Anita Grubišić, univ. mag. oec.[1]
Matija Blaće, mag. oec.[2]

# KRIPTOVALUTE I OPTIMIZACIJA INVESTICIJSKOG PORTFELJA: ANALIZA DIVERZIFIKACIJSKIH UČINAKA

*Pregledni rad / Review paper*
*UDK / UDC: 336.74:004*
*DOI: 10.51650/ezrvs.20.1-2.11*
*Primljeno / Received: 11/05/2026*
*Prihvaćeno / Accepted: 02/07/2026*

*S obzirom na izniman rast tržišne kapitalizacije i sve veću institucionalnu prihvaćenost, kriptovalute su postale nezaobilazan element suvremenih financijskih tržišta. Svrha ovog rada je analizirati ulogu kriptovaluta, prvenstveno Bitcoina i Ethereuma, u diverzifikaciji i performansama investicijskog portfelja prilagođenim riziku. U radu se primjenjuje narativni i komparativni pregled recentnih empirijskih studija, dopunjen ilustrativnim empirijskim elementima (korelacijska matrica i efikasna granica preuzeti iz ranijih istraživanja), kako bi se utvrdilo mogu li kriptovalute poslužiti kao efikasan instrument za diverzifikaciju. Pregled literature pokazuje da uključivanje kriptovaluta u tradicionalne portfelje (dionice, obveznice, zlato) može poboljšati Sharpeov omjer i ukupne performanse, unatoč njihovoj inherentno visokoj volatilnosti. Ovaj fenomen u literaturi se povezuje s relativno niskom korelacijom kriptoimovine s pojedinim tradicionalnim financijskim instrumentima, prije svega obveznicama i zlatom. Međutim, komparativna analiza metodoloških pristupa otkriva da klasični Markowitzev model srednje varijance nije adekvatan za kriptovalute zbog asimetričnih distribucija i rizika debelih repova. Stoga se za optimizaciju preporučuje primjena naprednih modela poput GARCH-Copula i uvjetne vrijednosti rizika (CVaR). Na temelju pregleda literature zaključuje se da kriptovalute djeluju ponajprije kao diverzifikator, ali ne nužno i kao sigurno utočište u razdobljima ekstremnih tržišnih šokova, te se preporučuje njihova ograničena alokacija u portfelju.*

***Ključne riječi:*** *kriptovalute; optimizacija portfelja; diverzifikacija; upravljanje rizikom; Bitcoin.*

[1] Viši predavač; Veleučilište u Šibeniku, Trg Andrije Hebranga 11, 22000 Šibenik, Republika Hrvatska; e-mail: anita.grubisic@vus.hr
[2] Student sveučilišnog specijalističkog studija (MBA), Ekonomski fakultet Sveučilišta u Rijeci, Ivana Filipovića 4, 51000 Rijeka, Hrvatska; e-mail: matijablace@gmail.com

## 1. Uvod

U posljednjem desetljeću financijska tržišta svjedoče paradigmatskoj promjeni potaknutoj pojavom i razvojem blockchain tehnologije i kriptovaluta. Od prve transakcije Bitcoinom 2010. godine do dosezanja tržišne kapitalizacije od gotovo tri bilijuna američkih dolara 2021. godine (Gorman i Hughen, 2024), kriptovalute su evoluirale iz tehnološkog eksperimenta u legitimnu klasu investicijske imovine (Jurić i sur., 2025). S obzirom na sve veći interes kako individualnih tako i institucionalnih investitora, raste i broj akademskih istraživanja koja se bave njihovom implementacijom u investicijske portfelje (Gulyás i sur., 2025).

Temeljni problem s kojim se investitori suočavaju pri razmatranju kriptovaluta jest njihova ekstremna volatilnost i regulatorna neizvjesnost (Boido i Aliano, 2025). Za razliku od tradicionalnih alternativnih izvora financiranja, poput crowdfundinga koji je doživio procvat nakon financijske krize 2008. godine kao odgovor na otežan pristup kapitalu (Blaće i Grubišić, 2016), kriptovalute ne posjeduju intrinzičnu vrijednost niti su podržane materijalnom aktivom (Šoja i Senarathne, 2019; Rashid i sur., 2023). Unatoč tome, njihova niska korelacija s tradicionalnim financijskim instrumentima čini ih potencijalno atraktivnim alatom za diverzifikaciju portfelja (Alihodžić, 2023; Rashid i sur., 2023).

Svrha ovog rada je analizirati ulogu kriptovaluta u performansama i diverzifikaciji investicijskog portfelja. Rad odgovara na sljedeće istraživačko pitanje: poboljšavaju li kriptovalute, prema nalazima dosadašnje literature, performanse portfelja prilagođene riziku, i pod kojim metodološkim uvjetima? U radu je primijenjen narativni i komparativni pregled recentnih empirijskih studija, dopunjen ilustrativnim empirijskim prikazima (korelacijska matrica i efikasna granica) preuzetima iz ranijih istraživanja autora i drugih izvora.

Rad je strukturiran u pet poglavlja. Nakon uvoda, u drugom poglavlju iznosi se teorijski okvir. Treće poglavlje analizira metodološke pristupe optimizaciji, dok četvrto poglavlje donosi sintezu empirijskih nalaza uz vizualizaciju korelacijskih matrica i efikasne granice. Rad završava zaključkom i preporukama za investitore.

## 2. Teorijski okvir i karakteristike kriptoimovine

Moderna teorija portfelja (engl. *Modern Portfolio Theory*, MPT), koju je 1952. godine utemeljio Harry Markowitz, počiva na pretpostavci da investitori mogu konstruirati „efikasnu granicu" portfelja koja maksimizira očekivani prinos za zadanu razinu rizika, mjerenog varijancom ili standardnom devijacijom. Iako se naziva „modernom", ovaj je okvir povijesno utemeljen i danas, u uvjetima algoritamskog ulaganja i primjene umjetne inteligencije, predstavlja polazišnu, a ne suvremenu metodologiju, što je posebno izraženo u kontekstu kriptoimovine (vidjeti poglavlje 3.2.). Ključni mehanizam za postizanje ovog cilja je diverzifikacija, odnosno kombiniranje imovine koja nije savršeno pozitivno korelirana (Šoja i Senarathne, 2019).

### *2.1. Kriptovalute kao nova klasa imovine*

Kriptovalute su se afirmirale ne samo kao sredstvo razmjene, već i kao značajan alat za diverzifikaciju investicijskih portfelja, unatoč njihovoj inherentnoj volatilnosti (Jurić i sur., 2025). Analiza ponašanja Bitcoina u kombinaciji s tradicionalnom imovinom, poput dionica, zlata i obveznica, pokazuje da on može služiti kao efikasan diverzifikator upravo zbog niske korelacije s tim klasama imovine (Alihodžić, 2023). Ova niska korelacija, u kombinaciji s povijesno visokim prinosima, omogućuje Bitcoinu da, čak i u malim udjelima, značajno poboljša kompromis između rizika i prinosa unutar portfelja.

Za razliku od dionica koje predstavljaju vlasnički udio u poduzeću i generiraju dividende, ili obveznica koje nose fiksni prinos, kriptovalute nemaju temeljne novčane tokove (engl. *cash flows*). Njihova vrijednost primarno je određena dinamikom ponude i potražnje, mrežnim efektima (Metcalfeov zakon) i troškovima rudarenja (kod Proof-of-Work sustava). Ova fundamentalna razlika u mehanizmu formiranja cijena glavni je razlog zašto kriptovalute pokazuju nisku korelaciju s makroekonomskim varijablama koje inače pokreću tradicionalna tržišta kapitala (Platanakis i Urquhart, 2020).

### *2.2. Regulatorni rizici i institucionalizacija*

Integracija kriptovaluta u tradicionalne financijske tokove nosi i regulatorne izazove. Slično kao što je rano tržište crowdfundinga u Kini bilo obilježeno prijevarama poput Ezubao skandala zbog nedostatka regulative (Blaće i Grubišić, 2017a), tako je i kripto tržište doživjelo kolapse poput Terra Lune i FTX burze. Stoga je prelazak prema reguliranim modelima, poput ponuda sigurnosnih tokena (engl. *Security Token Offering*, STO) i implementacije Uredbe o tržištima kriptoimovine (engl. *Markets in Crypto-Assets Regulation*, MiCA) u Europskoj uniji, ključan za dugoročnu institucionalnu prihvaćenost ove klase imovine (Blaće i Grubišić, 2017b). STO podrazumijeva izdavanje digitalnih tokena koji predstavljaju vlasnička ili dužnička prava i podliježu propisima o vrijednosnim papirima, dok MiCA predstavlja jedinstveni regulatorni okvir EU-a kojim se uređuje izdavanje i trgovanje kriptoimovinom. Institucionalizacija tržišta, vidljiva kroz odobrenje spot Bitcoin i Ethereum ETF-ova u SAD-u, dodatno smanjuje informacijsku asimetriju i olakšava pristup tradicionalnim investitorima.

## 3. Metodologija

Ovaj rad pregledno-komparativnog je karaktera s ilustrativnim empirijskim elementima. Primijenjena je metoda narativnog i komparativnog pregleda literature, a ne sustavni pregled u užem (PRISMA) smislu, budući da rad ne provodi formalni protokol pretraživanja s unaprijed definiranim kriterijima pretraživanja i selekcije literature. Pregledom su obuhvaćeni recentni radovi (pretežno objavljeni u razdoblju 2019.–2025.) pronađeni u bazama Google Scholar, Scopus i Web of Science, uz korištenje ključnih riječi poput „cryptocurrency portfolio diversification“, „Bitcoin safe haven“ i „crypto portfolio optimization“; u pregled su uključeni radovi tematski izravno vezani uz diverzifikacijska, hedge i safe-haven svojstva kriptovaluta te metodologiju optimizacije portfelja. U prvom dijelu (podpoglavlje 3.1.) opisuju se ilustrativni empirijski prikazi preuzeti iz ranijih istraživanja. U drugom dijelu (podpoglavlja 3.2. i 3.3.) daje se pregled metodoloških pristupa prisutnih u recentnoj literaturi, s ciljem kontekstualizacije nalaza i identifikacije ograničenja primijenjenih metoda.

### *3.1. Ilustrativni empirijski prikazi preuzeti iz ranijih istraživanja*

U empirijskom dijelu rada (poglavlje 4) ne provodi se nova vlastita optimizacija portfelja, nego se preuzimaju i ilustrativno prikazuju korelacijske analize iz prethodnog istraživanja autora (Jurić i sur., 2025). Korelacijska matrica stoga nije rezultat samostalno provedene analize u ovom radu, već je preuzeta iz navedenog izvora. U tom istraživanju primijenjena je Spearmanova korelacijska analiza na godišnjim prinosima sljedeće četiri klase imovine: dionički indeks S&P 500, Bitcoin, desetogodišnje američke državne obveznice (10-year U.S. Treasury bonds) i zlato. Razdoblje analize obuhvaća 11 godina (2013.-2023.). Podaci su preuzeti s platforme Yahoo Finance (za dionice, Bitcoin i zlato) te s U.S. Department of the Treasury (za prinose obveznica). Godišnji prinosi izračunati su kao logaritamski prinosi kako bi se djelomično ublažio problem vremenske nesumjerljivosti. Spearmanova korelacija odabrana je umjesto Pearsonove zbog neispunjavanja pretpostavke normalnosti distribucije prinosa kriptovaluta, što je potvrđeno Jarque-Bera testom ($p<0.01$ za sve godine promatranja).

Vizualizacija efikasne granice portfelja (Grafikon 2) nije rezultat samostalno provedene optimizacije portfelja, nego je konstruirana isključivo ilustrativno (shematski prikaz u programu Microsoft Excel) na temelju sljedećih ulaznih parametara preuzetih iz navedenog istraživanja i radova Boido i Aliano (2025) te Šoja i Senarathne (2019.): očekivani godišnji prinos tradicionalnog portfelja (dionice 60%, obveznice 30%, zlato 10%) iznosi 7,2% uz volatilnost od 9,8%; očekivani godišnji prinos portfelja s 5% alokacijom u kriptovalute (3% BTC, 2% ETH) iznosi 11,5% uz volatilnost od 10,4%. Navedene vrijednosti služe isključivo u ilustrativne svrhe i ne predstavljaju prognozu budućih prinosa.

### *3.2. Ograničenja klasičnih modela i mjera rizika u kontekstu kriptovaluta*

Tradicionalne mjere rizika, poput varijance i standardne devijacije, ne mogu adekvatno uhvatiti ekstremne događaje i repne rizike (tail risks) prisutne na tržištu kriptovaluta (Petukhina i sur., 2021). Iako uključivanje Bitcoina u portfelj može rezultirati superiornijim Sharpeovim omjerima u usporedbi s baznim portfeljima (Roška i Otročak, 2023), u periodima ekstremne volatilnosti primijećeno je pogoršanje tog omjera zbog nedovoljne kompenzacije za eksponencijalni rast cijene (Koutmos i Payne, 2021). Slično tome, klasični Value at Risk (VaR) model često podcjenjuje stvarne gubitke jer pretpostavlja normalnost distribucije i ne mjeri veličinu gubitka izvan utvrđene granice pouzdanosti (Šoja i Senarathne, 2019).

Primjena klasičnih modela optimizacije na portfelje koji uključuju kriptovalute pokazala se problematičnom zbog specifičnih statističkih svojstava ove klase imovine. Markowitzev model pretpostavlja normalnu distribuciju prinosa, što kod kriptovaluta redovito nije slučaj – kriptoimovina pokazuje izraženu asimetriju, visoku zaobljenost (kurtozu) i fenomen grupiranja volatilnosti (Wu i Yueh, 2025). Razumijevanje ovih ograničenja ključno je za ispravnu interpretaciju rezultata dobivenih u poglavlju 4.

### *3.3. Napredni ekonometrijski modeli u literaturi: GARCH i Copula*

Kako bi se prevladala ograničenja opisana u prethodnom potpoglavlju, suvremena empirijska istraživanja implementiraju napredne statističke modele koji nadilaze opseg ovog rada, ali čije razumijevanje je nužno za kontekstualizaciju dobivenih rezultata i smjernice za buduća istraživanja. Integracija modela poput GARCH-EVT-Copula-CVaR[3]pruža sveobuhvatan okvir za modeliranje volatilnosti ovisne o vremenu, poboljšanu procjenu repnog rizika i modeliranje nelinearnih ovisnosti među imovinom (Kyalo i sur., 2025). Ovi modeli omogućuju precizniju procjenu ranjivosti portfelja na sistemski rizik, posebice kod kriptovaluta (Clément, 2024).

Posebno se ističe primjena Conditional Value at Risk (CVaR) ili očekivanog manjka (engl. *Expected Shortfall*), koji za razliku od VaR-a mjeri prosječan gubitak u onim slučajevima kada gubitak premaši VaR granicu. U kombinaciji s Copula funkcijama koje modeliraju zavisnost u ekstremnim tržišnim uvjetima (kada korelacije teže konvergiranju prema jedinici), ovi modeli pružaju znatno robusniju osnovu za alokaciju kapitala (Jeleskovic i sur., 2023). Usporedba osnovnih obilježja, prednosti i ograničenja navedenih metodoloških pristupa optimizaciji portfelja s kriptovalutama sažeto je prikazana u Tablici 1.

Tablica 1. Komparativna analiza metodoloških pristupa optimizaciji portfelja

| **Metodološki pristup** | **Prednosti** | **Ograničenja za kriptovalute** |
|---|---|---|
| Markowitz (Mean-Variance) | Jednostavnost, intuitivnost, široka primjena u praksi | Pretpostavlja normalnu distribuciju, ignorira repne rizike i asimetriju |
| Value at Risk (VaR) | Kvantificira maksimalni gubitak u normalnim uvjetima | Ne mjeri gubitke izvan VaR granice (ekstremni šokovi) |
| Conditional VaR (CVaR) | Precizno mjeri očekivani gubitak u ekstremnim uvjetima | Računalno zahtjevniji, visoko osjetljiv na kvalitetu ulaznih podataka |
| GARCH-Copula modeli | Hvata nelinearne ovisnosti i grupiranje volatilnosti | Visoka kompleksnost implementacije i interpretacije rezultata |

Izvor: Obrada autora prema Aljinović i sur. (2021) i Kyalo i sur. (2025)

## 4. Sinteza empirijskih nalaza iz literature: kriptovalute u portfelju

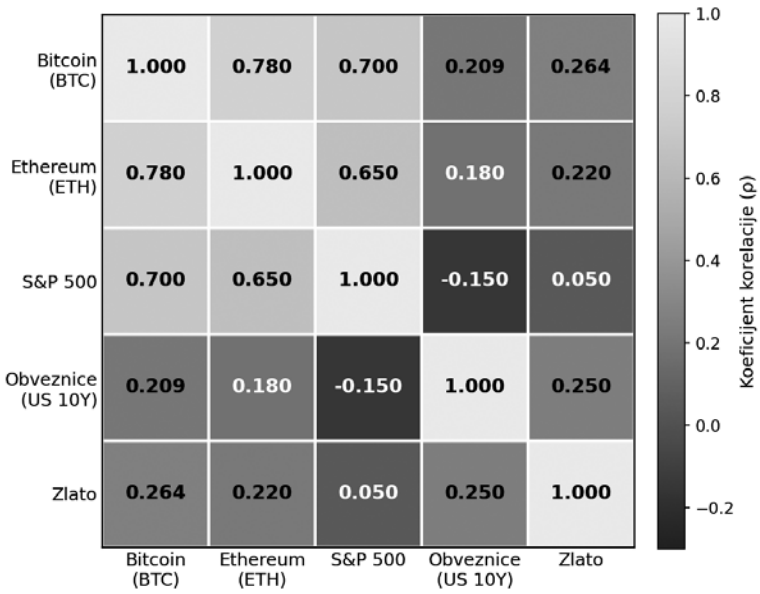
Pregled empirijske literature otkriva konsenzus o diverzifikacijskim prednostima kriptovaluta, ali uz značajne ograde vezane uz upravljanje rizikom i promjene u korelacijskoj dinamici tijekom vremena.

[3] Kombinacija modela uvjetne heteroskedastičnosti GARCH (engl. *Generalized Autoregressive Conditional Heteroskedasticity*), teorije ekstremnih vrijednosti EVT (engl. *Extreme Value Theory*), copula funkcija za modeliranje ovisnosti i uvjetne vrijednosti rizika CVaR (engl. *Conditional Value at Risk*).

### *4.1. Diverzifikacijski učinci i optimalna alokacija*

Empirijske analize su pokazale da portfelji s alokacijama kriptovaluta dosljedno nadmašuju portfelje bez kriptovaluta u smislu Sharpeovih omjera u značajnom postotku promatranih razdoblja (Boido i Aliano, 2025). Jurić i sur. (2025) u svojoj analizi za razdoblje 2013.-2023. utvrđuju da Bitcoin pokazuje umjerenu do visoku pozitivnu korelaciju s dioničkim indeksom S&P 500 (ρ = 0,700), koja se ne može smatrati niskom, dok korelacije s obveznicama i zlatom nisu statistički značajne. Diverzifikacijski učinci kriptovaluta stoga se prvenstveno odnose na njihov odnos s obveznicama i zlatom, a ne s dionicama, te ovise o promatranom razdoblju i tržišnim uvjetima.

*Grafikon 1. Korelacijska matrica kriptovaluta i tradicionalne imovine (2013.-2023.)*

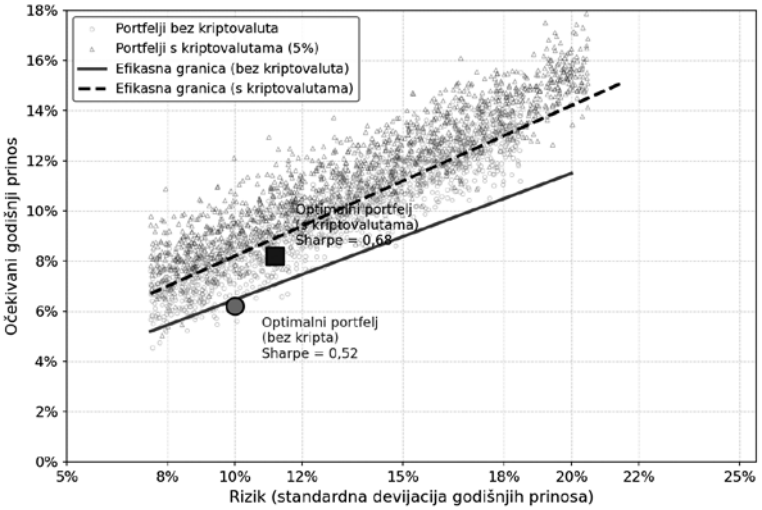



Izvor: Vlastita vizualizacija autora na temelju rezultata korelacijske analize iz Jurić i sur. (2025) i Boido i Aliano (2025)

Napomena: Boje u korelacijskoj matrici označavaju smjer i intenzitet korelacije. Tamniji tonovi sive označavaju niže odnosno negativne korelacije, a svjetliji tonovi više pozitivne korelacije.

Kao što je vidljivo iz Grafikona 1, niska korelacija kriptovaluta s obveznicama i zlatom predstavlja temelj za njihovu ulogu u diverzifikaciji. Postavlja se pitanje optimalne proporcije kriptovaluta unutar portfelja. Istraživanja sugeriraju da uključivanje malog udjela (obično između 1% i 5%) optimizira omjer rizika i prinosa (Šoja i Senarathne, 2019; Azouzi i Mghadmi, 2025). Iako rizičnost kriptovaluta znatno nadmašuje dionice, njihovi prinosi su višestruko veći, što rezultira povoljnijim Sharpeovim omjerom (Roška i Otročak, 2023).

*Grafikon 2. Efikasna granica portfelja s kriptovalutama i bez kriptovaluta*




Izvor: Ilustrativni prikaz autora temeljen na Boido i Aliano (2025) i Šoja i Senarathne (2019)

Napomena: Na vodoravnoj osi prikazana je godišnja volatilnost (standardna devijacija prinosa, izražena u postocima), a na okomitoj osi očekivani godišnji prinos (također u postocima). Krivulje su izračunate pod pretpostavkom normalne distribucije prinosa i konstantne korelacijske matrice tijekom cijelog promatranog razdoblja. Portfelj s kriptovalutama pretpostavlja alokaciju od 3% u Bitcoin i 2% u Ethereum.

Grafikon 2 ilustrativno prikazuje očekivani pomak efikasne granice prema gore i ulijevo kada se u tradicionalni portfelj uključi 5% kriptovaluta; budući da je riječ o shematskom prikazu temeljenom na preuzetim parametrima, a ne o rezultatu samostalne optimizacije, prikaz treba tumačiti kao konceptualnu ilustraciju nalaza iz literature. Prema toj literaturi, uključivanje kriptovaluta može investitorima omogućiti viši očekivani prinos za istu razinu rizika ili zadržavanje istog prinosa uz smanjeni ukupni rizik portfelja. Pojedina istraživanja pokazuju da optimizacija portfelja primjenom algoritama rojenja čestica (engl. *Particle Swarm Optimization*) pokazuje superiornu diverzifikaciju i bolju sposobnost hvatanja varijacija rizika u različitim tržišnim uvjetima u usporedbi s nasumičnom optimizacijom (Ntare i sur., 2025).

### *4.2. Sigurno utočište (Safe Haven) ili samo diverzifikator?*

Jedno od ključnih pitanja u literaturi je djeluje li Bitcoin kao sigurno utočište tijekom financijskih kriza, slično zlatu. Sigurno utočište definira se kao imovina koja je nekorelirana ili negativno korelirana s drugim portfeljem u vremenima tržišnog stresa. Dok pojedini autori tvrde da Bitcoin doprinosi smanjenju rizika portfelja tijekom kriza (Alihodžić, 2023.), novija istraživanja ukazuju na strukturnu promjenu nakon pandemije COVID-19.

Tijekom pandemije, korelacija kriptovaluta s tradicionalnim tržištima značajno je porasla, što je smanjilo njihove diverzifikacijske prednosti u trenucima kada su bile najpotrebnije (Gorman i Hughen, 2024; Azouzi i Mghadmi, 2025). Conlon i McGee (2020) na primjeru medvjeđeg tržišta tijekom pandemije COVID-19 pokazuju da se Bitcoin tada nije ponašao kao sigurno

utočište, nego je njegova cijena padala usporedno s tržištem dionica, pri čemu je alokacija u Bitcoin povećavala gubitke portfelja. S druge strane, Pavković i sur. (2019) na uzorku europskih tržišta potvrđuju da uključivanje kriptovaluta može poboljšati diverzifikaciju portfelja, čime se naglašava razlika između diverzifikacijskih svojstava u uobičajenim uvjetima i izostanka svojstva sigurnog utočišta u razdobljima krize. Oštar pad cijene Bitcoina u ožujku 2020. godine, sinkroniziran s padom globalnih dioničkih tržišta, dokazao je da Bitcoin nije imun na globalne šokove likvidnosti. Stoga se zaključuje da kriptovalute primarno djeluju kao diverzifikatori u normalnim tržišnim uvjetima, a ne kao pouzdana sigurna utočišta (Bakry i sur., 2021; Rashid i sur., 2023).

### *4.3. Uloga Ethereuma i altcoina u portfelju*

Iako je većina ranih istraživanja bila fokusirana isključivo na Bitcoin, novije studije naglašavaju važnost Ethereuma i drugih alternativnih kriptovaluta (altcoina). Ethereum, kao platforma za pametne ugovore i decentralizirane financije (DeFi), pokazuje drugačiju dinamiku prinosa od Bitcoina. Boido i Aliano (2025) ističu da uključivanje Ethereuma uz Bitcoin dodatno poboljšava Sharpeov omjer portfelja, jer korelacija između ove dvije vodeće kriptovalute, iako visoka ($\rho \approx 0.78$), nije savršena (vidljivo u Grafikonu 1).

Nadalje, prelazak Ethereuma na Proof-of-Stake (PoS) mehanizam konsenzusa („The Merge") omogućio je generiranje pasivnog prinosa kroz „staking", čime je Ethereum dobio karakteristike sličnije tradicionalnoj imovini koja generira novčane tokove (poput dividendi). Ovo ga čini posebno atraktivnim za institucionalne investitore koji traže prinos (yield) uz kapitalnu aprecijaciju, što dodatno produbljuje diverzifikacijski potencijal unutar same klase kriptoimovine (Ma i sur., 2020).

Pregled ključnih empirijskih studija obuhvaćenih ovim radom, s pripadajućom metodologijom i glavnim nalazima, sustavno je prikazan u Tablici 2.

Tablica 2. Pregled ključnih empirijskih studija o optimizaciji portfelja s kriptovalutama

| **Autori i godina** | **Primijenjena metodologija** | **Ključni nalaz / Preporuka** |
|---|---|---|
| Jurić i sur. (2025) | Korelacijska analiza (Spearman) | Kriptovalute mogu biti koristan alat za diverzifikaciju mješovitih portfelja (dionice, obveznice, zlato). |
| Boido i Aliano (2025) | Markowitz, Sharpeov omjer | U promatranom uzorku portfelji s kriptovalutama nadmašuju tradicionalne u oko 70% perioda. |
| Gorman i Hughen (2024) | Dinamička korelacija | Diverzifikacijske prednosti su se smanjile nakon COVID-19 pandemije zbog rasta korelacije. |
| Kyalo i sur. (2025) | GARCH-EVT-Copula-CVaR | Napredni modeli nužni su za preciznu procjenu repnog rizika kriptovaluta. |
| Šoja i Senarathne (2019) | Value at Risk (VaR) | Preporučuje se mali udio (1-5%) za maksimizaciju Sharpeovog omjera uz kontrolu rizika. |

Izvor: Sistematizacija autora

## 5. Ograničenja rada

Ovo istraživanje ima nekoliko ograničenja koja treba uzeti u obzir pri tumačenju rezultata. Prvo, rad ne provodi vlastitu originalnu empirijsku analizu naprednih modela poput GARCH-Copula ili CVaR, već se oslanja na pregled literature. Drugo, korelacijska matrica i efikasna granica temelje se na povijesnim podacima koji ne garantiraju buduće odnose. Treće, analiza ne uključuje transakcijske troškove, porezne implikacije niti likvidnosne rizike specifične za pojedine kripto burze. Buduća bi se istraživanja trebala usredotočiti na implementaciju adaptivnih modela optimizacije koji uključuju ove faktore.

## 6. Zaključak

Ovaj rad pruža pregled i sintezu dosadašnjih istraživanja o optimizaciji investicijskih portfelja s uključenjem kriptovaluta, kombinirajući prikaz naprednih statističkih modela iz literature s ilustrativnim empirijskim prikazima. Nalazi iz pregledane literature upućuju na to da kriptovalute, unatoč svojoj ekstremnoj volatilnosti, mogu poboljšati diverzifikaciju i ravnotežu između rizika i prinosa unutar investicijskog portfelja. Njihova relativno niska korelacija s pojedinim tradicionalnim klasama imovine (osobito obveznicama i zlatom) može doprinijeti postizanju povoljnijih Sharpeovih omjera, što je u radu ilustrativno prikazano pomakom efikasne granice.

Istraživanje je pokazalo da tradicionalne metodologije izgradnje portfelja, poput Markowitzovog modela, nisu adekvatne za upravljanje rizicima ovih digitalnih instrumenata zbog asimetričnih distribucija i rizika debelih repova. Za učinkovito upravljanje portfeljem nužna je primjena naprednih modela (poput GARCH-Copula i CVaR) koji mogu dinamički reagirati na promjene u volatilnosti i uhvatiti nelinearne ovisnosti u razdobljima tržišnog stresa.

Za investitore, ključna preporuka je ograničena i kontrolirana alokacija (1% do 5% ukupnog portfelja), čime se maksimiziraju diverzifikacijski učinci uz zadržavanje prihvatljive razine ukupnog rizika (Šoja i Senarathne, 2019.; Azouzi i Mghadmi, 2025.). Također, investitori moraju biti svjesni da kriptovalute primarno djeluju kao diverzifikatori u stabilnim uvjetima, a ne kao pouzdana sigurna utočišta tijekom globalnih ekonomskih šokova, što je zorno prikazano tijekom pandemije COVID-19 (Rashid i sur., 2023.; Gorman i Hughen, 2024.). Buduća istraživanja trebala bi se usredotočiti na utjecaj novih regulatornih okvira (poput MiCA uredbe) na korelacijsku dinamiku kriptoimovine i tradicionalnih financijskih tržišta, te na razvoj adaptivnih algoritama temeljenih na strojnom učenju za dinamičku alokaciju imovine.

## LITERATURA

1. Alihodžić, A. (2023). The volatility of bitcoin and the riskiness of the financial portfolio. *Bankarstvo*, 52 (2-3), 128-165.
2. Aljinović, Z.; Marasović, B.; Šestanović, T. (2021). Cryptocurrency portfolio selection–a multicriteria approach. *Mathematics,* 9(14), 1677.
3. Azouzi, M. A.; Mghadmi, N. (2025). The portfolio management properties of Bitcoin during the coronavirus crisis. *Interdisciplinary Journal of Management Studies (IJMS)*, 18(2), 333-347.
4. Bakry, W.; Rashid, A.; Al-Mohamad, S.; Elkanj, N. (2021). Bitcoin and portfolio diversification: A portfolio optimization approach. *Journal of Risk and Financial Management*, 14(7), 282.
5. Blaće, M.; Grubišić, A. (2016). Crowdfunding in the EU – Challenges of the innovative source of financing. U: M. Przygoda, M. Mikic i P. Kurecic (Ur.), Economic and Social Development: 17th International Scientific Conference on Economic and Social Development (str. 415-424). Varazdin Development and Entrepreneurship Agency.
6. Blaće, M.; Grubišić, A. (2017a). Crowdfunding in China – Development perspectives. U: G. Kozina, L. Juznik Rotar i D. Tomic (Ur.), Economic and Social Development: 19th International Scientific Conference on Economic and Social Development (str. 188-196). Varazdin Development and Entrepreneurship Agency.
7. Blaće, M.; Grubišić, A. (2017b). Equity crowdfunding. U: Li Yongqiang, A. Hunjet i A. Roncevic (Ur.), Economic and Social Development: 20th International Scientific Conference on Economic and Social Development (str. 443-450). Varazdin Development and Entrepreneurship Agency.
8. Boido, C.; Aliano, M. (2025). The contribution of cryptocurrencies to portfolio diversification. *Investment Management and Financial Innovations*, 22(2), 26–35.
9. Clément, J. (2024). Assessing portfolio vulnerability to systemic risk: A vine copula and APARCH-DCC approach. *Financial Innovation*, 10(1).
10. Conlon, T.; McGee, R. (2020). Safe haven or risky hazard? Bitcoin during the COVID-19 bear market. *Finance Research Letters*, 35, 101607.
11. Gorman, M.; Hughen, W. K. (2024). Does bitcoin still enhance an investment portfolio in a post Covid-19 world? *Finance Research Letters*, 62, 105170.
12. Gulyás, R.; Gál, V.; Sipiczki, Z. (2025). Unlocking blockchain-driven financial opportunities: Optimizing portfolios with cryptocurrencies and European stock markets. *Frontiers in Blockchain*, 8.
13. Jeleskovic, V.; Latini, C.; Younas, Z. I.; Al-Faryan, M. A. S. (2023). Optimization of portfolios with cryptocurrencies: Markowitz and GARCH-Copula model approach. arXiv (Cornell University).
14. Jurić, V.; Rački, T.; Grubišić, A. (2025). Cryptocurrencies as a tool for portfolio diversification. U: I. Klopotan, V. Buterin i H. Ribeiro (Ur.), Resilience in an Unsustainable World: Shaping the Future – Book of Proceedings, 131st ESD Zagreb (str. 165-176). Varazdin Development and Entrepreneurship Agency.
15. Koutmos, D.; Payne, J. E. (2021). Intertemporal asset pricing with bitcoin. *Review of Quantitative Finance and Accounting*, 56(2), 619–645.

16. Kyalo, I. N.; Omari, C. O.; Ngunyi, A. (2025). Optimization of financial asset portfolio using GARCH-EVT-Copula-CVaR model. *Journal of Mathematical Finance*, 15(3), 579-615.
17. Ma, Y.; Ahmad, F.; Liu, M.; Wang, Z. (2020). Portfolio optimization in the era of digital financialization using cryptocurrencies. *Technological Forecasting and Social Change*, 161, 120265.
18. Ntare, H. B.; Mwamba, J. W. M.; Adékambi, F. (2025). Dynamic portfolio optimization with diversification analysis and asset selection amidst high correlation using cryptocurrencies and bank equities. *Risks*, 13(6), 113.
19. Pavković, A.; Anđelinović, M.; Pavković, M. (2019). Achieving portfolio diversification through cryptocurrencies in European markets. *Ekonomski pregled*, 70(4), 599-626.
20. Petukhina, A.; Trimborn, S.; Härdle, W. K.; Elendner, H. (2021.). Investing with cryptocurrencies – evaluating their potential for portfolio allocation strategies. *Quantitative Finance*, 21(11), 1825-1853.
21. Platanakis, E.; Urquhart, A. (2020.). Should investors include Bitcoin in their portfolios? A portfolio theory approach. *The British Accounting Review*, 52(4), 100837.
22. Rashid, A.; Bakry, W.; Al-Mohamad, S. (2023.). Are cryptocurrencies a future safe haven for investors? The case of Bitcoin. *Economic Research–Ekonomska Istraživanja*, 36(2), 80-93.
23. Roška, V.; Otročak, M. (2023.). Prinosi na investicijska ulaganja: kriptovalute ili ETF. *Acta Economica et Turistica*, 9(1), 55-76.
24. Šoja, T.; Senarathne, C. W. (2019.). Bitcoin in portfolio diversification: The perspective of a global investor. *Bankarstvo*, 48(4), 44-63.
25. Wu, H.; Yueh, M. (2025.). Cryptocurrency risk management using Lévy processes and time-varying volatility. *Review of Quantitative Finance and Accounting*, 66(1), 33-61.

*Summary*

***Cryptocurrencies And Investment Portfolio Optimization: A Review Of Diversification Effects***

*Given the remarkable growth of market capitalization and increasing institutional acceptance, cryptocurrencies have become an unavoidable element of modern financial markets. The purpose of this paper is to examine the role of cryptocurrencies, primarily Bitcoin and Ethereum, in the diversification and risk-adjusted performance of investment portfolios. The paper applies a narrative and comparative review of recent empirical studies, complemented by illustrative empirical elements (a correlation matrix and an efficient frontier drawn from prior research), to determine whether cryptocurrencies can serve as an effective diversification instrument. The reviewed literature indicates that the inclusion of cryptocurrencies in traditional portfolios (stocks, bonds, gold) may improve the Sharpe ratio and overall performance, despite their inherently high volatility. This phenomenon is associated in the literature with the relatively low correlation of crypto assets with certain traditional financial instruments, primarily bonds and gold. However, a comparative analysis of methodological approaches reveals that the classic Markowitz mean-variance model is not adequate for cryptocurrencies due to asymmetric distributions and tail risks. Therefore, the application of advanced models such as GARCH-Copula and Conditional Value at Risk (CVaR) is recommended for optimization. Based on the literature review, it is concluded that cryptocurrencies act primarily as a diversifier, but not necessarily as a safe haven during periods of extreme market shocks, and their limited allocation in the portfolio is recommended.*

***Keywords:*** *cryptocurrencies; portfolio optimization; diversification; risk management; Bitcoin.*



Autorska prava: ©2026 Autori. Ovaj rad objavljen je u otvorenom pristupu pod licencom Creative Commons Imenovanje – Nekomercijalno 4.0 međunarodna.

*Copyright: ©2026 The Authors. Open Access: The work is licensed under a Creative Commons Attribution- NonCommercial 4.0. International License.*