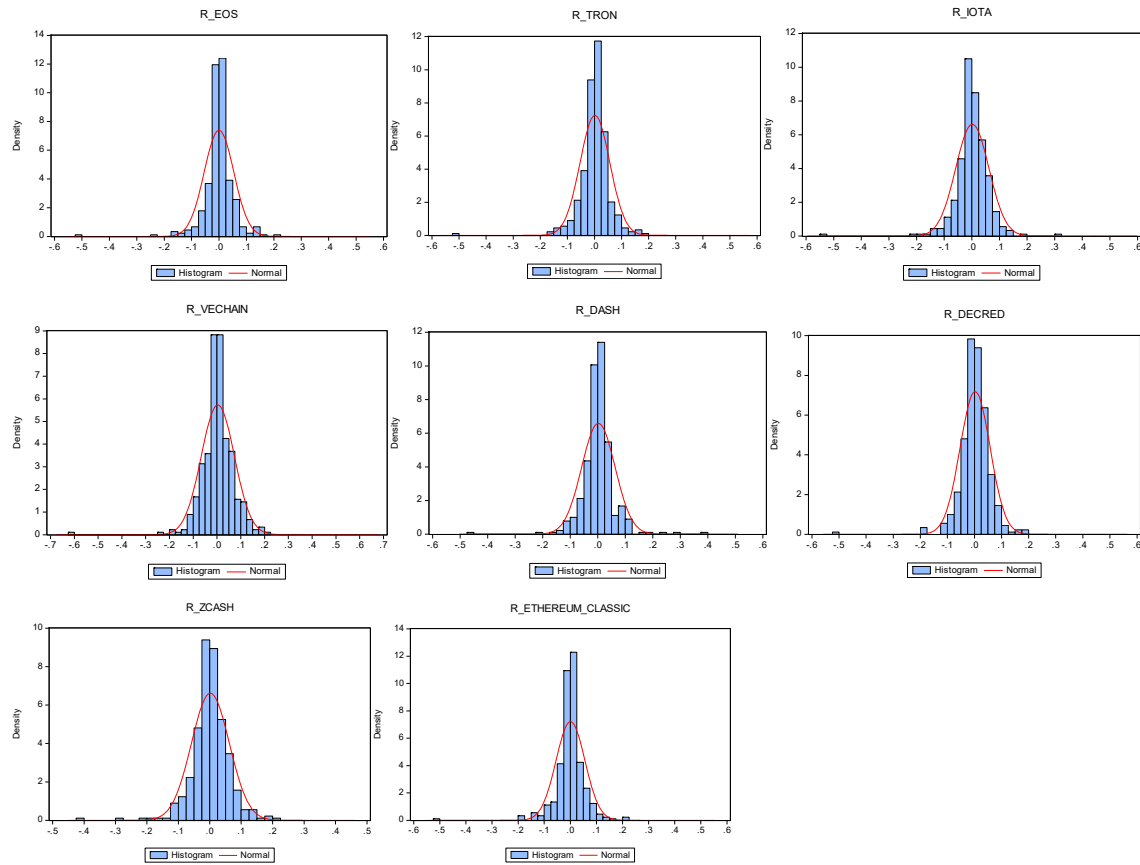




Sursa: Prelucrare proprie a datelor utilizând Eviews.

Setul de grafice 3: Comparația histogramei criptomonedelor cu legea normală de distribuție:





Sursa: Prelucrare proprie a datelor utilizând Eviews.

Tabelul 3: Teste de normalitate aplicate asupra seriei de randamente pentru fiecare criptomonedă.

Criptomoneda	Lilliefors (D)			Anderson-Darling (A2)			Jarque-Bera	
	Value	Adj. Value	Prob.	Value	Adj. Value	Prob.	Value	Prob.
Bitcoin	0,1449	NA	0,0000	13,6904	13,7193	0,0000	38050,99	0,0000
Ethereum	0,1105	NA	0,0000	8,9137	8,9326	0,0000	18042,78	0,0000
Cardano	0,0789	NA	0,0000	4,8536	4,8639	0,0000	3264,421	0,0000
Binance coin	0,1190	NA	0,0000	9,7549	9,7755	0,0000	19977,01	0,0000
Tether	0,1942	NA	0,0000	33,0075	33,0772	0,0000	30898,68	0,0000
XRP	0,1663	NA	0,0000	20,2636	20,3064	0,0000	9857,385	0,0000
Chainlink	0,0884	NA	0,0000	6,4448	6,4584	0,0000	5133,082	0,0000
Litecoin	0,1028	NA	0,0000	7,0055	7,0203	0,0000	3610,351	0,0000
Stellar	0,1309	NA	0,0000	10,7282	10,7509	0,0000	2638,193	0,0000
Dogecoin	0,1596	NA	0,0000	20,1390	20,1816	0,0000	5980,753	0,0000
NEM	0,1167	NA	0,0000	8,9690	8,9880	0,0000	380,9165	0,0000
Monero	0,0771	NA	0,0000	4,3934	4,4027	0,0000	12919,15	0,0000
EOS	0,1430	NA	0,0000	13,4853	13,5138	0,0000	7974,06	0,0000
Tron	0,1198	NA	0,0000	9,4834	9,5034	0,0000	8308,04	0,0000
IOTA	0,1015	NA	0,0000	7,1697	7,1848	0,0000	6433,05	0,0000
VeChain	0,0927	NA	0,0000	5,2092	5,2202	0,0000	4795,31	0,0000
Dash	0,1271	NA	0,0000	11,9680	11,9933	0,0000	3753,72	0,0000
Decred	0,0929	NA	0,0000	6,0091	6,0218	0,0000	6568,42	0,0000
Zcash	0,0898	NA	0,0000	5,4199	5,4314	0,0000	1102,91	0,0000
Ethereum classic	0,1276	NA	0,0000	12,0613	12,0867	0,0000	6749,97	0,0000

Sursa: Prelucrare proprie a datelor utilizând Eviews.

Tabelul 4: Rezultatele testelor de autocorelație a prețurilor.

Bitcoin												
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,968	342,240	0,000	0,977	348,310	0,000	0,977	348,470	0,000	0,966	340,440	0,000
2	0,939	664,710	0,000	0,955	682,270	0,000	0,959	685,180	0,000	0,936	660,830	0,000
3	0,913	970,390	0,000	0,935	1003,500	0,000	0,942	1010,600	0,000	0,915	968,040	0,000
4	0,887	1260,100	0,000	0,915	1311,900	0,000	0,926	1326,200	0,000	0,896	1263,700	0,000
5	0,863	1535,000	0,000	0,898	1609,800	0,000	0,913	1633,600	0,000	0,872	1544,100	0,000
6	0,838	1795,100	0,000	0,885	1900,000	0,000	0,900	1933,700	0,000	0,853	1813,400	0,000
7	0,818	2043,500	0,000	0,873	2183,200	0,000	0,889	2226,800	0,000	0,836	2072,600	0,000
8	0,800	2281,900	0,000	0,862	2460,100	0,000	0,876	2512,600	0,000	0,819	2322,500	0,000
9	0,783	2511,000	0,000	0,853	2731,500	0,000	0,867	2793,300	0,000	0,805	2564,100	0,000
10	0,765	2729,900	0,000	0,840	2995,900	0,000	0,855	3066,900	0,000	0,793	2799,800	0,000
11	0,748	2940,100	0,000	0,829	3253,800	0,000	0,845	3335,000	0,000	0,784	3030,700	0,000
12	0,730	3140,900	0,000	0,815	3504,100	0,000	0,832	3595,500	0,000	0,770	3253,700	0,000
13	0,709	3330,900	0,000	0,800	3745,400	0,000	0,818	3848,500	0,000	0,754	3468,500	0,000
14	0,689	3510,900	0,000	0,784	3977,900	0,000	0,805	4093,500	0,000	0,743	3677,600	0,000
Ethereum												
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,168	10,315	0,001	0,976	347,480	0,000	0,984	353,250	0,000	0,962	337,550	0,000
2	0,081	12,735	0,002	0,951	678,520	0,000	0,972	699,100	0,000	0,921	648,330	0,000
3	0,078	14,979	0,002	0,926	993,100	0,000	0,963	1039,800	0,000	0,881	933,480	0,000
4	0,102	18,783	0,001	0,899	1290,700	0,000	0,951	1372,700	0,000	0,840	1193,300	0,000
5	-0,104	22,798	0,000	0,872	1571,200	0,000	0,937	1696,700	0,000	0,802	1430,400	0,000
6	-0,182	35,023	0,000	0,846	1836,100	0,000	0,927	2014,500	0,000	0,765	1647,200	0,000
7	0,093	38,263	0,000	0,821	2086,100	0,000	0,917	2326,400	0,000	0,729	1844,500	0,000
8	0,059	39,562	0,000	0,792	2319,800	0,000	0,905	2631,200	0,000	0,702	2027,900	0,000
9	0,010	39,597	0,000	0,759	2535,000	0,000	0,893	2929,000	0,000	0,679	2200,300	0,000
10	-0,161	49,245	0,000	0,725	2731,800	0,000	0,882	3220,500	0,000	0,650	2358,700	0,000
11	-0,016	49,341	0,000	0,696	2913,400	0,000	0,872	3505,900	0,000	0,627	2506,100	0,000
12	0,033	49,754	0,000	0,664	3079,600	0,000	0,860	3784,100	0,000	0,597	2640,100	0,000
13	-0,101	53,628	0,000	0,633	3230,600	0,000	0,850	4056,800	0,000	0,561	2758,700	0,000
14	-0,052	54,669	0,000	0,602	3368,100	0,000	0,838	4322,500	0,000	0,528	2864,300	0,000
Cardano												
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,975	347,010	0,000	0,942	323,910	0,000	0,983	352,350	0,000	0,972	344,730	0,000
2	0,956	681,330	0,000	0,889	613,340	0,000	0,970	696,540	0,000	0,951	675,750	0,000
3	0,941	1006,100	0,000	0,855	881,810	0,000	0,956	1031,900	0,000	0,941	1001,000	0,000
4	0,914	1313,600	0,000	0,815	1126,500	0,000	0,940	1357,000	0,000	0,926	1316,400	0,000
5	0,885	1602,600	0,000	0,775	1348,100	0,000	0,922	1670,800	0,000	0,907	1619,700	0,000
6	0,861	1877,200	0,000	0,744	1553,100	0,000	0,906	1974,900	0,000	0,889	1912,300	0,000
7	0,834	2135,200	0,000	0,711	1740,800	0,000	0,890	2268,600	0,000	0,876	2197,100	0,000
8	0,808	2378,500	0,000	0,679	1912,300	0,000	0,871	2550,900	0,000	0,863	2474,000	0,000
9	0,784	2608,000	0,000	0,663	2076,200	0,000	0,854	2823,100	0,000	0,848	2742,700	0,000
10	0,757	2822,500	0,000	0,637	2227,900	0,000	0,832	3082,100	0,000	0,834	3002,900	0,000
11	0,735	3025,100	0,000	0,602	2364,100	0,000	0,810	3328,200	0,000	0,822	3256,600	0,000
12	0,711	3215,200	0,000	0,570	2486,600	0,000	0,789	3562,600	0,000	0,806	3501,000	0,000
13	0,683	3391,400	0,000	0,549	2600,400	0,000	0,765	3783,500	0,000	0,789	3736,100	0,000
14	0,659	3555,900	0,000	0,529	2706,300	0,000	0,742	3992,000	0,000	0,773	3962,400	0,000
Binance coin												
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,964	339,150	0,000	0,971	344,490	0,000	0,966	340,840	0,000	0,981	351,430	0,000
2	0,936	659,970	0,000	0,949	674,430	0,000	0,941	665,130	0,000	0,967	693,840	0,000
3	0,906	961,320	0,000	0,933	994,190	0,000	0,920	975,610	0,000	0,951	1025,700	0,000
4	0,879	1245,500	0,000	0,915	1302,700	0,000	0,899	1272,800	0,000	0,936	1348,500	0,000
5	0,845	1509,100	0,000	0,897	1599,300	0,000	0,875	1555,500	0,000	0,923	1662,700	0,000
6	0,816	1755,400	0,000	0,883	1887,900	0,000	0,856	1826,800	0,000	0,911	1970,000	0,000
7	0,786	1984,800	0,000	0,869	2168,100	0,000	0,836	2086,200	0,000	0,902	2272,200	0,000
8	0,760	2199,800	0,000	0,855	2440,200	0,000	0,817	2334,600	0,000	0,892	2568,600	0,000
9	0,735	2401,500	0,000	0,841	2704,000	0,000	0,794	2570,100	0,000	0,884	2860,400	0,000
10	0,710	2589,900	0,000	0,826	2959,300	0,000	0,771	2792,500	0,000	0,873	3146,000	0,000
11	0,685	2766,300	0,000	0,812	3207,100	0,000	0,749	3003,100	0,000	0,862	3424,900	0,000
12	0,663	2931,600	0,000	0,797	3446,100	0,000	0,725	3200,900	0,000	0,849	3696,400	0,000
13	0,638	3085,500	0,000	0,782	3676,900	0,000	0,700	3385,800	0,000	0,836	3960,000	0,000
14	0,611	3226,800	0,000	0,774	3903,700	0,000	0,675	3558,400	0,000	0,823	4216,300	0,000
Tether												
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,949	328,640	0,000	0,953	331,180	0,000	0,961	337,060	0,000	0,970	343,280	0,000
2	0,894	621,060	0,000	0,917	638,980	0,000	0,929	652,830	0,000	0,941	667,510	0,000
XRP												
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,975	347,010	0,000	0,942	323,910	0,000	0,983	352,350	0,000	0,972	344,730	0,000
2	0,956	681,330	0,000	0,889	613,340	0,000	0,970	696,540	0,000	0,951	675,750	0,000
3	0,941	1006,100	0,000	0,855	881,810	0,000	0,956	1031,900	0,000	0,941	1001,000	0,000
4	0,914	1313,600	0,000	0,815	1126,500	0,000	0,940	1357,000	0,000	0,926	1316,400	0,000
5	0,885	1602,600	0,000	0,775	1348,100	0,000	0,922	1670,800	0,000	0,907	1619,700	0,000
6	0,861	1877,200	0,000	0,744	1553,100	0,000	0,906	1974,900	0,000	0,889	1912,300	0,000
7	0,834	2135,200	0,000	0,711	1740,800	0,000	0,890	2268,600	0,000	0,876	2197,100	0,000
8	0,808	2378,500	0,000	0,679	1912,300	0,000	0,871	2550,900	0,000	0,863	2474,000	0,000
9	0,784	2608,000	0,000	0,663	2076,200	0,000	0,854	2823,100	0,000	0,848	2742,700	0,000
10	0,757	2822,500	0,000	0,637	2227,900	0,000	0,832	3082,100	0,000	0,834	3002,900	0,000
11	0,735	3025,100	0,000	0,602	2364,100	0,000	0,810	3328,200	0,000	0,822	3256,600	0,000
12	0,711	3215,200	0,000	0,570	2486,600	0,000	0,789	3562,600	0,000	0,806	3501,000	0,000
13	0,683	3391,400	0,000	0,549	2600,400	0,000	0,765	3783,500	0,000	0,789	3736,100	0,000
14	0,659	3555,900	0,000	0,529	2706,300	0,000	0,742	3992,000	0,000	0,773	3962,400	0,000
Chainlink												
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,975	347,010	0,000	0,942	323,910	0,000	0,983	352,350	0,000	0,972	344,730	0,000
2	0,956	681,330	0,000	0,889	613,340	0,000	0,970	696,540	0,000	0,951	675,750	0,000
3	0,941	1006,100	0,000	0,855	881,810	0,000	0,956	1031,900	0,000	0,941	1001,000	0,000
4	0,914	1313,600	0,000	0,815	1126,500	0,000	0,940	1357,000	0,000	0,926	1316,400	0,000
5	0,885	1602,600	0,000	0,775	1348,100	0,000	0,922	1670,800	0,000	0,907	1619,700	0,000
6	0,861	1877,200	0,000	0,744	1553,100	0,000	0,906	1974,900	0,000	0,889	1912,300	0,000
7	0,834	2135,200	0,000	0,711	1740,800	0,000	0,890	2268,600	0,000	0,876	2197,100	0,000
8	0,808	2378,500	0,000	0,679	1912,300	0,00						

3	0,849	885,930	0,000	0,884	926,110	0,000	0,904	953,070	0,000	0,912	972,970	0,000
4	0,811	1128,200	0,000	0,848	1190,900	0,000	0,881	1238,900	0,000	0,887	1262,300	0,000
5	0,768	1345,800	0,000	0,808	1431,700	0,000	0,855	1508,700	0,000	0,857	1533,500	0,000
6	0,725	1540,100	0,000	0,779	1656,000	0,000	0,829	1763,200	0,000	0,832	1789,400	0,000
7	0,686	1714,900	0,000	0,748	1863,500	0,000	0,809	2006,300	0,000	0,805	2029,900	0,000
8	0,649	1871,900	0,000	0,722	2057,800	0,000	0,787	2237,100	0,000	0,779	2255,600	0,000
9	0,615	2012,900	0,000	0,704	2242,900	0,000	0,764	2454,900	0,000	0,750	2465,700	0,000
10	0,577	2137,600	0,000	0,676	2414,200	0,000	0,741	2660,600	0,000	0,722	2661,100	0,000
11	0,542	2247,800	0,000	0,651	2573,500	0,000	0,719	2854,700	0,000	0,694	2841,900	0,000
12	0,506	2344,300	0,000	0,625	2720,700	0,000	0,694	3036,200	0,000	0,664	3007,900	0,000
13	0,467	2426,700	0,000	0,598	2855,700	0,000	0,670	3205,600	0,000	0,630	3157,700	0,000
14	0,432	2497,400	0,000	0,562	2975,300	0,000	0,644	3362,800	0,000	0,592	3290,300	0,000

Sursa: Prelucrare proprie a datelor utilizând Eviews.

Tabel 5: Rezultatele testelor de autocorelație a randamentelor criptomonedelor.

Lags	Bitcoin			Ethereum			Cardano			Binance coin		
	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	-0,126	5,718	0,017	-0,130	6,102	0,014	-0,129	6,018	0,014	-0,116	4,826	0,028
2	0,098	9,169	0,010	0,103	9,952	0,007	0,107	10,143	0,006	0,073	6,759	0,034
3	-0,089	12,061	0,007	-0,086	12,607	0,006	-0,031	10,485	0,015	-0,118	11,773	0,008
4	0,143	19,501	0,001	0,151	20,854	0,000	0,108	14,716	0,005	0,204	26,913	0,000
5	-0,013	19,561	0,002	-0,046	21,617	0,001	-0,042	15,348	0,009	-0,027	27,188	0,000
6	0,029	19,865	0,003	-0,010	21,655	0,001	0,008	15,371	0,018	0,018	27,311	0,000
7	-0,110	24,301	0,001	-0,098	25,151	0,001	-0,037	15,862	0,026	-0,135	33,974	0,000
8	-0,015	24,383	0,002	0,014	25,226	0,001	-0,012	15,913	0,044	-0,034	34,407	0,000
9	-0,008	24,407	0,004	-0,028	25,524	0,002	-0,015	16,001	0,067	-0,096	37,819	0,000
10	0,025	24,629	0,006	0,076	27,684	0,002	-0,016	16,095	0,097	-0,003	37,822	0,000
11	-0,071	26,527	0,005	-0,042	28,331	0,003	0,062	17,512	0,094	0,007	37,840	0,000
12	0,008	26,548	0,009	0,007	28,351	0,005	-0,050	18,447	0,103	-0,013	37,907	0,000
13	0,110	31,098	0,003	0,082	30,843	0,004	0,092	21,601	0,062	0,099	41,597	0,000
14	0,021	31,261	0,005	-0,021	31,004	0,006	-0,034	22,041	0,078	-0,080	44,003	0,000
Lags	Tether			XRP			Chainlink			Litecoin		
	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	-0,444	71,200	0,000	-0,072	1,846	0,174	-0,087	2,712	0,100	-0,107	4,109	0,043
2	-0,052	72,178	0,000	0,095	5,084	0,079	0,064	4,197	0,123	0,088	6,926	0,031
3	-0,016	72,267	0,000	0,020	5,223	0,156	0,004	4,203	0,240	-0,041	7,524	0,057
4	0,137	79,084	0,000	0,098	8,696	0,069	0,117	9,179	0,057	0,076	9,634	0,047
5	-0,077	81,275	0,000	-0,008	8,720	0,121	-0,011	9,224	0,100	-0,054	10,718	0,057
6	-0,215	98,129	0,000	0,039	9,270	0,159	0,002	9,226	0,161	0,007	10,735	0,097
7	0,189	111,210	0,000	0,023	9,464	0,221	-0,027	9,489	0,219	-0,048	11,574	0,115
8	0,011	111,250	0,000	0,091	12,497	0,130	-0,001	9,490	0,303	0,008	11,599	0,170
9	0,071	113,130	0,000	0,031	12,849	0,170	-0,083	12,040	0,211	-0,052	12,603	0,181
10	-0,192	126,740	0,000	-0,030	13,187	0,213	0,038	12,576	0,248	0,029	12,924	0,228
11	0,060	128,100	0,000	0,034	13,623	0,255	-0,002	12,578	0,322	0,011	12,968	0,295
12	0,110	132,580	0,000	-0,026	13,872	0,309	-0,103	16,538	0,168	-0,009	12,998	0,369
13	-0,112	137,250	0,000	-0,010	13,910	0,380	0,063	18,006	0,157	0,137	19,986	0,096
14	-0,076	139,400	0,000	-0,062	15,358	0,354	-0,033	18,416	0,188	-0,044	20,723	0,109
Lags	Stellar			Dogecoin			NEM			Monero		
	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	-0,094	3,179	0,075	-0,025	0,222	0,637	-0,106	4,080	0,043	-0,188	12,787	0,000
2	0,010	3,216	0,200	-0,098	3,674	0,159	-0,017	4,180	0,124	0,087	15,530	0,000
3	0,119	8,316	0,040	0,021	3,832	0,280	0,033	4,572	0,206	-0,061	16,877	0,001
4	0,134	14,810	0,005	0,052	4,806	0,308	0,109	8,920	0,063	0,174	27,845	0,000
5	-0,097	18,213	0,003	-0,103	8,644	0,124	-0,035	9,365	0,095	-0,013	27,906	0,000
6	0,069	19,949	0,003	0,013	8,705	0,191	0,051	10,333	0,111	-0,015	27,991	0,000
7	-0,055	21,053	0,004	-0,044	9,409	0,225	-0,050	11,268	0,127	-0,086	30,691	0,000
8	0,042	21,713	0,005	-0,044	10,129	0,256	0,013	11,329	0,184	0,015	30,776	0,000
9	-0,019	21,848	0,009	-0,047	10,955	0,279	0,076	13,490	0,142	0,026	31,026	0,000
10	-0,059	23,119	0,010	0,056	12,104	0,278	-0,008	13,516	0,196	0,011	31,069	0,001
11	0,012	23,174	0,017	0,002	12,105	0,356	-0,096	16,959	0,109	-0,013	31,129	0,001
12	0,000	23,175	0,026	-0,014	12,181	0,431	0,101	20,760	0,054	0,004	31,135	0,002
13	-0,037	23,695	0,034	0,010	12,219	0,510	-0,068	22,505	0,048	0,124	36,859	0,000

14	-0,121	29,225	0,010	0,012	12,269	0,585	0,000	22,505	0,069	-0,078	39,147	0,000
EOS			Tron			IOTA			VeChain			
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	-0,184	12,212	0,000	-0,108	4,211	0,040	-0,105	3,957	0,047	-0,108	4,234	0,040
2	0,083	14,723	0,001	0,031	4,548	0,103	-0,075	6,006	0,050	0,102	8,016	0,018
3	-0,073	16,639	0,001	-0,070	6,335	0,096	-0,058	7,217	0,065	-0,026	8,260	0,041
4	0,129	22,673	0,000	0,111	10,848	0,028	0,159	16,379	0,003	0,162	17,768	0,001
5	-0,062	24,080	0,000	-0,077	12,990	0,023	-0,036	16,846	0,005	-0,059	19,030	0,002
6	0,008	24,102	0,001	0,034	13,412	0,037	0,022	17,019	0,009	-0,034	19,459	0,003
7	-0,078	26,343	0,000	-0,078	15,631	0,029	-0,125	22,720	0,002	-0,009	19,489	0,007
8	0,017	26,444	0,001	0,008	15,655	0,048	0,076	24,840	0,002	-0,019	19,618	0,012
9	-0,009	26,477	0,002	-0,009	15,684	0,074	0,008	24,862	0,003	-0,008	19,641	0,020
10	-0,004	26,484	0,003	0,021	15,841	0,104	-0,004	24,867	0,006	0,058	20,903	0,022
11	-0,024	26,706	0,005	-0,016	15,934	0,144	-0,027	25,146	0,009	0,020	21,056	0,033
12	-0,022	26,888	0,008	-0,059	17,247	0,141	0,033	25,555	0,012	-0,026	21,308	0,046
13	0,074	28,917	0,007	-0,033	17,647	0,171	0,048	26,417	0,015	0,014	21,379	0,066
14	-0,030	29,258	0,010	-0,079	19,993	0,130	0,006	26,429	0,023	-0,012	21,430	0,091
Dash			Decred			Zcash			Ethereum classic			
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,043	0,658	0,417	-0,119	5,085	0,024	-0,045	0,716	0,397	-0,099	3,518	0,061
2	-0,034	1,086	0,581	0,038	5,611	0,060	0,023	0,912	0,634	0,075	5,542	0,063
3	-0,040	1,663	0,645	-0,074	7,581	0,056	-0,020	1,059	0,787	-0,101	9,237	0,026
4	0,078	3,894	0,421	0,141	14,813	0,005	0,033	1,444	0,837	0,141	16,517	0,002
5	0,062	5,283	0,382	-0,048	15,666	0,008	0,020	1,590	0,902	-0,044	17,238	0,004
6	-0,128	11,328	0,079	0,008	15,690	0,016	-0,071	3,441	0,752	0,042	17,870	0,007
7	-0,016	11,428	0,121	-0,106	19,814	0,006	-0,004	3,448	0,841	-0,055	18,973	0,008
8	-0,002	11,430	0,179	0,021	19,971	0,010	-0,050	4,350	0,824	0,052	19,952	0,011
9	0,028	11,716	0,230	0,078	22,197	0,008	-0,016	4,442	0,880	-0,050	20,882	0,013
10	0,014	11,788	0,299	-0,070	24,014	0,008	0,053	5,491	0,856	0,064	22,405	0,013
11	-0,012	11,838	0,376	-0,001	24,014	0,013	-0,022	5,668	0,895	0,000	22,405	0,021
12	0,043	12,528	0,404	0,018	24,132	0,020	0,017	5,780	0,927	0,042	23,076	0,027
13	0,032	12,906	0,455	0,101	27,941	0,009	0,135	12,597	0,479	0,075	25,199	0,022
14	-0,025	13,145	0,515	-0,068	29,653	0,009	-0,013	12,658	0,554	0,000	25,199	0,033

Sursa: prelucrare proprie a datelor utilizând Eviews.

Tabelul 6: Rezultatele testelor de autocorelație a randamentelor ridicate la pătrat.

Lags	Bitcoin			Ethereum			Cardano			Binance coin		
	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,036	0,458	0,499	0,078	2,177	0,140	0,089	2,841	0,092	0,036	0,458	0,499
2	0,004	0,465	0,793	0,006	2,190	0,335	0,019	2,972	0,226	0,004	0,465	0,793
3	0,009	0,497	0,920	-0,006	2,201	0,532	-0,002	2,974	0,396	0,009	0,497	0,920
4	0,119	5,623	0,229	0,126	7,953	0,093	0,082	5,410	0,248	0,119	5,623	0,229
5	0,015	5,703	0,336	-0,005	7,963	0,158	-0,005	5,418	0,367	0,015	5,703	0,336
6	0,000	5,703	0,457	0,005	7,971	0,240	-0,008	5,441	0,489	0,000	5,703	0,457
7	0,113	10,397	0,167	0,081	10,366	0,169	0,102	9,284	0,233	0,113	10,397	0,167
8	-0,007	10,413	0,237	-0,011	10,407	0,238	-0,020	9,425	0,308	-0,007	10,413	0,237
9	-0,001	10,414	0,318	-0,016	10,498	0,312	-0,030	9,761	0,370	-0,001	10,414	0,318
10	0,015	10,499	0,398	0,012	10,549	0,394	0,006	9,775	0,460	0,015	10,499	0,398
11	0,025	10,727	0,466	0,021	10,718	0,467	0,003	9,779	0,550	0,025	10,727	0,466
12	-0,002	10,728	0,552	-0,010	10,757	0,550	-0,025	10,018	0,614	-0,002	10,728	0,552
13	-0,017	10,833	0,625	-0,017	10,865	0,622	-0,030	10,354	0,665	-0,017	10,833	0,625
14	0,004	10,839	0,699	-0,012	10,917	0,693	-0,017	10,456	0,728	0,004	10,839	0,699
Lags	Tether			XRP			Chainlink			Litecoin		
	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,463	77,395	0,000	0,201	14,578	0,000	0,061	1,362	0,243	0,151	8,187	0,004
2	0,010	77,432	0,000	0,100	18,215	0,000	0,018	1,473	0,479	0,013	8,247	0,016
3	0,009	77,459	0,000	0,032	18,586	0,000	0,005	1,483	0,686	0,018	8,360	0,039
4	0,093	80,638	0,000	0,027	18,859	0,001	0,073	3,424	0,489	0,141	15,562	0,004
5	0,075	82,667	0,000	0,054	19,918	0,001	-0,005	3,432	0,634	0,002	15,563	0,008
6	0,127	88,604	0,000	0,016	20,010	0,003	-0,014	3,502	0,744	-0,003	15,567	0,016
7	0,136	95,393	0,000	0,094	23,238	0,002	0,049	4,386	0,734	0,077	17,757	0,013

8	0,005	95,402	0,000	0,016	23,327	0,003	-0,021	4,547	0,805	-0,012	17,812	0,023
9	0,008	95,424	0,000	-0,009	23,357	0,005	0,008	4,573	0,870	-0,014	17,888	0,036
10	0,010	95,464	0,000	-0,003	23,359	0,009	0,035	5,037	0,889	0,014	17,962	0,056
11	0,007	95,481	0,000	0,012	23,409	0,015	0,015	5,121	0,925	0,031	18,312	0,075
12	0,007	95,500	0,000	0,000	23,409	0,024	-0,012	5,177	0,952	-0,012	18,370	0,105
13	0,000	95,500	0,000	0,000	23,409	0,037	-0,008	5,201	0,971	-0,014	18,439	0,142
14	0,023	95,704	0,000	-0,004	23,414	0,054	0,003	5,204	0,983	-0,019	18,579	0,182
Stellar												
Dogecoin												
NEM												
Monero												
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,218	17,149	0,000	0,161	9,338	0,002	0,135	6,597	0,010	0,036	0,465	0,495
2	0,060	18,455	0,000	0,202	24,161	0,000	0,014	6,666	0,036	-0,016	0,558	0,757
3	0,186	31,040	0,000	0,059	25,419	0,000	-0,013	6,724	0,081	0,001	0,559	0,906
4	0,067	32,682	0,000	0,042	26,050	0,000	0,100	10,395	0,034	0,130	6,712	0,152
5	-0,007	32,700	0,000	0,046	26,830	0,000	0,055	11,493	0,042	0,004	6,717	0,243
6	-0,003	32,703	0,000	-0,014	26,899	0,000	0,112	16,084	0,013	-0,011	6,764	0,343
7	0,061	34,058	0,000	0,030	27,220	0,000	0,196	30,198	0,000	0,066	8,341	0,303
8	-0,008	34,084	0,000	-0,011	27,262	0,001	0,095	33,527	0,000	-0,009	8,373	0,398
9	-0,037	34,582	0,000	-0,021	27,422	0,001	-0,016	33,623	0,000	-0,009	8,404	0,494
10	0,022	34,769	0,000	0,025	27,654	0,002	0,007	33,640	0,000	0,019	8,540	0,576
11	0,008	34,790	0,000	-0,014	27,724	0,004	0,099	37,310	0,000	0,075	10,631	0,475
12	-0,017	34,902	0,000	-0,019	27,853	0,006	0,069	39,102	0,000	0,002	10,632	0,561
13	-0,015	34,991	0,001	-0,032	28,233	0,008	0,024	39,323	0,000	-0,011	10,676	0,638
14	0,006	35,005	0,001	-0,026	28,480	0,012	0,048	40,201	0,000	0,011	10,721	0,708
EOS												
Tron												
IOTA												
VeChain												
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,059	1,237	0,266	0,080	2,322	0,128	0,065	1,542	0,214	0,054	1,066	0,302
2	0,000	1,237	0,539	0,013	2,384	0,304	0,047	2,348	0,309	0,017	1,165	0,559
3	-0,008	1,260	0,739	0,008	2,407	0,492	0,069	4,061	0,255	-0,008	1,186	0,756
4	0,113	5,886	0,208	0,079	4,675	0,322	0,160	13,414	0,009	0,102	5,009	0,286
5	-0,002	5,887	0,317	0,012	4,728	0,450	0,029	13,712	0,018	0,007	5,026	0,413
6	-0,018	6,007	0,422	-0,014	4,797	0,570	0,002	13,714	0,033	-0,022	5,199	0,519
7	0,080	8,361	0,302	0,071	6,668	0,464	0,277	41,914	0,000	0,044	5,897	0,552
8	-0,011	8,406	0,395	-0,012	6,722	0,567	0,042	42,571	0,000	-0,020	6,043	0,642
9	-0,018	8,531	0,482	-0,017	6,832	0,655	-0,020	42,718	0,000	-0,026	6,294	0,710
10	0,002	8,532	0,577	0,018	6,953	0,730	0,027	42,979	0,000	0,007	6,313	0,788
11	0,014	8,608	0,658	0,023	7,153	0,787	0,048	43,824	0,000	0,007	6,331	0,850
12	-0,019	8,743	0,725	-0,011	7,202	0,844	-0,013	43,885	0,000	-0,013	6,390	0,895
13	-0,012	8,794	0,788	-0,015	7,287	0,887	-0,025	44,122	0,000	-0,025	6,630	0,920
14	-0,019	8,929	0,836	-0,003	7,291	0,923	-0,016	44,215	0,000	-0,019	6,769	0,943
Dash												
Decred												
Zcash												
Ethereum classic												
Lags	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.	ACF	Q-stat.	Prob.
1	0,138	6,889	0,009	0,039	0,558	0,455	0,042	0,630	0,427	0,145	7,542	0,006
2	0,040	7,479	0,024	-0,012	0,614	0,736	0,047	1,417	0,492	-0,005	7,551	0,023
3	0,025	7,698	0,053	0,007	0,630	0,890	0,015	1,503	0,682	0,042	8,197	0,042
4	0,132	14,068	0,007	0,132	7,021	0,135	0,085	4,144	0,387	0,166	18,229	0,001
5	0,025	14,288	0,014	-0,019	7,147	0,210	-0,035	4,579	0,469	0,005	18,239	0,003
6	0,184	26,732	0,000	-0,010	7,183	0,304	0,027	4,841	0,564	-0,015	18,317	0,005
7	0,007	26,751	0,000	0,114	11,942	0,102	0,005	4,852	0,678	0,039	18,881	0,009
8	-0,004	26,758	0,001	0,000	11,942	0,154	-0,044	5,552	0,697	0,006	18,892	0,015
9	-0,004	26,765	0,002	-0,009	11,969	0,215	-0,030	5,889	0,751	-0,009	18,925	0,026
10	0,060	28,100	0,002	0,001	11,969	0,287	0,025	6,123	0,805	0,028	19,211	0,038
11	0,020	28,254	0,003	-0,006	11,981	0,365	0,011	6,171	0,862	0,038	19,750	0,049
12	0,001	28,254	0,005	-0,002	11,983	0,447	-0,020	6,324	0,899	-0,011	19,794	0,071
13	-0,028	28,550	0,008	-0,005	11,994	0,528	-0,034	6,766	0,914	-0,009	19,824	0,100
14	-0,015	28,632	0,012	0,001	11,994	0,607	-0,035	7,236	0,925	-0,011	19,873	0,134

Sursa: Prelucrare proprie a datelor utilizând Eviews.

Tabel 7: Gruparea criptomonedelor în funcție de medie.

Partiție cu 2 clustere			Partiție cu 3 clustere			Partiție 4 clustere		
Criptomonedă	Media	Cluster	Criptomonedă	Media	Cluster	Criptomonedă	Media	Cluster
Bitcoin	0,3732%	1	Bitcoin	0,3732%	3	Bitcoin	0,3732%	1
Ethereum	0,4420%	1	Ethereum	0,4420%	3	Ethereum	0,4420%	4
Cardano	0,4289%	1	Cardano	0,4289%	3	Cardano	0,4289%	4
Binance coin	0,2374%	2	Binance coin	0,2374%	1	Binance coin	0,2374%	2
Tether	0,0009%	2	Tether	0,0009%	2	Tether	0,0009%	3
XRP	0,0338%	2	XRP	0,0338%	2	XRP	0,0338%	3
Chainlink	0,4573%	1	Chainlink	0,4573%	3	Chainlink	0,4573%	4
Litecoin	0,2882%	1	Litecoin	0,2882%	1	Litecoin	0,2882%	1
Stellar	0,2781%	1	Stellar	0,2781%	1	Stellar	0,2781%	1
Dogecoin	0,2269%	2	Dogecoin	0,2269%	1	Dogecoin	0,2269%	2
NEM	0,5113%	1	NEM	0,5113%	3	NEM	0,5113%	4
Monero	0,3209%	1	Monero	0,3209%	1	Monero	0,3209%	1
EOS	0,0058%	2	EOS	0,0058%	2	EOS	0,0058%	3
Tron	0,1793%	2	Tron	0,1793%	1	Tron	0,1793%	2
IOTA	0,1782%	2	IOTA	0,1782%	1	IOTA	0,1782%	2
VeChain	0,3381%	1	VeChain	0,3381%	3	VeChain	0,3381%	1
Dash	0,2286%	2	Dash	0,2286%	1	Dash	0,2286%	2
Decred	0,2390%	2	Decred	0,2390%	1	Decred	0,2390%	2
Zcash	0,1939%	2	Zcash	0,1939%	1	Zcash	0,1939%	2
Ethereum classic	0,0529%	2	Ethereum classic	0,0529%	2	Ethereum classic	0,0529%	3

Sursa: Prelucrare proprie a datelor utilizând RStudio.

Tabel 8: Gruparea criptomonedelor în funcție de abaterea medie pătratică.

Partiție cu 2 clustere			Partiție 3 clustere			Partiție 3 clustere		
Criptomonedă	SD	Cluster	Criptomonedă	SD	Cluster	Criptomonedă	SD	Cluster
Bitcoin	4,0481%	1	Bitcoin	4,0481%	1	Bitcoin	4,0481%	2
Ethereum	5,2697%	1	Ethereum	5,2697%	1	Ethereum	5,2697%	3
Cardano	5,9695%	1	Cardano	5,9695%	2	Cardano	5,9695%	4
Binance coin	5,1267%	1	Binance coin	5,1267%	1	Binance coin	5,1267%	3
Tether	0,5622%	2	Tether	0,5622%	3	Tether	0,5622%	1
XRP	6,2331%	1	XRP	6,2331%	2	XRP	6,2331%	4
Chainlink	6,9147%	1	Chainlink	6,9147%	2	Chainlink	6,9147%	4
Litecoin	5,3078%	1	Litecoin	5,3078%	1	Litecoin	5,3078%	3
Stellar	5,9854%	1	Stellar	5,9854%	2	Stellar	5,9854%	4
Dogecoin	5,2104%	1	Dogecoin	5,2104%	1	Dogecoin	5,2104%	3
NEM	6,0571%	1	NEM	6,0571%	2	NEM	6,0571%	4
Monero	4,9028%	1	Monero	4,9028%	1	Monero	4,9028%	3
EOS	5,3964%	1	EOS	5,3964%	1	EOS	5,3964%	3
Tron	5,5092%	1	Tron	5,5092%	1	Tron	5,5092%	3
IOTA	6,0227%	1	IOTA	6,0227%	2	IOTA	6,0227%	4
VeChain	6,9594%	1	VeChain	6,9594%	2	VeChain	6,9594%	4
Dash	6,0573%	1	Dash	6,0573%	2	Dash	6,0573%	4
Decred	5,5558%	1	Decred	5,5558%	1	Decred	5,5558%	3
Zcash	6,0335%	1	Zcash	6,0335%	2	Zcash	6,0335%	4
Ethereum classic	5,5260%	1	Ethereum classic	5,5260%	1	Ethereum classic	5,5260%	3

Sursa: Prelucrare proprie a datelor utilizând RStudio.

Tabel 9: Gruparea criptomonedelor în funcție de skewness.

Partiție 2 clustere			Partiție 3 clustere			Partiție 4 clustere		
Criptomoneda	Skewness	Cluster	Criptomoneda	Skewness	Cluster	Criptomoneda	Skewness	Cluster
Bitcoin	-4,0347	2	Bitcoin	-4,0347	3	Bitcoin	-4,0347	3
Ethereum	-3,1827	2	Ethereum	-3,1827	3	Ethereum	-3,1827	3
Cardano	-1,4987	2	Cardano	-1,4987	1	Cardano	-1,4987	4
Binance coin	-3,4409	2	Binance coin	-3,4409	3	Binance coin	-3,4409	3
Tether	0,2848	1	Tether	0,2848	2	Tether	0,2848	2
XRP	-1,6359	2	XRP	-1,6359	1	XRP	-1,6359	4
Chainlink	-1,7155	2	Chainlink	-1,7155	1	Chainlink	-1,7155	4
Litecoin	-1,6669	2	Litecoin	-1,6669	1	Litecoin	-1,6669	4
Stellar	0,2618	1	Stellar	0,2618	2	Stellar	0,2618	2
Dogecoin	0,8072	1	Dogecoin	0,8072	2	Dogecoin	0,8072	2
NEM	0,2858	1	NEM	0,2858	2	NEM	0,2858	2
Monero	-2,9845	2	Monero	-2,9845	3	Monero	-2,9845	3
EOS	-2,3524	2	EOS	-2,3524	1	EOS	-2,3524	1
Tron	-2,4135	2	Tron	-2,4135	1	Tron	-2,4135	1
IOTA	-1,8381	2	IOTA	-1,8381	1	IOTA	-1,8381	4
VeChain	-1,9243	2	VeChain	-1,9243	1	VeChain	-1,9243	1
Dash	0,0737	1	Dash	0,0737	2	Dash	0,0737	2
Decred	-2,1311	2	Decred	-2,1311	1	Decred	-2,1311	1
Zcash	-1,0916	2	Zcash	-1,0916	1	Zcash	-1,0916	4
Ethereum classic	-2,1965	2	Ethereum classic	-2,1965	1	Ethereum classic	-2,1965	1

Sursa: Prelucrare proprie a datelor utilizând RStudio.

Tabel 10: Gruparea criptomonedelor în funcție de kurtosis.

Partiție 2 clustere			Partiție 3 clustere			Partiție 4 clustere		
Criptomoneda	Kurtosis	Cluster	Criptomoneda	Kurtosis	Cluster	Criptomoneda	Kurtosis	Cluster
Bitcoin	52,8577	1	Bitcoin	52,8577	1	Bitcoin	52,8577	1
Ethereum	37,1914	1	Ethereum	37,1914	1	Ethereum	37,1914	4
Cardano	17,4865	2	Cardano	17,4865	3	Cardano	17,4865	2
Binance coin	38,9428	1	Binance coin	38,9428	1	Binance coin	38,9428	4
Tether	48,5093	1	Tether	48,5093	1	Tether	48,5093	1
XRP	28,4976	2	XRP	28,4976	2	XRP	28,4976	3
Chainlink	21,2303	2	Chainlink	21,2303	2	Chainlink	21,2303	3
Litecoin	18,1961	2	Litecoin	18,1961	3	Litecoin	18,1961	2
Stellar	16,2886	2	Stellar	16,2886	3	Stellar	16,2886	2
Dogecoin	22,9584	2	Dogecoin	22,9584	2	Dogecoin	22,9584	3
NEM	8,0209	2	NEM	8,0209	3	NEM	8,0209	2
Monero	31,8177	2	Monero	31,8177	2	Monero	31,8177	4
EOS	25,6371	2	EOS	25,6371	2	EOS	25,6371	3
Tron	26,1012	2	Tron	26,1012	2	Tron	26,1012	3
IOTA	23,4390	2	IOTA	23,4390	2	IOTA	23,4390	3
VeChain	20,5118	2	VeChain	20,5118	2	VeChain	20,5118	3
Dash	18,8627	2	Dash	18,8627	3	Dash	18,8627	2
Decred	23,5469	2	Decred	23,5469	2	Decred	23,5469	3
Zcash	11,3170	2	Zcash	11,3170	3	Zcash	11,3170	2
Ethereum classic	23,8138	2	Ethereum classic	23,8138	2	Ethereum classic	23,8138	3

Sursa: Prelucrare proprie a datelor utilizând RStudio.