



**VILNIUS
TECH**

Vilniaus Gedimino
technikos universitetas

Tomas PEČIULIS

VALIUTŲ RINKOS EVOLIUCIJOS SĄVEIKA SU MONETARINĖS POLITIKOS INSTRUMENTAIS SKAITMENIZACIJOS AMŽIUJE

DAKTARO DISERTACIJA

SOCIALINIAI MOKSLAI,
EKONOMIKA [S 004]

Vilnius, 2026

2026-031-M

VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

Tomas PEČIULIS

VALIUTŲ RINKOS EVOLIUCIJOS SĄVEIKA
SU MONETARINĖS POLITIKOS
INSTRUMENTAIS SKAITMENIZACIJOS
AMŽIUJE

DAKTARO DISERTACIJA

SOCIALINIAI MOKSLAI,
EKONOMIKA (S 004)

Vilnius, 2026

Disertacija rengta 2020-2026 metais Vilniaus Gedimino technikos universitete.

Vadovas

doc. dr. Asta VASILIAUSKAITĖ (Vilniaus Gedimino technikos universitetas, Ekonomika – S 004).

Vilniaus Gedimino technikos universiteto Ekonomikos mokslo krypties disertacijos gynimo taryba:

Pirmininkas

prof. dr. Daiva JUREVIČIENĖ (Vilniaus Gedimino technikos universitetas, Ekonomika – S 004).

Nariai:

dr. Tomas BALEŽENTIS (Vilniaus Gedimino technikos universitetas, Ekonomika – S 004),

prof. dr. Valdonė DARŠKUVIENĖ (ISM Vadybos ir ekonomikos universitetas, Ekonomika – S 004),

doc. dr. Donatella PORRINI (Salento universitetas, Italija, Ekonomika – S 004),

doc. dr. Viktorija SKVARIČIANY (Vilniaus Gedimino technikos universitetas, Ekonomika – S 004).

Disertacija bus ginama viešame Ekonomikos mokslo krypties disertacijos gynimo tarybos posėdyje **2026 m. birželio 10 d. 10 val.** Vilniaus Gedimino technikos universiteto *Aula Doctoralis* posėdžių salėje.

Adresas: Saulėtekio al. 11, LT-10223 Vilnius, Lietuva.

Tel. (0 5) 274 4956; faksas (0 5) 270 0112; el. paštas doktor@vilniustech.lt

Pranešimai apie numatomą ginti disertaciją išsiųsti 2026 m. gegužės 8 d.

Disertaciją galima peržiūrėti Vilniaus Gedimino technikos universiteto talpykloje <https://etalpykla.vilniustech.lt/>, Vilniaus Gedimino technikos universiteto bibliotekoje (Saulėtekio al. 14, LT-10223 Vilnius, Lietuva) ir Lietuvos socialinių mokslų centro bibliotekoje (A. Goštauto g. 9, LT-01108 Vilnius, Lietuva).

Vilniaus Gedimino technikos universiteto 2026-031-M mokslo literatūros knyga

<https://doi.org/10.20334/2026-031-M>

© Vilniaus Gedimino technikos universitetas, 2026

© Tomas Pečiulis, 2026

tomas.peciulis@vilniustech.lt

VILNIUS GEDIMINAS TECHNICAL UNIVERSITY

Tomas PEČIULIS

INTERACTION BETWEEN CURRENCY
MARKET EVOLUTION WITH MONETARY
POLICY INSTRUMENTS IN THE AGE OF
DIGITISATION

DOCTORAL DISSERTATION

SOCIAL SCIENCES,
ECONOMICS (S 004)

Vilnius, 2026

The doctoral dissertation was prepared at Vilnius Gediminas Technical University in 2020-2026.

Supervisor

Assoc. Prof. Dr Asta VASILIAUSKAITĖ (Vilnius Gediminas Technical University, Economics – S 004).

The Dissertation Defence Council of the Scientific Field of Economics of Vilnius Gediminas Technical University:

Chairperson

Prof. Dr Daiva JUREVIČIENĖ (Vilnius Gediminas Technical University, Economics – S 004).

Members:

Dr Tomas BALEŽENTIS (Vilnius Gediminas Technical University, Economics – S 004),

Prof. Dr Valdonė DARŠKUVIENĖ (ISM University of Management and Economics, Economics – S 004),

Assoc. Prof. Dr Donatella PORRINI (University of Salento, Italy, Economics – S 004),

Assoc. Prof. Dr Viktorija SKVARCIANY (Vilnius Gediminas Technical University, Economics – S 004).

The dissertation will be defended at the public meeting of the Dissertation Defence Council of the Scientific Field of Economics in the *Aula Doctoralis* Meeting Hall of Vilnius Gediminas Technical University at **10 a.m. on 10 June 2026**.

Address: Saulėtekio al. 11, LT-10223 Vilnius, Lithuania.

Tel.: +370 5 274 4956; fax +370 5 270 0112; e-mail: doktor@vilniustech.lt

A notification on the intended defence of the dissertation was sent on 8 May 2026. A copy of the doctoral dissertation is available for review at the Vilnius Gediminas Technical University repository <https://etalpykla.vilniustech.lt/>, the Library of Vilnius Gediminas Technical University (Saulėtekio al. 14, LT-10223 Vilnius, Lithuania) and the library of the Lithuanian Centre for Social Sciences (A. Goštauto g. 9, LT-01108 Vilnius, Lithuania).

Reziomė

Decentralizuotų kriptovaliutų atsiradimas sukėlė esminių iššūkių tradicinėms pinigų politikos sistemoms. Nors šie skaitmeniniai aktyvai turi potencialą didinti finansinį įtrauktumą ir efektyvumą, jiems būdingas nepastovumas ir centralizuotos priežiūros trūkumas sukuria sisteminę riziką, kurią tinkamai valdyti, naudojant klasikinius modelius, nepavyksta. Šioje disertacijoje pristatoma integruota hibridinė analitinė sistema, padedanti kiekybiškai įvertinti kriptovaliutų poveikį pinigų politikos perdavimo mechanizmams, kuri politikos formuotojams suteikia empiriškai pagrįstus įrankius, padedančius veiksmingiau analizuoti šią besikeičiančią finansų sritį.

Disertacija suskirstyta į tris skyrius. Pirmajame skyriuje apibendrinamas kriptovaliutų teorinis vaidmuo šiuolaikinėje pinigų teorijoje. Antrajame skyriuje pristatoma ir pagrindžiama nauja metodika, mašininio mokymosi technikas derinanti su pažangiu ekonometriniu modeliavimu, konkrečiai naudojant "Elastic Net" mašininio mokymo modelį su ARIMA liekanomis ir MSGARCH specifikacijomis, siekiant užfiksuoti nuo režimo priklausomą elgseną. Trečiajame skyriuje sistema empiriškai patvirtinama naudojant kriptovaliutų rinkų ir centrinių bankų politikos operacijų duomenis.

Empiriniai rezultatai rodo didelį asimetrinį politikos poveikį, bitkoino kainai reaguojant $-15\,348$ USD į 1 % Federalinės rezervų sistemos palūkanų normos pokyčius. Analizė nustato kritines kintamumo ribas ($\sigma > 80\%$), kai kriptovaliutų svyravimai didina infliacijos riziką. Šie rezultatai rodo didėjančią kriptovaliutų sistemine svarbą pinigų politikos dinamikoje.

Tyrimas prisideda prie naujos skaitmeninio turto ekonomikos srities plėtotės. Integruotas modeliavimo metodas padeda įveikti ilgalaikės nelinejinių finansinių reiškinių analizės ribotumus. Praktinės jos taikymo galimybės apima finansinio stabilumo rizikos stebėsenos realiuoju laiku sistemas ir įrodymais pagrįstas reguliavimo intervencijų gaires. Modulinė sistemos struktūra leidžia ją plėsti ateityje, įtraukiant besikeičiančias rinkos struktūras ir naujus skaitmeninius turtus.

Disertacijos tema paskelbtos aštuonios recenzuotos publikacijos moksliniuose žurnaluose ir konferencijų straipsnių rinkiniuose. Šis darbas suteikia centriniams bankams būtinas analitines priemones pinigų stabilumui palaikyti ir atsakingoms finansinėms inovacijoms skaitmeninėje eroje skatinti.

Abstract

The emergence of decentralised cryptocurrencies has created fundamental challenges for traditional monetary policy systems. Although these digital assets have the potential to increase financial inclusion and efficiency, their volatility and the lack of centralised oversight create systemic risks that cannot be properly managed using classical models. This dissertation presents an integrated hybrid analytical framework designed to quantitatively assess the impact of cryptocurrencies on monetary policy transmission mechanisms, providing policymakers with empirically grounded tools to analyse this evolving financial domain more effectively.

The dissertation is divided into three main parts. The First Chapter summarises the theoretical role of cryptocurrencies in modern monetary theory. The Second Chapter presents and substantiates a new methodology that combines machine-learning techniques with advanced econometric modelling, specifically using an Elastic Net machine learning model with ARIMA residuals and MSGARCH specifications to capture regime-dependent behaviour. The Third Chapter empirically validates the framework using data from cryptocurrency markets and central bank policy operations.

The empirical results show a significant asymmetric policy transmission effect, with the price of Bitcoin reacting by USD -15,348 to a 1% change in the Federal Reserve interest rate. The analysis also identifies critical volatility thresholds ($\sigma > 80\%$) at which cryptocurrency fluctuations increase inflation risk. These results indicate the growing systemic importance of cryptocurrencies in monetary policy dynamics.

The study contributes to the emerging field of digital asset economics. The integrated modelling approach helps overcome the long-standing limitations of analysing nonlinear financial phenomena. Practical applications include real-time financial stability risk monitoring systems and evidence-based guidelines for regulatory interventions. The modular structure of the framework allows for future expansion by incorporating evolving market structures and new digital assets.

The dissertation's results have been presented to the scientific community in eight peer-reviewed publications in scientific journals and conference proceedings. This work provides central banks with essential analytical tools to maintain monetary stability and to promote responsible financial innovation in the digital era.

Žymėjimai

Simboliai

α – „Elastic Net“ reguliavimo parametras (angl. *Elastic Net regularisation parameter*)

($\alpha \in \mathbb{R}$) / ARCH efekto koeficientas (angl. *ARCH effect coefficient*)

β – regresijos koeficientų vektorius (angl. *vector of regression coefficients*) / GARCH efekto koeficientas (angl. *GARCH effect coefficient*)

β_0 – laisvasis narys (angl. *constant term*)

γ – sverto efekto koeficientas (angl. *leverage effect coefficient*)

δ – regresijos koeficientai makroekonominio perdavimo lygtyje (angl. *regression coefficients in the macroeconomic transmission equation*)

ε – paklaidos nariai (angl. *error terms*)

ε_t – paklaidos narys laiko momentu t (angl. *error term at time t*)

θ – slankiojo vidurkio parametrai (angl. *moving average parameters*)

θ_j – j -asis slankiojo vidurkio parametras (angl. *j -th moving average parameter*)

λ – reguliavimo stiprumo parametras (angl. *regularisation strength parameter*) ($\lambda \in \mathbb{R}^+$)

μ – vidurkis (angl. *mean*)

v – paklaidos narys politikos reakcijos funkcijoje (angl. *error term in the policy reaction function*)

ρ – politikos reakcijos koeficientai (angl. *policy reaction coefficients*)

ρ_{kt} – laiko atžvilgiu kintantis koeficientas k laiko momentu t (angl. *time-varying coefficient k at time t*)

σ – standartinis nuokrypis (angl. *standard deviation*)

σ_t^2 – sąlyginė dispersija laiko momentu t (angl. *conditional variance at time t*)

σ^2 – dispersijos parametras (angl. *variance parameter*)
 φ – autoregresiniai parametrai (angl. *autoregressive parameters*)
 φ_i – i -tasis autoregresinis parametras (angl. *i -th autoregressive parameter*)
 $\Phi(L)$ – autoregresinis atsilikimų polinomas (angl. *autoregressive lag polynomial*)
 $\Theta(L)$ – slankiojo vidurkio atsilikimų polinomas (angl. *moving average lag polynomial*)
 ω – pastovusis narys GARCH modeliuose (angl. *constant term in GARCH models*)
 ψ_k – dinaminiai egzogeninių veiksnių svoriai (angl. *dynamic weights for exogenous factors*)
 c – pastovusis narys (angl. *constant term*)
 d – frakcinio integravimo parametras (angl. *fractional integration parameter*) ($0 < d < 1$)
 h – prognozės horizontas (angl. *forecast horizon*)
 i – palūkanų norma (angl. *interest rate*)
 j – indeksas (angl. *index*)
 k – kintamųjų skaičius (angl. *number of variables*)
 L – atsilikimo operatorius (angl. *lag operator*)
 m – kryžminio tikrinimo kartų skaičius (angl. *number of cross-validation folds*)
 n – imties dydis (angl. *sample size*)
 p – autoregresijos eilė (angl. *order of autoregression*)
 q – slankiojo vidurkio eilė (angl. *order of moving average*)
 s – režimo būseną (angl. *regime state*)
 s_t – režimo būseną laiko momentu t (angl. *regime state at time t*)
 t – laiko indeksas (angl. *time index*)
 τ – vieno iš eigos indeksas (angl. *leave-one-out index*)
 P_t – kriptovaliutos kaina laiko momentu t (angl. *cryptocurrency price at time t*)
 P^{crypto} – kriptovaliutos kaina (angl. *cryptocurrency price*)
 y_t – priklausomasis kintamasis (angl. *dependent variable*) (kriptovaliutos kaina / grąža (angl. *cryptocurrency price / return*))
 x_t – egzogeninis veiksnys (angl. *exogenous factor*)
 X_t – kontrolinių kintamųjų matrica (angl. *matrix of control variables*)
 W_t – regresorių matrica (angl. *matrix of regressors*)
 Z_t – instrumentinių kintamųjų matrica (angl. *matrix of instrumental variables*)
 u_t – paklaidos narys (angl. *error term*)
 i^{tb} – bazinė palūkanų norma (angl. *base interest rate*)
 QE_t – kiekybinis švelninimas laiko momentu t (angl. *quantitative easing at time t*)
 QT – kiekybinis griežtinimas (angl. *quantitative tightening*)
 $E[\cdot]$ – tikėtimumo operatorius (angl. *expectation operator*)
 $\ln(\cdot)$ – natūralusis logaritmas (angl. *natural logarithm*)
 Δ – skirtumo operatorius (angl. *difference operator*)
 $(1-L)^d$ – frakcinio skirtumo operatorius (angl. *fractional differencing operator*)
 argmin – argumentų minimizavimas (angl. *argument of the minimum*)
 \prod – sandaugos ženklas (angl. *product sign*)
 \mathbb{R} – realieji skaičiai (angl. *real numbers*)
 \mathbb{R}^+ – teigiamieji realieji skaičiai (angl. *positive real numbers*)
 \mathbb{R}^k – k matmenų realiųjų skaičių erdvė (angl. *k -dimensional real vector space*)
 \mathbb{Z}^+ – teigiamieji sveikieji skaičiai (angl. *positive integers*)

$N(0, \sigma^2)$ – normalusis skirstinys su 0 vidurkiu ir dispersija σ^2 (angl. *normal distribution with mean 0 and variance σ^2*)
 $\sim I(0)$ – integruotas nulio eilės (stacionarus) (angl. *integrated of order zero (stationary)*)
 $Cryptokin_t$ – kriptovaliutų kintamumas laiko momentu t (angl. *cryptocurrency volatility at time t*)
 $Reguliavimas_t$ – reguliavimo matas laiko momentu t (angl. *regulation measure at time t*)
 $Politika_t$ – politikos kintamasis laiko momentu t (angl. *policy variable at time t*)
 $Infliacija_t$ – infliacija laiko momentu t (angl. *inflation at time t*)
 $Adopt_{t-1}$ – uždelsti priėmimo rodikliai (angl. *lagged adoption indicators*)
 R^2 – determinacijos koeficientas (angl. *coefficient of determination*)

Santrumpos

AIC – Akaike informacinis kriterijus (angl. *Akaike Information Criterion*)
 AML – kovos su pinigų plovimu (angl. *Anti-Money Laundering*)
 ARIMA(p, d, q) – autoregresinis integruotas slankiojo vidurkio modelis (angl. *Autoregressive Integrated Moving Average model*)
 ARIMAX – ARIMA su egzogeniniais kintamaisiais (angl. *ARIMA with exogenous variables*)
 BIC – Bajeso informacinis kriterijus (angl. *Bayesian Information Criterion*)
 BNB – „Binance Coin“ (angl. *Binance Coin*)
 BTC – bitkoinas (angl. *Bitcoin*)
 CBDC – Centrinio banko skaitmeninė valiuta (angl. *Central Bank Digital Currency*)
 CMC Crypto 200 – „CoinMarketCap Crypto 200“ indeksas (angl. *CoinMarketCap Crypto 200 Index*)
 CV – kryžminis tikrinimas (angl. *Cross-validation*)
 DAX 30 – Vokietijos akcijų indeksas (angl. *German stock index*)
 DeFi – decentralizuotas finansavimas (angl. *Decentralised Finance*)
 ECB – Europos Centrinis Bankas (angl. *European Central Bank*)
 ECT – paklaidos koregavimo koeficientai (angl. *Error Correction Terms*)
 EGARCH – eksponentinis GARCH (angl. *Exponential GARCH*)
 ETH – eteris (angl. *Ethereum*)
 FED – Federalinis rezervas (JAV) (angl. *Federal Reserve (USA)*)
 FFR – federalinių fondų palūkanų norma (angl. *Federal Funds Rate*)
 FIGARCH – frakciškai integruotas GARCH (angl. *Fractionally Integrated GARCH*)
 GARCH – apibendrintas autoregresinis sąlyginis heteroskedastiškumas (angl. *Generalised Autoregressive Conditional Heteroskedasticity*)
 GMM – apibendrintas momentų metodas (angl. *Generalised Method of Moments*)
 IRF – impulso atsako funkcijos (angl. *Impulse Response Functions*)
 KYC – sistemos „Pažink savo klientą“ (angl. *Know Your Customer systems*)
 LIML – ribotos informacijos maksimalios tikimybės metodas (angl. *Limited Information Maximum Likelihood method*)
 MAE – vidutinė absoliučioji paklaida (angl. *Mean Absolute Error*)
 MASE – vidutinė absoliučioji skalės klaida (angl. *Mean Absolute Scaled Error*)
 MICA – Kriptovaliutų rinkų reglamentas (angl. *Markets in Crypto-Assets Regulation*)
 MSGARCH – Markovo perjungimo GARCH (angl. *Markov-Switching GARCH*)

OLS – mažiausiųjų kvadratų metodas (angl. *Ordinary Least Squares*)
RMSE – vidutinė kvadratinė paklaida (angl. *Root Mean Squared Error*)
S&P500 – „Standard & Poor’s 500“ indeksas (angl. *Standard & Poor’s 500 Index*)
TPS – operacijos per sekundę (angl. *Transactions Per Second*)
TVP – kintamojo parametro regresijos / laikui bėgant kintantys parametrai (angl. *Time-Varying Parameter regression / time-varying parameters*)
UMPT – nekonvencinės pinigų politikos priemonės (angl. *Unconventional Monetary Policy Tools*)
VAR – vektorinė autoregresija (angl. *Vector Autoregression*)
VIX – kintamumo indeksas (angl. *Volatility Index*)

Turinys

IVADAS	1
Problemos formulavimas.....	1
Darbo aktualumas.....	2
Tyrimų objektas.....	3
Darbo tikslas.....	3
Darbo uždaviniai	3
Tyrimų metodika	4
Darbo mokslinis naujumas	4
Darbo rezultatų praktinė reikšmė	5
Ginamieji teiginiai	5
Darbo rezultatų aprobavimas.....	6
Disertacijos struktūra.....	6
1. KRIPTOVALIUTŲ IR PINIGŲ POLITIKOS SĄVEIKOS TEORINIAI PAGRINDAI.....	7
1.1. Kripto valiutos kaip decentralizuotos pinigų priemonės	7
1.2. Pinigų politikos perdavimo mechanizmai skaitmeniniame amžiuje: tradiciniai ir decentralizuotų valiutų pažeisti kanalai	13
1.3. Centrinų bankų atsakas į kripto valiutas: reguliavimo sistemos ir politikos pritaikymas	18

1.4. Kripto valiutų kintamumas ir makroekonominis stabilumas	22
1.4.1. Infliacinis spaudimas ir turto burbulai	24
1.4.2. Politikos neapibrėžtumas ir centrinio banko iššūkiai	25
1.4.3. Užkrato poveikis ir finansų sistemos tarpusavio sąsajos	26
1.4.4. Nepastovumas kaip inovacijų ir atsparumo varomoji jėga	27
1.5. Pirmojo skyriaus išvados ir disertacijos uždavinių formulavimas.....	29
2. KRIPTOVALIUTŲ IR PINIGŲ POLITIKOS SĄVEIKOS SKAITMENINĖJE EKONOMIKOJE TYRIMO METODOLOGIJA	31
2.1. Tyrimo modelio metodologinis pagrindimas	32
2.1.1. Decentralizuotų finansų ir pinigų politikos derinimas: hibridinis požiūris	32
2.1.2. Centrinio banko pinigų politikos perdavimo kriptovaliutų rinkoms analizė taikant hibridinį modeliavimą	34
2.2. Decentralizuotų kriptovaliutų ir pinigų politikos sąveikos struktūrinis vertinimo modelis	36
2.2.1. Modelio architektūra: grįžtamojo ryšio kilpos ir dvikryptė sąveika	37
2.2.2. Pinigų politikos ir kriptovaliutų kintamųjų parinkimas hibridiniam modeliui.....	40
2.3. Centrinio banko politikos poveikio kriptovaliutų rinkoms „Elastic Net“ mašininio mokymo su autoregresinio integruoto slankiojo vidurkio modelio liekanomis modulis.....	43
2.3.1. Tradicinės pinigų politikos priemonės ir jų kintamieji Centrinio banko politikos poveikio modulyje	44
2.3.2. Netradicinės pinigų politikos priemonės ir jų kintamieji Centrinio banko politikos poveikio modulyje	46
2.4. Kintamumo grįžtamojo ryšio modulis	49
2.5. Egzogeninių kintamųjų svorių modulis.....	51
2.6. Centrinio banko atsako funkcijos modulis	53
2.7. Integruotas politikos ir kriptovaliutos sąveikos modelis	56
2.8. Taikomų modelių apžvalga ir metodologiniai sprendimai	58
2.9. Integruoto modelio rezultatų skaitymo ir interpretavimo principai	63
2.10. Antrojo skyriaus išvados	66
3. INTEGRUOTO KRIPTOVALIUTŲ IR PINIGŲ POLITIKOS PERDAVIMO MODELIO APROBAVIMAS	69
3.1. Politikos perdavimo modulio rezultatai.....	70
3.1.1. Įprastinės pinigų politikos ryšys su kriptovaliutų rinka	70
3.1.2. Netradicinių pinigų politikos priemonių veiksmingumas.....	77
3.2. Kintamumo grįžtamojo ryšio modulio rezultatai.....	82
3.3. Egzogeninių veiksnių modulio rezultatai	91
3.4. Centrinio banko reagavimo modulio rezultatai	97

3.5. Integruoto modelio patvirtinimas	102
3.6. Diskusija ir tyrimo apribojimai	111
3.7. Trečiojo skyriaus išvados	114
BENDROSIOS IŠVADOS	117
LITERATŪRA IR ŠALTINIAI.....	119
AUTORIAUS MOKSLINIŲ PUBLIKACIJŲ DISERTACIJOS TEMA SĄRAŠAS	135
SUMMARY IN ENGLISH.....	137

Contents

INTRODUCTION	1
Problem Formulation	1
Relevance of the Dissertation	2
Object of Research	3
Aim of the Dissertation	3
Tasks of the Dissertation	3
Research Methodology	4
Scientific Novelty of the Dissertation	4
Practical Value of Research Findings	5
Defended Statements	5
Approval of the Research Findings	6
Structure of the Dissertation	6
1. THEORETICAL FOUNDATIONS OF THE INTERACTION BETWEEN CRYPTOCURRENCIES AND MONETARY POLICY	7
1.1. Cryptocurrencies as Decentralised Monetary Instruments	7
1.2. Monetary Policy Transmission Mechanisms in the Digital Age: Traditional and Decentralised Currency-Disrupted Channels	13
1.3. Central Bank Responses to Cryptocurrencies: Regulatory Frameworks and Policy Adaptation	18

1.4. Cryptocurrency Volatility and Macroeconomic Stability	22
1.4.1. Inflationary Pressure and Asset Bubbles.....	24
1.4.2. Policy Uncertainty and Central Bank Challenges	25
1.4.3. Contagion Effects and Financial System Interconnections	26
1.4.4. Volatility as a Driver of Innovation and Resilience	27
1.5. Conclusions of the First Chapter and Formulation of the Dissertation Tasks ..	29
2. METHODOLOGY FOR INVESTIGATING THE INTERACTION BETWEEN CRYPTOCURRENCY AND MONETARY POLICY INTERACTION IN THE DIGITAL ECONOMY.....	31
2.1. Methodological Justification of the Research Model	32
2.1.1. Integrating Decentralised Finance and Monetary Policy: A Hybrid Approach	32
2.1.2. Analysis of Central Bank Monetary Policy Transmission to Cryptocurrency Markets Using Hybrid Modelling	34
2.2. Structural Assessment Model of the Interaction Between Decentralised Cryptocurrencies and Monetary Policy	36
2.2.1. Model Architecture: Feedback Loops and Bidirectional Interaction.	37
2.2.2. Selection of Monetary Policy and Cryptocurrency Variables for the Hybrid Model	40
2.3. Elastic Net Machine Learning with ARIMA Residuals Module for Assessing the Impact of Central Bank Policy on Cryptocurrency Markets	43
2.3.1. Traditional Monetary Policy Instruments and Their Variables in the Central Bank Policy Impact Module	44
2.3.2. Non-Traditional Monetary Policy Instruments and Their Variables in the Central Bank Policy Impact Module.	46
2.4. Volatility Feedback Module	49
2.5. Exogenous Variable Weighting Module	51
2.6. Central Bank Reaction Function Module	53
2.7. Integrated Policy and Cryptocurrency Interaction Model	56
2.8. Overview of Applied Models and Methodological Decisions	58
2.9. Principles for Reading and Interpreting the Results of the Integrated Model ..	63
2.10. Conclusions of the Second Chapter	66
3. APPROBATION OF THE INTEGRATED CRYPTOCURRENCY AND MONETARY POLICY TRANSMISSION MODEL.	69
3.1. Results of the Policy Transmission Module	70
3.1.1. Relationship Between Conventional Monetary Policy and the Cryptocurrency Market	70
3.1.2. Effectiveness of Non-Traditional Monetary Policy Instruments	77
3.2. Results of the Volatility Feedback Module	82
3.3. Results of the Exogenous Factors Module.	91
3.4. Results of the Central Bank Response Module	97

3.5. Validation of the Integrated Model	102
3.6. Discussion and Research Limitations.....	111
3.7. Conclusions of the Third Chapter.....	114
GENERAL CONCLUSIONS	117
REFERENCES	119
LIST OF SCIENTIFIC PUBLICATIONS BY THE AUTHOR ON THE TOPIC OF THE DISSERTATION	135
SUMMARY IN ENGLISH.....	137

Įvadas

Problemos formulavimas

Skaitmeninė revoliucija iš esmės pakeitė pasaulio finansų sistemas, nes atsirado decentralizuotos kriptovaliutos. Nuo tada, kai Nakamoto (2008) pristatė bitkoiną, šie skaitmeniniai turtai iš neaiškių kriptografinių eksperimentų išaugo į 2,5 trilijono JAV dolerių vertės rinką (CoinMarketCap, 2023) ir kelia iššūkį tradicinėms pinigų politikos sistemoms.

Tarptautinis valiutos fondas (2023) įspėja, kad kriptovaliutų veikimas be sienų ir nepriklausomybė nuo centrinių bankų priežiūros kelia beprecedenčius iššūkius makroekonominiam stabilumui, ypač besivystančiose ekonomikos šalyse, kur jų naudojimo mastas viršija 30 %. Sukrečiantis kriptovaliutų potencialas ypač paaiškėjo per pastarąsias finansų krizes. Kaip dokumentavo Tarptautinis atsiskaitymų bankas 2022 m. gegužės mėn., „TerraUSD“ žlugimas pasiglemžė 40 mlrd. JAV dolerių rinkos vertės ir sukėlė užkrato efektą tradicinėse finansų rinkose. Kita vertus, kriptovaliutų sandoriai suteikė ypatingą finansinę infrastruktūrą Ukrainai po Rusijos invazijos, o Argentinoje, kur 2023 m. metinė infliacija pasiekė 211 % (Tarptautinis valiutos fondas, 2023), jie buvo naudojami kaip infliacijos rizikos draudimas. Šios paradoksalios savybės – sisteminės rizikos ir finansinių inovacijų derinys – kelia esminių problemų pinigų politikos formuotojams.

Tradicinės pinigų politikos sistemos, sukurtos centralizuotoms finansų sistemoms, šioje naujoje aplinkoje tampa vis mažiau tinkamos. Kaip pažymėjo Carsens (2021), kriptovaliutos yra pinigų suvereniteto Achilo kulnas. Cornelli et al. (2023) empiriniai tyrimai rodo, kad Federalinės rezervų sistemos politikos sprendimai paaiškina iki 70 % bitkoino kainos svyravimų, o tai prieštarauja teorinei šio turto nepriklausymo nuo tradicinių finansų sampratai. Europos Centrinio Banko kriptovaliutų rinkų reglamentas (MiCA) yra pavėluotas bandymas spręsti šiuos iššūkius, tačiau, kaip teigia Manaa et al. (2021), tokios reaktyvios priemonės nesuteikia išsamių sprendimų. Šioje besikeičiančioje situacijoje atsiranda trys kritinės spragos. Pirma, centriniai bankai neturi tvirtų analitinių sistemų, leidžiančių kiekybiškai įvertinti kriptovaliutų perdavimo kanalus. Antra, esami modeliai negali tinkamai atspindėti kriptovaliutų rinkų netiesinės dinamikos, kai ištikus krizei svyravimai dažnai viršija 80 %. Trečia, tarptautinių koordinavimo mechanizmų nebuvimas sudaro galimybes reguliavimo arbitražui, kaip rodo skirtingi JAV Vertybinių popierių ir biržos komisijos bei ES reguliavimo institucijų požiūriai (Arner et al., 2023). Disertacijoje šie iššūkiai sprendžiami kuriant integruotą ekonometrinį modelį, kuris sistemingai analizuoja decentralizuotų kriptovaliutų poveikį pinigų politikos perdavimui. Tyrimas politikos formuotojams suteikia priemones makroekonominiam stabilumui išlaikyti, kartu suderinant finansines inovacijas skaitmeninėje eroje.

Probleminis disertacijos klausimas – kaip decentralizuotų kriptovaliutų ir pinigų politikos sąveika keičia pinigų politikos perdavimo veiksmingumą?

Darbo aktualumas

Naujausi moksliniai tyrimai patvirtina augančią sisteminę kriptovaliutų reikšmę globalioje finansų architektūroje. Chen (2025) rodo, kad kriptovaliutų kainų šokai paaiškina 18 % akcijų rinkų svyravimų ir 27 % žaliavų kainų svyravimų, taip pat sudaro 18 % kainų lygio prognozės paklaidos dispersijos ilguoju laikotarpiu. Tai rodo didžiulę integraciją su tradicinėmis finansų sistemomis ir didelį infliacinį poveikį pinigų politikai. Adelopo ir Luo (2025) tai papildė sisteminėmis 137 recenzuotų publikacijų apžvalga, kurioje nustato, kad kripto- ir tradicinių rinkų persiliejimo efektai, kintamumo perdavimas ir uodegos priklausomybė stiprėja įvykus dideliems sukrėtimams, todėl finansiniam stabilumui užtikrinti reikalingos ankstyvojo perspėjimo ir proaktyvios stebėsenos sistemos.

Empirinėje literatūroje vis dažniau dokumentuojama, kad kriptovaliutos kelia iššūkių centrinių bankų politikos efektyvumui. Furaijl et al. (2025) daro išvadą, kad kriptovaliutų sandoriai labai silpnina įprastinių pinigų politikos instrumentų veiksmingumą, įskaitant infliacijos valdymą, pinigų pasiūlos reguliavimą ir palū-

kanų normų kanalo efektyvumą. Kartu pabrėžia, kad geriau sureguliuotos kriptovaliutų rinkos yra mažiau nepastovios nei prastai sureguliuotos. Panigrahi (2023), remdamasis Indijos situacija, pateikia įrodymų, kad kiekvienas 1 % kriptovaliutų investicijų padidėjimas sumažina finansinį stabilumą maždaug 5 %, nors poveikis ekonomikos augimui išlieka palyginti nedidelis. Joseph et al. (2025), analizuodami penkių didžiausių Afrikos šalių ekonomikas ir taikydami BEKK-GARCH ir DCC-GARCH modelius, nustato reikšmingą, bet augantį poveikio persiliejamą iš kriptovaliutų į tradicines finansų rinkas, ypač Pietų Afrikoje, Nigerijoje ir Kenijoje, o sąlyginės koreliacijos rezultatai rodo didesnę ilgalaikę šių rinkų integraciją.

Mokslinėje literatūroje taip pat aiškiai įtvirtintas metodologinis poreikis pažangiems ekonometriniais metodams, kurie gebėtų fiksuoti kriptovaliutų ir pinigų politikos sąveikas. Ozili (2023) rodo, kad plačiai taikoma Centrinio banko skaitmeninė valiuta (CBDC) gali paspartinti indėlių migraciją iš bankų į CBDC, padidinti bankų likvidumo riziką ir per finansų sistemą platinti finansinio stabilumo rizikas. Vis dėlto ji kartu gali sustiprinti pinigų politikos perdavimą, jei pinigų politikos palūkanų norma efektyviai koordinuojama su CBDC indėlių palūkanų norma. Rachamadugu et al. (2025) pabrėžia, kad CBDC potencialas siekti ekonominio stabilumo reikalauja strateginių įgyvendinimo sistemų, apimančių kibernetinį saugumą, skaitmeninį raštingumą ir perdavimo mechanizmų efektyvumo užtikrinimą. Galiausiai kriptovaliutų rinkoms būdinga ne tiesinė, nuo režimų priklausoma dinamika, o tokie reiškiniai kaip slenkstiniai efektai ir asimetrinis kintamumas.

Todėl tirti kriptovaliutų ir pinigų politikos sąveiką yra aktualu siekiant įvertinti jų poveikį makroekonominiam stabilumui skaitmenizacijos sąlygomis.

Tyrimų objektas

Darbo tyrimų objektas – decentralizuotų kriptovaliutų ir pinigų politikos sąveika.

Darbo tikslas

Disertacinio darbo tikslas – sukurti hibridinį modelį, kuris kiekybiškai įvertintų decentralizuotų kriptovaliutų ir pinigų politikos sąveiką, leidžiant politikos formuotojams pritaikyti makroekonominio stabilumo sistemas skaitmeninėje eroje.

Darbo uždaviniai

Darbo tikslui pasiekti reikia spręsti šiuos uždavinius:

1. Išanalizuoti mokslinę literatūrą apie decentralizuotas kriptovaliutas ir pinigų politikos perdavimo mechanizmus.
2. Sukurti ir metodologiškai pagrįsti integruotą ekonometrinių modelių, kuris kiekybiškai įvertintų kriptovaliutų poveikį pinigų politikos veiksmingumui esant skirtingiems rinkos režimams.
3. Nustatyti ir įvertinti pagrindinius perdavimo kanalus, per kuriuos kriptovaliutos daro poveikį kainų stabilumui, kintamumui ir politikos įgyvendinimui.
4. Empiriškai patikrinti siūlomą modelį, naudojant ECB ir Federalinės rezervų sistemos politikos duomenis bei kriptovaliutų rinkos reakcijas.

Tyrimų metodika

Tyrimo buvo taikomi šie metodai:

1. Sisteminė literatūros apžvalga.
2. Mašininio mokymosi pagrįsti modeliai („Elastic Net“ su ARIMA liekanomis) politikos perdavimo poveikiui izoliuoti.
3. Laiko eilučių kintamumo modeliavimas, naudojant išplėstines GARCH modifikacijas, struktūriniams lūžiams ir asimetriniams procesams užfiksuoti.
4. Laiko kintamųjų parametrų regresija taikant Kalmano filtravimą centrinio banko prisitaikymo reakcijoms analizuoti.
5. Impulso atsako testavimas, siekiant įvertinti modelio patikimumą skirtingomis rinkos sąlygomis.

Darbo mokslinis naujumas

Rengiant disertaciją gauti šie ekonomikos mokslui nauji rezultatai:

1. Sukurtas integruotas ekonometrinis modelis, skirtas decentralizuotų kriptovaliutų poveikiui pinigų politikos perdavimui analizuoti. Jis apima mašininio mokymosi technologijomis patobulintą politikos perdavimo analizę, režimų keitimo kintamumo modeliavimą ir prisitaikančius Centrinio banko reagavimo mechanizmus, skirtus makroekonominiam stabilumui skaitmeninėse finansinėse ekosistemose palaikyti.
2. Sukurta sistema, padedanti analitiškai įvertinti pinigų politikos perdavimo mastą decentralizuotoms kriptovaliutoms, rodanti asimetrinį pinigų

politikos poveikį skirtingiems skaitmeniniams turtams. Tai leidžia analizuoti ir vertinti monetarinės politikos priemonių įtaką, įtraukiant kriptovaliutų rinkos segmentą.

3. Parengtas svyravimo ribinių rodiklių nustatymo mechanizmų rinkinys, nes slenkstinės kintamumo ribos leidžia tiksliai identifikuoti perėjimą į didesnės sisteminės rizikos režimus, kurie būtini siūlomam modeliui veikti. Šie rodikliai tapo pagrindu kriptovaliutų svyravimo stabilumo indeksui, skirtam sisteminės rizikos lygiui ir tinkamoms politikos priemonėms vertinti, remiantis kiekybiniais rinkos duomenimis ir struktūriniais kriptovaliutų elgsenos pokyčiais.

Darbo rezultatų praktinė reikšmė

Tyrimas suteikia centriniams bankams kiekybinius įrankius kriptovaliutų rinkoms stebėti, vertinti ir parinkti laiką pinigų politikos priemonėms įgyvendinti. Sukurtas modelis leidžia politikos formuotojams numatyti kriptovaliutų sukeltą finansinį nestabilumą, naudojant jo kintamumo ribinių verčių rodiklius ir scenarijų analizės galimybes. Finansų reguliavimo institucijoms tyrimas pateikia įrodymais pagrįstas gaires, kada ir kaip kištis į kriptovaliutų rinkas, ypač esant dideliame kintamumui ($\sigma > 80\%$).

Tyrimo rezultatai yra ypač vertingi besivystančių šalių centriniams bankams, kur kriptovaliutų naudojimo mastas viršija 30%. Rezultatai padeda jiems suderinti finansines inovacijas ir makroekonominį stabilumą. Modulinė modelio struktūra leidžia ateityje jį plėsti, įtraukiant papildomus skaitmeninius turtus.

Ginamieji teiginiai

1. Decentralizuotos kriptovaliutos tapo sisteminiais pinigų politikos perdavimo subjektais, todėl jas reikia integruoti į makroekonominius modelius.
2. Kriptovaliutų kintamumas atitinka režimui būdingus modelius, kurie krizės metu padidina politikos veiksmingumą.
3. Centriniai bankai turi priimti prisitaikančias sistemas su kriptovaliutomis būdingais rodikliais, kad išlaikytų skaitmeninių finansų ekosistemų stabilumą.
4. Tarptautinis politikos koordinavimas yra būtinas siekiant sumažinti tarpvalstybinį kriptovaliutų rinkų poveikį.

Darbo rezultatų apibavimas

Disertacijos tema yra atspausdinti 8 moksliniai straipsniai: penki – mokslo žurnaluose, įtrauktuose į *Clarivate Analytics Web of Science* ir *Scopus* duomenų bazines (Pečiulis et al., 2024; Peciulis & Vasiliauskaite, 2024a; Pečiulis & Vasiliauskaite, 2025a; Pečiulis & Vasiliauskaitė, 2024b; Peciulis & Vasiliauskaite, 2025), trys – recenzuojamuose tarptautinių konferencijų straipsnių rinkiniuose (Pečiulis & Vasiliauskaitė, 2021a, 2023a, 2025).

Disertacijoje atliktų tyrimų rezultatai buvo paskelbti trijose tarptautinėse mokslinėse konferencijose Lietuvoje ir užsienyje:

- 15-osios tarptautinės statistikos ir ekonomikos dienos, 2021 m. rugsėjo 9-11 d., Praha, Čekija;
- 13-oji tarptautinė mokslinė konferencija „Verslas ir vadyba 2023“, 2023 m. gegužės 11–12 d., Vilnius, Lietuva;
- Tarptautinė mokslinė konferencija „Naujausios ekonomikos, kultūros ir humanitarinių mokslų tendencijos (etECH2025)“, 2025 m., balandžio 23–23 d., Ryga, Latvija.

Autorius taip pat skaitė keturis pranešimus doktorantūros seminaruose Vilniaus Gedimino technikos universitete, vieną pranešimą Latvijoje Ekonomikos ir kultūros taikomųjų mokslų universitete.

Disertacijos struktūra

Disertaciją sudaro įvadas, trys skyriai, bendrosios išvados, literatūros sąrašas, autoriaus publikacijų sąrašas ir disertacijos santrauka anglų kalba. Bendra disertacijos apimtis – 173 puslapiai, joje yra 9 numeruoti paveikslai, 37 sunumeruotos lentelės, 27 sunumeruotos formulės ir 217 literatūros šaltiniai.

Kripto valiutų ir pinigų politikos sąveikos teoriniai pagrindai

Šiame skyriuje teoriškai pagrindžiama decentralizuotų kripto valiutų ir pinigų politikos sąveika. Nagrinėjamos kripto valiutų ekonominės funkcijos, jų poveikis tradiciniams pinigų politikos perdavimo mechanizmomams ir besivystantis centrinių bankų atsakas į kripto valiutų keliamus pinigų politikos ir finansinio stabilumo iššūkius. Skyriuje taip pat nagrinėjama makroekonominė rizika ir galimybės, kurias kelia kripto valiutų kainų nepastovumas.

Šio skyriaus tyrimų rezultatai paskelbti dviejuose moksliniuose straipsniuose (Pečiulis & Vasiliauskaitė, 2023; Pečiulis & Vasiliauskaitė, 2024).

1.1. Kripto valiutos kaip decentralizuotos pinigų priemonės

XXI amžiaus finansinių sistemų skaitmeninimas sukėlė transformacinių iššūkių tradicinėms pinigų sistemoms. Pelagidis ir Kostika (2022) pabrėžia, kad skaitmenizacija iš esmės keičia institucinį pinigų valdymo pagrindą, o Nabilou (2020) iškelia klausimą dėl reguliavimo atitikties naujoms finansinėms formoms. Tarp jų labiausiai išsiskiria decentralizuotų kripto valiutų atsiradimas, kurios, kaip pažymi

Sharma ir Agarwal (2024), iš naujo apibrėžia pinigų sąvoką, eliminuodami tradicinius tarpininkus – centrinius bankus ir komercines finansų institucijas.

Bitkoino atsiradimas 2009 m. (Nakamoto, 2008) tapo lūžio momentu, pasiūlius elektroninių pinigų sistemą, paremtą blokų grandinės technologija. Ramadoss (2022) ir Aljabr et al. (2019) akcentuoja, kad ši technologija veikia kaip decentralizuota, kriptografiškai apsaugota apskaitos knyga, kurios duomenų neįmanoma suklastoti, o Saxena et al. (2021) ir Bahr et al. (2024) išryškina jos saugumo ir skaidrumo aspektus.

M. Gupta ir P. Gupta (2018) pažymi, kad 2013 m. bitkoino rinkos kapitalizacija viršijo 1 mlrd. JAV dolerių, o tai perteikė augantį visuomenės susidomėjimą. Horch et al. (2022) nurodo, kad 2021 m. pasaulinė kriptovaliutų rinkos kapitalizacija viršijo 3 trilijonus JAV dolerių, prilygdama tokių šalių kaip Didžioji Britanija ar Indija BVP (Pasaulio bankas, 2023). Spartus augimas paskatino centrinius bankus ir pinigų politikos formuotojus pripažinti naują monetarinį fenomeną ir pradėti svarstyti, ar decentralizuotos kriptovaliutos gali atlikti tradicines pinigų funkcijas bei kokios yra jų priėmimo makroekonominės pasekmės.

1.1 lentelė. Kriptovaliutų moksliniai apibrėžimai

Table 1.1. Scientific definitions of cryptocurrency

Šaltinis	Kriptovaliutų apibrėžimai
Nakamoto (2008)	Kriptovaliutos – decentralizuotos skaitmeninės valiutos, naudojančios kriptografinį šifravimą vietoj finansinių tarpininkų, leidžiančios tiesioginius vartotojo vartotojui sandorius, naudojant blokų grandinę.
Böhme et al. (2015)	Kriptovaliutos – skaitmeninis turtas, sukurtas veikti kaip mainų priemonė, apsaugotas kriptografija ir veikiantis nepriklausomai nuo centrinės valdžios per decentralizuotus konsensuso mechanizmus.
Catalini ir Gans, (2019)	Kriptovaliutos – blokų grandinės pagrindu veikiančios sistemos, leidžiančios perduoti vertę tinkle, be tarpininkų, naudojant kriptografinį šifravimą.
Yermack (2015)	Kriptovaliutos – tai skaitmeniniai žetonai, kurie yra programuojami, veikia tarptautiniu mastu be sienų, turi vertės saugyklos ir mainų priemonės savybių, tačiau jų nepastovumas dažnai riboja jų, kaip atsiskaitymo vienetų, naudingumą.
BIS – Bank of international settlement (2021)	Kriptovaliutos – privačiai išleisti skaitmeniniai turtai, kurie remiasi decentralizuota registrų technologija sandoriams patvirtinti, neturintys vidinės vertės ar reikalavimų leidėjams.

1.1 lentelės pabaiga

Šaltinis	Kripto valiutų apibrėžimai
International Monetary Fund (2020)	Kripto valiutos – kriptoturto poaibis, sukurtas veikti kaip alternatyvios mokėjimo sistemos, nors jų teisinis kaip valiutos statusas lieka ginčytinas.
Cong ir He (2019)	Kripto valiutos – decentralizuotos skaitmeninės platformos, jungiančios kriptografinę saugą, žetonų ekonomiką ir konsensuso algoritmus, kad būtų galima atlikti sandorius be pasitikėjimo.
Dyrberg (2016a)	Kripto valiutos – hibridiniai instrumentai, turintys ir prekių (pvz., aukso), ir valiutų savybių, ir galimybių apsisaugoti nuo rinkos rizikos.
Bank of Canada (2014)	Kripto valiutos – skaitmeniniai žetonai, kurių vertė kyla dėl tinklo poveikio, kai naudotojų priėmimas skatina paklausą ir likvidumą.
Foley et al. (2019)	Kripto valiutos – decentralizuoti, reguliavimui atsparūs skaitmeniniai turtai, leidžiantys anoniminius sandorius, dažnai susijusius su nelegalia veikla.
Schilling ir Uhlig (2019)	Kripto valiutos – spekuliaciniai burbulai, neturintys jokios esminės vertės, palaikomi tik dėl savaime išsipildančių lūkesčių, kad ateityje jos bus priimtos.
Wheatley (2024)	Kripto valiutos – skaitmeninės platformos, jungiančios pinigines ir technologines naujoves, kuriose valiutos kasėjai patvirtina operacijas mainais į atlygį.
Baur et al. (2018)	Kripto valiutos – skaitmeninės alternatyvos konvencinėms valiutomis, siūlančios anonimiškumą ir decentralizaciją, tačiau neturinčios teisinio atsiskaitymo priemonės statuso.

1.1 lentelėje pateiktos apibendrintos įvairios mokslinės ir institucinės kripto valiutų perspektyvos, atspindinčios daugialypį jų vaidmenį šiuolaikinėse ekonomikos sistemose. Apibrėžimai, paimti iš svarbių akademinų straipsnių ir autoritetinių institucijų, kartu pabrėžia pagrindines kripto valiutų savybes: decentralizaciją, kriptografinį saugumą ir blokų grandine pagrįstą operacijų patvirtinimą. Tarptautinių atsiskaitymų bankas (Bank For International Settlements, 2022) pabrėžia jų vidinės vertės trūkumą ir priklausomybę nuo paskirstytų apskaitos knygų technologijos. Visgi kartais požiūriai išsiskiria. Kai kurie apibrėžimai kripto valiutas apibūdina kaip spekuliacinį turtą (Bullmann et al., 2019), kiti – kaip finansinių inovacijų įrankius (Catalini & Gans, 2019), o institucijos, tokios kaip TVF, pabrėžia jų teisinį statusą. Atsižvelgiant į disertacijos tyrimo objektą, šiame darbe kripto valiuta apibrėžiama kaip decentralizuotas skaitmeninis turtas, kurio vertės perleidimas organizuojamas blokų grandinės pagrindu, o jo reikšmė

makroekonominėi analizei pirmiausia siejama su galimu poveikiu pinigų politikos perdavimo kanalams, finansiniam stabilumui ir reguliavimo aplinkos formavimui skaitmenizacijos sąlygomis.

Bendri aspektai suvienija šias perspektyvas. Daugumoje apibrėžimų pripažįstamas hibridinis kriptovaliutų pobūdis – veikiantis ir kaip mainų priemonė, ir kaip vertės saugykla (Dyhrberg, 2016), tačiau atkreipiamas dėmesys į jų nepastovumą ir reguliavimo iššūkius (Foley et al., Pasikartojantis dėmesys skiriamas finansinių tarpininkų atsisakymui ir pinigų suvereniteto erozijai (Bank For International Settlements, 2022; Bank of Canada, 2014). Šie apibrėžimai pabrėžia disertacijos temos aktualumą, nes decentralizuotos kriptovaliutos sutrikdo tradicines pinigų politikos sistemas. Susisteminius šiuos apibrėžimus 1.1 lentelėje, atsiranda teorinis pagrindas analizuoti kriptovaliutų ekonominius padarinius, ypač jų vaidmenį keičiant kainų dinamiką ir centrinio banko kontrolę.

Kriptovaliutų, kaip piniginių priemonių, evoliucija vyko kartu su svarbiais reguliavimo ir technologiniais pokyčiais (Albanki et al., 2024). 2010 m. užregistruotas pirmasis sandoris, kurio metu buvo atsiskaitoma kriptovaliutomis – 10 000 bitkoinų už dvi picas – pademonstravo dar tik besiformuojantį mainų priemonės potencialą (Moussa & Cuzzocrea, 2021). Visgi monetarinės politikos institucijos dėmesį į šį fenomeną pirmą kartą atkreipė tik 2013 m., kai Europos bankininkystės institucija įspėjo apie pinigų plovimo riziką ir žalą vartotojams ir 2014 m. galutinai išreiškė savo poziciją (Bank of Ireland, 2014), o JAV mokesčių inspekcija kriptovaliutas priskyrė apmokestinamam turtui (Vidaus mokesčių tarnyba, 2025). 2017 m. rugsėjį Kinijos Vyriausybė uždarė kriptovaliutų prekybos platformas ir uždraudė pradinis valiutų pardavimus (ICO) (Chen & Liu, 2022). 2018 m. Venesuela, siekdama apeiti sankcijas, paleido valstybės remiamą „Petro“ . Iki 2019 m. „Facebook“ pasiūlymas „Libra“ (vėliau „Diem“) sukėlė visuotinį pasipriešinimą ir paskatino G7 perspėti dėl stabilųjų monetų, keliančių grėsmę pinigų suverenumui (Bank For International Settlements, 2019). Ši eiga chronologiškai pavaizduota 1.1 pav., kuriame išryškinta inovacijų, priėmimo ir reguliavimo reakcijų sąveika.

Menger (1892) ir Keynes (1937) suformulavo klasikinių pinigų apibrėžimą ir jų savybes: mainų priemonė, vertės saugojimo priemonė ir apskaitos vienetas. Iki XXI a. šias funkcijas atliko tik konvenciniai centralizuoti pinigai, tad pinigų reguliavimas taip pat buvo tik monetarinių institucijų prerogatyva. Decentralizuotos kriptovaliutos vis dažniau vertinamos kaip alternatyvūs pinigai, galintys bent iš dalies atlikti visas klasikinės ekonomikos apibrėžtas pinigų funkcijas. Afolabi ir Olanrewaju (2023) išskiria jų gebėjimą veikti kaip mainų priemone, vertės saugotoju ir apskaitos vienetu. Baldi ir Chiaraluce (2017) akcentuoja jų potencialą transformuoti pinigų sistemų struktūrą. Vis dėlto bitkoino kaip mainų priemonės efektyvumas išlieka ribotas, tai patvirtina ir praktiniai naudojimo atvejai.



1.1 pav. Svarbiausi kriptovaliutų reguliavimo ir įvedimo etapai (sudaryta autoriaus)

Fig. 1.1. Key milestones in cryptocurrency regulation and adoption
(Created by the author)

Siekiant išspręsti šią problemą, buvo sukurtas žaibo tinklas (angl. *Lightning Network*), leidžiantis vykdyti transakcijas už blokų grandinės ribų. Sarode et al. (2023) bei Bartolucci et al. (2020) pažymi, kad tokie sandoriai yra gerokai greitesni ir pigesni nei tie, kurie vykdomi tiesiogiai blokų grandinėje, o Guasoni et al. (2024) išskiria jų efektyvumą mikrotransakcijų kontekste. Kriptovaliutų gebėjimas mažinti tarptautinių perlaidų sąnaudas ir didinti mokėjimų greitį vis labiau

pripažįstamas, ypač atsižvelgiant į tai, kad šis sektorius tradiciškai susiduria su dideliais mokesčiais ir lėtu apdorojimo laiku (Khan et al., 2023). Tačiau mastelio problema išlieka aktuali: Chow et al. (2018) nurodo, kad „Visa“ gali atlikti daugiau kaip 1500 operacijų per sekundę (TPS), „PayPal“ – 193 TPS, o eteris prieš naujausius atnaujinimus tesugebėjo apdoroti apie 15 TPS. Bitkoinas dažnai lyginamas su auksu dėl savo vertės saugojimo savybių. Jain et al. (2023) pažymi, kad abu šie aktyvai laikomi apsidraudimu nuo infliacijos ir valiutos nuvertėjimo, o bitkoino decentralizuotas pobūdis ir ribota pasiūla daro jį patrauklia alternatyva konvencinėms valiutoms. Visgi, kaip teigia Sakariyahu et al. (2024) ir Welch (2023), kriptovaliutos susiduria su dideliais iššūkiais, susijusiais su nepastovumu, reguliavimo neapibrėžtumu ir rinkos sentimentais. „TerraUSD“ žlugimas 2022 m. gegužę, kurio vertė siekė 40 mlrd. dolerių, kaip nurodo Choi & Wang (2024), išryškino stabilumo riziką. Kaip apskaitos vienetas, stabiliosios kriptovaliutos, tokios kaip algoritminė DAI ir konvencinėmis valiutomis dengtos USDT ir USDC, savo funkcionalumu nedaug skiriasi nuo valiutų, su kuriomis yra susietos. Visgi Duan ir Urquhart (2023) pabrėžia, kad algoritmškai stabilizuotos kriptovaliutos yra mažiau stabilios nei faktiškai dengtos. 2020–2023 m. stabilijų kriptovaliutų kapitalizacija išaugo daugiau nei 500 %, pasiekdama daugiau nei 150 mlrd. JAV dolerių (Statista, 2023; CoinMarketCap, 2023).

Kriptovaliutomis būdinga decentralizacija iš esmės keičia santykį tarp pinigų sistemų ir jas prižiūrinčių institucijų. Le (2023) pabrėžia, kad blokų grandinėmis grįsti tinklai veikia be centralizuotos priežiūros, o Afolabi ir Olanrewaju (2023) išskiria jų gebėjimą sudaryti sąlygas tarpusavio sandoriams, kurie apeina tradicinius finansinius tarpininkus, tokius kaip komerciniai bankai ar mokėjimų vykdytojai. Toks decentralizuotas tarpininkavimas mažina priklausomybę nuo centrinių bankų likvidumo užtikrinimo ir pinigų stabilumo srityse. Šį pokytį iliustruoja bitkoino fiksuotos pasiūlos algoritmas, kuris, kaip pažymi Fama et al. (2024), nustato 21 mln. vienetų ribą nepriklausomai nuo bet kokios institucinės politikos. Kriptovaliutos taip pat siejamos su finansinės įtraukties didinimu. Demirgüç-Kunt et al. (2022) atkreipia dėmesį, kad net 1,4 mlrd. suaugusiųjų pasaulyje vis dar neturi banko sąskaitų, ypač regionuose, kuriuose finansinė infrastruktūra yra menkai išvystyta. Vienas ryškiausių pavyzdžių – į pietus nuo Sacharos išsidėsčiusios Afrikos valstybės, kur, kaip rodo Chainalysis (2021), 2020–2022 m. kriptovaliutų priėmimas išaugo 1200 %, daugiausia dėl tokių platformų kaip „Paxful“, leidžiančių atlikti pinigines perlaidas ir mikrokreditus be oficialių bankų reikalavimų. Tačiau šis finansų demokratizavimas kelia iššūkių pinigų suverenumui. Dadhich et al. (2024) pažymi, kad augantis decentralizuotų valiutų priėmimas mažina centrinių bankų galimybes kontroliuoti pinigų pasiūlą, ypač atsižvelgiant į bitkoino defliacijos protokolą, kuris kontrastuoja su ekspansine centrinių bankų politika. Fama et al. (2024) taip pat išskiria palūkanų normos perdavimo mechanizmo silpnėjimą. Ši tendencija ypač ryški šalyse, susiduriančiose su aukšta infliacija, pvz.,

Argentinoje, kur 2023 m. metinė infliacija viršijo 211 %, o kriptovaliutų naudojimo mastas padvigubėjo, taip dar labiau apsunkindamas Centrinio banko pastangas stabilizuoti pesą (Bank For International Settlements, 2023; Statista, 2023). Atsakydama į šiuos iššūkius, Europos Sąjunga 2023 m. priėmė kriptovaliutų rinkų reglamentą, kuriuo siekiama sumažinti rizikas nustatant skaidrumo reikalavimus. Barcentewicz ir De Gândara Gomes (2024) pabrėžia, kad šis reglamentas atskleidžia įtampą tarp technologinių inovacijų ir institucinės kontrolės skaitmeniniame amžiuje.

Decentralizuotų kriptovaliutų evoliucija nuo nišinių technologinių naujovių priemonės iki beveik monetarinio instrumento išryškina esminę ekonominės literatūros spragą: tradicinės pinigų sistemos nepakankamai atsižvelgia į jų sistemine įtaką kainų dinamikai, finansiniam tarpininkavimui ir monetarinės politikos perdavimui. Kriptovaliutos vis dažniau atlieka pagrindines pinigų funkcijas, tai rodo jų naudojimas tarptautiniams mokėjimams atlikti ir jų pripažinimas tokiose institucijose kaip Europos Centrinis Bankas. Jos silpnina centrinių bankų pinigų pasiūlos ir palūkanų normų mechanizmų kontrolę. Vis dėlto esamuose tyrimuose nepateikiama nuoseklaus modelio, kuris kiekybiškai įvertintų, kaip šios decentralizuotos sistemos trikdo makroekonominį stabilumą. Šiame poskyryje atskleidžiama, jog dėl augančios decentralizuotų valiutų reikšmės būtina papildyti monetarinės politikos analizavimo metodus, todėl toliau nagrinėjama, kaip kriptovaliutos iškreipia tradicinius pinigų politikos perdavimo kanalus.

1.2. Pinigų politikos perdavimo mechanizmai skaitmeniniame amžiuje: tradiciniai ir decentralizuotų valiutų pakeisti kanalai

Pinigų politika – procesas, kurio metu centriniai bankai, kontroliuodami pinigų pasiūlą ir palūkanų normas, daro įtaką ekonominei veiklai, turi seniai įtvirtintus perdavimo kanalus, kuriais veikia (Switala et al., 2021). Šie mechanizmai, ypač palūkanų normos, valiutos kurso, turto kainos ir kredito kanalai, leidžia politikos formuotojams stabilizuoti infliaciją, valdyti užimtumą ir sušvelninti finansų krizes (Bernanke & Blinder, 1988). Kredito kanalas veikia per bankų skolinimo elgseną, o monetarinės politikos perdavimo mechanizmai sąveikauja su makroekonomiškais kintamaisiais. Pvz., kai Centrinis bankas sumažina savo bazinę palūkanų normą, komerciniai bankai paprastai sumažina skolinimo palūkanų normas, taip skatindami skolinimąsi ir investicijas bei visuminę paklausą). Panašiai atvirosios rinkos operacijos, kaip kiekybinis skatinimas, į finansų sistemas įlieja likvidumo, sumažindamos ilgalaikį pajamingumą ir skatindamos turto kainas. Tačiau finansų skaitmeninimas, ypač decentralizuotų kriptovaliutų atsiradimas, įnešė precedento

neturinčių lūžių šiuose įprastiniuose perdavimo kanaluose. Kripto valiutos, veikiančios už centrinių bankų reguliavimo ribų, iš naujo apibrėžia, kaip pinigų politikos signalai sklinda ekonomikoje – tai paradigmos pokytis, kuris meta iššūkį pamatinėms makroekonominio stabilumo prielaidoms (Mitawa & Bhambu, 2024).

1.2 lentelėje apibendrinti 7 esminiai pinigų politikos apibrėžimai, atskleidžiantys pagrindinius panašumus ir svarbiausius skirtumus tarp teorinių požiūrių. Egzistuoja sutarimas dėl pinigų politikos tikslų, pirmiausia kainų stabilumo ir ekonominės veiklos stabilizavimo, taip pat dėl priemonių, kuriomis šių tikslų siekiama, ypač palūkanų normų ir pinigų pasiūlos koregavimo (Mishkin & Serletis, 2019).

1.2 lentelė. Pinigų politikos moksliniai apibrėžimai

Table 1.2. Scientific definitions of the monetary policy

Šaltinis	Pinigų politikos apibrėžimai
Mishkin ir Serletis (2019)	Pinigų politika – tai centrinio banko veiksmai, skirti pinigų ir kredito prieinamumui bei kainai paveikti, siekiant nacionalinių ekonominių tikslų.
Bernanke ir Gertler (1995b)	Pinigų politika apima centrinio banko priemonių, tokių kaip palūkanų normos ir privalomųjų atsargų reikalavimai, naudojimą pinigų pasiūlai ir kredito sąlygoms valdyti, siekiant kainų stabilumo ir ekonominio augimo.
Taylor (1993b)	Pinigų politika – tai procesas, kuriuo monetarinės institucijos koreguoja trumpalaikes palūkanų normas ir pinigų pasiūlą, siekdamas makroekonominių tikslų, tokių kaip infliacijos kontrolė ir produkcijos stabilizavimas.
Woodford (2004)	Pinigų politika – tai strateginis centrinio banko balanso valdymas, skirtas paveikti nominaliąsias palūkanų normas, o per jas – bendrąją paklausą ir infliaciją.
Friedman (1968)	Pinigų politika susideda iš sąmoningų pinigų pasiūlos ar jos augimo tempo pokyčių, siekiant norimų makroekonominių rezultatų, ypač kainų stabilumo.
Clarida et al. (1999)	Pinigų politika – tai trumpalaikių nominaliųjų palūkanų normų nustatymas centriniam bankui siekiant infliacijos ir produkcijos tikslų.
Gali (2008)	Pinigų politika – tai sistemingas nominaliųjų palūkanų normų valdymas pagal naująją keinsistinę teoriją, siekiant stabilizuoti infliaciją ir produkcijos spragas.

Vis dėlto apibrėžimuose nevienodai pabrėžiami instituciniai vaidmenys ir teorinės prielaidos. Friedman (1968) pinigų politiką sieja su pinigų pasiūlos augimo tempo valdymu, Gali (2008) dėmesį telkia į nominaliųjų palūkanų normų valdymą ir per jį formuojamus infliacijos lūkesčius. Bernanke ir Gertler (1995) papildomai išskiria kredito kanalo reikšmę, pabrėždami Centrinio banko sprendimų poveikį finansinio tarpininkavimo sąlygoms, o Clarida et al. (1999) akcentuoja trumpalaikių nominaliųjų palūkanų normų nustatymą siekiant infliacijos ir produkcijos tikslų. Šie skirtumai rodo pinigų teorijos raidą nuo pinigų kiekio kontrolės link lūkesčiais grindžiamo palūkanų normų valdymo, tačiau visuose apibrėžimuose numanoma prielaida, kad centriniai bankai išlaiko lemiamą įtaką pinigų ir kredito sąlygoms, o būtent ši prielaida skaitmenizuotoje finansų aplinkoje tampa vis labiau ginčytina.

Lentelė taip pat atskleidžia laiko požūriu pasikeitusius prioritetus. Ankstesniuose apibrėžimuose didesnis dėmesys skiriamas pinigų pasiūlos mechanikai, o vėlesniuose labiau akcentuojamas nominaliųjų palūkanų normų nustatymas, infliacijos tikslų siekimas ir politikos orientacija į ateitį (Clarida et al., 1999; Friedman, 1968; Gali, 2008). Ši raida atspindi sudėtingėjančią makroekonominę aplinką, kai pinigų politikos veiksmingumas vis labiau priklauso nuo perdavimo kanalų funkcionavimo ir finansų sistemos struktūros pokyčių. Taigi 1.2 lentelėje pateikiami apibrėžimai sudaro teorinį pagrindą tolesnei analizei, kurioje vertinama, kaip skaitmenizuota ir decentralizuota finansų ekosistema gali keisti tradicinių pinigų politikos priemonių poveikio sklaidą.

Nors šiuolaikinėje literatūroje 2015–2025 m. vis dažniau nagrinėjami skaitmeniniai iššūkiai pinigų politikai, daugiausia dėmesio skiriama kriptovaliutų poveikiui perdavimo kanalams (Furaij et al., 2025), Centrinio banko skaitmeninių valiutų diegimo pasekmėms (Rachamadugu et al., 2025) ir netradicinių priemonių veiksmingumui žemų palūkanų normų aplinkoje. Vis dėlto fundamentiniai pinigų politikos apibrėžimai išlieka gana stabilūs, nes naujais tyrimais dažniau plėtoja ne pačią sąvoką, o jos taikymo turinį ir ribas decentralizuotų finansų sąlygomis. Kitaip tariant, aktualiausiu tampa klausimas, kaip centriniai bankai gali išlaikyti palūkanų normų ir pinigų pasiūlos kontrolę, kai decentralizuotos kriptovaliutos veikia nepriklausomai nuo institucinio reguliavimo (Adelopo & Luo, 2025). Būtent instrumentų veiksmingumo klausimas, o ne teorinių apibrėžimų peržiūra sudaro dabartinių pinigų politikos tyrimų branduolį ir atitinka šios disertacijos problematiką.

Toliau disertacijoje pinigų politika bus apibrėžiama kaip procesas, kuriuo Centrinis bankas, valdydamas pinigų pasiūlą ir nustatydamas trumpalaikes palūkanų normas, daro poveikį ekonominei veiklai, siekdamas kainų stabilumo ir produkcijos stabilizavimo.

Pinigų politikos perdavimo mechanizmas tebėra daugialypis procesas, kurio tradiciniai kanalai, tokie kaip palūkanų normos, valiutos kursas, turto kainos ir

kreditas, buvo išsamiai išnagrinėti ir performuluoti atsižvelgiant į naujus ekonominius iššūkius ir technologines naujoves. Klasikiniu pavidalu palūkanų normos kanalas laikomas pinigų politikos kertiniu akmeniu (Moiseev, 2020). Centriniai bankai koreguoja trumpalaikes palūkanų normas pagal tokius principus, kaip Taylora taisyklė (Taylor, 1993), kad pakeistų namų ūkių ir įmonių skolinimosi sąlygas, kurios vėliau daro įtaką vartojimo ir investavimo sprendimams. Nirmala et al. (2022) įrodo, kad, sumažinus bazines palūkanų normas, sumažėja kapitalo kaina, o tai savo ruožtu skatina išlaidas ir investicijas. Papildydami šį požiūrį, Siregar et al. (2023) pateikia empirinių įrodymų iš Indonezijos rinkų, kuriose greitas politinių palūkanų normų perdavimas rinkos palūkanų normoms labai paveikė akcijų kainas ir skolinimosi elgseną. Be to, Younas (2020) teigia, kad nors tradicinė Taylora tipo taisyklė numato aiškų poveikį kainų lygiui per palūkanų normų kanalą, jos veiksmingumas tam tikromis sąlygomis gali būti ribotas, pabrėždamas poreikį atlikti šio kanalo poveikio stiprumo analizę. Tačiau šiose sistemose daroma prielaida, kad finansų sistema yra uždara, neatsižvelgiama į decentralizuotų kriptovaliutų trikdančią įtaką. Tai, kaip parodė ankstesnė analizė, atskleidžia kritinę spragą, kurią būtina tirti toliau siekiant suprasti, kaip kriptovaliutos silpnina palūkanų normų perdavimo kanalą.

Valiutų kursų kanalas sulaukė dėmesio dėl savo gebėjimo perduoti piniginius sukrėtimus tarptautiniu lygmeniu. Hussain (2022) aiškina, kad vidaus palūkanų normos pokyčiai tarptautinių lyginamųjų indeksų atžvilgiu išprovokuoja kapitalo srautus ir taip keičia valiutos kursą. Šis kanalas, kurį toliau nagrinėja Auer (2022), parodo, kad net ir aplinkoje, kuriai būdingas mažas perdavimo elastingumas, stipresnis valiutos kurso kanalo veikimas ir dėl to atsirandantis turto poveikis gali kompensuoti tam tikrą neigiamą griežtesnių vidaus palūkanų sąlygų poveikį. Tokie išvados pateikia išsamūs tyrimai, kurie rodo tvirtą ryšį tarp politikos nulemtų palūkanų normų pokyčių ir valiutos kurso pokyčių, taigi ir poveikį prekybos balansui ir visuminei paklausai. Vis dėlto kriptovaliutų, kaip mokėjimo priemonių be sienų, populiarėjimas (pvz., bitkoino vaidmuo tarpvalstybinių perlaidų srityje), apsunkina centrinių bankų gebėjimą valdyti kapitalo srautus, todėl būtina sukurti priemones, leidžiančias pinigų politikos formuotojams modeliuoti jų turimų priemonių veiksmingumo atsaką.

Turto kainų kanalas veikia darydamas įtaką namų ūkių turtui per akcijų ir nekilnojamojo turto vertės svyravimus *Click or tap here to enter text.* Jiang ir Wang (2017), taikydami įvykių tyrimo metodiką, parodė, kad turto kainos greitai reaguoja į nenumatytus pinigų politikos pokyčius, taip darydamos poveikį vartojimo sprendimams per turto kanalą. Babilla (2022) modeliuoja, kaip bankų skolinimo dinamiką veikia turto vertinimo pokyčiai, o tai reiškia turto kainų ir realiosios ekonominės veiklos ryšį. Pažymėtina, kad Asiedu et al. (2020) pateikia daugelio Afrikos šalių ekonomikų rezultatus kaip įrodymą, kurie išryškina, kaip turto kainų pokyčiai atlieka tarpininko vaidmenį tarp pinigų politikos veiksmų ir

realios ekonomikos veiklos rezultatų. Šią dinamiką vis labiau destabilizuoja kriptovaliutų įtaka.

Kredito kanalas pabrėžia bankų vaidmenį tarpininkaujant pinigų politikos perdavimui į realiąją ekonomiką. Tradicinė skolinimo praktika gali arba sustiprinti, arba susilpninti pinigų politikos sukurtimų poveikį. Marshal ir Toby (2021), atlikdami empirinį tyrimą Nigerijoje, iliustruoja, kad centrinių bankų palūkanų normų pokyčiai tiesiogiai veikia bankų skolinimo pajėgumus, o tai turi didelį poveikį mažosioms ir vidutinėms įmonėms. Chakravarty (2015) taip pat pabrėžia, kad svarbu atskirti bankų skolinimo ir balanso kanalus, ypač ekonomikose, pasižyminčiose skirtingomis institucinėmis charakteristikomis. Papildydami šias išvadas, Ansari ir Sensarma (2023) aptaria perdavimo mechanizmo likvidumo kūrimo aspektą teigdami, kad bankų likvidumo pokyčiai gali dar labiau modeliuoti tai, kaip veiksmingai politikos veiksmai perduodami platesnei ekonomikai. Thirunavukkarasu ir Pradha (2022) pratęsia šias diskusijas, pateikdami *ex-post* analizę, kuri susieja efektyvų kredito kanalo veikimą su patikima visuminės paklausos reakcija.

Tačiau naujausi finansinių technologijų pokyčiai metė naujų iššūkių šioms tradicinėms paradigmoms. Atsiradus decentralizuotoms kriptovaliutomis ir tokioms naujovėms kaip išmaniosios sutartys ir stabilios virtualiosios valiutos, pradėjo mažėti centralizuota kontrolė, kurią tradiciškai vykdo suverenios pinigų institucijos. Xing ir Wang (2024) teigia, kad fiksuoti tokio turto, kaip bitkoinas, tiekimo grafikai ir programuojamos tokių platformų, kaip eteris, savybės sukūrė paralelines finansines ekosistemas. Šis reiškinys trikdo klasikinius kanalus, nusilpnindamas centrinių bankų galimybes daryti įtaką pinigų kūrimui ir valdyti kredito sąlygas. Yang ir Zhou (2022) išplėtoja šį argumentą nagrinėdami, kaip centrinių bankų skaitmeninės valiutos, kurių pavyzdys yra Kinijos e-CNY, palaiptiui keičia perdavimo mechanizmą, siūlydamos alternatyvius pinigų politikos įgyvendinimo būdus. Be to, Liu ir Hu (2022) pabrėžia, kad decentralizuotoms finansų sistemoms būdingas neapibrėžtumas apsunkina tradicinį politikos kalibravimą, todėl reikia peržiūrėti politikos perdavimo modelius. Šioje disertacijoje tiesiogiai nagrinėjama ši spraga, integruojant mašininį mokymąsi su ekonometriniais metodais, kad būtų galima kiekybiškai įvertinti kriptovaliutų sukeltus trikdžius. Oladimeji et al. (2020) taip pat pažymi, kad nors kredito ir turto kainų kanalai išlieka dominuojantys perduodant pinigų politiką į realųjį sektorių, dėl naujo finansinio kraštovaizdžio reikia sustiprinti šių kanalų stebėseną didesnio sisteminio neapibrėžtumo sąlygomis. Galiausiai Ghauri et al. (2022) siūlo platesnę perspektyvą, nustatydami daugybę tiesioginių ir netiesioginių kanalų pinigų politikos perdavimo mechanizme. Ši sistema tampa vis aktualesnė, nes finansų ekosistema diversifikuojasi.

Apibendrinant teigtina, kad gausybė naujausių įrodymų kartu su klasikiniais darbais atskleidžia, kad nors palūkanų normos, valiutos kurso, turto kainos ir kredito kanalai ir toliau yra pinigų politikos perdavimo pagrindas, nauji pokyčiai, ypač skaitmeninių valiutų ir decentralizuotų finansų srityje, kelia didelių iššūkių tradiciniams kontrolės mechanizmomams. Šie trikdžiai, kurių pavyzdys – kriptovaliutų naudojimas vietoje konvencinių valiutų griežtinant pinigų politiką, pabrėžia skubų šioje disertacijoje sukurto integruoto modelio poreikį. Užpildant atotrūkį tarp teorinių sistemų ir kriptovaliutų sukeltos tikrovės, būtina pabrėžti, kad šiai problemai spręsti reikalingas modelis, gebantis fiksuoti netiesinius ryšius, režimų kaitą ir kintamumo sklidimą tarp tradicinių ir decentralizuotų finansų sistemų – tai kryptis, kurią toliau plėtoja ši disertacijoje pristatoma metodologinė struktūra.

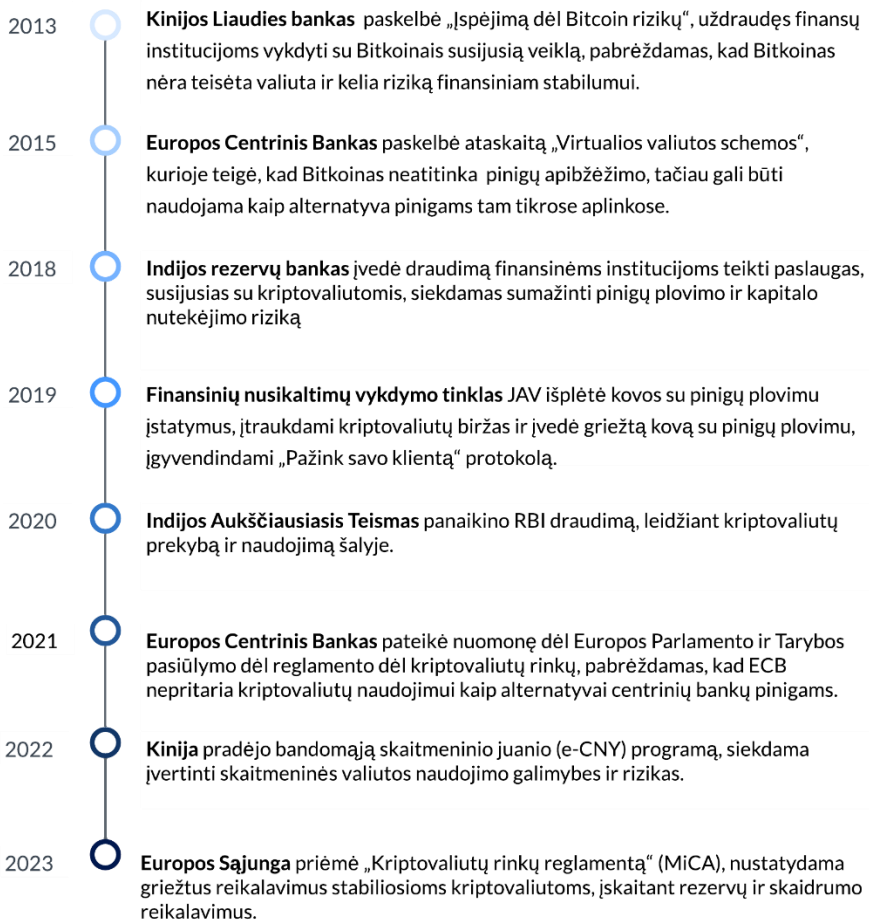
1.3. Centrinų bankų atsakas į kriptovaliutas: reguliavimo sistemos ir politikos pritaikymas

Sparti decentralizuotų kriptovaliutų raida privertė centrinius bankus permąstyti savo tradicines reguliavimo sistemas ir priimti naują politiką, kad būtų užtikrintas finansinis stabilumas, o kartu priimtoms inovacijoms. Naujausi moksliniai darbai pateikė vertingų įžvalgų apie šį paradigmos pokytį, kai pradinis skepticizmas palaipsniui užleido vietą struktūriškesniam ir aktyvesniam reguliavimo požiūriui (Attarde et al., 2025). Šis besikeičiantis požiūris pabrėžia, kad būtina ištirti, kaip decentralizuotos kriptovaliutos trikdo pinigų politikos perdavimą.

Keletas tyrėjų pabrėžė, kad pirminės centrinių bankų reakcijos buvo tik dėl kriptovaliutų saugumo. Guerini et al. (2018) rašo, kad tokie centriniai bankai, kaip Kinijos liaudies bankas ir Indijos rezervų bankas, iš pradžių nustatė griežtus kriptovaliutų sandorių apribojimus, siekdami sumažinti pinigų plovimo ir kapitalo nutekėjimo riziką (Kinijos liaudies bankas, 2013; Reserve Bank of India, 2018). Chokor ir Alfieri (2021) išplečia šį požiūrį, analizuodami trumpalaikį ir ilgalaikį tokių reguliavimų poveikį nepastovioms kriptovaliutų rinkoms. Šis ankstyvasis reguliavimo etapas pasižymėjo gynybine pozicija, atspindinčia platesnį susirūpinimą dėl finansinio stabilumo, kurį pakartotoje daugelis reguliavimo institucijų. Tačiau šios priemonės, taikytos reaguojant į situaciją, nepašalina sisteminio iššūkio, kurį sukėlė kriptovaliutų struktūrinė integracija į pinigų sistemas. Pastaruoju metu ypač išryškėjo poreikis vertinti šią sąveiką nuosekliau, modeliuojant, kaip kriptovaliutos keičia pinigų politikos priemonių veiksmingumą.

1.2 pav. pateikta chronologinė decentralizuotų kriptovaliutų reguliavimo įvykių seka, atskleidžianti, kaip skirtingos valstybės ir institucijos reagojo į šio naujo finansinio reiškinio keliamus iššūkius. Pradedant 2013 m., kai Kinijos liaudies bankas pirmasis oficialiai įspėjo apie bitkoino rizikas ir uždraudė finansų institu-

cijoms su juo susijusią veiklą, nuosekliai atskleidžiama, kaip kriptovaliutų augimas skatino vis griežtesnes reguliavimo priemones. 2015 m. ECB pripažino bitkoiną kaip priemonę, neatliekančią pinigų funkcijų, o 2018 m. Indijos rezervų bankas įvedė draudimą, kurį vėliau 2020 m. panaikino Aukščiausiasis Teismas. 2019 m. JAV FinCEN išplėtė AML/KYC reikalavimus kriptovaliutų biržoms, o 2021 m. ECB išreiškė nepritarimą kriptovaliutų naudojimui kaip alternatyvai centrinių bankų pinigams.



1.2 pav. Centrinų bankų reakcijų į decentralizuotas kriptovaliutas chronologinė seka (Sudaryta autoriaus)

Fig. 1.2. Evolution of central banks' responses to decentralised cryptocurrencies (Created by the author)

2022 m. Kinija pradėjo e-CNY bandomąjį projektą, o 2023 m. ES priėmė MiCA reglamentą, nustatantį griežtus reikalavimus stabiliosioms kriptovaliutoms. Ši chronologinės sekos analizė ne tik atspindi augantį reguliavimo aktyvumą, bet ir pabrėžia, kad kriptovaliutų integracija į finansų sistemas išprovokavo paradigminį poslinkį – nuo gynybinės pozicijos prie strateginės integracijos, kurioje reguliavimas tampa esminiu makroekonominio stabilumo palaikymo įrankiu.

Kriptovaliutų rinkai subrendus (tai rodo eksponentinis pasaulinės rinkos kapitalizacijos augimas) dėl ekonominių padarinių, kontroliuojančiosioms institucijoms teko keisti reguliavimo filosofiją. Centriniai bankai pripažino, kad kriptovaliutos bent iš dalies atlieka klasikinės pinigų funkcijas, taip suteikdami joms struktūrinį vaidmenį šiuolaikinėse pinigų sistemose. Tai paskatino reguliuojančias institucijas įgyvendinti priemones, kurios ne tik mažina finansinę riziką, bet ir palengvina inovacijų diegimą. Europos Centrinio Banko atlikti kriptovaliutų reguliavimo sistemų pakeitimai rodo, jog judama prie kriptovaliutų strateginės integracijos (European Central Bank, 2021). Taip FinCEN 2021 m. išplėtė bankų slaptumo įstatymą, įtraukdamas į jį kriptovaliutų biržas, ir pradėjo griežtą kovą su pinigų plovimu, įgyvendinant protokolą „Pažink savo klientą“ (Financial Crimes Enforcement Network, 2021). Tai rodo griežtesnės priežiūros tendenciją, reaguojant į kylančias rizikas, kaip pažymi Chokor ir Alfieri (2021).

Kartu centriniai bankai aktyviai tyrinėjo skaitmenines inovacijas kaip alternatyvias reguliuojamų pinigų formas. Nabilou (2019) kritiškai nagrinėja CBDC įvedimo teisinius aspektus ir pabrėžia galimą riziką ir naudą, kurią šios skaitmeninės, bet sykiu konvencinės pinigų formos gali kelti pinigų suverenumui. Mainetti et al. (2023) pateikia alternatyvią nuomonę, aptardami technines inovacijas, būtinas saugioms ir patikimoms CBDC sistemoms sukurti. Šis dvigubas siekis stiprinti reguliavimo priežiūrą ir diegti skaitmeninių valiutų technologijas, atspindi strateginį prisitaikymą, kai centriniai bankai siekia susigrąžinti pinigų sistemų kontrolę, kartu užtikrindami, kad finansų įstaigos išliktų atviros inovacijoms. Xu (2022) toliau iliustruoja aktyvią didžiųjų ekonomikų, tokių kaip Kinija, poziciją, kur e-CNY įvedimas rodo sąmoningas pastangas išnaudoti skaitmeninių valiutų veiksmingumą, kartu mažinant susijusią riziką. Tačiau, kaip teigiama šioje disertacijoje, CBDC sukūrimas neišsprendžia privačių kriptovaliutų struktūrinio griaunamojo poveikio, kurio esami modeliai neįvertina, todėl būtina taikyti čia siūlomą naują ekonometrinį metodą, kad būtų atskirtas jų poveikis pinigų politikos perdavimui.

Be anksčiau minėtų priemonių, mokslininkai nagrinėjo naujų reguliavimo metodų ir platesnės makroprudencinės politikos sąveiką. Krug (2018) aptaria diskusiją, ar centriniai bankai turėtų integruoti makroprudencines priemones su tradicine pinigų politika, kad galėtų spręsti sisteminės rizikos problemas. Kriptovaliutų rinkoms būdingas kintamumas, kurį pabrėžia Alp et al. (2020), kelia unikalių

iššūkių, reikalaujančių koordinuoto reguliavimo atsako. Kripto valiutų, kaip įtakingų pinigų rinkų elementų, atsiradimas paskatino kai kuriuos tyrėjus teigti, kad jos gali iš esmės pakeisti tradicinius pinigų mechanizmus. Tokiuose tyrimuose, kaip Tuori (2022), pabrėžiama, kad dėl kintančio skaitmeninio turto vaidmens centriniai bankai turi iš naujo apsvarstyti ir savo reguliavimo sistemas, ir politikos priemones.

Be to, besikeičianti ECB strategija atspindi bandymą suderinti inovacijas su atskaitomybe ir skaidrumu, kurių reikalauja šiuolaikinė ekonomika (Fama et al., 2024). Šis perėjimas akivaizdus ne tik perklasifikuojant reguliavimą, bet ir kuriant sudėtingas priežiūros metodikas, kuriomis siekiama užkirsti kelią rizikoms. Paratchi et al. (2023) išsamiau aptaria platesnes pinigų funkcijas skaitmenizuotoje ekonomikoje, teigdami, kad kripto valiutų integracija į finansų sistemą pabrėžia prisitaikančių reguliavimo sistemų poreikį.

Chen & Adams (2023) pateikia papildomų įrodymų iš Kinijos pastangų sukurti tinkamą reguliacinį mechanizmą, pabrėždami, kad valstybės kontroliuojamoms skaitmeninėms valiutoms būtina reformuoti teisinę ir veiklos aplinką. Jų analizė sustiprina pasaulinį imperatyvą centriniams bankams diegti naujoves formuojant politiką, kartu užtikrinant, kad būtų išsaugoti tradiciniai pinigų kontrolės ir finansinio stabilumo principai.

Viena iš svarbiausių reguliavimo priemonių – griežtesnės kovos su pinigų plovimu ir „Pažink savo klientą“ sistemos sukūrimas (Boyko et al., 2024). Pagal šias priemones finansinių veiksmų darbo grupės 2019 m. „Kelionės taisyklė“ įpareigoja kripto valiutų biržas dalytis siuntėjo ir gavėjo duomenimis apie sandorius, viršijančius 1000 JAV dolerių (Financial Action Task Force, 2023). Šią politiką patvirtino daugelis jurisdikcijų visame pasaulyje (Khan et al., 2023). „Chainalysis“ ataskaitoje nurodoma, kad tokių priemonių laikymasis buvo veiksmingas – neteisėtų kripto valiutų sandorių sumažėjo nuo 2,1 % (Huang, 2021). Šių priemonių taikymas apčiuopiamai atgrasė nuo kripto valiutomis grindžiamų finansinių nusikaltimų. Pabrėžiama, kad reguliavimo institucijos turi pritaikyti tradicines atitikties priemones decentralizuotai aplinkai. Be to, Kiriyakova ir Kalieva (2022) pabrėžia teisinius sunkumus, kylančius vykdant kripto valiutų reguliavimo reikalavimų laikymąsi, ir akcentuoja poreikį plačioms reguliavimo permainoms. Tačiau šiuose tyrimuose daugiausia dėmesio skiriama teisinės atitikties reikalavimų vertinimui, o ne kripto valiutų griaunamojo poveikio pinigų politikos perdavimo mechanizmams vertinti.

Kalbant apie stabilizuotų virtualiųjų valiutų reguliavimą, rinkos šokas, kurį sukėlė 2022 m. įvykęs „TerraUSD“ žlugimas, paskatino didelės rinkos vertės praradimą, rodo, kad reikia griežtų priežiūros mechanizmų (Sobański et al., 2023b). Remiantis Europos Sąjungos kripto valiutų rinkų priežiūros sistema dabar reikalaujama, kad stabilizuotos virtualiosios valiutos emitentai turėtų likvidžių atsargų

santykiu 1:1 ir išsamiai atskleistą informaciją apie valdymo protokolą. Šis reguliavimo atsakas yra labai svarbus užtikrinant pinigų politikos tvarumą, kaip pažymi Bozma ir Akdag (2021). Jie teigia, kad svarbu užtikrinti skaitmeninio turto skaidrumą. Tačiau šiuose darbuose kiekybiškai nemodeliuojama, kaip stabilieji pinigai veikia tradicines pinigų politikos priemones.

Rinkos priežiūra, ypač pasitelkiant pažangią analitiką, yra dar vienas svarbus centrinio banko reagavimo elementas (Youssef & Ismail, 2024). Iniciatyvos, susijusios su paskirstytųjų duomenų technologija (angl. *Distributed Ledger Technology*), rodo, kaip blokų grandinės analitika gali būti veiksmingai panaudota kriptovaliutų sandorių stebėsenai realiuoju laiku vykdyti, šalinant reikšmingas tradicinių priežiūros sistemų spragas (Jain & Jain, 2024). Be to, skaitmeninių priežiūros priemonių integravimas yra būtinas siekiant veiksmingai valdyti riziką besivystančioje „kriptoeconomikoje“. Literatūroje pabrėžiama, kad dinaminės stebėsenos pinigų politikos priemonės padeda suderinti decentralizuotą kriptovaliutų prigimtį su centralizuota priežiūra. Be to, dėl kriptovaliutų priėmimo ir tradicinių finansų rinkų santykio reikia iš naujo įvertinti rinkos struktūrą. Tai rodo, kad centriniai bankai turi pritaikyti savo reguliavimo sistemas, kad sparčiai besikeičiančioje finansinėje aplinkoje galėtų ir kovoti su rizika, ir išsaugoti pinigų politikos veiksmingumą (Safarli & Safarli, 2024; Allen et al., 2020).

Apibendrinant galima teigti, kad besikeičianti reguliavimo reakcija į decentralizuotą kriptovaliutą – nuo pradinių ribojamųjų priemonių iki strateginių integracijos pastangų – rodo, kad centriniai bankai vis labiau pripažįsta kriptovaliutų sisteminį poveikį pinigų sistemoms. Nors esamuose tyrimuose išryškėja reguliavimo prisitaikymas siekiant sumažinti riziką, juose nepateikiama struktūrinė sistema, kuri leistų kiekybiškai įvertinti, kaip kriptovaliutos keičia pinigų politikos perdavimo veiksmingumą, arba prognozuoti jų atsaką į politikos sukrėtimus. Pateikti įrodymai, apimantys AML/KYC reformas, CBDC naujoves ir makroprudencinius koregavimus, patvirtina, kad reikia integruoto ekonometrinio modelio, galinčio įvertinti dvikryptį pinigų politikos sprendimų ir kriptovaliutų rinkų poveikį.

1.4. Kriptovaliutų kintamumas ir makroekonominis stabilumas

Kriptovaliutų kainų nepastovumas (angl. *volatility*), būdingas decentralizuotam skaitmeniniam turtui, tapo ir destabilizuojančia jėga, ir finansinių inovacijų katalizatoriumi (Zhang et al., 2024). Skirtingai nuo tradicinių konvencinių valiutų, kurių vertę įtvirtina centrinių bankų patikimumas ir makroekonominiai pagrindai, kriptovaliutoms būdinga kainų dinamika, kurią lemia spekuliacinė prekyba, technologijų plėtra ir pasaulinės rizikos nuotaikos (Saleem et al., 2024).

1.3 lentelėje pateikta bitkoino ir S&P 500 nepastovumo dinamikos lyginamoji analizė. Šie du instrumentai pasirinkti kaip kriptovaliutų pasaulio ir tradicinės finansinės sistemos atstovai. S&P 500 indeksas pasirinktas kaip palyginimo etalonas, nes jis plačiai naudojamas kaip JAV akcijų rinkos barometras ir atspindi didelės kapitalizacijos viešai kotiruojamų bendrovių grąžos bei rizikos dinamiką, todėl yra patogus tradicinių finansų rinkų reprezentantas. Toks pasirinkimas leidžia aiškiau įvertinti, kiek kriptovaliutų (bitkoino) nepastovumas skiriasi nuo plačiai diversifikuoto, likvidaus ir plačiai stebimo tradicinio rizikos turto etalono. Qezelbash et al. (2023) nustatė, kad bazinis bitkoino kintamumas yra 3,3 karto didesnis nei S&P 500. Dehouche (2022) užfiksavo jam taip pat būdingus didesnius vienos dienos svyravimus. Paradoksalu, bet Mazur (2022) nustatė, kad bitkoinas krizės laikotarpiu pasižymi didesniu stabilumu nei akcijos, o tai rodo hibridines apsidraudimo savybes. Manevich (2024) atskleidžia, kad bitkoino kintamumo prognozės yra tikslesnės negu klasikiniai atitikmenys. Nzokem ir Maposa (2024) patvirtina, bitkoino grąžos rizikos vertė (angl. *Value-at-Risk*) yra keturis kartus didesnė už S&P 500 indekso grąžą, esant tokiai pačiai rizikai.

1.3 lentelė. Bitkoino ir S&P 500 nepastovumo dinamikos lyginamoji analizė
Table 1.3. Comparative analysis of bitcoin and S&P 500 volatility dynamics

Aspektas	Bitkoinas	S&P 500
Santykinis nepastovumas	3,3 karto didesnis	Mažesnis
Dieninis nepastovumas	Aukštas	Mažesnis
Nepastovumas krizėse	Mažesnis nei kitose aktyvų klasėse	Didesnis krizės metu
Nepastovumo prognozavimo tikslumas	Didesnis tikslumas	Mažesnis tikslumas
Rizikos vertė (VaR)	Žymiai didesnė	Mažesnė

Šis kriptovaliutoms būdingas nepastovumas kelia didelių iššūkių makroekonominiam stabilumui. Remiantis ankstesne kriptovaliutų piniginių funkcijų ir sutrikdytų politikos kanalų analize, šiame poskyryje nagrinėjamas dvejopas kriptovaliutų nepastovumo pobūdis, įvertinant jo keliamą riziką (infliacinis spaudimas, politinis neapibrėžtumas, užkrato poveikis) ir galimybes (apsidraudimas, inovacijos) pasaulio ekonomikos kontekste.

1.4.1. Infliacinis spaudimas ir turto burbulai

Kripto valiutų rinkos sulaukė nemažai dėmesio dėl savo ryškaus kintamumo, kuris gali turėti makroekonominių pasekmių, ypač susijusių su infliaciniu spaudimu ir turto burbulų susidarymu. Ekstremaliems kripto valiutų kainų svyravimams įtakos turi įvairi rinkos dinamika, investuotojų elgsena ir platesnės ekonominės sąlygos (Sayim & My, 2023; Bouteska et al., 2025). Daugelyje tyrimų pabrėžiama, kaip šis kintamumas gali sustiprinti spekuliacinius burbulus, iškreipti kapitalo paskirstymą ir daryti įtaką vartotojų elgsenos ciklams (W.-P. Chen et al., 2025).

Hodula (2025b) tyrimai rodo, kad didelės infliacijos laikotarpiais vartotojų išlaidų suvaržymai neigiamai veikia kripto valiutų kainas, pabrėžiant neigiamą infliacinio spaudimo ir kripto valiutų vertinimų koreliaciją. Tačiau pažymėtina, kad kai kurie tyrimai atskleidė teigiamą kripto valiutų ir išankstinių infliacijos rodiklių ryšį, ypač konkrečių ekonominių nuosmukių, pvz., COVID-19 pandemijos metu (Smale, 2024). Tai rodo, kad impulsyvus investuotojų elgesys gali sukurti burbulus. 2021 m. lapkričio mėn. įvykęs dramatiškas bitkoino kainos šuolis iki 69 000 JAV dolerių, kurį skatino tiek mažmeninės, tiek institucinės investicijos, o paskui sekė reikšminga rinkos korekcija, sukėlusį didelius rinkos nuostolius (Mungo et al., 2024).

Dar labiau pabrėždamas tokią burbulų elgseną, Panigrahi (2023b) nagrinėjo kripto valiutų kainų svyravimų ir ekonominio stabilumo ryšį teigdamas, kad kripto valiutų rinkos svyravimai gali perkelti riziką į tradicines finansų rinkas, potencialiai sustiprindami turto burbulams palankias sąlygas. Hanif et al. (2023) pritarė šiam požiūriui parodydami, kad ekstremalūs rinkos įvykiai koreliuoja su padidėjusiu kripto valiutų, akcijų ir žaliavų tarpusavio ryšiu, o tai rodo, kad kripto valiutos gali pasitarnauti ir kaip prieglobstis, ir kaip riziką didinanti priemonė infliacinių krizių metu.

Iqbal et al. (2023) išvados atskleidė, kad kripto valiutų rinka yra gerokai nepastovesnė nei tradicinės turto klasės, todėl būtina kurti patikimus modelius rizikai prognozuoti ir efektyviai valdyti portfelius. Jie pabrėžia, kad kripto valiutų erdvei būdingi dideli rinkos svyravimai, kuriuos galima paaiškinti netradiciniais vertinimo rodikliais ir jos spekuliaciniu pobūdžiu. Šį nepastovumą dar labiau apsunkina makroekonominiai veiksniai, pvz., agresyvi pinigų politika, kuria siekiama kovoti su didėjančia infliacija, didina nepastovumą, darydama įtaką investuotojų nuotaikoms ir elgsenai kripto valiutų atžvilgiu (Ti & Husodo, 2024).

Akademiniai vertinimai taip pat pabrėžia investuotojų nuotaikų svarbą kripto valiutų kainų elgsenai. Yang et al. (2025) atskleidė, kad ekstremalių investuotojų nuotaikų indeksai koreliuoja su bitkoinų kainų svyravimais, kas rodo, kad netikėtos infliacijos ar defliacijos laikotarpiais rinkos dinamika gerokai pasikeičia, o tai gali lemti neteisingą įkainojimą ir didesnę kintamumą. Makroekonominio stabilumo ir turto burbulų kripto valiutų rinkose sąveika nėra pakankamai iširta,

kaip pabrėžė Gapurbaeva et al. (2023), kuri pažymi, kad su kriptovaliutomis susijęs kintamumas ir investicinė rizika kelia iššūkį tradiciniams finansinio stabilumo konstruktais, todėl pateisina griežtesnę reguliavimo kontrolę.

Apibendrinant teigtina, kad įvairiapusis ryšys tarp kriptovaliutų kintamumo, makroekonominio stabilumo, infliacinio spaudimo ir turto burbulų pabrėžia būtinybę tirti šią dinamiką. Nors kriptovaliutų patiriamas kintamumas gali suteikti unikalų investavimo galimybių, jis taip pat kelia didelę riziką platesnėms ekonominėms sąlygoms, todėl būtinas didesnis investuotojų ir reguliavimo institucijų informuotumas.

1.4.2. Politikos neapibrėžtumas ir centrinio banko iššūkiai

Politikos neapibrėžtumas, centrinių bankų iššūkiai, kriptovaliutų svyravimai daro didelį poveikį makroekonominiam stabilumui. Skaitmeninių valiutų išpopuliarėjimas sukėlė didelį neapibrėžtumą formuojant ir vykdant pinigų politiką. Šią riziką ypač didina asmenų ir įmonių elgesys, kurie, esant didelei infliacijai, linkę rinktis kriptovaliutas, o ne tradicines valiutas. Pvz., 2022 m. Turkijoje buvo didelė – maždaug 85 % – infliacija, todėl piliečiai, siekdami išsaugoti perkamąją galią, savo santaupas konvertavo į kriptovaliutas, o tai buvo susiję su gerokai padidėjusia kriptovaliutų prekybos apimtimi (Juhro, 2022).

Keliuose tyrimuose pabrėžiama, kad toks pokytis gali pakenkti centrinių bankų gebėjimui veiksmingai valdyti pinigų pasiūlą. Kriptovaliutos veikia už tradicinių pinigų sistemų ribų, o tai apsunkina ekonominius vertinimus ir pinigų politikos atsaką (Kóczyán et al., 2022). Federalinės rezervų sistemos 2022 m. finansinio stabilumo ataskaitoje nurodyta, kad kriptovaliutų kintamumas kelia „struktūrinį pažeidžiamumą“, pažymint, kad didelė dalis JAV namų ūkių, dalyvaujančių kriptovaliutų cirkuliacijose, pasižymi išlaidų elgsena, mažiau jautria palūkanų normoms (Labouré et al., 2021). Šis atsiejimas rodo kovos su infliacija poveikio susilpninimą, verčiantį centrinius bankus iš naujo permąstyti, kaip jie vertina pinigų politikos atsaką greitį ir mastą.

Be to, politikos neapibrėžtumo ir kriptovaliutų kintamumo sąveika centrinėms bankams kelia papildomų iššūkių. Tyrimai rodo, kad padidėjęs politikos neapibrėžtumas koreliuoja su didesniu kintamumu finansų rinkose, o tai gali sutrikdyti investicijas ir užimtumą sektoriuose, kurie jautriai reaguoja į pinigų politikos pokyčius. Tokie sutrikimai gali sukelti netinkamą išteklių paskirstymą, sukurti turto burbulus ir padidinti infliacinį spaudimą, nes rinkos dalyviai reaguoja į nenusipėjamą reguliavimo aplinką (Kim, 2021).

CBDC atsiradimas sukėlė diskusijų dėl jų potencialo sušvelninti šiuos iššūkius. Tačiau, kaip pabrėžiama literatūroje, CBDC įvedimą reikia kruopščiai apsvarstyti (Nieborak, 2024). Nors jos galėtų padidinti pinigų politikos efektyvumą,

palengvindamos tiesiogines intervencijas, jos taip pat gali nustumti į šalį tradicinius bankų mechanizmus, potencialiai padidindamos finansavimo sąnaudas ir sumažindamos investicijas (Allen et al., 2020). Taigi diskusija dėl optimalaus CBDC dizaino ir integravimo į esamas pinigų sistemas tęsiasi. Be to, sparti skaitmeninių valiutų raida apsunkina centrinių bankų pinigų politikos patikimumą. Visuomenės pasitikėjimas centrinių bankų veiksmais dažnai mažėja ekonominio nepibrėžtumo sąlygomis, o tai mažina netradicinių pinigų politikos strategijų veiksmingumą, ypač kai tradicinės politikos priemonės nepasiteisina. Šis pasitikėjimo sumažėjimas gali išprovokuoti neracionalų rinkos elgesį, sustiprinti kriptovaliutų kintamumą ir pakenkti bendram ekonominiam stabilumui (Istrefi & Piloju, 2020).

Apibendrinant teigtina, kad dėl kriptovaliutų kintamumo, makroekonominių iššūkių, infliacinio spaudimo būtina kurti ekonometrines modeliavimo priemones, leidžiančias tiksliau prognozuoti centrinių bankų veiksmų atsaką kriptovaliutoms.

1.4.3. Užkrato poveikis ir finansų sistemos tarpusavio sąsajos

Kriptovaliutų integracija į tradicines finansų sistemas turi didelį poveikį makroekonominiam stabilumui, ypač dėl itin aukšto kintamumo šalutinio poveikio ir finansų rinkų tarpusavio sąsajų (Iuga et al., 2024). Kriptovaliutoms vis labiau susipinant su akcijų ir obligacijų rinkomis, būtina suprasti šią dinamiką, kad būtų galima įvertinti galimą užkrato poveikį, kuris gali pasklisti po finansų ekosistemą.

Kriptovaliutoms būdingas didelis kintamumas, jos pasižymi didele tarpusavio priklausomybe nuo makroekonominių kintamųjų ir tradicinių turto klasių, taip darydamos įtaką sisteminei rizikai. Nakagawa ir Sakemoto (2023) tyrimai rodo, kad makroekonominiai fundamentalūs rodikliai daro poveikį tikėtinais kriptovaliutų gražai, o tai leidžia daryti prielaidą, kad egzistuoja ryšys tarp makroekonominių rodiklių ir kriptovaliutų rinkos stabilumo. Ši išvada ryškėja analizuojant finansų rinkų tarpusavio priklausomybę, kai tokios technologijos kaip bitkoinų ETF ir įmonių kriptovaliutų iždai iliustruoja, kaip tradicinis turtas tampa vis jautresnis skaitmeninių valiutų kainų svyravimams (Zhu et al., 2024) nustatė ryšį tarp kriptovaliutų ir tradicinių akcijų rinkų kintamumo nurodydami, kad kriptovaliutų svyravimai gali lemti platesnių finansų rinkų nestabilumą.

Per tokius įvykius, kaip 2023 m. kovo mėn. „Silvergate“ banko krizė, dėl kurios kriptovaliutų indėlininkai atsieniė daug lėšų ir dėl to krito „KBW Nasdaq“ bankų indeksas, pastebėtas užkrato poveikis pabrėžia sisteminius kriptovaliutų rinkų ir tradicinio finansų sektoriaus ryšius, kaip aprašo Harb et al. (2022). Šis incidentas išryškina kriptovaliutų kaip užkrato šaltinio potencialą. Kumah ir Baafi (2024) toliau tiria šią riziką analizuodami pagrindinių kriptovaliutų tarpusavio sąsajas, parodydami, kad padidėjęs kintamumas dažnai yra susijęs su dideliu šio turto išplitimu.

Be to, decentralizuoto finansavimo (DeFi) platformų vaidmuo didina sisteminio užkrato potencialą. Corbet et al. (2022) nagrinėja kriptovaliutų rinkų ir akcijų rinkų likvidumo sukrėtimų koreliaciją COVID-19 pandemijos metu, nurodydami, kad krizės gali sukelti kaskadinį poveikį šiose tarpusavyje susijusiose rinkose. Jiang et al. (2022) tyrimai nustato tris pagrindinius kanalus, kuriais kriptovaliutų ir akcijų rinkos sąveikauja tarpusavyje: portfelių paskirstymo, pavedimų tarp rinkų srautų ir technologinio prisitaikymo lūkesčių. Taip sustiprinamos šių rinkų tarpusavio sąsajos.

Pažymėtina, kad keliuose tyrimuose pabrėžtas makroekonominų sąlygų poveikis kriptovaliutų kintamumui. Pvz., Wang et al. (2022) nustatė, kad makroekonominiai rodikliai pranašesni už techninius rodiklius prognozuojant bitkoino kintamumą. Tai rodo, kad ekonominiai sukrėtimai, pvz., susiję su infliacija ar palūkanų normų svyravimais, gali daryti reikšmingą įtaką kriptovaliutų rezultatams, todėl jos tampa jautrios platesnėms ekonominėms tendencijoms, kurios gali lemti finansų rinkų destabilizaciją (Oldani et al., 2024).

Kalbant apie ekonominių nuosmukių sukeltą užkrato poveikį, Panigrahi (2023) įrodymai pabrėžia, kad ekstremalus rinkos įvykiai didina finansų sistemų, ypač besiformuojančių rinkų, nepastovumą. Šis sisteminis pažeidžiamumas išryškina susirūpinimą, kad plačiai paplitęs kriptovaliutų priėmimas gali sutrikdyti ekonominį stabilumą, o tai rodo, kad finansų reguliavimo institucijos turi skubiai apsvarstyti kriptovaliutų integravimo į pagrindinius finansus pasekmes. Kriptovaliutų kintamumo ir sisteminės rizikos ryšį patvirtina ir tyrimai, rodantys reikšmingą kriptovaliutų ir tradicinių turto klasių dvikryptį šalutinį poveikį, o tai atskleidžia grįžtamąjį ryšį, kai sukrėtimai vienoje rinkoje gali paveikti kitą (Shahrour et al., 2024).

1.4.4. Nepastovumas kaip inovacijų ir atsparumo varomoji jėga

Nepastovumo ir inovacijų sankirta atveria unikalių galimybių finansų ekosistemos, ypač per kriptovaliutų ir blokų grandinės technologijų prizmę. Šiame diskurse nagrinėjama, kaip nepastovumas gali palengvinti ekonomikos atsparumą ir inovacijas, ypač kontekstuose, kuriems būdingas valiutos nuvertėjimas, infrastruktūros pažanga ir išorės geopolitiniai įvykiai.

Kriptovaliutos yra kaip apsidraudimas nuo konvencinių valiutų nestabilumo, ypač hiperinfliacijos sąlygomis (Jana et al., 2024). Stulbinanti Argentinos infliacija, 2023 m. siekusi daugiau kaip 211 %, sukėlė didelį bitkoino paklausos šuolį – apie 60 % mažų įmonių priėmė kriptovaliutas, kad išvengtų peso nepastovumo (Tanos & Badr, 2024). Tai sustiprina mintį, kad, nepaisant savo nepastovumo, bitkoinas tapo „skaitmeniniu saugiu prieglobsčiu“ tomis aplinkybėmis, kai tradicinės valiutos silpsta (Mensi et al., 2023). Panašiai po Rusijos invazijos 2022 m.

Ukrainoje smarkiai nuvertėjo jos grivina, o tai paskatino pastebimą kriptovaliutų aukų, skirtų humanitarinėms pastangoms remti, padidėjimą (Assaf et al., 2024). Šie atvejai pabrėžia kriptovaliutų naudingumą teikiant alternatyvią mainų priemonę ir vertės saugyklą ypatingo ekonominio nestabilumo laikotarpiais, iliustruojant jų adaptacinį atsparumą išorinių nepalankių veiksnių akivaizdoje (Juwita et al., 2023).

Kriptovaliutoms būdingas nepastovumas paskatino inovacijų bangą, kuria siekiama didinti finansinį efektyvumą. Tokie projektai kaip „MakerDAO DAI“, kuriame naudojamos algoritminės stabiliosios monetos, yra pastangų stabilizuoti kainų svyravimus, naudojant užstatu užtikrintas skolos pozicijas, pavyzdys (Li, 2023). Be to, eterio perėjimas prie *proof-of-stake* konsensuso mechanizmo smarkiai sumažino energijos sąnaudas, o tai yra labai svarbi pažanga siekiant masto ekonomijos proceso mokėjimo sistemose (Polat, 2023). Kriptovaliutų pažanga paskatino ECB įdiegti TARGET momentinių mokėjimų atsiskaitymo sistemą (TIPS), kasdien apdorojančia 1,3 trilijono eurų sekundės tikslumu, yra dar vienas šios tendencijos įrodymas (Zhang, 2024). Be to, naujausių tyrimų išvalgos rodo reikšmingą blokų grandinės atnaujinimo ir kriptovaliutų gražos sąveiką, liudijančią tendenciją, kai rinkos pokyčiai vis labiau siejami su blokų grandinės technologijos raida (Apergis, 2022). Šis sudėtingas nepastovumo ir inovacijų ryšys skatina aplinką, palankią finansiniam efektyvumui ir patobulintiems rinkos mechanizmams.

Nepastovumui kriptovaliutų rinkose didelę įtaką daro ir išorės veiksniai, pvz., pasauliniai geopolitiniai įvykiai ir krizės, kurie sukuria ir grėsmių, ir galimybių prisitaikymo mechanizmams. COVID-19 pandemija pastebimai pakeitė bitkoino rinkos koreliaciją su auksu, rodydama, kad infliacijos baimė paskatino investuotojus rinktis alternatyvias vertės saugyklas (Hung et al., 2023). Be to, 2023 m. JAV skolos lūbų krizė paspartino staigų bitkoino kainų kritimą, išryškindama geopolitinio neapibrėžtumo sukeltas likvidumo krizes (Caporale et al., 2019). Be to, 2021 m. Kinijos vyriausybei uždraudus kriptovaliutų kasybą, bitkoino maišos kursas reikšmingai persiskirstė pirmiausia į kitas šalis (Movva & Dasaraju, 2024). Tokie poslinkiai kursto didelę rinkos dinamiką, dėl kurios reikia patikimų modelių, galinčių integruoti platesnius pasaulinės rizikos rodiklius, kaip tai nagrinėta tyrimuose, tyrusiuose kriptovaliutų svyravimų ir ekonominės politikos sąsajas (Dashkevich et al., 2020). Šiuo atveju novatoriškos sistemos, kuriomis siekiama atsižvelgti į naują dinamiką, gali atlikti lemiamą vaidmenį skatinant rinkos stabilumą.

1.5. Pirmojo skyriaus išvados ir disertacijos uždavinių formulavimas

Teorinė decentralizuotų kriptovaliutų sąveikos su pinigų politika analizė leidžia daryti šias išvadas:

1. Decentralizuotos kriptovaliutos tapo pinigų sistemas keičiančia jėga, metančia iššūkį tradicinėms sistemoms, nes jos neturi sienų ir veikia be tarpininkų. Analizė rodo, kad kriptovaliutos vis dažniau atlieka pagrindines pinigų funkcijas: mainų priemonės, vertės saugyklos ir atsiskaitymo vieto, ypač šalyse, susiduriančiose su valiutos nestabilumu, pvz., Argentinos infliacijos krizė ir Ukrainos karo metu kriptovaliutų pritaikymas perlaidoms. Tačiau jų nepastovumas ir centrinės priežiūros nebuvimas kenkia pinigų suverenumui. Dėl šio dvilypumo būtina iš naujo įvertinti, kaip pinigų politika prisitaiko prie naujų finansinių instrumentų.
2. Kriptovaliutos sutrikdo tradicinius pinigų politikos perdavimo mechanizmus, nes sukuria lygiagrečias finansines ekosistemas. Šie trikdžiai rodo, kad esami modeliai nepakankami kriptovaliutų makroekonominiam poveikiui aprėpti.
3. Į kriptovaliutų keliamus struktūrinius iššūkius centriniai bankai reagavo fragmentiškomis reguliavimo ir technologinėmis adaptacijomis, pradedant ES MiCA reglamentu ir baigiant CBDC projektais, tokiais kaip skaitmeninis euras. Nors šiomis priemonėmis sprendžiami tokie pavojai kaip pinigų plovimas ir stabilų kriptovaliutų žlugimas, jomis nepavyksta sistemingai integruoti kriptovaliutų struktūrinio poveikio į pinigų politikos sistemas. Nigerijos ir Salvadoro bitkoinų eksperimento atvejų tyrimai atskleidžia įtampą tarp inovacijų ir kontrolės, pabrėžiant nuoseklus analitinio požiūrio poreikį.
4. Kriptovaliutų kintamumas kelia ir riziką, ir galimybes makroekonominiam stabilumui. Rizika apima infliacinius turto burbulus, politikos neapibrėžtumą ir užkrato poveikį. Ir atvirkščiai, kriptovaliutos yra kaip apsidraudimo priemonė nuo hiperinfliacijos, sudaro sąlygas finansinei įtraukčiai ir skatina blokų grandinės efektyvumo didėjimą.
5. Galima konstatuoti, kad greitai kintančios aplinkos sąlygomis reikia naujo ekonometrinio modelio, galinčio integruoti mašininio mokymosi įrankius, fiksuoti netiesinius ryšius ir režimų kaitą bei įvertinti dvikryptį kriptovaliutų ir pinigų politikos poveikį. Ši kryptis sudaro pagrindą 2 dalyje kuriamai modeliavimo sistemai, kuri atliepia 1 dalyje identifikuotus poreikius. Remiantis ankstesniais tyrimais – įskaitant ARCH/GARCH kintamumo analizę, *Elastic-net* regresijos priežastingumo išvadas ir sisteminės reguliavimo apžvalgas – atliktas tyrimas. Išvados patvirtintos

naudojant ECB / FED politikos duomenis ir kriptovaliutų rinkos reakcijas. Politikos formuotojams pasiūlytos pritaikomosios sistemos. Moksliniais tyrimais, mažinant atotrūkį tarp decentralizuotų finansų ir tradicinių pinigų sistemų, siekiama stabilizuoti makroekonominis rezultatus skaitmeninėje eroje ir kartu išnaudoti kriptovaliutų inovacinį potencialą. Remiantis literatūros analizės rezultatais, suformuluoti šie uždaviniai: sukurti integruotą ekonometrinių modelių, nustatyti pagrindinius perdavimo kanalus ir empiriškai patikrinti modelių, naudojant ECB ir FED duomenis.

Kripto valiutų ir pinigų politikos sąveikos skaitmeninėje ekonomikoje tyrimo metodologija

Šiame skyriuje formuojama modelio struktūra ir parenkami metodai, skirti dvikryptei pinigų politikos ir decentralizuotų kripto valiutų sąveikai per grįžtamojo ryšio mechanizmus modeliuoti. Jame derinami mašininio mokymosi ir ekonometriiniai metodai, siekiant kiekybiškai įvertinti šį poveikį tiek stabiliais, tiek krizės laikotarpiais.

Pirmiausia, pagrindžiama modelio struktūra ir jos komponentai, o iš alternatyvių metodų parenkami tie, kurie geriausiai tinka dvikryptei pinigų politikai ir decentralizuotų kripto valiutų sąveikai modeliuoti. Vėliau išsamiai pristatomi pagrindiniai modelio moduliai – politikos perdavimo analizė, kintamumo grįžtamojo ryšio mechanizmai ir centrinio banko atsako funkcijos. Kiekvienas komponentas pagrindžiamas literatūros apžvalgos išvadomis ir formuojamas pasirenkant atitinkamus modeliavimo sprendinius.

Sistemoje konkrečiai nagrinėjamos bitkoino, eterio ir „Binance Coin“, sudarančių daugiau kaip 60 % kripto valiutų rinkos. Į ją įtraukiami pasauliniai ekonominiai veiksniai ir tikrinamas nuo režimo priklausomas poveikis. Patvirtinimo procedūromis užtikrinamas patikimumas politikos formavimui.

Šio skyriaus metodiniai sprendimai ir jų rezultatai buvo pateikti recenzuojamose publikacijose (Pečiulis et al., 2024; Pečiulis & Vasiliauskaitė, 2021, 2023;

Peciulis & Vasiliauskaite, 2024; Pečiulis & Vasiliauskaitė, 2024; Pečiulis & Vasiliauskaite, 2025a; Peciulis & Vasiliauskaite, 2025). Sudarytas modelis suteikia centriniams bankams priemonių su kriptovaliutomis susijusiai rizikai vertinti ir atitinkamai politikos strategijoms koreguoti.

2.1. Tyrimo modelio metodologinis pagrindimas

Šiame poskyryje pateikiami teoriniai kriptovaliutų ir pinigų politikos sąveikos analizės aspektai, pagrindžiantys hibridinį ekonometrinių modelių, papildytą mašininio mokymosi metodais. Jame lyginami tradiciniai ekonometriniai metodai su naujais mašininio mokymosi metodais, rodant, kodėl jų integracija yra būtina, norint užfiksuoti sudėtingus netiesinius ryšius decentralizuotose finansų sistemose. Analizė sujungia pinigų ekonomiką su „FinTech“ inovacijomis, nustatydama konkretų pagrindą modeliams toliau kurti.

2.1.1. Decentralizuotų finansų ir pinigų politikos derinimas: hibridinis požiūris

Tradicinės pinigų politikos analizės sistemos, kurias taiko tokios institucijos, kaip ECB ir FED, remiasi dinaminiais DSGE ir didelės apimties struktūriniais ekonometriniais modeliais, tačiau šie modeliai nėra suprojektuoti fiksuoti decentralizuotų kriptovaliutų rinkoms būdingos dinamikos. Kriptovaliutų elgsenai būdingi ryškūs režimų pokyčiai, netiesiniai sąryšiai ir skirtinga reakcija priklausomai nuo nepastovumo fazės, kaip rodo režimų perjungimo analizė (Chimprang et al., 2022). Naujesni tyrimai taip pat atskleidžia, kad net tradicinių pinigų politikos rodiklių poveikis laikui bėgant kinta, o tai reikalauja metodų, gebančių fiksuoti struktūrinių ryšių pokyčius (van Lill, 2024). Vis dėlto nei DSGE, nei struktūriniai centrinio banko modeliai nenaudoja mašininio mokymosi priemonių, kurios leistų sistemingai apdoroti tokį netiesiškumą, režimų kaitą ir aukšto dažnio kintamumo elgseną. Todėl išlieka hibridinės modeliavimo struktūros poreikis, galinčios sujungti ekonometrines sistemas su mašininio mokymosi lankstumu. Šis poreikis sudaro metodologinį pagrindą toliau šiame darbe kuriamam modeliui.

Ekonometriniai metodai plačiai naudojami politikos perdavimo mechanizams analizuoti, tačiau jų taikymas kriptovaliutų rinkoms susiduria su svarbiais ribotumais. Tradicinės GARCH klasės specifikacijos, tokios kaip taikytos Liu ir Serletis (2019), leidžia įvertinti kintamumo persiliejimą, tačiau jos nėra priežastinės ir neapdoruoja režimų kaitos, sudėtingų netiesinių ryšių ar rinkos fazių pasikeitimų, būdingų decentralizuotiems aktyvams. Be to, kai analizuojama daug tarpusavyje susijusių politikos ir rinkos veiksnių, fiksuotos specifikacijos modeliai

dažnai nebesugeba prisitaikyti prie staigių pokyčių, tokių kaip 2020–2022 m. pinigų politikos ekspansija ir vėlesnis griežtinimas. Tai pabrėžia poreikį lankstesniems metodams, kurie gali įtraukti tiek rinkos sąlygų kaitą, tiek didelės dimensijos duomenų struktūrą ir kartu išlaikyti interpretacijai būtiną ekonominę struktūrą.

Mašininio mokymosi metodais kai kurie iš šių apribojimų pašalinami, taikant automatine požymių atranką ir neparimetrinį lankstumą. „Elastic Net“ derina L1 ir L2 reguliavimą, kad būtų galima susidoroti su politikos kintamųjų multikolinearumu, kartu išlaikant interpretuojamus koeficientus (Zou & Hastie, 2005). Tai ypač aktualu kriptovaliutų rinkoms, kuriose tokie nepriklausomi kintamieji, kaip centrinių bankų balansai, palūkanų normos ir rizikos nuotaikų rodikliai, dažnai pasižymi stipriomis koreliacijomis. Tačiau grynojo mašininio mokymosi metodams trūksta teorinio pagrindo, reikalingo politikos analizei, nes juose pirmenybė teikiama prognozavimo tikslumui, o ne struktūriniam aiškinimui (Mullainathan & Spiess, 2017).

Hibridinis metodas sujungia šiuos privalumus, siekiant sukurti modelį, leidžiantį nuosekliai įvertinti kriptovaliutų ir pinigų politikos sąveiką. Ekonometriinių laiko eilučių metodų integravimas su mašininio mokymosi reguliavimu leidžia daryti priežastines išvadas, kartu taikant adaptyvią specifikaciją, kuri leidžia pagrįstai parinkti įtraukiamus kintamuosius ir modeliavimo etapus. Tai įrodo naujusias Ozupek et al. (2024) darbas, kuriame pademonstruoti geresni finansinio turto prognozavimo rezultatai, taikant hibridinius modelius. Kriptovaliutų ir pinigų politikos analizei tokia sistema pritaikoma unikalioms duomenų savybėms, kartu išlaikant interpretuojamumą, būtiną centrinio banko reikmėms.

2.1 lentelė. Kriptovaliutų politikos analizės metodų palyginimas

Table 2.1. Comparison of methodological approaches for cryptocurrency-policy analysis

Metodas	Stipriosios pusės	Trūkumai	Taikymas kriptovaliutų politikos tyrimams
Tradicinis ekonometrinis	Priežastinis aiškinimas, politiškai svarbūs rezultatai	Tiesinės prielaidos, parametrų nekintamumas	Ribotas fiksuojant netiesinę kripto dinamiką (Malladi, 2022;)
Mašininio mokymo	Tvarko didelės dimensijos, netiesinius duomenis	Juodosios dėžė“ pobūdis, silpnas teorinis pagrindas	Naudingas požymių atrankai, ne politikos kūrimui (Sun, 2024)
Hibridinis	Subalansuoja interpretuojamumą ir lankstumą (Okechukwu, 2024; Maleki et al., 2020)	Skaičiavimų požiūriu sudėtingas (Kyriazis, 2021)	Tinkamas dvikryptei kriptovaliutų ir pinigų politikos sąveikai, išlaikant ekonominę interpretavimą ir prisitaikymą prie duomenų.

2.1 lentelėje apibendrinami pagrindiniai skirtingų metodikų aspektai. Tradicinis ekonometrinis metodas, nors ir teoriškai pagrįstas, sunkiai susidoroja su kriptovaliutų duomenų savybėmis. Mašininis mokymasis geriau atpažįsta modelius, bet siūlo ribotas politikos išvalgas. Šiame tyrime plėtojama hibridiniu metodu pasirinktinai derinami metodai šioms spragoms pašalinti. „Elastic Net“ regresijos integravimas su ARIMA liekanomis leidžia išskirti reikšmingą politikos poveikį ir kartu sumažinti autokoreliacijos problemą, taip pašalinant dalį tradicinių metodų taikymo finansinėms laiko eilutėms apribojimų. ARIMAX modeliai, kuriuose egzogeniniai veiksniai vertinami pagal prognozavimo svarbą, nepraranda interpretuojamumo.

Empiriniai tyrimai patvirtina šią sintezę. Seo ir Kim (2020) nustatė, kad hibridiniai modeliai, prognozuodami bitkoinų kintamumą, pranoko grynuosius ekonometrinius ar mašininio mokymosi metodus. Panašiai Storm et al. (2020) pasisako už pusiau struktūrinius modelius, kai, taikant mašininio mokymosi metodus, išsprendžiama problema dėl didelės duomenų dimensijos kartu išsaugant priežastinių ryšių. Tai atitinka tolesniuose skirsniuose sukurtą sistemą, ypač politikos perdavimo modulį ir egzogeninių veiksnių integraciją.

Mišriąją metodiką sprendžiami trys konkretūs 1 skyriuje nustatyti uždaviniai:

1. Atsižvelgia į nelineinį kriptovaliutų kainų atsaką į piniginius sukrėtimus, kurį rodo asimetriniai kintamumo modeliai.
2. Prisietaiko prie režimo pokyčių, perėjimo iš mažų palūkanų normų aplinkos (iki 2020 m.) į infliacijos laikotarpius (po 2021 m.).
3. Išlaiko politikos aiškinamumą per reguliarizuotus, bet ekonomiškai reikšmingus koeficientus, o tai labai svarbu centrinių bankų ekonomistams interpretuojant rezultatus.

Mišri metodika neužkerta kelio taikyti alternatyvius metodus, bet pasirenka metodus, remdamasis tyrimais pagrįstais rezultatais panašiomis finansinėmis aplinkybėmis. Panašiai ARIMA liekanų įtraukimas grindžiamas Boxo ir Jenkinso metodika (Box et al., 2015), užtikrinančia modelio įvesties duomenų stacionarumą neprarandant ekonominio konteksto.

2.1.2. Centrinio banko pinigų politikos perdavimo kriptovaliutų rinkoms analizė taikant hibridinį modeliavimą

Centriniam bankams reikalingos analitinės priemonės, kuriomis remiantis būtų galima apskaičiuoti ir interpretuoti pinigų politikos perdavimo koeficientus bei gautus rezultatus naudoti argumentuotam kriptovaliutų rinkos poveikio vertinimui. Tradiciniuose pinigų modeliuose vertinami fiksuoti parametrai, tačiau decentralizuotam skaitmeniniam turtui būdinga netiesinė dinamika, reikalaujanti

lanksčių specifikacijų. Sukurtame hibridiniame metode derinami mašininio mokymosi modelių atpažinimo ir ekonometrijos priežastinių išvadų darymo gebėjimai, siekiant patenkinti šiuos reikalavimus.

Pastaraisiais metais atlikti empiriniai tyrimai rodo sėkmingą pažangių kintamumo modeliavimo metodų taikymą kriptovaliutų rinkose. Maciel (2021) ir Wu et al. (2020) nustatė MSGARCH modelių pranašumą prieš tradicinius vienos sistemos GARCH modelius, prognozuodami kintamumą ir rizikos rodiklius. Kim ir Hwang (2018) parodė, kad režimų perjungimo mechanizmai leidžia modeliuoti dinamišką kintamumo elgseną, o Ghezal ir Zemmouri (2024) patvirtino šių modelių tinkamumą fiksuoti netiesinius pokyčius ir staigius svyravimus, būdingus kriptovaliutų rinkoms. Atsižvelgiant į šiuos rezultatus, kuriamame hibridiniame modelyje integruojami režimų perjungimo principai ir ilgalaikės atminties komponentas, paremtas FIGARCH modeliu, kaip tai pagrindė Pallotta ir Ciciretti (2024). Tai leidžia FIGARCH modeliams atsižvelgti į svyravimų pastovumą ilgiais laikotarpiais.

Lopez-Cabarcos et al. (2021) taip pat parodė, kad S&P 500 ir VIX gražos reikšmingai veikia bitkoino kintamumą, ypač stabiliais laikotarpiais. Han (2024) nustatė netiesinį ryšį tarp kriptovaliutų gražos ir JAV akcijų rinkos kintamumo VIX indekso. Chowdhury ir Abdullah (2024) parodė, kad ekonominės politikos neapibrėžtumo indeksas (EPU) ir VIX turi reikšmingą poveikį kriptovaliutų gražai. Atsižvelgiant į šiuos empirinius rezultatus, S&P 500 ir VIX įtraukiami į kuriamą modelį kaip egzogeniniai kintamieji, o EPU naudojamas kaip literatūrinis argumentas pagrindžiant neapibrėžtumo svarbą kriptovaliutų rinkose.

Kintamumo prognozavimo atveju naudojami modelio tikslumo rodikliai – vidutinė kvadratinė paklaida (RMSE), vidutinė absoliučioji paklaida (MAE) ir vidutinė absoliučioji mastelio paklaida (MASE) – leidžia įvertinti prognozavimo paklaidų dydį ir palyginti alternatyvių modelio specifikacijų našumą (2.2 lentelė).

2.2 lentelėje apibendrinama, kaip empiriniai rezultatai tiesiogiai veikia modelio struktūrą. Hibridinė sistema nukreipia šiuos komponentus per tris nuoseklius analitinius sluoksnius:

1. Politikos poveikio įvertinimas, naudojant regularizuotą regresiją.
2. Kintamumo režimo klasifikavimas naudojant pažangias GARCH specifikacijas.
3. Egzogeninių veiksnių integravimas su mašininio mokymosi prioritetu nustatymu.

Tokia struktūra užtikrina, kad kiekvienas modulis būtų skirtas konkrečiam kriptovaliutų ir politikos sąveikos kanalui, kartu išlaikant sąveiką visos sistemos analizei.

2.2 lentelė. Empirinių tyrimų apie pinigų politikos poveikį kriptovaliutomis apibendrinimas ir jų taikymas modelyje

Table 2.2. Summary of empirical studies on the impact of monetary policy on cryptocurrencies and their application in the model

Tyrimas	Pagrindinė išvada	Modelio pritaikymas
Nur et al. (2023); Enwere ir Ogoke (2023); Al-Jawarneh et al. (2021)	Pinigų sukrėtimai paaš- kina 69 % kriptovaliutų kainų variacijos (pakore- guota i^2)	(„Elastic Net“) + ARIMA liekanos politikos povei- kio matavimui
Maciel (2021) Wu et al. (2020b); Kim ir Hwang (2018); Ghezal ir Zemmouri (2024); Pallotta ir Ciciretti (2024)	MSGARCH/FIGARCH pranašesis kriptovaliutų kintamumui	Režimo perjungimo ir il- galaikės atminties kin- tamumo modeliai
Pečiulis ir Vasiliauskaitė (2021); López-Cabarcos et al. (2021); Han (2024); Chowdhury ir Abdullah (2024)	S&P 500 ir VIX domi- nuoja tarp kitų pasaulinių veiksnių	ARIMAX, naudojant <i>max (log likelihood)</i>

Sistemos konstrukcijoje atsižvelgiama į du kriptovaliutomis būdingus apribojimus. Pirmia, dėl parametų nestabilumo, siekiant aptikti struktūrinius lūžius, antra, dėl grįžtamojo ryšio tarp kriptovaliutų rinkų ir politikos reikia taikyti instrumentinių kintamųjų metodus, kurie galutiniame modelyje įgyvendinami taikant GMM sistemą. Šie pritaikymai skiria šį metodą nuo įprastinių pinigų analizės priemonių, kartu išsaugant teorinį pagrindą, būtiną pinigų politikai taikyti.

2.2. Decentralizuotų kriptovaliutų ir pinigų politikos sąveikos struktūrinis vertinimo modelis

Šiame poskyryje pristatoma CMP-IA modelio architektūra, kuri sukonstruota taip, kad užtikrintų dvikryptės kriptovaliutų ir pinigų politikos sąveikos (grįžtamojo ryšio) kiekybinį vertinimą, o šiam tikslui įgyvendinti modelis suskaidytas į tris tarpusavyje susietus modulius: politikos perdavimo, kintamumo grįžtamojo ryšio ir adaptyvaus centrinio banko atsako. Sistema integruoja tris pagrindinius modulius: politikos perdavimo, kintamumo grįžtamojo ryšio ir adaptyvaus atsako mechanizmus. Jame nurodomi kintamųjų atrankos kriterijai ir sistemos dinamika tarp tradicinių ir skaitmeninių finansinių sistemų. Šiuo modeliu sprendžiami unikalūs decentralizuoto turto modeliavimo iššūkiai įprastinėse politikos sistemose. Ši

struktūra leidžia visapusiškai analizuoti dvikrypčių kriptovaliutų ir politikos ryšius.

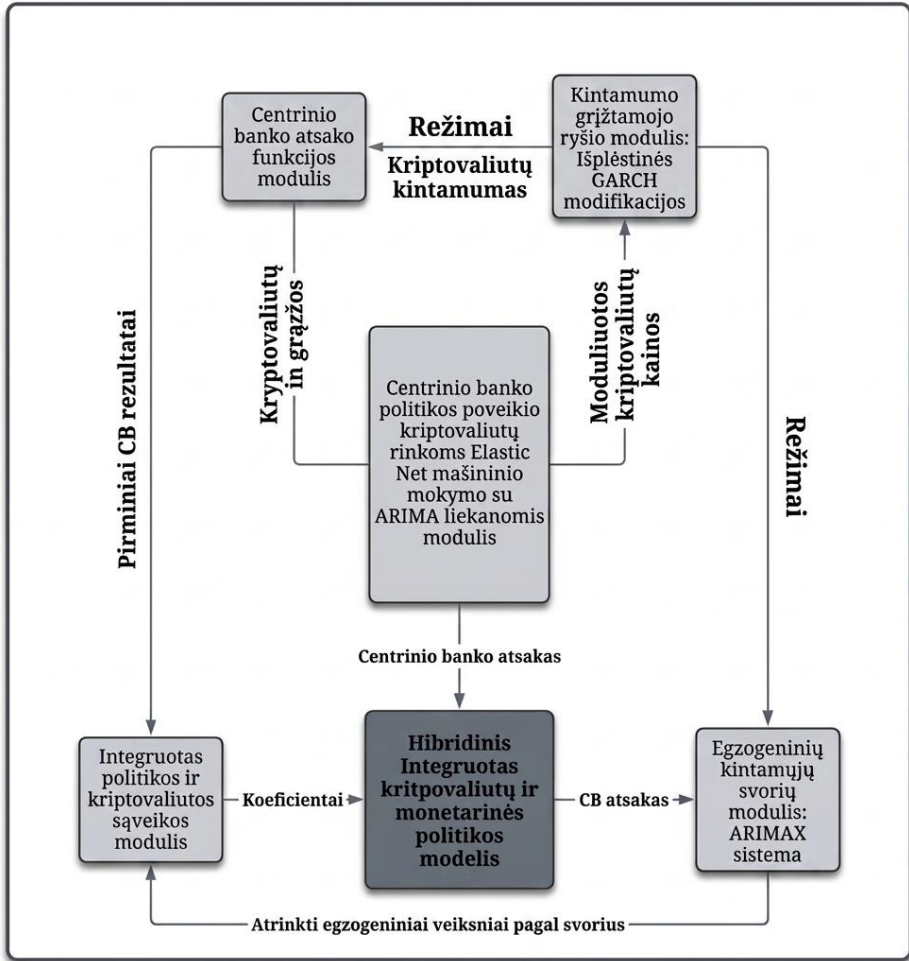
2.2.1. Modelio architektūra: grįžtamojo ryšio kilpos ir dvikryptė sąveika

Modelio architektūra atspindi dvikryptę pinigų politikos ir decentralizuotų kriptovaliutų sąveiką, taip pašalinant 1.2 poskyryje (sutrikę perdavimo kanalai) ir 1.4.3 poskyryje (užkrato poveikis) nustatytas spragas. Tradiciniuose pinigų politikos perdavimo modeliuose dažniausiai daroma prielaida, kad poveikis sklinda viena kryptimi (nuo centrinio banko sprendimų į finansų rinkas ir realią ekonomiką), tačiau kriptovaliutų rinka sukuria grįžtamojo ryšio kilpas, t. y. situacijas, kai kriptovaliutų kainų ir kintamumo pokyčiai patys tampa veiksniais, keičiančiais finansines sąlygas, rizikos nuotaikas ir galiausiai grįžtamai veikia pinigų politikos sprendimus bei jos perdavimo stiprumą. Todėl ši dvikryptė sąveika turi būti aiškiai įtraukta į modelį. Siūlomoje sistemoje ši dinamika integruojama per tarpusavyje susijusių modulių sistemą.

Pagrindinę struktūrą iliustruoja 2.1 pav. pinigų politikos sukrėtimai, pvz., palūkanų normų pokyčiai arba kiekybinio skatinimo koregavimai, pirmiausia daro poveikį kriptovaliutų grąžai. Šie kainų pokyčiai sukelia kintamumo reakcijas, kurios vertinamos režimo perjungimo GARCH (MSGARCH) modeliais. Jie leidžia atskirti žemo ir aukšto kintamumo laikotarpius ir įvertinti, kaip kintamumo dinamika skiriasi esant skirtingoms rinkos būsenoms. Atsiradęs kintamumas daro įtaką makroekonominiam stabilumui, kuris savo ruožtu daro įtaką centrinio banko politikos sprendimams. Taip sukuriamą uždaro ciklo sistema, kurioje politikos veiksmai ir kriptovaliutų rinkos nuolat sąveikauja.

Pagrindinis grįžtamojo ryšio mechanizmas veikia per kintamumo persiliejimą. Pvz., kai ECB didina palūkanų normas, bitkoino kainos paprastai mažėja. Padidėjęs kintamumas didina neapibrėžtumą tradicinėse finansų rinkose, o tai gali pakeisti centrinių bankų politikos trajektorijas. Tokios sąveikos negalima aprėpti standartiniais SVAR ar VAR modeliais, kuriuose kriptovaliutos traktuojamos kaip egzogeninės.

Modelyje netiesinė dinamika pritaikoma trimis būdais. Pirma, atskiriami stabilūs ir didelio kintamumo režimai, leidžiant parametrams keistis rinkos įtampos metu. Antra, ji apima egzogeninius pasaulinius veiksnius, tokius kaip akcijų rinkų rezultatai ir žaliavų kainos, kurie sušvelnina politikos ir kriptovaliutų sąsajas. Trečia, jis taiko mašininio mokymosi metodus, kad dinamiškai įvertintų šiuos veiksnius, taip pagerindamas prisitaikymą prie įvairių ekonominių sąlygų.



2.1 pav. Integruoto hibridinio modelio struktūra dvikryptei kriptovaliutų ir pinigų politikos sąveikai vertinti

Fig. 2.1. Methodological structure of the integrated hybrid model for assessing the bidirectional interaction between cryptocurrencies and monetary policy

Techninis įgyvendinimas apima keturis nuoseklius etapus. Politikos kintamieji patenka į „Elastic Net“ – ARIMA modelis, kad būtų įvertintas pradinis poveikis kriptovaliutų kainoms. Kintamumo modulis apdoroja šiuos kainų pokyčius, nustatydama režimo pasikeitimus ir išplitimo riziką. Trečiajame modulyje vertinamas makroekonominis poveikis, o paskutinis komponentas modeliuoja centri-

nių bankų atsaką taikant laiko parametų regresiją. Tokia struktūra užtikrina visišką žiedinį priežastingumą ir kartu išlieka skaičiavimo požiūriu lengvai įgyvendinama.

Šios struktūros apribojimai apima duomenų dažnumo neatitikimus. Kripto valiutų rinkos veikia nepertraukiamai, o politikos kintamieji stebimi mažesniu dažnumu. Modelis juos suderina per laiko agregaciją, o patikimumo patikros patvirtina, kad iškraipymai yra minimalūs. Ateityje plėtiniai galėtų apimti aukšto dažnio prekybos duomenis arba konkrečius blokų grandinės rodiklius. Ši struktūra kuriama adaptuojant ir sujungiant atskirus literatūroje plačiai taikomus metodinius blokus į integruotą architektūrą (o ne adaptuojant vieną egzistuojantį centrinio banko modelį). Kitame skyriuje aprašoma kintamųjų atranka, o vėlesniuose poskyriuose – vertinimo metodai.

2.1 pav. vaizduoja disertacijoje sukurto modelio struktūrą, kuri integruoja penkis tarpusavyje susijusius modulius, skirtus centrinių bankų politikos poveikiui, daromam decentralizuotų kriptovaliutų rinkoms, kiekybiškai įvertinti. Pagrindinis komponentas – Centrinio banko politikos poveikio kriptovaliutų rinkoms „Elastic Net“ mašininio mokymo su ARIMA liekanomis modelis – analizuoja politikos sukrėtimų įtaką kriptovaliutų kainoms, sprendamas multikolinearumo ir autokoreliacijos problemas. Šis modulis sąveikauja su kintamumo grįžtamojo ryšio moduliu, kuriame taikomos išplėstinės GARCH klasės specifikacijos, leidžiančios modeliuoti priklausomą režimo kintamumą ir jo šalutinį poveikį makroekonominiam stabilumui. Egzogeninių kintamųjų svorių modulis naudoja ARIMAX sistemą ir „XGBoost“ analizę, kad nustatytų pasaulinių veiksnių, tokių kaip VIX, S&P 500 ar CMC Crypto 200, dinaminį svorį kriptovaliutų gražai. Centrinio banko atsako funkcijos modulis modeliuoja prisitaikančius politikos sprendimus, taikant Kalmano filtravimą ir laikui einant kintančių parametų regresiją, atsižvelgiant į kriptovaliutų kintamumą ir reguliavimo intensyvumą. Visi šie komponentai sujungiami į hibridinį integruotą kriptovaliutų ir monetarinės politikos sąveikos modelį, kuris užtikrina žiedinį priežastingumą ir leidžia vienu metu vertinti politikos poveikį, rinkos reakciją ir institucijų atsaką. Tokia struktūra atspindi disertacijos siekį sukurti empiriškai pagrįstą, teoriškai nuoseklų ir skaičiavimo požiūriu efektyvų modelį, skirtą monetarinės politikos veiksmingumui analizuoti skaitmenizuotoje finansų ekosistemoje.

Ši struktūra padeda įgyvendinti 1 skyriuje aptartus teorinius trikdžius ir suteikia išmatuojamą pagrindą politikos analizei. Vėlesniuose skyriuose jos sudedamosios dalys patvirtinamos empiriškai, užtikrinant patikimumą įvairiose ekonominėse aplinkose.

2.2.2. Pinigų politikos ir kriptovaliutų kintamųjų parinkimas hibridiniam modeliui

Modelio kintamųjų atrankos procese vadovaujamosi ankstesnių tyrimų empiriniais įrodymais, siekiant užtikrinti patikimą kriptovaliutų ir pinigų politikos sąveikos analizę. Pinigų politikos rodikliai apima centrinių bankų palūkanų normas ir nekonvencines pinigų politikos priemones (UMPT) iš Europos Centrinio Banko ir Federalinės rezervų sistemos. Be to, Buthelezi (2025) tyrimai rodo, kad JAV pinigų politikos sukrėtimai, įskaitant palūkanų normų pokyčius, turi didelį poveikį kriptovaliutų kainoms ir svyravimams. Konkrečiai pinigų politikos sugriežtinimas paprastai stabilizuoja rinką esant žemoms kriptovaliutų kainoms, o palūkanų normų didinimas siejamas su kriptovaliutų kainų mažėjimu ir svyravimais esant aukštesnėms kainoms.

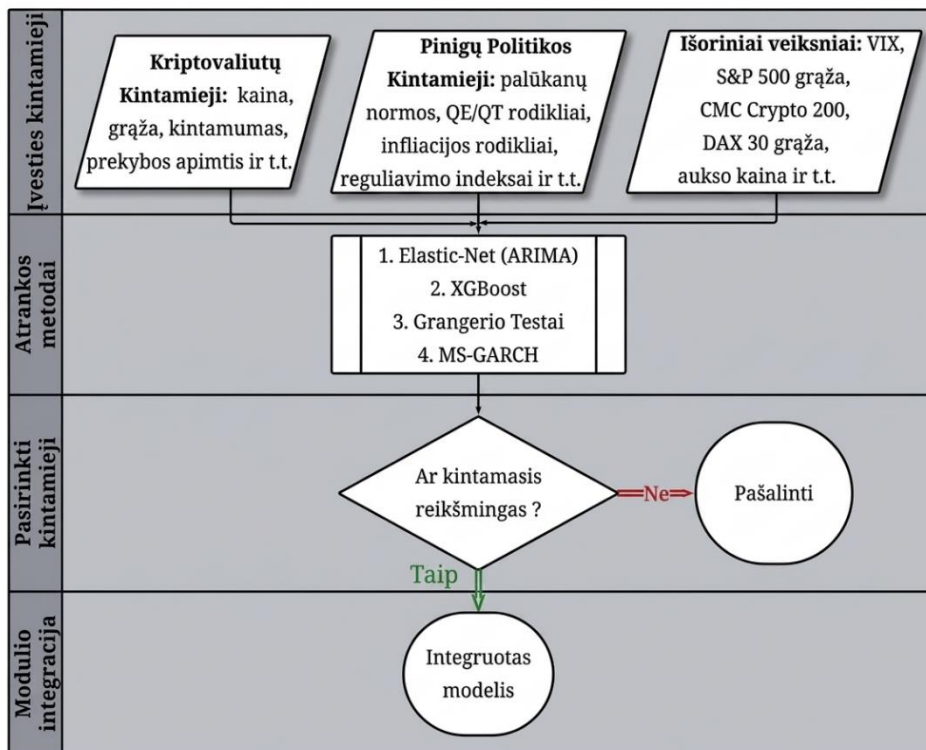
Kalbant apie kriptovaliutų rodiklius, modelyje daugiausia dėmesio skiriama bitkoinui, eteriui ir „Binance Coin“, kurie sudaro apie 60 % visos rinkos kapitalizacijos. Rinkos kapitalizacijos svoris užtikrina, kad modelis fiksuoja sisteminius kriptovaliutų rinkos pokyčius, o ne atsitiktinę sektoriaus elgseną.

Kontroliniai kintamieji apima pasaulines rizikos nuotaikas ir akcijų rinkos rezultatus, konkrečiai VIX kintamumo indeksą ir S&P 500 indekso grąžą. Žaliavų kainos, ypač žalios naftos, nebuvo įtrauktos dėl nereikšmingų p reikšmių, viršijančių reikšmingumo koeficientą (0,05).

Kintamųjų atranka yra vienas svarbiausių hibridinio modelio sudarymo etapų, nes nuo jos priklauso, kurie veiksniai bus įtraukti į analizę ir kokia informacija pasieks modelio struktūrą. Į galutinę specifikaciją tikslinga įtraukti tik tuos kintamuosius, kurie turi aiškų teorinį pagrindą, yra empiriškai pagrįsti duomenimis ir gali būti patikimai išmatuojami bei suderinami laikui einant. 2.2 pav. pateikta atrankos logika rodo, kad didžiausias dėmesys šiame etape skiriamas reikšmingiems kintamiesiems identifikuoti ir nereikšmingiems veiksniams eliminuoti, o pasirinktų komponentų tinkamumas ir jų poveikio vertinimas nuosekliai nagrinėjamas toliau.

2.2 pav. iliustruoja kintamųjų atrankos sistemą, kuri sudaro metodologinį pagrindą integruotam kriptovaliutų ir pinigų politikos sąveikos modeliui. Paveiksle pavaizduotas hierarchinis procesas, kuriame įvesties duomenys suskirstyti į tris pagrindines kategorijas: kriptovaliutų kintamuosius (pvz., kainos, grąža, kintamumas), monetarinės politikos kintamuosius (pvz., palūkanų normos, QE/QT indikatoriai, infliacijos indeksai, reguliavimo intensyvumo rodikliai) ir egzogeninius veiksnius (pvz., VIX, S&P 500 grąža, CMC Crypto 200, DAX 30 grąža, aukso kaina). Šie kintamieji toliau apdorojami taikant keturis atrankos metodus – „Elastic Net“ su ARIMA liekanomis, „XGBoost“ svarbos analizę, Grangerio priešastingumo testus ir TVP regresiją – siekiant nustatyti jų statistinį ir ekonominį reikšmingumą. Kiekvienam kintamajam taikomas sprendimo kriterijus: jei

reikšmingumas nepatvirtinamas, kintamasis pašalinamas, jei patvirtinamas, jis įtraukiamas į galutinį integruotą modelį. Tokia struktūra užtikrina, kad į modelį patektų tik empiriškai pagrįsti ir teoriškai svarbūs kintamieji, taip padidinant prognozavimo tikslumą ir sumažinant per didelio pritaikymo riziką.



2.2 pav. Kintamųjų atrankos sistema kriptovaliutų ir pinigų politikos sąveikos analizei atlikti

Fig. 2.2. Variable selection framework for cryptocurrency-monetary policy interaction analysis

2.3 lentelėje pateikiami visi empirinėje analizėje naudoti kintamieji ir jų šaltiniai. Kintamieji suskirstyti į keturias grupes pagal funkcinį pobūdį. Monetarinės politikos kintamuosius sudaro ECB pagrindinė palūkanų norma, federalinių fondų palūkanų norma ir centrinių bankų nekonvencinės priemonės dydžiai. Šie duomenys paimti tiesiogiai iš ECB ir FED ataskaitų, naudojami 2.3 poskyryje siekiant įvertinti tiesioginį politikos poveikį kriptovaliutų kainoms.

2.3 lentelė. Kriptovaliutų ir monetarinės politikos sąveikos tyrimo kintamųjų specifikacija

Table 2.3. Specification of variables for the study on the interaction between cryptocurrencies and monetary policy

Katego- rija	Kintamasis	Šaltinis	Aprašas
Moneta- rinės po- litikos	ECB pagrini- dinė palūkanų norma	ECB duomenys	Pagrindinis monetarinės politikos įrankis, veikiantis kriptovaliutų kainas
	<i>FED funds rate</i>	FED duomenys	JAV Centrinio banko palūkanų norma, reikšmingai veikianti globalias finansų rinkas
	ECB/Fed ne- konvencinės priemonė	Centrinių bankų ataskaitos ir pranešimai	Nekonvencinių monetarinių politikos priemonių poveikis
Kriptova- liutos	BTC/USD kaina	<i>CoinMarketCap</i>	Pagrindinė kriptovaliuta, sudaranti ~40 % rinkos kapitalizacijos
	ETH/USD kaina	<i>CoinMarketCap</i>	Antra pagal dydį kriptovaliuta su išplėstomis blokų grandinės funkcijomis
	BNB/USD kaina	„Binance“ duomenys	Svarbi biržos susieta kriptovaliuta, atspindinti centralizuotų platformų įtaką
Egzoge- niniai veiksniai	VIX indeksas	CBOE	Globalios rinkos nepastovumo rodiklis, patvirtintas kaip reikšmingas
	S&P 500 graža	<i>Yahoo Finance</i>	Akcijų rinkos sėkmės rodiklis, koreliuojantis su kriptovaliutų tendencijomis
	CMC Crypto 200 indeksas	<i>CoinMarketCap</i>	Kriptovaliutų rinkos bendros tendencijos

Kriptovaliutų kategorijoje pateikiami trijų didžiausių pagal rinkos kapitalizaciją valiutų duomenys: BTC/USD, ETH/USD ir BNB/USD kainos. Jas aprūpina „CoinMarketCap“ ir „Binance“ platformos. Šie kintamieji taikomi tiek politikos perdavimo analizėje (1 modulis), tiek modeliuojant kintamumą (2 modulis). Egzogeninių veiksmų grupėje pateikiami VIX indeksas, S&P 500 graža ir CMC Crypto 200 indeksas.

2.3 lentelėje taip pat nurodomi kintamieji, kurie buvo išskirti dėl statistiškai nereikšmingo poveikio. Pvz., EUR/USD valiutos kursas ir aukso kaina nepateko į galutinį modelį, nes jų p reikšmės viršijo 0,05 ribą.

Kiekvieno kintamojo paskirtis aiškiai susieta su konkrečiu modelio komponentu. Pvz., VIX indeksas įtrauktas kaip pagrindinis globalios rinkos nepastovumo rodiklis ARIMAX modelio svorinėje procedūroje (3 modulis). ECB skelbimai naudojami kaip neįprastos monetarinės politikos priemonės poveikio matas „Elastic Net“ modelyje (1 modulis).

Duomenų šaltiniai nurodyti kiekvienam kintamajam atskirai. Centrinų bankų duomenys paimti iš oficialių ataskaitų, kriptovaliutų kainos – iš patikimų kriptovaliutų duomenų platformų, o akcijų rinkos rodikliai – iš standartinių finansinių duomenų bazių. Šis skaidrumas užtikrina, kad visi naudoti duomenys atitinka akademinis reikalavimus ir gali būti atkartoti kitų tyrėjų.

Visi atrinkti kintamieji atitinka tris kriterijus: ankstesniuose tyrimuose įrodytas empirinis reikšmingumas, statistinis reikšmingumas, atliekant preliminarinius testus, ir teorinis suderinamumas su pinigų perdavimo kanalais. Pasirinkti kintamieji išlaiko pusiausvyrą tarp išsamios aprėpties ir modelio efektyvumo, vengiant per didelio pritaikymo ir kartu išgaunant esminius ryšius. Vėlesniuose skyriuose šis pagrindas grindžiamas nurodant tikslias kiekvienos kategorijos kintamųjų funkcinės formas ir vertinimo metodus.

2.3. Centrinio banko politikos poveikio kriptovaliutų rinkoms „Elastic Net“ mašininio mokymo su autoregresinio integruoto slankiojo vidurkio modelio liekanomis modulis

Čia perdavimo modulyje centrinių bankų veiksmų poveikis kriptovaliutų kainoms vertinamas kiekybiškai, taikant „Elastic Net“ mašininio mokymo modelį su ARIMA liekanomis. Taikant šį metodą sprendžiamos dvi empirinės problemos: politikos kintamųjų multikolinearumas ir kriptovaliutų grąžos autokoreliacija. Šio modulio metodologinis pagrindas remiasi Zou ir Hastie (2005) pristatytu reguliavimo ir kintamųjų atrankos modeliu, kuris taikomas (2.1)–(2.4) formulėse. Visoje specifikacijoje derinami reguliarizavimo metodai su laiko eilučių korekcijomis:

$$\hat{\beta} = \underset{\beta}{\operatorname{argmin}} \left\{ \frac{1}{2n} \sum (y_t - \beta^0 - x_t' \beta)^2 + \lambda \left[\frac{1-\alpha}{2} \|\beta\|^2 + \alpha \|\beta\|^1 \right] \right\}, \quad (2.1)$$

čia β^0, β – modelio koeficientai; $y_t \in \mathbb{R}$ – kriptovaliutų (BTC, ETH, BNB) dienos kaina; $x_t \in \mathbb{R}^k$ – politikos kintamieji (i^{ib}, QE_t) ir kontroliniai kintamieji (VIX, S&P500); $\lambda \in \mathbb{R}^+$ – kontroliuoja bendrą reguliavimo stiprumą; $\alpha \in [0, 1]$ subalansuoja L_1/L_2 baudas kriptovaliutų grąžą (BTC, ETH, BNB).

Klaidos ε_t priklauso nuo ARIMA(p, d, q) proceso:

$$\Phi(L)(1-L)^d \varepsilon_t = \theta(L)\omega_t, \omega_t \sim N(0, \sigma^2), \quad (2.2)$$

čia $\Phi(L) = 1 - \sum \phi_i L^i$ (autoregresinė komponentė); $\theta(L) = 1 + \sum \theta_j L^j$ (slankiojo vidurkio komponentas); L – atsilikimo operatorius; $d \in \mathbb{Z}^+$ – diferencijavimo tvarka.

2.1 ir 2.2 formulėmis parodome, kaip modelyje sprendžiama multikolinearumo problema, taikant „Elastic Net“ priemonę $P(\beta) = \lambda \left[\frac{1-\alpha}{2} \|\beta\|^2 + \alpha \|\beta\|_1 \right] L_1$. Šis komponentas atlieka kintamųjų atranką, sumažindamas nereikšmingus koeficientus iki nulio, o L_2 narys stabilizuoja koreliuotų nepriklausomų kintamųjų įverčius.

Optimalūs (λ_s, α_s) nustatomi taikant kryžminį tikrinimą:

$$(\hat{\lambda}_s, \hat{\alpha}_s) = \operatorname{argmin} CV(\lambda, \alpha) \quad \lambda > 0, \alpha \in [0, 1], \quad (2.3)$$

čia kryžminio patikrinimo rezultatas apskaičiuojamas pagal palikimo vieno iš eišgos kryžminio patikrinimo metodą:

$$CV(\lambda, \alpha) = \left(\frac{1}{m} \right) \sum \left\| y_{\{\tau+1\}} - x'_\tau \hat{\beta}_s^{\{(-\tau)\}} \right\|^2 \quad \tau \in W_s, \quad (2.4)$$

čia $\hat{\beta}_s^{\{(-\tau)\}}$ – „Elastic Net“ įvertis, išskyrus stebėjimą τ .

Tarp langų s ir $s+1$ apskaičiuojame struktūrinio lūžio statistiką.

Modulio rezultatai vėlesnei analizei naudojami kintamumo grįžtamojo ryšio modulyje, tikrinant, ar kriptovaliutų kainos atsakas nėra perduodamas infliacijai.

2.3.1. Tradicinės pinigų politikos priemonės ir jų kintamieji centrinio banko politikos poveikio modulyje

Šiame skirsnyje aprašoma, kaip pristatytas „Elastic Net“ su ARIMA liekanomis metodas taikomas tradicinių pinigų politikos priemonių – FED ir ECB palūkanų normų sprendimų poveikiui kriptovaliutų kainoms įvertinti. Poskyrio paskirtis yra metodinė: apibrėžti priklausomuosius ir nepriklausomuosius kintamuosius, jų matavimo dažnį, imties ribas ir papildomų (komunikacinių) politikos signalų kodavimą, kad empirinė analizė būtų atkartojama.

Tyrimė analizuojamos trys didžiausios pagal rinkos kapitalizaciją kriptovaliutos, kotiruojamos JAV dolerio atžvilgiu: BTC, ETH ir BNB. Šios kriptovaliutos atrinktos taikant 60 % rinkos kapitalizacijos aprėpties kriterijų (2022 m. lapkričio 1 d.), siekiant, kad analizė atspindėtų sisteminę kriptovaliutų rinkos dalį, o ne pavienių mažesnio likvidumo projektų dinamiką. Stabiliosios kriptovaliutos (pvz., „Tether“ ar „USD Coin“) į imtį neįtrauktos, nes jų tiesioginis susiejimas su JAV doleriu iš esmės keičia kainodaros mechanizmą ir galėtų dirbtinai iškraipyti palūkanų normų poveikio vertinimą.

Imties laikotarpis – 2017 m. lapkričio 7 – 2022 m. lapkričio 18 d. Šios ribos pasirinktos dėl dviejų priežasčių: 1) užtikrinamas visų trijų kriptovaliutų duomenų vientisumas ir palyginamumas; 2) įtraukiami tiek palyginti ramūs, tiek didelio nepibrėžtumo laikotarpiai, įskaitant COVID-19 pandemijos pradžią ir po josėjusius pinigų politikos režimo pokyčius. Analizėje naudojamos dienos uždarymo kainos darbo dienomis, nes taip duomenų struktūra geriau sutampa su centrinių bankų sprendimų skelbimo laiku, kuris paprastai patenka į įprastas finansų rinkų darbo valandas.

Pagrindinis JAV pinigų politikos kintamasis šiame poskyryje yra federalinių fondų palūkanų norma (FFR), pasirinkta dėl jos centrinio vaidmens FED pinigų politikos įgyvendinimo sistemoje. Euro zonos atveju į modelį įtraukiamos trys ECB palūkanų normos, sudarančios palūkanų normų koridorių: indėlių palūkanų norma, pagrindinių refinansavimo operacijų (fiksotos palūkanų normos konkurso) norma ir ribinio skolinimosi galimybės norma. Toks sprendimas leidžia išvengti išankstinio (subjektyvaus) vienos „pagrindinės“ ECB normos parinkimo ir suteikia galimybę „Elastic Net“ atrankos mechanizmui empiriškai nustatyti, kuri palūkanų normos dalis turi didžiausią informacinį svorį kriptovaliutų kainų dinamikoje.

Be kiekybinių palūkanų normų, šiame poskyryje įtraukiami ir kokybiniai pinigų politikos signalai, susiję su centrinių bankų komunikacija. Tam naudojami koduoti FOMC ir ECB pranešimai, suskirstyti į ekspansinį (skatinamąjį) ir kontraktinį (ribojantį) toną atspindinčias kategorijas. Ši komunikacinė informacija į modelį įtraukiama todėl, kad rinkos reakcija dažnai kyla ne vien iš faktinio normos pokyčio, bet ir iš formuluojamų lūkesčių dėl būsimų sprendimų, o tai ypač aktualu dideliu jautrumu ir spekuliatyvumu pasižyminčiose kriptovaliutų rinkose.

Kintamųjų atranka ir jų įtraukimas į modelį derinami su teoriniu pinigų politikos perdavimo kanalų pagrindimu ir su 2.3 poskyryje aprašyta reguliarizuotos regresijos logika. Monetarinės politikos kintamieji apima centrinių bankų palūkanų normas (kaip tradicines priemones) ir kitus su politika susijusius signalus, o kriptovaliutų bloką sudaro BTC, ETH ir BNB kainos, kurios kartu sudaro didelę visos rinkos kapitalizacijos dalį. Kontroliniai kintamieji (kai jie taikomi bendroje 2.3 modulio specifikacijoje) apima pasaulinių rizikos nuotaikų ir finansų rinkų būklės rodiklius (pvz., VIX ir S&P 500 grąžą), kad pinigų politikos poveikis nebūtų supainiotas su bendru „rizikos režimu“ pasaulinėse rinkose.

Skirtingai nuo tradicinių prieigų, kurios dažnai remiasi logaritminiais skirtumais, šiame tyrime (vertinant palūkanų normų sprendimų poveikį) naudojami netransformuoti kainų lygiai. Toks pasirinkimas daromas siekiant tiesiogiai interpretuoti pinigų politikos impulso poveikį kriptovaliutų vertei piniginiiais vienetais, kas yra praktiškai patogiu politikos formuotojams ir atitinka disertacijoje pasirinktą interpretavimo kryptį.

2.3.2. Netradicinės pinigų politikos priemonės ir jų kintamieji centrinio banko politikos poveikio modulyje

Šis skirsnis pratęsia 2.3 poskyrio logiką ir parodo, kaip netradicinės pinigų politikos priemonės įtraukiamos į tą pačią politikos poveikio vertinimo sistemą, kuri naudojama ir kituose 2 skyriaus modeliuose. Šiame skirsnyje aprašoma, kaip sudaromi kintamieji, kokie duomenys naudojami ir kokia tvarka atliekamas įvertinimas, kad vėliau, 3 skyriuje, būtų galima nuosekliai pateikti empirinius rezultatus.

Metodinis akcentas čia yra ne atskirų priemonių „sėkmės“ interpretavimas, o aiškus tyrimo dizainas: 1) kaip apibrėžiamos netradicinės priemonės; 2) kaip suderinami makroekonominiai rodikliai su politikos sprendimų laiko struktūra; 3) kaip užtikrinamas modelio atkartojamumas ir palyginamumas su 2.3.1 skirsnyje taikoma schema. Čia aiškinama metodika skirta nekonvencinių monetarinės politikos priemonių – ECB UMPT bei jų poveikiui infliacijai ir BVP augimui euro zonoje kiekybiniam vertinimui.

ECB buvo pasirinktas dėl svarbaus jo vaidmens pasaulinėje pinigų politikoje ir plačiai naudojamų UMPT nuo 2008 m. pasaulio finansų krizės. Tyrimas apima laikotarpį nuo 2008 m. iki 2023 m., įskaitant didelius ekonominius sukrėtimus, pvz., didžiąją recesiją, valstybės skolos krizę, COVID-19 pandemiją, Rusijos ir Ukrainos karą. Šis ilgas laikotarpis leidžia išsamiai analizuoti politikos veiksmingumą įvairiose makroekonominėse sistemose.

Infliacijai ir BVP augimui buvo naudojami mėnesio duomenys. Infliacijos duomenys buvo laisvai prieinami šiuo dažnumu, nes tokia statistika pateikiama kas mėnesį, o BVP augimo duomenys, kurie paprastai pateikiami kas ketvirtį, buvo interpoluoti į mėnesio formatą, siekiant užtikrinti nuoseklumą. Šis metodas maksimaliai padidina duomenų detalumą ir sustiprina modelio patikimumą.

Duomenų rinkinys buvo padalytas į mokymo (80 %) ir bandymo (20 %) pogrupius, siekiant įvertinti modelio tikslumą. Toks padalijimas leidžia testuoti modelį su naujais duomenis įsitikinant, kad modelio prognozavimo gebėjimai neapsiriboja vien istoriniais duomenimis.

Į tyrimą įtrauktos septynios pagrindinės ECB įvestos UMPT, įskaitant LTRO, TLTRO, APP, PEPP, OMT, SMP ir neigiamas palūkanų normas (žr. 2.4 lentelę). Kiekviena priemonė buvo užkoduota kaip dvejopi fiktyvūs kintamieji: 1, kai aktyvi; 0, kai neaktyvi. Bazinė kategorija atitinka laikotarpius, kai buvo naudojamos tik tradicinės priemonės. Tokia struktūra leidžia izoliuoti kiekvienos priemonės ribinį poveikį makroekonominiams rezultatams.

2.4 lentelė. ECB tradicinės ir netradicinės pinigų politikos priemonės**Table 2.4.** ECB traditional and non-traditional monetary policy instruments

Priemonė	Aprašymas	Įvedimo data
Tradicinės priemonės		
1. Pagrindinė palūkanų norma	Pagrindinė priemonė, naudojama skolinimosi sąnaudoms paveikti ir ekonominei veiklai skatinti arba riboti.	ECB įkūrimas, 1998 m. birželis
2. Atvirosios rinkos operacijos	Vyriausybės obligacijų ir kitų vertybinių popierių pirkimas ar pardavimas likvidumui ir palūkanų normoms valdyti.	ECB įkūrimas, 1998 m. birželis
3. Privalomosios atsargos	Reikalavimas bankams laikyti tam tikrą lėšų kiekį atsargose, kuris daro įtaką jų skolinimo galimybėms.	ECB įkūrimas, 1998 m. birželis
4. Pagrindinės refinansavimo operacijos (MRO)	Likvidumo teikimas bankams aukcionuose, paprastai vykstančiuose kas savaitę.	ECB įkūrimas, 1998 m. birželis
Netradicinės priemonės		
1. Ilgalaikės refinansavimo operacijos (LTRO)	Trumpalaikių (3 metų) paskolų teikimas bankams likvidumui didinti ir skolinimui skatinti.	2011 m. gruodis
2. Turto pirkimo programos (APP)	Įvairių turto rūšių pirkimas siekiant suteikti likvidumo ir paveikti palūkanų normas.	2015 m. sausis (SMP pradžia), išplėsta per COVID-19 pandemiją
3. Tikslinės ilgalaikės refinansavimo operacijos (TLTRO)	Ilgalaikių paskolų teikimas bankams palankiomis sąlygomis, siekiant skatinti skolinimą konkreitiems sektoriams.	2014 m. rugsėjis, išplėsta per COVID-19 pandemiją
4. Pandeminė skubi pirkimo programa (PEPP)	Turto pirkimas siekiant palaikyti palankias skolinimosi sąlygas COVID-19 pandemijos metu.	2020 m. kovas
5. Tiesioginiai piniginiai sandoriai (OMT)	Galimas probleminių euro zonos šalių obligacijų pirkimas antrinėje rinkoje.	2012 m. rugsėjis

2.4 lentelės pabaiga

Priemonė	Aprašymas	Įvedimo data
6. Neigiamos palūkanų normos	Palūkanų normų nustatymas žemiau nulio, bankų apmokestinimas už perteklinių rezervų laikymą.	2014 m. birželis
7. Vertybinių popierių rinkos programa (SMP)	Vyriausybės obligacijų pirkimas iš probleminių šalių siekiant stabilizuoti rinkas ir sumažinti skolinimosi kaštus.	2010 m. gegužė

Netradicinės pinigų politikos priemonės šiame darbe operacionalizuojamos taip, kad būtų galima palyginti jų poveikį tarpusavyje ir kartu išvengti dviprasmybių, kai kelios priemonės taikomos vienu metu. Praktiniu požiūriu kiekviena priemonė aprašoma kaip aktyvi arba neaktyvi konkrečiu laikotarpiu, remiantis oficialia centrinių bankų komunikacija ir programų įgyvendinimo datomis.

Baziniais atskaitos taškais laikomi laikotarpiai, kai dominuoja tradiciniai pinigų politikos instrumentai. Toks apibrėžimas leidžia aiškiau interpretuoti papildomą netradicinių priemonių informaciją modelyje ir išlaikyti suderinamumą su bendra 2.3 poskyrio idėja – atskirti politikos poveikį nuo kitų veiksnių.

Inflacijos ir BVP duomenys buvo paimti iš ECB statistikos duomenų portalo. Informacija apie UMPT buvo rankiniu būdu išgauta iš ECB spaudos pranešimų, daugiausia dėmesio skiriant kiekvienos politikos pradžios ir pabaigos datoms. Tai užtikrino tikslų laiko suderinimą tarp politikos įgyvendinimo ir makroekonominių rodiklių.

Vertinimas atliekamas nuoseklia seka, kad modelis išliktų tinkamas politikos analizei ir nebūtų pritemptas prie konkretaus laikotarpio. Pirmiausia įvertinama bazinė specifikacija, kuri leidžia patikrinti bendrą ryšį tarp politikos priemonių ir makroekonominių rodiklių. Tuomet taikomas regularizuotas įvertinimas, kuris sumažina tarpusavyje susijusių politikos priemonių problemą ir padeda išvengti perteklinių kintamųjų įtraukimo.

Kadangi inflacija ir BVP augimas natūraliai pasižymi inercija, po įvertinimo tikrinama, ar modelio liekanos neturi autokoreliacijos. Jei aptinkama, taikomas ARIMA procesas, kuris pašalina liekanų laiko priklausomybę. Tai būtina, kad politikos priemonių koeficientai atspindėtų tikrąjį poveikį, o ne duomenų inerciją.

Skaičiavimams atlikti buvo taikomos (2.1)–(2.4) formulės. Šis metodas buvo pasirinktas dėl jo gebėjimo tvarkyti daugialypį kolinearumą ir atlikti kintamųjų atranką didelės dimensijos aplinkose. Modelis įvertintas naudojant pakoreguotą R^2 ir patvirtintas liekanų diagnostika.

Šio poskyrio metodika reikalinga tam, kad netradicinių priemonių informacija būtų nuosekliai įtraukta į bendrą disertacijos analitinę sistemą, o ne analizuojama atskirai. Kitaip tariant, 2.3.2 skirsnis užtikrina, kad pinigų politika būtų aprašyta nuosekliai, įtraukiant ne tik palūkanų normų sprendimus, bet ir netradicinių programų taikymą.

Toliau 2.4 poskyryje pereinama prie kriptovaliutų kintamumo modelio, nes būtent kintamumo režimai vėliau leidžia tikrinti, ar padidėjęs finansinis neapibrėžtumas sustiprina ar susilpnina pinigų politikos perdavimo ryšius. Empiriniai šios sąsajos patvirtinimai pateikiami 3 skyriuje, laikantis disertacijos struktūrinės logikos: 2 skyriuje – metodika, 3 skyriuje – rezultatai.

2.4. Kintamumo grįžtamojo ryšio modulis

Šiame poskyryje kuriamas kintamumo grįžtamojo ryšio modulis, kuris modeliuoja kriptovaliutų kintamumo dinamiką ir jų makroekonominis šalutinius poveikius naudodamas pažangias GARCH klasės specififikacijas. Modulis skirtas keiturioms empirinėms kriptovaliutų rinkų savybėms: kintamumo klasterizacijai, asimetriniams sukrėtimams, režimo pasikeitimui ir ilgos atminties patvarumui. Sistemą sudaro du integruoti komponentai: 1) režimo perjungimo kintamumo modeliavimas; 2) slenksčiu pagrįsta šalutinio poveikio analizė (Baillie et al., 1996; Hamilton, 1989; Nelson, 1991).

Bazinėje specififikacijoje sverto poveikiui fiksuoti taikomas EGARCH(1,1) procesas:

$$\ln(\sigma_t^2) = \omega + \alpha(|z_t^{-1}| - E|z_t^{-1}|) + \gamma z_t^{-1} + \beta \ln(\sigma_t^{-12}), \quad (2.5)$$

čia $\ln(\sigma_t^2)$ – natūralusis sąlyginės dispersijos logaritmas laiko momentu t ; ω – pastovusis narys (bazinis kintamumo lygis); α – ARCH efekto koeficientas (reakcijos į praeities sukrėtimus dydis); z_t^{-1} – standartizuotos paklaidos $t - 1$ metu ($z_t = \varepsilon_t / \sigma_t$); $E|z_t^{-1}|$ – standartizuotų paklaidų laukiama absoliučioji vertė; γ – sverto poveikio koeficientas (asimetrinė reakcija į kintamumą); β – GARCH efekto koeficientas (kintamumo pastovumas); $\ln(\sigma_t^{-12})$ – natūralusis sąlyginės dispersijos logaritmas $t - 1$ metu.

Naudojant nuo režimo priklausomą kintamumą modulyje įgyvendinamas MSGARCH modelis:

$$\sigma_t^2 = \omega_{st} + \alpha_{st}\varepsilon_{t-1}^2 + \beta_{st}\sigma_{t-1}^2, \quad (2.6)$$

čia $st \in \{1, 2\}$ – Markovo grandinė su perėjimo matrica P . Išlygintos režimo tikimybės nustato didelio / mažo kintamumo būsenas, naudojant Hamiltono filtrą (Hamilton, 1989).

Ilgos atminties poveikis modeliuojamas naudojant FIGARCH(1, d, 1):

$$(1 - \beta L)\sigma_t^2 = \omega + [1 - \beta L - (1 - \alpha L - \beta L)(1 - L)^d]\varepsilon_t^2, \quad (2.7)$$

čia L – atsilikimo operatorius; d – frakcinio integravimo parametras ($0 < d < 1$); $(1 - L)^d$ – frakcinio skirtumo operatorius. Modulis įvertina d naudojant pusiau parametrinį Whittle'o įvertį, kad būtų išvengta skirstinio prielaidų.

Siekiant nustatyti slenkstinę reikšmę taikomas dvigubo slenksčio metodas. Pirmą, statistinis slenkstis buvo apibrėžtas naudojant 90-ąjį sąlyginio kintamumo pasiskirstymo procentilį, kuris atspindi viršutinį kintamumo stebėjimų dešimtdalį. Antra, buvo įtraukta įvykiais pagrįsta riba, susieta su COVID-19 pandemijos laikotarpiu, kuris empiriškai patvirtintas kaip vienintelis makrofinansinis sukrėtimas, kuris labai padidino kriptovaliutų rinkos svyravimus (Pečiulis & Vasiliauskaitė, 2025). Šis kombinuotas metodas užtikrina, kad režimo keitimo rizikos analizėje būtų užfiksuoti tiek statistiniu požiūriu ekstremalūs, tiek kontekstualiai reikšmingi svyravimų epizodai.

Siekiant įvertinti kriptovaliutų kintamumo poveikį makroekonominiams rodikliams, naudojama kintamumo perdavimo politikos kintamiesiems lygtis. Ši lygtis padeda nustatyti, ar kriptovaliutų kintamumas tiesiogiai veikia tradicinius ekonominius rodiklius, tokius kaip infliacija. Skaičiuojama pagal (2.8) lygtį:

$$\Delta Infliacija_t = \gamma^0 + \gamma^1 \sigma_t^{\{crypto\}} + \gamma^2 \sigma_t^{\{VIX\}} + \varepsilon_t, \quad (2.8)$$

čia $\Delta Infliacija_t$ – infliacijos lygio pokytis; $\sigma_t^{\{crypto\}}$ – kriptovaliutų kintamumas (MSGARCH išvestis); $\sigma_t^{\{VIX\}}$ – akcijų rinkos kintamumas (kontrolinis kintamumas). Teigiamasis γ^1 rodo, kad kriptovaliutų kintamumas sustiprina infliacinį spaudimą ir apsunkina politikos stabilizavimo pastangas. Ši formulė yra pasirinkta siekiant tiesiogiai patikrinti, ar kriptovaliutų kintamumas sukuria naujus perdavimo kanalus, veikiančius makroekonominis kintamuosius.

Šio modulio metodika apima kelis etapus. Tinklelio paieškos optimizavimas taikomas siekiant rasti optimalius GARCH modelio eilių parametrus (p , q reikšmės iš intervalo $[1,5]$) ir optimalų klaidos pasiskirstymą. Studento t pasiskirstymas dažnai yra tinkamiausias, nes jis geriau užfiksuoja plačius skirstinio galus ir asimetriją, būdingą kriptovaliutų gražoms. „Out-of-Sample“ validavimas atliekamas naudojant tokius rodiklius kaip RMSE ir MAE, apskaičiuotus pagal (2.9) ir (2.10) formules:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2}, \quad (2.9)$$

$$MAE = \left(\frac{1}{n}\right) \sum_{i=1}^n |\hat{Y}_i - Y_i|, \quad (2.10)$$

čia \hat{Y}_i – prognozuojama reikšmė; Y_i – tikroji reikšmė; n – stebėjimų skaičius.

Imties laikotarpis – nuo 2017 m. lapkričio 7 d. iki 2024 m. gruodžio 31 d. Taip pasirinkta, siekiant užtikrinti visų trijų kriptovaliutų duomenų prieinamumą

ir apimti tiek stabilius, tiek nestabilius makroekonominis periodus, įskaitant COVID-19 pandemijos pradžią.

Šio modulio rezultatai suteikia esminių įžvalgų apie kriptovaliutų rinkos elgesį. Jos apima aiškiai apibrėžtus kintamumo režimus. Be to, pateikiami užkrato rizikos rodikliai, kurie kiekybiškai įvertina, kiek kriptovaliutų kintamumas prisideda prie nestabilumo tradiciniuose makroekonominuose rodikliuose, tokiuose kaip infliacija. Šie rezultatai suteikia duomenų apie galimus sisteminės rizikos kanalus ir padeda suprasti platesnį kriptovaliutų poveikį finansų sistemoms ir ekonomikai.

2.5. Egzogeninių kintamųjų svorių modulis

Decentralizuota kriptovaliutų rinka veikia sudėtingoje pasaulio finansų ekosistemoje. Norint tiksliai įvertinti pinigų politikos poveikį, būtina suprasti šios platesnės aplinkos įtaką. Šiame skyriuje sujungiami du esminiai analitiniai moduliai: egzogeninių veiksnių modulis su kintamumo grįžtamojo ryšio moduliu. Jų integracija padeda atskirti politikos nulemtą poveikį nuo išorinių rinkos jėgų.

Egzogeninių veiksnių modulis kiekybiškai įvertina pasaulio finansinių ir makroekonominų veiksnių įtaką ryšiui tarp pinigų politikos ir kriptovaliutų kainų dinaminį poveikį BTC, ETH ir BNB grąžai. Šis atskyrimas yra būtinas siekiant išvengti per didelio centrinio banko veiksmų tiesioginio poveikio įvertinimo, kontroliuojant platesnes rinkos tendencijas. Modulio tikslas – sistemškai nustatyti ir išmatuoti išorinių veiksnių indėlį, taip suteikiant tikslesnį supratimą apie tiesiogines pinigų politikos ir kriptovaliutų elgesio sąsajas.

Ši integracija svarbi ir metodologiniu požiūriu: neįtraukus pasaulinių veiksnių į modulį, jų sukelti sukrėtimai būtų priskirti liekanoms ir vėliau galėtų būti klaidingai interpretuojami kaip endogeniniai kriptovaliutų rinkos režimų pokyčiai. Dėl to egzogeninių veiksnių kontrolė šiame modulyje yra būtina prielaida patikimam kintamumo grįžtamojo ryšio modulio rezultatų interpretavimui.

Poskyryje taikoma ARIMAX sistema modeliuoja trumpalaikius ryšius tarp egzogeninių veiksnių ir kriptovaliutų grąžų, o Engle'o–Grangerio testas papildomai tikrina ilgalaikę kainų lygių kointegraciją. Toks metodų derinys atskiria trumpalaikius bendrus svyravimus nuo stabilios ilgalaikės pusiausvyros ir neleidžia trumpalaikių ryšių rezultatų nepagrįstai perkelti ilgam laikotarpiui.

Šio modulio įvestys apima penkis statistiškai reikšmingus egzogeninius kintamuosius, pasirinktus atsižvelgiant į jų nustatytą svarbą finansų rinkose ir reikšmę pirminiuose tyrimuose (Pečiulis & Vasiliauskaitė, 2021; Ahmed et al., 2023; Bazán-Palomino & Svogun, 2023; Jotaki et al., 2024): 1) VIX, kuris matuoja pasaulinę rizikos vengimo tendenciją; 2) aukso kainos, dažnai laikomos saugiu prieglobsčiu, kurios krizės laikotarpiais gali koreliuoti su kriptovaliutomis;

3) CMC Crypto 200 indeksas, plačiai atspindintis bendrą kriptovaliutų rinkos našumą; 4) S&P 500 graža, veikianči kaip pasaulinių akcijų rinkos tendencijų įgaliotinis; 5) DAX 30 graža, atspindinti Europos akcijų rinkos našumą. Imties periodas apima laikotarpį nuo 2019 m. sausio 2 d. iki 2024 m. gruodžio 31 d. Ši imtis pasirinkta siekiant užtikrinti visų trijų kriptovaliutų duomenų prieinamumą ir apimti tiek stabilius, tiek nestabilius makroekonominis periodus, įskaitant COVID-19 pandemijos pradžią.

Šio modulio analitinė sistema yra ARIMAX. Šis modelis pasirinktas dėl jo gebėjimo įtraukti išorinius regresorius, kartu fiksuojant būdingas kriptovaliutų gražos autokoreliacijos charakteristikas. Šiame modulyje taikomi analitiniai metodai – ARIMAX modeliavimas (2.11 formulė), AIC grįstas modelio parinkimas (2.12 formulė), Engle'o–Grangerio kointegracijos testas (2.14 formulė) ir Grangerio priežastingumo testas (2.15 ir 2.16 formulės) – remiasi Box et al. (2016) sukurta sistema. Bendra ARIMAX modelio forma yra tokia:

$$(1 - \sum_{i=1}^p \phi_i L^i) \Delta \ln(P_t^{crypto}) = c + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \sum_{k=1}^5 \psi_k Z_{k,t} + \epsilon_t, \quad (2.11)$$

čia $Z_{k,t}$ – egzogeniniai veiksniai (VIX, auksas ir t. t.); ψ_k – dinaminiai svoriai, rodantys kiekvieno egzogeninio veiksnio poveikį.

Norint užtikrinti ARIMAX modelio tinkamumą ir tikslumą, taikomas hiperparametrų optimizavimo metodas, vadinamas tinklelio paieška, kuris sistemingai ieško geriausių autoregresijos (AR) ir slankiojo vidurkio (MA) eilių parametru porų (p, q) iš anksto nustatyto intervalo, $p, q \in \{x \in \mathbb{Z} \mid 0 \leq x \leq 10\}$. Kiekvienai galimai parametru kombinacijai įvertinamas ARIMAX modelis, kurio bendra forma pateikta (2.11) lygtimi. Modelio tinkamumas vertinamas pagal informacijos kriterijų AIC, kurio :minimizavimas leidžia pasirinkti optimalų parametru rinkinį pagal (2.12) formulę

$$(p^*, q^*) = \operatorname{argmin}_{\{(p, q) \in G\}} AIC(p, q). \quad (2.12)$$

„XGBoost“ šiame poskyryje naudojamas kaip papildomas kintamųjų reikšmingumo testavimo instrumentas, orientuotas į nuspėjamąją galią. Toks sprendinys leidžia patikrinti, ar egzogeninių kintamųjų svarbos tvarka išlieka ir tuomet, kai galimos netiesinės priklausomybės bei sąveikos, kurių ARIMAX koeficientai tiesiogiai neaprašo.

Mašininio mokymosi svoriai nustatomi konkrečiai naudojant „XGBoost“ savybių svarbos testavimą, kuris leidžia įvertinti kiekvieno kintamojo nuspėjamąją galią pagal savybių svarbos metriką. „XGBoost“ modelyje savybių svarba apskaičiuojama pagal kiekvieno kintamojo indėlį į klaidos sumažinimą medžių struktūroje, o formalioji svarbos reikšmė I_j kiekvienam kintamajam j gali būti apibrėžta pagal (2.13) formulę:

$$I_j = \sum \Delta Loss_t, t \in T. \quad (2.13)$$

Toliau atliekami kointegracijos testai, siekiant įvertinti, ar tarp kriptovaliutų kainų ir egzogeninių veiksnių egzistuoja ilgalaikiai ryšiai. Vienas iš taikomų testų – Engle'o–Grangerio dviejų žingsnių metodas, kurio pirmi žingsniai įvertinama regresija pagal (2.14) formulę:

$$y_t = \alpha + \beta x_t + u_t, \quad (2.14)$$

čia y_t – kriptovaliutos kaina; x_t – egzogeninis veiksnys; u_t – likutinė paklaida. Antrame žingsnyje tikrinama, ar u_t yra stacionari, taikant Dickey'io–Fullerio testą. Jei $u_t \sim I(0)$, tariama, kad y_t ir x_t yra kointegruoti, t. y. tarp jų yra ilgalaikė pusiausvyra.

Galiausiai, siekiant nustatyti priežastinius ryšius tarp egzogeninių veiksnių ir kriptovaliutų grąžų, atliekamas Grangerio priežastingumo testas. Šio testo esmė – įvertinti, ar praeities egzogeninio kintamojo reikšmės padeda prognozuoti kriptovaliutos grąžą. Formaliai Grangerio testas grindžiamas dviejų regresijų palyginimu. Pirmoji regresija apima tik priklausomojo kintamojo reikšmes pagal (2.15) formulę:

$$y_t = \sum_{i=1}^p \alpha_i y_{t-i} + \varepsilon_t, \quad (2.15)$$

o antroji pagal (2.16) formulę – papildomai įtraukia egzogeninį kintamąjį x_t :

$$y_t = \sum_{i=1}^p \alpha_i y_{t-i} + \sum_{j=1}^q \beta_j x_{t-j} + \varepsilon_t. \quad (2.16)$$

Jei įtraukus x_t reikšmingai sumažėja prognozavimo klaida, tariama, kad x_t Grangerio prasme sukelia y_t . Šis testas padeda identifikuoti pirmumo ir atsilikimo santykius tarp pasaulinių veiksnių ir kriptovaliutų grąžų, taip suteikiant papildomų įžvalgų apie galimus perdavimo kanalus. Integruotas šių metodų taikymas leidžia ne tik kiekybiškai įvertinti egzogeninių veiksnių svarbą, bet ir užtikrinti, kad nustatyti ryšiai būtų statistiškai pagrįsti ir ekonomiškai interpretuojami.

2.6. Centrinio banko atsako funkcijos modulis

Centrinio banko atsako funkcijos modulyje nagrinėjama, kaip pinigų institucijos koreguoja politikos priemones reaguodamos į kriptovaliutų rinkos pokyčius. Analizėje taikoma laikui einant kintanti sistema, kad būtų galima užfiksuoti kintančią centrinių bankų reakciją į skaitmeninio turto kintamumą ir reguliavimo intervencijas. Modulio specifikacija remiasi nusistovėjusiomis pinigų reakcijos funkcijomis, kartu įtraukdama naujus kriptovaliutoms būdingus kintamuosius. Metodologinis pagrindas remiasi Stock ir Watson (1996) laikui einant kintančių

parametrų regresijos sistema, Kalman (1960) pristatytu filtravimo vertinimo metodu bei Taylor (1993) suformuluota pinigų politikos reakcijos funkcijos tradicija, kurie kartu sudaro (2.17)–(2.21) formulių pagrindą.

Pagrindinė lygtis (žr. formulę 2.17) – tai laikui einant kintančių parametrų regresija, kuri susieja politikos sprendimus su kriptovaliutų rinkos sąlygomis ir reguliavimo priemonėmis:

$$Politika_t = \rho^0 + \rho^1_t \cdot Cryptokin_t + \rho^2_t \cdot Reguliavimas_t + v_t, \quad (2.17)$$

čia $Politika_t$ – centrinio banko politikos priemonę (pvz., bazinę palūkanų normą arba kiekybinio švelninimo apimtį) laiko momentu t (šiuo atveju naudotas federalinių fondų palūkanų norma). Kintamasis $Cryptokin_t$ rodo kriptovaliutų rinkos kintamumą, gautą taikant (2.19) formulę, o $Reguliavimas_t$ kiekybiškai įvertina vyraujančią reguliavimo poziciją per indeksą, pagrįstą teisės aktų pokyčiais sudarytą pagal Rahsaz (2025) duomenų bazę. Intercepcinis narys ρ^0 atspindi bazinę politikos nuostatą, o ρ^1_t ir ρ^2_t yra laikui einant kintantys koeficientai, kuriais matuojamas politikos jautrumas atitinkamai kriptovaliutų kintamumui ir reguliavimo pokyčiams. Paklaidos narys v_t parodo nepaaiškintą svyravimą.

Matavimo paklaida v_t pasiskirsto pagal normalųjį skirstinį su dispersija σ^2 . Tokia specifikacija leidžia laipsniškai pritaikyti politikos reakciją į kriptovaliutų rinkas, kartu išlaikant tiesinės reakcijos funkcijos sistemą.

(2.17) formulės struktūra parinkta remiantis pinigų politikos reakcijos funkcijų tradicija, pagal kurią centrinis bankas sprendimus priima sistemškai, t. y. politikos priemonę sieja su informacijos rinkiniu, aprašančiu ekonominės ir finansinės aplinkos pokyčius. Klasikinėje literatūroje ši logika formuluojama kaip taisyklėmis paremtas politikos elgesys (pvz., Taylora tipo reakcija), tačiau skaitmeninio turto aplinka reikalauja išplėsti reakcijos funkciją taip, kad ji aprėptų ir finansinio stabilumo rizikas, kurios atsiranda už tradicinių pinigų rinkos ribų. Todėl pasirinkta paprasta, bet ekonomiškai aiški struktūrinė lygtis, kuri išlaiko interpretuojamą reakcijos funkcijos formą ir leidžia nuosekliai įvertinti, ar ir kaip centrinio banko politika koreguojama reaguojant į sukrėtimus, susijusius su kriptovaliutų rinka, bei institucionalizuotus priežiūros pokyčius. Kadangi disertacijoje pabrėžiama, kad kriptovaliutų poveikis ir pačios politikos perdavimo sąlygos kinta tarp skirtingų laikotarpių ir režimų, lygtis specifikuota kaip laikui einant kintančių parametrų sistema, kad būtų galima užfiksuoti centrinio banko prisitaikymą (mokymąsi) ir besikeičiantį reakcijos intensyvumą, o ne priverstinai laikyti jį pastoviu visoje imtyje.

Laiko kintamieji koeficientai ρ^1_t ir ρ^2_t priklauso nuo atsitiktinio pasivaikščiojimo proceso (žr. formulę 2.18), įvertinto taikant Kalmano filtravimą, kuris užtikrina optimalų rekursinį nestebimų būsenos kintamųjų įvertinimą. Būklės erdvės formuluotė sudaro dvi lygtys. Būklės lygtis aprašo koeficientų kitimą:

$$\rho_{kt} = \rho_{kt}^{-1} + \eta_{kt}, \quad \eta_{kt} \sim N(0, \sigma^2_k), \quad k \in \{1, 2\}, \quad (2.18)$$

čia η_{kt} – koeficientų sukrėtimai, kurie, kaip daroma prielaida, yra normaliai pasiskirstę su dispersija σ^2_k . Stebėjimo lygtis susieja šiuos laike kintančius parametrus su politikos rezultatais.

Siekiant išspręsti galimas endogeniškumo problemas, ypač atvirkštinio priešingumo tarp politikos veiksmų ir kriptovaliutų kintamumo, į modelį įtraukiami instrumentiniai kintamieji. Pirmojo etapo regresija prognozuoja kriptovaliutų kintamumą naudodama vėluojančius priėmimo rodiklius:

$$Cryptokin_t = \gamma_0 + \gamma_1 \cdot Adopt_{t-1} + \gamma_2 \cdot Z_t + \varepsilon_t, \quad (2.19)$$

čia $Adopt_{t-1}$ – vėluojantys kriptovaliutų priėmimo pakaitiniai rodikliai, pvz., mainų apimtys; Z_t – kontroliniai kintamieji, įskaitant tradicinius makroekonominius rodiklius. Tada šios regresijos prognozuojamos reikšmės patenka į (2.17) lygtį.

Empiriniam šio modulio įgyvendinimui reikia kruopščiai išmatuoti kiekvieną komponentą. Politikos kintamajam naudojamos standartizuotos centrinių bankų palūkanų normos arba pranešimai, kad įvertintume nekonvencinių priemonių veiksmingumą. Kriptovaliutų kintamumas gaunamas iš 21 dienos slankiojo lango įverčio, o reguliavimo indeksas apima ir kiekybines priemones (šiuo atveju naujienų apie kriptovaliutas analizę).

Kalmano filtrą įgyvendinti pradeda nuo dispersijos parametrų σ^2_1 , σ^2_2 ir σ^2_v didžiausio tikėtimumo įvertinimo. Paskui rekursinis algoritmas sukuria filtruotus laiko atžvilgiu kintančių koeficientų įverčius, o galutiniai išlyginti įverčiai gaunami taikant grįžtamąją rekursiją.

Šio modulio rezultatai apima įvertintas politikos jautrumo ρ^1_t ir ρ^2_t laiko trajektorijas, kurios atskleidžia, kaip keitėsi centrinių bankų reakcijos į kriptovaliutų rinkas. Impulsinio atsako funkcijos kiekybiškai įvertina dinamišką kintamumo šokų poveikį politikai, o ribinio poveikio analizė įvertina, kaip reguliavimo pokyčiai daro įtaką politikos nustatymams skirtingomis rinkos sąlygomis pagal (2.20) ir (2.21) formules:

$$IRF_{Crypto}(t+h) = E[\rho^1_{t+h}] \cdot \Delta Crypto_t, \quad (2.20)$$

$$IRF_{Reg}(t+h) = E[\rho^2_{t+h}] \cdot \Delta Reguliavimas_t, \quad (2.21)$$

čia $E[\rho^k_{t+h}]$ – prognozuotas koeficientas po h laikotarpių, gautas iš Kalmano filtro; $IRF_{Reg}(t+h)$ – impulsinio atsako funkcija, kuri parodo, kaip vienkartinis šokas reguliavimo kintamajam laiko momentu t paveikia centrinio banko politikos priemonę po h laikotarpių; $IRF_{Crypto}(t+h)$ – tikėtinas politikos pokytis po h laikotarpių dėl šio šoko.

Modulyje daromos kelios prielaidos. Tiesinė specifikacija reiškia proporcingą politikos reakciją į kriptovaliutų svyravimus atskirais režimais. Instrumentinių kintamųjų egzogeniškumo prielaida reikalauja, kad vėluojantys įsisavinimo rodikliai paveiktų dabartinę politiką tik per jų poveikį kriptovaliutų kintamumui. Gauso (normaliojo) klaidų struktūra būsenos ir stebėjimo lygtyse (2.18 ir 2.17) parenkama pirmiausia dėl praktinės priežasties: ji leidžia nuosekliai taikyti Kalmano filtrą ir patogiai įvertinti modelio parametrus didžiausio tikėtimumo metodu. Tokia formuluočių padeda aiškiai atskirti lėtai kintančius, sisteminius centrinio banko reakcijos pokyčius, kuriuos aprašo (2.18) būsenos lygtis, nuo trumpalaikių, atsitiktinių politikos sprendimų nukrypimų, kurie lieka (2.17) stebėjimo lygties paklaidoje. Šiuo moduliui siekiama empiriškai įvertinti, ar centrinio banko jautrumas kriptovaliutų rinkos kintamumui ir reguliavimo pokyčiams laikui bėgant keičiasi, t. y. ar reakcijos koeficientai $\beta_{1,t}$ ir $\beta_{2,t}$ rodo prisitaikymą skirtingais laikotarpiais ir rinkos būsenomis.

2.7. Integruotas politikos ir kriptovaliutos sąveikos modelis

Integruotas politikos ir kriptovaliutos sąveikos modelis sujungia visas ankstesnius modulius į išsamią sistemą, kuri atspindi dinamišką pinigų politikos ir decentralizuotų kriptovaliutų sąveiką. Naudojant modelį vienu metu vertinami trys svarbiausi ryšiai: kaip pinigų politika veikia kriptovaliutas, kaip kriptovaliutų kintamumas perduodamas makroekonominiam stabilumui ir kaip politikos formuotojai pritaiko savo strategijas reaguodami į kriptovaliutų rinkos pokyčius.

Šio integruoto požiūrio pagrindas – struktūrinių lygčių sistema, išlaikant nuoseklumą su ankstesniuose moduluose nustatytais teoriniais pagrindais. Šiame skyriuje pristatoma integruota struktūrinių lygčių sistema remiasi Sims (1980) vektorinės autoregresijos sistema, Hansen (1982) apibendrintų momentų metodu bei Hamilton (1989) Markovo perjungimo režimo metodologija. Struktūrinė forma prasideda nuo kriptovaliutų kainodaros lygties, kuri remiasi 1 modulio rezultatais, bet išplečia juos, kad būtų atsižvelgta į kintamumo grįžtamojo ryšio poveikį:

$$P_t = \alpha + \beta_1 \cdot Politika_t + \beta_2 \cdot X_t + \beta_3 \cdot \sigma_{t-1} + \varepsilon_t, \quad (2.22)$$

čia P_t – pagrindinių kriptovaliutų (BTC, ETH, BNB) kaina; $Politika_t$ – pinigų politikos priemonės, įskaitant tiek įprastines palūkanų normas (nustatytas 1 modulyje), tiek netradicines priemones; X_t – 3 modulyje nustatyti egzogeniniai kontrolės kintamieji (VIX, S&P500 ir kitus pasaulinius veiksnius); σ_{t-1} apima uždelsto kintamumo matą iš MSGARCH modelio 2 modulyje. Paklaidos terminas ε_t atsižvelgia į nepaaiškintus kainų svyravimus.

Makroekonominė perdavimo lygtis formalizuoja kriptovaliutų kintamumo ir pagrindinių monetarinės politikos tikslų ryšį:

$$Infliacija_t = \gamma + \delta^1 \cdot \sigma_t + \delta^2 \cdot Politika_t + \delta^3 \cdot Y_t^{-1} + u_t, \quad (2.23)$$

čia *Infliacija_t* – pagrindinis pinigų politikos tikslinis kintamasis; σ_t – dabartinis kriptovaliutų kintamumas; *Politika_t* – FFR; Y_t^{-1} kontroliuoja uždelsto BVP augimo poveikį. Šioje specifikacijoje tiesiogiai įtraukiami 2 modulio rezultatai apie netradicinės pinigų politikos perdavimą.

Politikos reakcijos funkcija užbaigia sistemą modeliudama, kaip centriniai bankai koreguoja savo strategijas reaguodami į kriptovaliutų rinkos sąlygas:

$$Politika_t = \rho_0 + \rho_{1t} \cdot \sigma_t + \rho_{2t} \cdot Reguliavimas_t + v_t, \quad (2.24)$$

čia *Reguliavimas_t* kiekybiškai įvertins vyraujančią reguliavimo poziciją pagal Pečiulio ir Vasiliauskaitės (2023) pristatytą indeksą.

Modelis vertinamas pagal kruopščiai struktūrizuotą seką, kurioje atsižvelgiama į priežastinius ryšius tarp šių lygčių.

Antrajame etape kriptovaliutų kainodaros lygčiai įvertinti naudojamas ribotos informacijos maksimalios tikimybės (LIML) metodas, atsižvelgiant į galimą politikos kintamųjų endogeniškumą. Instrumentų rinkinį šiuo atveju sudaro JAV BVP ir vartotojų kainų indeksas.

Paskutiniame etape visai sistemai taikomas apibendrintas momentų metodas (GMM), sprendžiant lygiagrečius lygtis su atitinkamomis momentų sąlygomis nurodytose (2.25) ir (2.26) formulėse:

$$E[Z_t' \cdot (\Delta \ln(P_t) - \beta \cdot W_t)] = 0, \quad (2.25)$$

$$E[Z_t' \cdot (Inflation_t - \delta \cdot V_t)] = 0, \quad (2.26)$$

čia Z_t apima visą instrumentinių kintamųjų rinkinį; W_t ir V_t – kiekvienos lygties regresoriaus matricos.

Empirinis įgyvendinimas reikalauja kruopštaus kintamųjų suderinimo laiko požiūriu. Centrinų bankų politikos kintamieji matuojami kas mėnesį, kriptovaliutų kainos ir kintamumo rodikliai agreguojami nuo dienos iki mėnesio vidurkių, o makroekonominiai kintamieji interpoliuojami nuo ketvirčio iki mėnesio dažnio naudojant kubinius „splainus“. Tai išlaiko nuoseklumą su pagrindiniais ekonomiais procesais ir leidžia atlikti sistemos vertinimus.

Modelio režimo priklausomieji daugikliai apskaičiuojami naudojant Markovo perjungimo vektoriaus autoregresiją:

$$y_t = \mu(s_t) + \Sigma \Phi_j(s_t) y_{t-j} + \varepsilon_t, \quad (2.27)$$

čia $s_t \in \{1,2\}$ rodo vyraujančią nepastovumo režimą. Šioje Markovo perjungimo VAR specifikacijoje koeficientai nėra laikomi pastoviais: jie indeksuojami režimo

būsenos s_t , todėl įgyja skirtingas reikšmes esant žemo ir aukšto nepastovumo režimams, t. y. politikos perdavimo parametrai (kaip ir kiti modelio koeficientai) modelyje įvertinami atskirai kiekvienam rinkos režimui.

2.8. Taikomų modelių apžvalga ir metodologiniai sprendimai

Šiame poskyryje apibendrinami taikyti metodiniai sprendimai: kokie modeliai naudoti ir pagal kokias taisykles parinkti jų parametrai bei eilių reikšmės integruotoje analizėje. Kadangi 2 skyriaus metodologija dėstoma moduliškai, o atskirų modelių specifikacijos ir eilių nustatymo procedūros išsidėsto per kelis poskyrius, jos šiame poskyryje pateikiamos vienoje vietoje, išlaikant ankstesniuose poskyriuose suformuluotus teorinius argumentus ir rezultatų interpretavimo logiką. Todėl čia apsiribojama procedūrine informacija, būtina tyrimo metodikai atsekti: nurodomi taikyti modeliai ir aprašoma, kaip buvo nustatyti jų parametrai.

2.5 lentelėje sistemiškai suvedami visi pagrindiniai disertacijoje taikyti modeliavimo ir tikrinimo metodai, jų parametrizacija ir formalios specifikacijų parinkimo taisyklės, užtikrinančios empirinės analizės nuoseklumą ir atkartojamumą. Modeliai pateikiami tokia seka, kuri atitinka modulinę metodologijos logiką: pirma identifikuojamas pinigų politikos poveikis ir atliekama kintamųjų atranka, toliau koreguojama laiko eilučių priklausomybė, paskui modeliuojamas kintamumas (įskaitant asimetriją, ilgus atminties ir režimų kaitos efektus), galiausiai vertinamas laikui einant kintantis politikos jautrumas, tikrinamas netiesinis kintamųjų reikšmingumas ir atliekami endogeniškumo bei dinaminio ryšio testai.

2.5 lentelė. Disertacijoje taikomų modelių specifikacija ir parinkimo kriterijai
Table 2.5. Specification and selection criteria of the models used in the dissertation

Modelis	Eilė / Parametrai	Pasirinkimo pagrindimas	Eilės pagrindimas
„Elastic Net“	$\alpha \in [0,1]$; λ optimizuojamas CV	Sprendžia multikolinearumo problemą tarp pinigų politikos kintamųjų	α ir λ optimizuojami atliekant kryžminį tikrinimą, minimizuojant vidurinę kvadratinę paklaidą
ARIMA(p, d, q)	$p, q \in [0,10]$; d pagal stacionarumą	Fiksuoja kriptovaliutų gražų autokoreliaciją liekanose po „Elastic Net“. Atskiria pinigų politikos	p ir q parenkami tinkamo tinklelio paieška, minimizuojant AIC/BIC.

2.5 lentelės tęsinys

Modelis	Eilė / Parametrai	Pasirinkimo pagrindimas	Eilės pagrindimas
		poveikį nuo laiko eilučių inercinės dinamikos.	
ARIMAX	p, q kaip ARIMA + egzogeniniai X	Išplečia ARIMA, įtraukdamas globalius veiksnius (VIX, SP500, CMC Crypto 200, DAX30). Atskiria pinigų politikos poveikį nuo pasaulinių rinkos sąlygų.	Tokia pat kaip ARIMA
GARCH(1,1)	$p = 1, q = 1$	Bazinis kintamumo modelis, fiksuojantis klasterizaciją. Naudojamas kaip etalonas sudėtingesnėms specifikacijoms.	$p, q \in [1,5]$ testuoti tinklelio paieška, minimizuojant AIC. $p = q = 1$ pasirodė optimalus dėl konvergencijos stabilumo. Aukštesniosios eilės nesuteikė reikšmingo pagerinimo.
EGARCH(1,1)	$p = 1, q = 1$	Fiksuoja sverto efektą – neigiamos grąžos didina kintamumą labiau nei teigiamos.	$p, q \in [1,5]$ testuoti tinklelio paieška. $p = q = 1$ pasirinkta dėl skaičiavimo stabilumo. Aukštesniosios eilės sumažino konvergenciją.
FI-GARCH(1,d,1)	$p = 1, d \in (0,1), q = 1$	Fiksuoja ilgą atminties efektą – kintamumo šokai išlieka ilgiau. Svarbu ilgalaikiams politikos poveikiams.	$p, q \in [1,5]$ testuoti tinklelio paieška. $p = q = 1$ pasirinkta dėl skaičiavimo stabilumo. Aukštesniosios eilės sumažino konvergenciją.
MSGARCH	$K = 2$ režimai; kiekvienam $p = 1, q = 1$	Fiksuoja režimų kitimą – kintamumo parametrai skiriasi esant žemo / aukšto nepastovumo režimams.	$K = 2$ nustatyta BIC analize; RSS stabilizavosi po 2 lūžio taškų. Kiekvienam režimui $p =$

2.5 lentelės tęsinys

Modelis	Eilė / Parametrai	Pasirinkimo pagrindimas	Eilės pagrindimas
			$q = 1$ testuoti tinklelio paieška [1, 5], optimalus pagal AIC.
CS-GARCH(1,1)	$p = 1, q = 1$	Atskiria trumpalaikį ir ilgalaikį kintamumo komponentus.	$p = q = 1$ tinklelio paieška [1, 5]
TVP regresija	Parametrai kinta laikui einant	Modeliuoja centrinio banko adaptaciją – politikos jautrumas kriptovaliutų kintamumui ir reguliavimui kinta laikui einant.	Nėra fiksuotos eilės – parametrai keičiasi. Gaunami, naudojant Kalmano filtrą
„XGBoost“	Medžių gylis ir skaičius	Mašininio mokymo metodas, nustatantis kintamųjų svarbą netiesiniu būdu.	Hiperparametrai parinkti taikant tinklelio paiešką: tikrintos didžiausio medžio gylio $\max_depth \in \{2, 3, 4, 5, 6\}$ ir ansamblių sudarančių medžių skaičiaus $n_estimators \in \{100, 200, 300, 500, 800\}$ kombinacijos; optimalus derinys nustatytas pagal mažiausią kryžminio tikrinimo metu gautą prognozės paklaidą.
Instrumentinių kintamųjų regresija (IV)	Dviejų etapų procedūra	Sprendžia endogeniškumo problemą tarp kriptovaliutų kintamumo ir politikos.	Dviejų etapų: 1) Cryptovol regresija į $\text{Adopt}_{\{t-1\}}$, Z; 2) politika regresija į prognozuotą Cryptovol.

2.5 lentelės pabaiga

Modelis	Eilė / Parametrai	Pasirinkimo pagrindimas	Eilės pagrindimas
Engle'o–Grangerio kointegracijos testas	Dviejų etapų testas	Tikrina ilgalaikius ryšius tarp kriptovaliutų ir egzogeninių veiksnių.	Dviejų etapų: 1) regresija $y = \alpha + \beta x$; 2) ADF testas liekanoms.
Grangerio priešingumo testas	Vėlavimai: 2–5]	Nustato priešastinius ryšius – ar DAX30, SP500 lemia kriptovaliutų grąžas, ar atvirkščiai.	Vėlavimai parenkami AIC/BIC tinklo paieška [1,10]; dažniausiai optimalūs 2–5 vėlavimai.

„Elastic Net“ eilutė apibrėžia reguliarizuotos regresijos taikymą, kai mišriosios bausdos parametras α ribojamas intervale $[0, 1]$, o reguliavimo stiprumas λ parenkamas optimizavimo būdu atliekant kryžminį tikrinimą. Šis metodas lentelėje įvardijamas kaip priemonė multikolinearumo problemai tarp pinigų politikos kintamųjų spręsti, nes reguliavimas stabilizuoja koeficientų įverčius ir leidžia atlikti kintamųjų atranką, sumažinant nereikšmingus koeficientus iki nulio.

Parametrų parinkimas suformuluotas procedūriškai: α ir λ optimizuojami atliekant kryžminį tikrinimą, minimizuojant vidutinę kvadratinę paklaidą, t. y. pasirenkama tokia reguliavimo konfigūracija, kuri geriausiai apibendrina duomenis už imties ribų. ARIMA(p, d, q) blokas lentelėje skirtas liekanų dinamikai po „Elastic Net“ įvertinti, kai tikslas – pašalinti autokoreliaciją ir atskirti pinigų politikos poveikį nuo laiko eilučių inercinės dinamikos. Eilių ribos apibrėžtos kaip $p, q \in [0,10]$, o diferencijavimo tvarka d parenkama pagal stacionarumo reikalavimą, kad būtų suderinta su laiko eilučių modeliavimo prielaidomis. Eilių parinkimo taisyklė sukonkretinta: p ir q nustatomi tinklo paieška, minimizuojant informacijos kriterijus (AIC ir BIC), todėl modelio sudėtingumas valdomas formaliu kriterijumi. ARIMAX eilutė apibrėžia ARIMA išplėtimą, kai prie autoregresinės ir slankiojo vidurkio struktūros prijungiami egzogeniniai veiksniai X , siekiant kontroliuoti globalias finansų rinkos sąlygas. 2.5 lentelėje išvardyti egzogeniniai kintamieji (VIX, SP500, CMC Crypto 200, DAX30) apibrėžia kontrolinę informacijos bazę, kuri leidžia pinigų politikos poveikį vertinti neatsiejamai nuo bendro rizikos režimo ir rinkos nuotaikų. Parinkimo taisyklė išlaikoma nuosekli su ARIMA: AR ir MA eilės parenkamos atliekant tinklo paiešką pagal AIC/BIC, o egzogeninių kintamųjų įtaka (dinaminiai svoriai) įvertinama kartu su ARMA parametrais, taip išvengiant dviejų atskirų tarpusavyje nesusuderintų optimizacijų.

Kintamumo modelių grupėje GARCH(1, 1) pateikiamas kaip bazinė specifikacija, fiksuojanti kintamumo klasterizaciją ir naudojama kaip atskaitos taškas sudėtingesnėms GARCH klasės modifikacijoms. Nors lentelėje nurodyta galutinė eilė $p = q = 1$, eilių parinkimas aprašytas kaip sisteminė tinklelio paieška $p, q \in [1,5]$, minimizuojant AIC, o pasirinkimas pagrįstas ir skaitiniu stabilumu: aukštesniosios eilės nesuteikė reikšmingo pagerinimo ir didino konvergencijos problemas. EGARCH(1, 1) analogiškai parametrizuojamas $p = q = 1$, tačiau pasirinkimo pagrindimas išskiria asimetriją: modelis skirtas svarto efektui fiksuoti, kai neigiamos grąžos didina kintamumą labiau nei teigiamos, todėl yra tinkamas kriptovaliutų rinkoms, kuriose dažni staigūs kritimai. Eilių parinkimo logika išlieka tokia pati (tinklelio paieška [1, 5]), o galutinė (1, 1) specifikacija pasirenkama dėl skaičiavimo stabilumo ir geresnės konvergencijos. FIGARCH(1, d , 1) lentelėje įtrauktas siekiant modeliuoti ilgus atminties efektą, kai kintamumo šokai išlieka ilgesnį laiką ir dėl to tampa svarbūs vertinant ilgalaikius politikos poveikius bei rizikos režimų patvarumą. Parametras $d \in (0,1)$ formaliai apibrėžia frakcinį integravimą, o p ir q parinkimo taisyklė išlieka suderinta su kitomis specifikacijomis: tinklelio paieška [1, 5] ir stabilumo kriterijai, nes sudėtingesnės eilės mažina konvergencijos tikimybę. Ši nuosekli eilių parinkimo schema leidžia skirtingus kintamumo modelius lyginti vienodomis atrankos taisyklėmis, kartu neperkraunant modelio pertekliniu sudėtingumu. MSGARCH eilutė apibūdina režimų kaitos kintamumo modelį su $K = 2$ režimais, kai kiekvienam režimui taikoma pirmąją GARCH struktūrą $p = q = 1$, o skirtingi režimai atspindi žemo ir aukšto nepastovumo fazes. Lentelėje nurodoma, kad režimų skaičius parenkamas pagal BIC. Kiekvienu režimu eilių atranka atliekama tinklelio paieška $p, q \in [1,5]$, pasirenkant AIC požiūriu optimalų ir skaitiniu požiūriu stabilų variantą, todėl režimų kaita nėra įvedama atsitiktiniu būdu, o paremta formaliais atrankos kriterijais.

TVP regresija lentelėje įvardijama kaip laikui einant kintančių parametru metodas, skirtas centrinio banko adaptacijai modeliuoti, kai politikos jautrumas kriptovaliutų kintamumui ir reguliavimo veiksniams gali kisti laiko atžvilgiu. Kadangi šio tipo modeliuose koeficientai traktuojami kaip būsenos, nėra fiksuotos „eilės“ klasikine prasme; parametru trajektorijos gaunamos taikant Kalmano filtrą, t. y. rekursinį būsenų erdvės vertinimo algoritmą. Tokia specifikacija leidžia empiriškai identifikuoti struktūrinius santykių pokyčius, neapribojant jų iš anksto nustatyti lūžių skaičiumi.

„XGBoost“ eilutė apima netiesinį mašininio mokymo metodą, taikomą kintamųjų svarbai nustatyti, kai ryšiai tarp aiškinamųjų veiksnių ir kriptovaliutų grąžų gali būti nelinijiniai ir sąveikaujantys. Hiperparametru parinkimas aprašytas formaliai: taikyta tinklelio paieška, tikrinant didžiausio medžio gylio $\in \{2,3,4,5,6\}$ ir ansamblį sudarančių medžių skaičiaus $\in \{100, 200, 300, 500, 800\}$

kombinacijas, o optimalus derinys pasirinktas pagal mažiausią kryžminio tikrinimo metu gautą prognozės paklaidą.

Instrumentinių kintamųjų regresija (IV) lentelėje aprašoma kaip dviejų etapų procedūra, skirta endogeniškumo problemai tarp kriptovaliutų kintamumo ir politikos kintamųjų spręsti. Procedūra sukonkretinta: pirmajame etape kintamumas (Cryptovol) regresuojamas į uždelstą priėmimo rodiklį $Adopt_{t-1}$ ir instrumentų matricą Z , o antrajame etape politikos kintamasis regresuojamas į prognozuotą kintamumo komponentą, taip atskiriant egzogeninę kintamumo dalį nuo galimai simultaniinės sąveikos. Tokiu būdu lentelė pateikia ne bendrą IV idėją, o tiksliai apibrėžtą identifikavimo ir vertinimo seką, kuri būtina metodinei atsekamybei.

Engle'o–Grangerio kointegracijos testas pateikiamas kaip dviejų etapų procedūra, skirta ilgalaikiams ryšiams tarp kriptovaliutų kainų ir egzogeninių veiksnių patikrinti. Pirmajame etape įvertinama regresija $y = \alpha + \beta x$, o antrajame etape liekanoms taikomas papildytas Dickey'io–Fullerio testas, siekiant nustatyti liekanų stacionarumą ir taip patvirtinti (ar paneigti) ilgalaikės pusiausvyros egzistavimą. Grangerio priežastingumo testas lentelėje įtrauktas priežastinių krypties ryšių diagnostikai, kai tikrinama, ar tokie veiksniai kaip DAX30 ar SP500, padeda prognozuoti kriptovaliutų grąžas, ar stebima atvirkštinė priklausomybė. Vėlavimų parinkimas aprašytas formaliai: vėlavimai parenkami tinklo paieška [1, 10] pagal AIC/BIC, o empiriniuose rezultatuose dažniausiai optimalūs yra 2–5 vėlavimai, todėl testas taikomas ne savavališkai, o remiantis informacijos kriterijais.

Šis poskyris apibendrina ir racionalizuoja pasirinktus metodus ir jų specifikacijas, pateikiamos kintamųjų kategorijos, pavadinimai, šaltiniai ir trumpi aprašai.

2.9. Integruoto modelio rezultatų skaitymo ir interpretavimo principai

Šiame poskyryje pateikiamos centrinio banko atsako funkcijos modulis, aprašyto 2 skyriuje, empirinių rezultatų interpretavimo gairės, būtinos 3 skyriaus rezultatams tinkamai suprasti ir vertinti. Kadangi modulis grindžiamas laiku einant kintančiais parametrais, vertintais taikant būsenos erdvės sistemą su Kalmano filtravimu, empiriniai rezultatai reikalauja aiškaus teorinio pagrindo, kaip juos skaityti, interpretuoti ir palyginti esant skirtingiems režimams bei laikotarpiams.

Centrinio banko atsako funkcija, pateikta (2.17) formulėje, apibūdina, kaip centrinis bankas koreguoja politikos priemonę reaguodamas į kriptovaliutų rinkos kintamumo ir reguliavimo aplinkos pokyčius. Modelyje vertinami du pagrindiniai laikui einant kintantys koeficientai, žymimi beta su laiko žymėjimu. Pirmasis koeficientas nustato centrinio banko politikos jautrumą kriptovaliutų rinkos kin-

tamumui, o antrasis nustato jautrumą reguliavimo aplinkos pokyčiams. Šie koeficientai nėra fiksuoti visiems stebėjimams, jie keičiasi kiekvienu laiko momentu ir atspindi centrinio banko atsaką, politikos prioritetų pokyčius bei kintančias makroekonominės ir finansinės sąlygas.

Laikui einant kintantys koeficientai vertinami taikant būsenos erdvės modelį, kurio būsenos lygtis pateikta (2.18) formulėje. Pagal šią lygtį kiekvienas koeficientas laiko momentu t yra lygus ankstesnio laikotarpio koeficiento reikšmei su pridėtu atsitiktiniu triukšmo nariu, kuris pasiskirsto pagal normalųjį skirstinį. Toks atsitiktinio pasivaikščiojimo procesas leidžia koeficientams laipsniškai keistis, nereikalaujant iš anksto nustatyti konkretaus kitimo modelio. Kalmano filtras užtikrina optimalų nestebimų koeficientų vertinimą, naudojant visą prieinamą informaciją kiekvienu laiko momentu.

Pirmojo koeficiento interpretavimas priklauso nuo jo ženklo ir dydžio. Teigiamoji koeficiento reikšmė rodo, kad Centrinis bankas aktyviai reaguoja į padidėjusį kriptovaliutų kintamumą ir didina politikos priemonės reikšmę. Priklausomas kintamasis yra federalinių fondų palūkanų norma, teigiamasis koeficientas rodo, kad padidėjęs kriptovaliutų kintamumas sukelia palūkanų normos padidinimą. Kuo didesnis koeficientas, tuo stipresnė Centrinio banko reakcija. Jei koeficientas artimas nuliui, Centrinis bankas nekreipia dėmesio į kriptovaliutų kintamumą arba jo reakcija yra neutrali, o tai gali reikšti, kad kriptovaliutos dar nėra laikomos sistemiškai reikšmingu rizikos šaltiniu. Neigiamasis koeficientas rodo atvirkštinę reakciją, kai Centrinis bankas mažina politikos priemonės reikšmę reguliuodamas į padidėjusį kintamumą. Toks atvejis retai pasitaiko empiriniuose tyrimuose ir reikalauja papildomo ekonominio pagrindimo, pvz., kai prioritetas teikiamas priešciklinei politikai.

Antrasis koeficientas apibūdina Centrinio banko jautrumą reguliavimo pokyčiams ir paprastai yra neigiamasis. Tai reiškia, kad griežtesnė reguliavimo aplinka, matuojama aukštesnėmis reguliavimo indekso reikšmėmis, sumažina Centrinio banko poreikį aktyviai reaguoti į kriptovaliutų kintamumą palūkanų normų koregavimo priemonėmis. Kitaip tariant, jei reguliavimo sistema veiksmingai absorbuoja dalį sisteminio nestabilumo rizikos, Centrinis bankas gali pasirinkti mažiau aktyvų atsaką. Kuo didesnė šio koeficiento absoliučioji reikšmė, tuo stipresnis reguliavimo stabilizuojantis poveikis. Pavyzdžiui, koeficiento reikšmė minus viena šimtoji rodo, kad dešimties punktų reguliavimo indekso padidėjimas sumažina politikos jautrumą kintamumui maždaug 10 proc. Laiko dinamika taip pat yra svarbi interpretuojant. Jei koeficiento absoliučioji reikšmė didėja laikui bėgant, tai rodo, kad reguliavimo sistema tampa efektyvesnė ir palaipsniui perima dalį sisteminės rizikos valdymo funkcijos iš Centrinio banko diskrecinio politikos koregavimo.

Impulso atsako funkcijos, pateiktos (2.20) ir (2.21) formulėse, kiekybiškai vertina, kaip vienkartinis kintamumo ar reguliavimo šokas veikia politikos priemonę kelių laikotarpių perspektyvoje. Teigiamas kriptovaliutų kintamumo impulso atsako funkcijos rezultatas rodo, kad kriptovaliutų kintamumo šokas sukelia politikos priemonės padidinimą po tam tikro laikotarpių skaičiaus. Neigiamas reguliavimo impulso atsako funkcijos rezultatas rodo, kad reguliavimo griežtėjimas sumažina politikos reakcijos intensyvumą.

Ribinio poveikio analizė rodo, kaip keičiasi kriptovaliutų grąžos pereinant iš vieno kintamumo režimo į kitą ir kaip reguliavimo aplinka modifikuoja šiuos poveikius. Jei bitkoino grąža stabilaus kintamumo sąlygomis yra teigiama 17 proc., o aukšto kintamumo sąlygomis tampa neigiama 14 proc., tai rodo bendrą skirtingų režimų poveikį, kuris siekia 181 proc. Šis pokytis atspindi ne tik rinkos sąlygų pasikeitimą, bet ir Centrinio banko bei reguliavimo institucijų veiksmų įtaką. Jei tam tikra kriptovaliuta rodo teigiamą grąžos pokytį net aukšto kintamumo sąlygomis, tai rodo atsparumą krizinėms sąlygoms arba mažesnę integravimosi lygį su tradicinėmis finansų rinkomis ir pinigų politikos kanalais.

Endogeniškumo problema yra kritinė modelio specifikacijoje, nes kriptovaliutų kintamumas ir Centrinio banko politikos sprendimai gali būti abipusiškai susiję. Siekiant išvengti klaidingo priežastinio ryšio nustatymo, modelyje taikomi instrumentiniai kintamieji, kurių pirmojo etapo regresija pateikta (2.19) formulėje. Pirmajame etape kriptovaliutų kintamumas prognozuojamas naudojant vėluojančias prekybos apimtis ir išorinius finansinių rinkų rodiklius, tokius kaip akcijų rinkos grąžos bei kitus pasaulinius veiksnius. Tik prognozuota kintamumo dalis įtraukiama į politikos reakcijos lygtį užtikrinant, kad vertinami koeficientai atspindi tikrąjį Centrinio banko atsako jautrumą, o ne atsitiktinius statistinius ryšius. Instrumentinių kintamųjų stiprumas vertinamas pirmojo etapo F statistika, kuri pateikiama empiriniuose rezultatuose. Reikšmės, viršijančios 10, rodo gana stiprų instrumentą, o reikšmės, viršijančios 30, rodo labai stiprų instrumentą, kaip bitkoino atveju, kai F statistika siekia 31. Tai patvirtina, kad instrumentiniai kintamieji atitinka reikalaujamas sąlygas ir modelio rezultatai yra patikimi priežastinės analizės požiūriu.

Taigi šiame poskyryje pateiktos gairės leis nuosekliai interpretuoti 3 skyriuje pateiktus empirinius rezultatus, atsižvelgiant į modelio laikui einant kintančią struktūrą, režimų skirtumus ir endogeniškumo kontrolę. Be šių gairių empiriniai koeficientai ir lentelės gali būti klaidingai suprasti arba laikyti paviršutiniškais statistiniais duomenimis, o ne sisteminiu Centrinio banko politikos prisitaikymo įrodymu.

2.10. Antrojo skyriaus išvados

Remiantis integruotos metodinės sistemos, skirtos decentralizuotų kriptovaliutų poveikiui pinigų politikos perdavimui analizuoti, sukūrimu, suformuluotos šios išvados:

1. Hibridinė ekonometrinio-mašininio mokymosi sistema sujungia keturis pagrindinius modulius, skirtus dvikryptės sąveikos tarp pinigų politikos ir decentralizuotų kriptovaliutų problemai spręsti. Į politikos perdavimo modulį įtraukiamas „Elastic Net“ mašininio mokymo metodas su ARIMA liekanomis, kad izoliuotų pinigų politikos poveikį kriptovaliutų kainoms, sprendžiamas daugiakolinearumo ir autokoreliacijos klausimus. Nepastovumo grįžtamojo ryšio modulis integruoja režimo keitimo GARCH modelius, kad užfiksuotų asimetrinę nepastovumo dinamiką ir struktūrinius lūžius. Egzogeninių veiksnių modulis taiko ARIMAX metodą su mašininio mokymosi pagrindu sukurtais svoriais, kad nustatytų prioritetus pasaulinei ekonominei įtakai, o Centrinio banko atsako modulis modeliuoja adaptyvų politikos formavimą naudodamas laiko atžvilgiu kintančių parametrų regresiją. Šie komponentai sujungiami į vienalaikę lygčių sistemą, sprendžiant endogeniškumą taikant trijų pakopų mažiausių kvadratų vertinimą.
2. Politikos perdavimo metodika tobulinama pritaikius tradicinius metodus, derinant reguliavimo metodus su slankiojo lango patvirtinimu. Šis modelis pritaikomas netiesinei kriptovaliutų kainų dinamikai stabiliais ir kriziniais laikotarpiais, išlaikant interpretuojamus koeficientus, kurie yra labai svarbūs politikos analizei. Kryžminis patvirtinimas užtikrina atsparumą struktūriniams pokyčiams, pvz., perėjimui nuo mažų palūkanų režimų prie infliacinės aplinkos.
3. Nepastovumo modeliavimas apima pažangias GARCH klasės specifikacijas (MSGARCH, FIGARCH), kad būtų galima spręsti kriptovaliutoms būdingas ypatybes, įskaitant klasterinį nepastovumą, svarto efektus ir ilgalaikę atmintį.
4. Egzogeninių veiksnių integravimas sukuria sisteminių kintamųjų atrankos protokolą, derindamas statistinio reikšmingumo testus (pvz., Grangerio priešastingumo testą) su mašininio mokymosi ypatybių svarbos reitinguais. Šis dvigubas metodas filtruoja klaidingas koreliacijas, kartu išsaugant ekonomiškai reikšmingus pasaulinius veiksnius, tokius kaip akcijų rinkos rezultatai ir rizikos nuotaikų indeksai.
5. Centrinio banko adaptacija įgyvendinama naudojant būsenos erdvės sistemą, kurioje Kalmano filtravimas seka besikeičiantį politikos jautrumą kriptovaliutų nepastovumui ir reguliavimo pokyčiams. Instrumentiniai kintamieji mažina atvirkštinio priešastingumo problemas, užtikrindami

nešališkus politikos formuotojų reakcijos į kriptovaliutų rinkos sutrikimus įvertinimus.

6. Integruota sistema formalizuoja grįžtamojo ryšio ciklus tarp politikos veiksmų, kriptovaliutų kainų dinamikos ir makroekonominio stabilumo. Scenarijų testavimo protokolai leidžia atlikti kontrafaktinę analizę, pvz., įvertinti, kaip hipotetiniai reguliavimo terminai gali pakeisti infliacijos rezultatus.

Integruoto kriptovaliutų ir pinigų politikos perdavimo modelio aprobavimas

Šiame skyriuje pristatomi 2 skyriuje konceptualizuoto integruoto hibridinio modelio testavimo rezultatai, kuriuo kiekybiškai įvertinamas decentralizuotų kriptovaliutų poveikis pinigų politikos perdavimui, empirinis patvirtinimas. Analizėje modelio modulinė sistema, jungianti mašininio mokymosi patobulintą elastingumo vertinimą („Elastic Net“ + ARIMA), kintamumo režimo analizę (MSGARCH) ir egzogeninių veiksnių integraciją (ARIMAX), taikoma trims dominuojančioms kriptovaliutoms (BTC, ETH, BNB) ir centrinių bankų (ECB, FED) politikai esant įvairiems ekonominiams režimams (2018–2022 m.). Nors empirinis dėmesys sutelktas į euro zonos ir JAV rinkas, modelio dizainas užtikrina galimybę jį pritaikyti ir kitose jurisdikcijose, susiduriančiose su kriptovaliutų ir pinigų politikos sąveika.

Pagrindinės šio skyriaus išvados buvo paskelbtos recenzuojamuose moksliniuose leidiniuose (Pečiulis et al., 2024; Pečiulis & Vasiliauskaitė, 2021a; Pečiulis & Vasiliauskaite, 2024; Pečiulis & Vasiliauskaitė, 2024b; Pečiulis & Vasiliauskaite, 2025a; Pečiulis & Vasiliauskaite, 2025), kuriuose patvirtintas teorinis modelio patikimumas ir praktin⁴ nauda politikos formuotojams. Rezultatai ne tik patvirtina reikšmingus kriptovaliutų politikos perdavimo kanalus, bet ir atskleidžia

nuo režimo priklausančius šalutinius poveikius, suteikiančius informacijos apie adaptyvias reguliavimo strategijas siekiant makroekonominio stabilumo skaitmeninėje eroje.

3.1. Politikos perdavimo modulio rezultatai

Šiame poskyryje pateikiami empiriniai politikos perdavimo modulio, kuriuo kiekybiškai įvertinamas pinigų politikos sukrėtimų poveikis kriptovaliutų kainoms, rezultatai. Jo struktūra yra tokia: 3.1.1 skirsnyje analizuojamas įprastinės pinigų politikos (palūkanų normų) poveikis BTC, ETH, BNB grąžai; 3.1.2 skirsnyje vertinamas UMPT) vaidmuo kriptovaliutų rinkose; 3.1.3 skirsnyje nagrinėjama nuo režimo priklausanti reakcija stabiliais ir krizės laikotarpiais (2018–2022 m.).

3.1.1. Įprastinės pinigų politikos ryšys su kriptovaliutų rinka

Empirinė įprastinės pinigų politikos perdavimo kriptovaliutų rinkoms analizė rodo statistiškai patikimus ir ekonomiškai reikšmingus ryšius, taikant (2.1)–(2.10) formulėse aprašytus metodus. Kaip matyti 3.1 lentelėje, regresiniai modeliai pasižymi didele bendra aiškinamąja galia: F statistika svyruoja nuo 40 iki 432 (visais atvejais reikšminga 1% lygmeniu), o didesnės F reikšmės rodo, kad pasirinkti pinigų politikos kintamieji, vertinami kartu, labai gerina modelio paaiškinimą (t. y. ryšys nėra atsitiktinis). R^2 reikšmės (nuo 0,3944 iki 0,6976; vidurkis 0,5468) rodo, kad pinigų politikos veiksniai paaiškina apčiuopiamą kriptovaliutų kainų pokyčių dalį, o mažesnės R^2 vertės signalizuoja, kad konkrečiais laikotarpiais ar turto grupėse didesnę kainų dinamikos dalį lemia kiti (neįtraukti) veiksniai. Pažymėtina, kad bitkoinas pasižymi didžiausiu jautrumu politikos pokyčiams (pvz., 3.2 lentelėje fiksuojamas reikšmingas neigiamas ryšys su federalinių fondų norma), kas dera su jo, kaip pagrindinio etaloninio skaitmeninio turto, vaidmeniu rinkoje. Visos imties modeliai paprastai lenkia imties poskyrius prognozavimo tikslumu, o iki COVID laikotarpio silpnesni rezultatai tikėtini dėl ribotesnio duomenų prieinamumo ir mažiau intensyvios pinigų politikos tuo laikotarpiu. Šie apibendrinti rezultatai sudaro aiškų pagrindą toliau nuosekliai nagrinėti konkrečius perdavimo mechanizmus, pradedant tradiciniu palūkanų normų kanalu.

3.2 ir 3.3 lentelėse atskleidžiami svarbūs centrinių bankų įtakos niuansai skirtingoms kriptovaliutoms ir laikotarpiams. „Elastic Net“ efektyviai pašalina nereikšmingus koeficientus, o ECB ribinio skolinimosi galimybės palūkanų norma nuosekliai rodo nulinių poveikį visoms kriptovaliutoms.

3.1 lentelė. Modelio našumo rodikliai, taikomi pinigų politikai perduoti kriptovaliutų rinkoms

Table 3.1. Model performance metrics for monetary policy transmission to cryptocurrency markets

Imtis	F statistika	P reikšmė	R kvadratas
BTC-USD visa imtis	432,5	0	0,6976
BTC-USD prieš COVID'ą	40,13425072	1,62E-50	0,3944
BTC-USD po COVID'o	199,7849108	9,2337E-179	0,6188
ETH-USD visa imtis	298,1591381	5,0336E-288	0,6153
ETH-USD po COVID'o	99,60301094	2,8767E-102	0,5514
ETH-USD COVID'o	148,409287	6,0818E-148	0,5466
BNB-USD visa imtis	331,168657	0	0,4863
BNB-USD prieš COVID'ą	105,7203298	1,5671E-106	0,4028
BNB-USD po COVID'o	194,918554	4,3969E-176	0,6085
Vidurkis	205,5997932	1,80297E-51	0,546855556

3.2 lentelė. Kriptovaliutų reakcijos į pinigų politiką: visos imties rezultatai

Table 3.2. Cryptocurrency reaction to monetary policy: full sample results

BTC				
Rodiklis	Koeficientas	Standartinė paklaida	t statistika	p reikšmė
Federalinių fondų norma	-15348,86	485,44	-31,62	0
ECB indėlių norma	-11347,14	9428,85	-3,87	0
ECB fiksuota norma	30518,27	8611,49	6,22	0
ECB ribinės paskolos	0	-	-	-
FOMC neigiami	1898,39	675,88	2,82	0
FOMC teigiami	12879,46	750,27	16,55	0
ECB neigiami	3299,96	730,65	4,47	0
ECB teigiami	-16870,84	746,75	-23,37	0
ETH				
Federalinių fondų norma	-1059,44	38,81	-27,3	0
ECB indėlių norma	0	-	-	-

3.2 lentelės pabaiga

Rodiklis	Koeficientas	Standartinė paklaida	<i>t</i> statistika	<i>p</i> reikšmė
ECB fiksuota norma	1488,03	753,91	-0,89	0,38
ECB ribinės paskolos	0	-	-	-
FOMC neigiami	575,07	54,04	10,64	0
FOMC teigiami	924,82	59,99	15,42	0
ECB neigiami	0	-	-	-
ECB teigiami	-1151,17	59,71	-19,28	0
BNB				
Federalinių fondų norma	-135,36	5,75	-23,55	0
ECB indėlių norma	0	-	-	-
ECB fiksuota norma	173,42	111,62	-5,54	0
ECB ribinės paskolos	0	-	-	-
FOMC neigiami	24,49	8	11,05	0
FOMC teigiami	57,37	8,88	18,68	0
ECB neigiami	0	-	-	-

Nors ETH ir BNB rodo ribotą jautrumą daugumai ECB politikos priemonių (tik ekspansinės ECB komunikacijos rodo reikšmę ETH), visos trys kriptovaliutos rodo stiprią ir statistiškai reikšmingą reakciją į Federalinio rezervo sistemos politikos priemones. Šis skirtingas centrinių bankų jautrumas ypač išryškėja iki COVID'o imties, kur su FED susiję kintamieji išlaiko reikšmingumą, o ECB parametrai iš esmės neįtraukiami į optimizuotus modelius. Šie rezultatai ne tik patvirtina modelio tinkamumą reikšmingiems politikos perdavimo kanalams nustatyti, bet ir pabrėžia dominuojantį JAV pinigų politikos vaidmenį kriptovaliutų rinkose, sudarydami sąlygas išsamiai aptarti įprastinių palūkanų normų poveikį kitame poskyryje.

Iki COVID laikotarpio empiriniai rezultatai (3.3 lentelė) atitinka visos imties rezultatus (3.2 lentelė): ECB ribinio skolinimosi galimybės palūkanų norma statistiškai nereikšminga visoms kriptovaliutomis, o FED politikos instrumentai (FFR ir FOMC pranešimai) išlieka dominuojantys kintamieji, aiškinantys kriptovaliutų kainų pokyčius. ECB ribinio skolinimosi galimybė statistiškai nereikšminga nagrinėtose kriptovaliutose, todėl ji nėra įtraukta į modulį. Pažymėtina, kad BNB nrodo jokios reikšmingos reakcijos į jokių ECB palūkanų normų instrumentus, o aiškinamąją galią išlaiko tik Federalinio rezervo sistemos kintamieji (FFR ir FOMC plėtros pranešimai) ir ECB ribojančios politikos pranešimai. BTC atveju,

nors ECB ribojančios politikos koeficientas išlieka modelyje, jo p reikšmė, lygi 0,19, neatitinka įprastų reikšmingumo ribų. ETH atvejis yra ypač įdomus, nes tik du parametrai išlieka pasirinkus „Elastic Net“ modelį: federalinių fondų palūkanų norma ir ECB indėlių galimybės palūkanų norma, o visi politikos pranešimų kintamieji yra eliminuoti.

3.3 lentelė. Kriptovaliutų reakcijos į pinigų politiką: Prieš COVID

Table 3.3. Cryptocurrency reaction to monetary policy: pre-covid sample results

BTC				
Rodiklis	Koefi- cientas	Standar- tinė pak- laida	<i>t</i> statistika	<i>p</i> reikšmė
Federalinių fondų norma	-5303,5	301,95	-17,56	0
ECB indėlių norma	44069,62	4269,45	10,32	0
ECB fiksuota norma	0	–	–	–
ECB ribinės paskolos	0	–	–	–
FOMC neigiami	-883,61	259,97	-3,4	0
FOMC teigiami	3947,6	322,91	12,23	0
ECB neigiami	356,86	272,21	1,31	0,19
ECB teigiami	2288,36	469,47	4,87	0
ETH				
Federalinių fondų norma	-406,42	21,38	-25,19	0
ECB indėlių norma	1695,95	302,36	13,48	0
ECB fiksuota norma	0	–	–	–
ECB ribinės paskolos	0	–	–	–
FOMC neigiami	0	–	–	–
FOMC teigiami	0	–	–	–
ECB neigiami	0	–	–	–
ECB teigiami	0	–	–	–
BNB				
Federalinių fondų norma	3,67	0,65	10,84	0
ECB indėlių norma	0	–	–	–
ECB fiksuota norma	0	–	–	–
ECB ribinės paskolos	0	–	–	–
FOMC neigiami	0	–	–	–

Pereidami prie laikotarpio po COVID rezultatų (3.4 lentelė), stebime tarpinį modelio sudėtingumą tarp visos ir iki COVID imčių. Šeši koeficientai išlieka reikšmingi BTC, penki – BNB ir ETH. ECB ribinio skolinimosi galimybė vėl pasirodo esanti visuotinai nereikšminga, o ECB indėlių galimybė išryškėja kaip viintelė nuosekliai reikšminga palūkanų norma, daranti įtaką visoms kriptovaliutoms. Šie rezultatai atitinka ekonomikos teoriją, nes indėlių galimybės palūkanų norma yra pagrindinis Europos bankų sektoriaus kainodaros lyginamasis rodiklis. Šiame imties poskyryje išlieka nuolatinis su FED susijusių kintamųjų dominavimas, aiškinant kriptovaliutų kainų pokyčius, atspindintis ankstesnius rezultatus.

3.4 lentelė. Kriptovaliutų reakcijos į pinigų politiką po COVID atsiradimo

Table 3.4. Cryptocurrency reaction to monetary policy: post-covid sample results

BTC				
Rodiklis	Koeficientas	Standartinė paklaida	<i>t</i> statistika	<i>p</i> reikšmė
Federalinių fondų norma	-19293,77	852,25	-22,64	1,59E-86
ECB indėlių palūkanos	21381,58	2007,99	10,65	1,01E-24
ECB fiksuotos palūkanos	0	–	–	–
ECB ribinės paskolos	0	–	–	–
FOMC neigiami	6325,58	1104,96	5,72	1,51E-08
FOMC teigiami	16265,47	1092,29	14,89	4,95E-44
ECB neigiami	5246,01	1154,96	4,54	6,51E-06
ECB teigiami	-19262,92	1005,48	-19,16	1,11E-66
ETH				
Federalinių fondų norma	-1326,16	69,7	-19,03	6,04E-66
ECB indėlių palūkanos	1760,62	164,23	10,72	5,12E-25
ECB fiksuotos palūkanos	0	–	–	–
ECB ribinės paskolos	0	–	–	–
FOMC neigiami	1126,74	90,37	12,47	1,66E-32
FOMC teigiami	1375,23	89,34	15,39	1,46E-46
ECB neigiami	0	–	–	–
ECB teigiami	-1207,83	82,24	-14,69	5,10E-43
BNB				
Federalinių fondų norma	-179,69	9,61	-18,69	4,40E-64

3.4 lentelės pabaiga

Rodiklis	Koeficientas	Standartinė paklaida	<i>t</i> statistika	<i>p</i> reikšmė
ECB indėlių palūkanos	252,39	22,65	13,56	1,46E–37
ECB fiksuotos palūkanos	0	–	–	–
ECB ribinės paskolos	0	–	–	–
FOMC neigiami	187,2	12,47	15,02	1,16E–44
FOMC teigiami	254,71	12,32	20,67	3,37E–75
ECB neigiami	0	–	–	–
ECB teigiami	–191,15	11,34	–16,85	3,95E–54

Nepaisant decentralizuoto kriptovaliutų pobūdžio ir teorinio nepriklausomumo nuo tradicinių pinigų politikos institucijų, modeliai rodo nepaprastai stiprius ryšius (R^2 iki 0,69) tarp Centrinio banko politikos ir skaitmeninio turto kainų. Nors ši koreliacija nereiškia tiesioginio priežastinio ryšio ar kontrolės, ji rodo svarbų perdavimo mechanizmą, kuris, greičiausiai, veikia per investuotojų nuotaikų kanalus. Ekspansinė pinigų politika gali skatinti rizikos apetitą ir ekonominių optimizmą, skatindama kriptovaliutų paklausą ir kartu mažindama turimą pasiūlą, investuotojams taikant laikymo strategijas. Ir atvirkščiai, ribojanti politika gali sukelti priešingą poveikį blogėjant nuotaikoms. Tačiau turime pabrėžti, kad šiam hipotetiniam perdavimo mechanizmui reikalingas atskiras empirinis patvirtinimas.

Praktiniu požiūriu šie rezultatai suteikia vertingų įžvalgų tiek politikos formuotojams, tiek rinkos dalyviams. Centrinų bankų vadovai gauna empirinių įrodymų apie nenumatytas savo politikos pasekmes kriptovaliutų rinkose, o investuotojai įgyja sistemą, skirtą skaitmeninio turto kainų pokyčiams, pagrįstiems pinigų politikos pokyčiais, numatyti.

Šių išvadų patikimumą dar labiau patvirtina slankiojo lango kryžminio patvirtinimo analizė ir vidutinės absoliučiosios mastelio paklaidos metrika, rodanti nuoseklų modelio veikimą skirtingu laiku. Šis patvirtinimo procesas įtvirtina nustatytų ryšių stabilumą, kartu apsaugodamas nuo pernelyg didelio pritaikymo problemų, kurios gali trikdyti įprastus ekonometrinius metodus šioje naujoje tyrimų srityje.

3.5 lentelėje pateikiami MASE rodikliai, gauti atlikus kryžminio patikrinimo analizę, rodantys modelio veikimą skirtingomis rinkos sąlygomis. Nors metrikų reikšmės paprastai viršija vienetą, rezultatai atskleidžia svarbias įžvalgas apie modelio pritaikymo galimybes. Visų pirma, modelis pasiekia geresnį bitkoino prognozavimo tikslumą laikotarpiu iki COVID, sėkmingai atspindėdamas unikalią šio laikotarpio rinkos dinamiką.

3.5 lentelė. Prognozavimo tikslumas (MASE) pagal kriptovaliutą ir laikotarpį
Table 3.5. Forecasting Accuracy (MASE) by cryptocurrency and period

Kriptovaliuta	Imtis	MASE
BTC/USD	Visa imtis	2,19
BTC/USD	Prieš COVID'ą	0,98
BTC/USD	Po COVID'o	1,61
ETH/USD	Visa imtis	2,67
ETH/USD	Prieš COVID'ą	-18,17
ETH/USD	Po COVID'o	1,74
BNB/USD	Visa imtis	2,94
BNB/USD	Prieš COVID'ą	1,13
BNB/USD	Po COVID'o	1,87

Analizė patvirtina, kad modulis suteikia vertingų prognozavimo išvalgų, ypač pagrindinių kriptovaliutų, tokių kaip bitkoinas atveju, ir kartu nurodo sritis, kurias ateityje reikėtų tobulinti. Skaičiavimo intensyvumas atspindi sudėtingą modelio architektūrą, skirtą sudėtingiems pinigų politikos perdavimo mechanizmams fiksuoti – tai kompromisas dėl gilesnio supratimo, kurį jis suteikia, palyginti su paprastesniais lyginamaisiais modeliais. Šie rezultatai sukuria tvirtą pagrindą tolesniam kriptovaliutų prognozavimo sistemų tobulinimui besikeičiančioje rinkos aplinkoje.

Šiame skirsnyje pateikti empiriniai rezultatai rodo stiprius statistinius ryšius tarp centrinių bankų politikos ir kriptovaliutų kainų, kai R^2 reikšmės svyruoja nuo 0,39 iki 0,70, o F statistikos visais atvejais yra reikšmingos 1 proc. lygmeniu, Kartu nustatoma, kad Federalinio rezervo sistemos instrumentai nuosekliai dominuoja prieš ECB priemones visų trijų kriptovaliutų ir visų analizuotų laikotarpių atveju. Šis nustatytas jautrumas prieštarauja teorinei decentralizacijos prielaidai, kurią pabrėžia Fernández-Villaverde ir Sanches (2019), teigdami, kad privačiai leidžiamos valiutos turėtų veikti nepriklausomai nuo Centrinio banko politikos, nors jie pripažįsta, kad valiutų konkurencija sukuria problemų perduodant pinigų politiką. Ypač stipri bitkoino reakcija į FED politiką dera su Dyhrberg (2016a) pateiktu bitkoino apibūdinimu, pagal kurį bitkoinas pasižymi apsidraudimo savybėmis, panašiomis į aukso, kuris taip pat reaguoja į JAV doleriais denominuotos pinigų politikos pokyčius. Tačiau nulinis ECB ribinio skolinimosi galimybės koeficientas visuose modeliuose prieštarauja lūkesčiui, kad kriptovaliutų rinkos, kaip globaliai integruotas finansinis turtas, kurį aprašo Corbet et al. (2019), turėtų simetriškai reaguoti į pagrindinių centrinių bankų veiksmus. Didelis modelio sudėtingumas ir koeficientų reikšmingumas laikotarpiu po COVID gali atspindėti

išaugusį politikos neapibrėžtumą, kurį fiksuoja Lucey et al. (2022) sukurtas kriptovaliutų neapibrėžtumo indeksas, pasižymintis aiškiais svyravimais apie reikšmingus įvykius kriptovaliutų erdvėje. Nors Fernández-Villaverde et al. (2021) teigia, kad centrinių bankų skaitmeninės valiutos galėtų stabilizuoti tarpininkavimą panikos laikotarpiais, šiame tyrime gauti rezultatai rodo, kad net ir be CBDC įprastinės pinigų politikos priemonės daro išmatuojamą poveikį decentralizuotų kriptovaliutų vertinimui, ypač per FED dominuojančius perdavimo kanalus.

3.1.2. Netradicinių pinigų politikos priemonių veiksmingumas

Šiame skirsnyje pateikiami empiriniai analizės rezultatai, lyginant juos su ankstesniais tyrimais ir nagrinėjant pagrindinius metodologinius trūkumus. 3.6 lentelėje apibendrinamos visuose tyrimuose atliktų regresijų pakoreguotos R kvadrato vertės. Pažymėtina, kad P reikšmių, t -statistikų ir F -statistikų nepateikiame dėl šių rodiklių apskaičiavimo „Elastic Net“ būdingų sunkumų. Nors šiuos statistinius duomenis būtų galima gauti taikant įprastą mažiausiųjų kvadratų (OLS) regresiją, mes teikėme pirmenybę metodologiniam patikimumui ir rėmėmės „Elastic Net“ regresija, kuri nesuteikia tiesioginio reikšmingumo testavimo. Esama literatūra (Horel & Giesecke, 2020) patvirtina, kad šių metrikų išvedimas „Elastic Net“ modeliui yra sudėtingas skaičiavimo požiūriu, o standartinės programavimo priemonės (pvz., *Python*, *R*) šiuo metu nesiūlo sprendimų.

3.6 lentelė. OLS ir E-net regresijų statistika BVP ir infliacijai

Table 3.6. OLS and E-net regression statistics for GDP and inflation

Imtis	OLS	„Elastic Net“
BVP (UMPTs + palūkanos)	0,6208	0,1344
BVP (palūkanos)	0,3763	0,1122
BVP (UMPTs)	0,2971	0,137
Infliacija (UMPTs + palūkanos)	0,7897	0,6356
Infliacija (palūkanos)	0,4705	0,4146
Infliacija (UMPTs)	0,4942	0,3372
BVP vidurkis	0,4267	0,1323

Norėdami gauti patikimus rezultatus, pirmiausia įvertinome bazines OLS regresijas, kurios, derinant UMPT ir tradicines (palūkanų normos) pinigų politikos priemones, davė dideles pakoreguotas BVP augimo (0,62) ir infliacijos (0,79) R kvadrato vertes. Tačiau „Elastic Net“ – mūsų pagrindinis modelis – atskleidė ryškų skirtumą: infliacija išlaikė didelę aiškinamąją galią (koreguotas $R^2 = 0,64$),

o BVP augimo prognozinis pajėgumas smarkiai sumažėjo (koreguotas $R^2 = 0,13$). Šis rezultatas rodo, kad „Elastic Net“ efektyviai slopina daugiareikšmius ar klaidingus koeficientus, o tai atitinka ekonomikos teoriją. Konkrečiai šiuolaikinėje pinigų politikoje pirmenybė teikiama tiesioginiam infliacijos tikslo nustatymui, o ne BVP augimui, kuriam netiesioginę įtaką daro daugiau ekonominių aspektų.

Hipotezės tikrinimo procedūra buvo įgyvendinta taikant judančių blokų „Bootstrap“ (MBB) modeliavimą, kad būtų įvertintas modelio aiškinamosios galios statistinis reikšmingumas. 3.7 lentelėje pateikiami modeliavimo rezultatai, o stulpelyje „Imtis“ nurodomi konkretūs duomenų pogrupiai, kuriems buvo taikoma MBB analizė. Sukurti keturi skirtingi „Bootstrap“ pasiskirstymai, įskaitant vieną, kuris kiekybiškai įvertina alternatyvių modelio specifikacijų pakoreguotų R kvadrato verčių skirtumą. Pvz., pasiskirstymas, pažymėtas „Infliacija ((UMPT + Palūkanų normos) – Palūkanų normos)“, parodo papildomą aiškinamąją galią, gautą infliacijai modeliuoti kartu su įprastinėmis palūkanų normomis, įtraukus nekonvencinės pinigų politikos priemones.

3.7 lentelė. 5 % BVP augimo tempo ir infliacijos patikimumo intervalai pritaikius MBB su UMPT ir palūkanų normomis

Table 3.7. 5% confidence intervals for GDP growth rate and inflation after applying MBB with UMPTs and interest rates

Imtis	5 % patikimumo intervalai („Bootstrap“ metodas)
Infliacija ((UMPT + palūkanos) – palūkanos)	(0,03, 0,34)
Infliacija (tik UMPT))	(0,052, 0,36)
BVP augimo lygis ((UMPT + palūkanos) – palūkanos)	(–0,01, 0,04)
BVP augimo lygis (UMPTs alone)	(–0,12, 0,19)

Iš 3.7 lentelėje pateiktų modeliavimo rezultatų matyti statistiškai reikšmingas infliacijos poveikis, kaip rodo abiejų atitinkamų pasiskirstymų pasikliautinieji intervalai, išskyrus nulį. Priešingai, BVP augimo modeliai parodė nereikšmingus rezultatus, kurių pasikliautinieji intervalai apima nulį. Šis empirinis modelis tiksliai atitinka pagrindinį Europos Centrinio Banko įgaliojimą – infliacijos tikslo nustatymą, o BVP augimas tebėra antraeilis veiksnys, kuriam netiesioginę įtaką daro platesni politikos kanalai. Mūsų statistinių išvadų ir nustatytų pinigų politikos sistemų atitikimas patvirtina 2 skyriuje išdėstytą metodologinį požiūrį ir sustiprina mūsų rezultatų ekonominių patikimumą.

3.8 lentelėje pateikiami koeficientų įverčiai, gauti taikant „Elastic Net“ analizę. Rezultatai rodo aiškius skirtumus tarp BVP augimo ir infliacijos modelių.

Augant BVP dauguma koeficientų sumažėja iki nulio, išskyrus ribinio skolinimo priemonės ir turto pirkimo programos koeficientus, o tai rodo, kad šios priemonės yra pagrindiniai pinigų politikos veiksniai, lemiantys BVP svyravimus modulio sistemoje. Infliacijos modelyje išlieka daug nulinės vertės koeficientų, o tai rodo jų santykinę svarbą aiškinant infliacijos dinamiką.

3.8 lentelė. „Elastic Net“ koeficientai infliacijai ir BVP augimo tempui taikant įvairias pinigų politikos priemones

Table 3.8. 5% Elastic Net coefficients for inflation and GDP growth rate across various monetary policy tools

Įrankiai	Infliacija	BVP augimas
Indėlių norma	0,124844	0
Pagrindinės refinansavimo operacijos	0,264186	0
Ribinis skolinimo norma	0,161843	-0,33459
Ilgalaikės refinansavimo operacijos (LTRO)	-0,12895	0
Turto pirkimo programa	0,171578	0,174876
Tikslinės ilgalaikės refinansavimo operacijos (TLTRO)	-0,55942	0
Pandemijos pirkimo programa (PEPP)	0	0
TLTRO II	-0,0087	0
TLTRO III	0,014713	0
Vertybinių popierių rinkos programa (SMP)	0,632258	0

Pažymėtina, kad pandemijos nepaprastosios padėties pirkimų programos (PEPP) koeficientas sumažėjo iki nulio, o tai reiškia, kad modulio specifikacijoje ji neturėjo matomo poveikio infliacijai. Šie rezultatai rodo netradicinių pinigų politikos priemonių selektyvų veiksmingumą skirtingiems ekonominiams rodikliams. Atlikę „Elastic Net“ įvertinimo metodą, ARIMA procesus pritaikėme tiek UMPT, tiek palūkanų normų modelių liekanoms. Infliacijai nurodėme ARIMA(4,1,3) procesą, o BVP augimui reikėjo ARIMA(5,0,5) specifikacijos. Vėlesni diagnostiniai testai (3.9 lentelė) parodė, kad modelis puikiai tinka infliacijai: liekanos buvo nulinės vidutinės vertės ($\mu \approx 0$), be autokoreliacijos (Ljung-Box $p > 0,05$), normaliai pasiskirsčiusios (Shapiro–Wilk $p = 0,62$) ir homoscedastinės (ARCH $p = 0,72$).

3.9 lentelė. Infliacijos ir BVP augimo likučių diagnostinių testų rezultatai


Table 3.9. 5% diagnostic test results of residuals for inflation and GDP growth rate

Testas	Infliacija	BVP augimo lygis
Vidurkis	0,002	-0,009
Ljungbox testas	0,98	0,79
Shapiro–Wilk testas	0,62	4,87E-12
ARCH testas	0,72	8,29E-14

BVP augimo modelis parodė labiau nevienareikšmiškus rezultatus – nors vidurkis buvo lygus nuliui ir nebuvo autokoreliacijos (Box–Pierce $p = 0,79$), liekanos pažeidė normalumo ir homoskedastiškumo prielaidas. Šie rezultatai rodo, kad mūsų modeliavimo metodas yra ypač tinkamas infliacijos analizei, o BVP augimo prognozes reikia interpretuoti atsargiai dėl liekanų pažeidimų. Svarbu pažymėti, kad šie diagnostiniai rezultatai nepaneigia „Elastic Net“ koeficientų įverčių, bet veikiau informuoja apie susijusių pasikliautinojo intervalo tikslumą prognozuojant taikymus. Skirtingi rodiklių rezultatai atitinka nusistovėjusius pinigų politikos perdavimo mechanizmus, pagal kuriuos infliacija paprastai tiesiogiai reaguoja į politikos priemones labiau nei BVP augimas.

3.1 pav. pateikiami vizualūs „Elastic Net“ modelio su ARIMA liekanomis pritaikytų verčių atvaizdai. Šios pritaikytos vertės susijusios su infliacijos duomenimis ir yra pagrįstos mokymo duomenų rinkiniu. Atidžiai išnagrinėjus šiuos paveikslus matyti, kad pritaikytos ir faktinės vertės labai sutampa, o tai rodo, kad modelis gerai veikia mokymo rinkinyje. Pažymėtina, kad modelis sėkmingai atspindi didelius nuosmukius po didžiosios recesijos. Jis taip pat tiksliai atspindi vėlesnį atsigavimą, įrodydamas savo veiksmingumą tiek stabilioje, tiek nestabilioje ekonominėje aplinkoje, pvz., didžiosios recesijos ir skolos krizės metu.

3.1.2 skirsnio rezultatai rodo aiškią netradicinių pinigų politikos priemonių poveikio asimetriją: „Elastic Net“ modeliai gerai paaiškina infliacijos dinamiką, tačiau BVP augimo paaiškinamumas išlieka menkas. Toks skirtumas atitinka Anzuini (2022) išvadą, kad turto pirkimų makroekonominis poveikis priklauso nuo būsenos ir labiausiai pasireiškia tik esant įtemptoms finansų rinkų sąlygoms. Infliacijos kanalo reikšmingumas taip pat dera su Boneva et al. (2016) rezultatais, kurie parodė, kad kiekybinis skatinimas didina JK įmonių kainų ir darbo užmokesčio infliacijos lūkesčius, patvirtindami, kad infliacijos lūkesčiai yra vienas iš tiesioginių perdavimo mechanizmų. Silpnas poveikis BVP modeliuose kontrastuoja su Kapetanios et al. (2012) vertinimais, jog pirmasis Anglijos banko QE turėjo apčiuopiamą didžiausią poveikį realaus BVP lygiui, ir su Churm et al. (2021) išvada, kad QE2 prisidėjo prie JK BVP padidėjimo maždaug 0,5–0,8 proc.



3.1 pav. „Elastic Net“ modelio modeliuotos ir faktinės infliacijos vertės mokymo duomenų rinkiniui (2008–2020 m.)

Fig. 3.1. Elastic Net model's fitted vs actual values for inflation for the training set (2008–2020)

Visiškas PEPP koeficiento sumažėjimas iki nulio „Elastic Net“ specifikacijoje išryškina skirtumą su Chionis et al. (2021) rezultatais, kuriais nustatytas reikšmingas ECB QE poveikis euro zonos šalių valdžios skolai ir neveiksnioms paskoloms, tai yra poveikis labiau pasireiškė per fiskalinius ir bankų sektoriaus rodiklius nei per modeliuose identifikuojamą tiesioginį BVP kanalą. Skirtumai tarp infliacijos ir BVP rezultatų taip pat suderinami su Matousek et al. (2019) įrodymais, kad QE Japonijoje veikia per bankų vertybinių popierių portfelius ir sverto preferencijas, o poveikio stiprumas priklauso nuo bankų dydžio, todėl agreguotu lygmeniu realiosios ekonomikos poveikiai gali būti nevienodi.

3.2. Kintamumo grįžtamojo ryšio modulio rezultatai

Siekdami nustatyti optimalias integruoto hibridinio modelio kintamumo specifikacijas, sistemingai įvertinome 6720 GARCH klasės konfigūracijas (8 modelių klasės \times 4 kriptovaliutos \times 210 hiperparametrų deriniai), teikdami pirmenybę skaičiavimo įgyvendinamumui ir apribodami ARMA vėlavimo variacijas iki standartinių GARCH modelių. Konvergencijos sėkmės laipsnis labai skyrėsi tarp skirtingų modelių tipų, tradiciniai GARCH (96,4 %) ir Log-GARCH (95,0 %) modeliai parodė geresnį skaitinį stabilumą, palyginti su pažangesniais variantais, tokiais kaip EGARCH (87,5 %) ir CS-GARCH (80,0 %). Svarbu pažymėti, kad ilgos atminties FIGARCH (49,8 %) ir HYGARCH (37,5 %) modeliai dažnai nesikonvergavo, o režimų keitimo MSGARCH pasiekė tik 55,0 % stabilumą, kas kiekybiškai parodo metodologinį kompromisą tarp kriptovaliutų kintamumo dinamikos fiksavimo ir skaičiavimo patikimumo išlaikymo (3.10 lentelė).

3.10 lentelė. GARCH modelių konvergencijos laipsnis

Table 3.10. Convergence Rates of GARCH Models

Modelis	Konvergencijų skaičius	Sėkmės procentas
GARCH	810	96,4
Log-GARCH	798	95,0
EGARCH	735	87,5
CS-GARCH	672	80,0
GJR-GARCH	693	82,5
MSGARCH	462	55,0
FIGARCH	412	49,8
HYGARCH	315	37,5

Papildyti Dickey-Fuller testai (3.11 lentelė) patvirtino stacionarumą visose kriptovaliutų gražos serijose (testų statistika $< -11,79$, $p < 0,01$), atitinkant kintamumo modeliavimo prielaidas. 3.2 pav. pateikti BTC, ETH, BNB ir XRP dienos logaritminiai gražos rodikliai, kurie rodo stochastinius svyravimus apie nulį, o XRP-USD svyravimų diapazonas yra gerokai platesnis ($\pm 0,6$ palyginti su $\pm 0,3$ BTC/ETH). Nepaisant skirtingo dydžio, rinkos sukrėtimų metu pasireiškė sinchronizuotas kintamumo klasterizavimas, kurį rodo kvadratinių gražų diagramos (3.3 pav.). Jos parodė pakaitinius didelio judumo pikus (0,2–0,3) ir ramias fazes, laikinai sutampančias su makroekonominiais įvykiais (pvz., 2021 m. bulių rinka, 2022 m. kritimas).

3.11 lentelė. Kriptovaliutų logaritminių gražų padidintų Dickey'io–Fullerio testų rezultatai

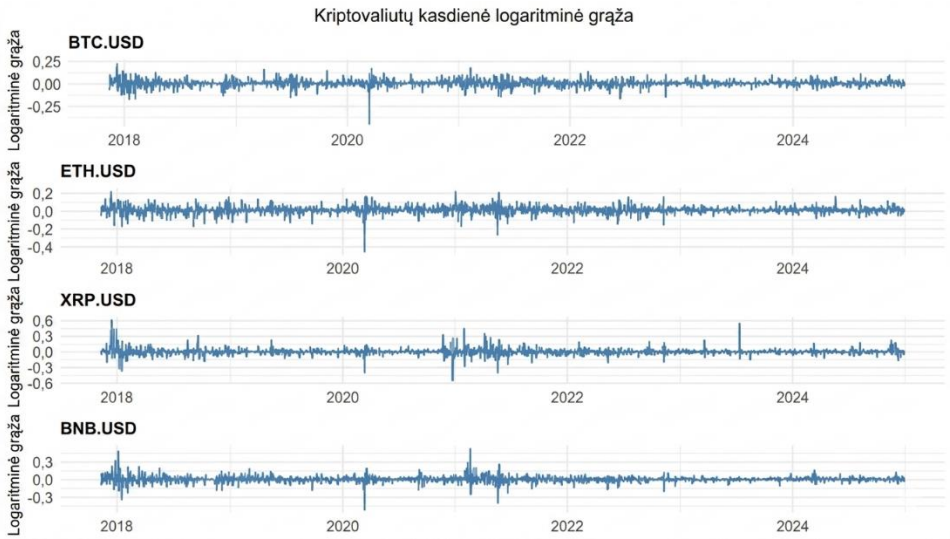
Table 3.11. Results of augmented Dickey–Fuller tests for cryptocurrency log returns

Kriptovaliuta	Testavimo statistika	Vėlavimas	p reikšmė	Išvada
BTC-USD	-12,92	13	<0,01	Stacionari
ETH-USD	-13,20	13	<0,01	Stacionari
XRP-USD	-12,90	13	<0,01	Stacionari
BNB-USD	-11,79	13	<0,01	Stacionari

Autokoreliacijos analizė (3.12 lentelė) parodė statistiškai reikšmingą pastovumą ($p < 0,05$), stipriausią BNB-USD, patvirtinančią GARCH laiko kintančios dispersijos prielaidas. Nors ACF (3.4 pav.) parodė greitą nuosmukį, PACF (3.5 pav.) nustatė nuolatinę dalinę autokoreliaciją iki 10 vėlavimo (ypač 1, 5, 10 vėlavimų), atmetant paprastas AR(1) specifikacijas. Dėl to vidurkių lygtys turi būti aukštesniosios eilės AR procesai (iki AR(10)), suderinti su ARIMAX metodu, siekiant išskirti kelių laikotarpių priklausomybes kriptovaliutų gražose.

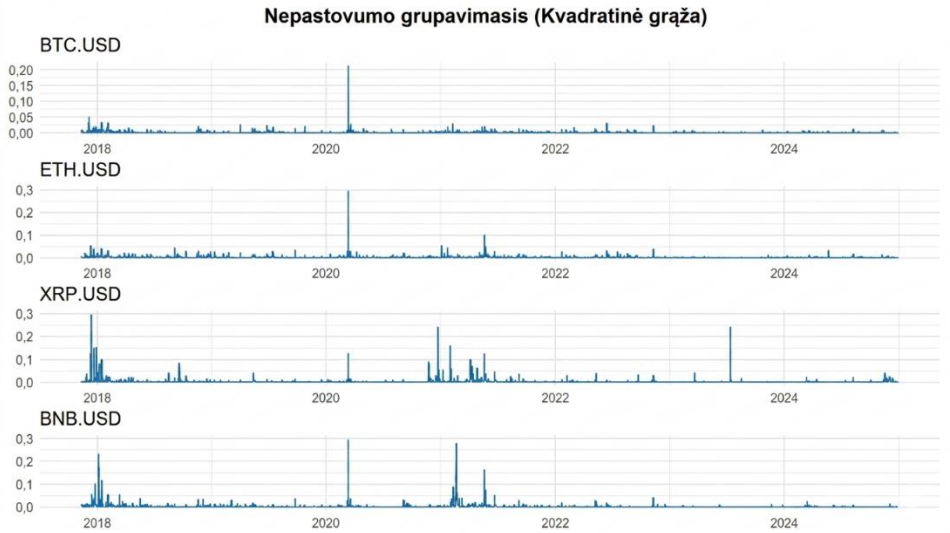
3.5 pav. parodyta RSS, mėlyna linija BIC ir juoda linija per keturių kriptovaliutų kandidatinių lūžio taškų skaičių (0–8). Nors BIC techniškai pasiekia minimumą nuliniuose lūžio taškuose (tai rodo, kad nėra struktūrinių lūžių), jis rodo lygesnę trajektoriją tik su nedideliu didesnių lūžio taškų skaičiaus padidėjimu. Tačiau RSS kreivė rodo didelį pagerėjimą iki dviejų lūžio taškų, paskui stabilizuojasi. Šis modelis rodo, kad du lūžio taškai optimaliai subalansuoja modelio tinkamumą ir sudėtingumą, nes nedidelis RSS pagerėjimas po dviejų lūžio taškų nebetenkinamas BIC nuolatiniame didėjime. RSS pagerėjimo tempo ir BIC laipsniško didėjimo susikirtimas dviejuose lūžio taškuose empiriškai pagrindžia šios specifikacijos pasirinkimą MSGARCH sistemoje užtikrinant, kad aptikti režimai yra statistiškai reikšmingi ir ekonomiškai interpretuojami be pernelyg didelio pritaikymo.

3.13 lentelėje pateikiamos aštuonių konkuruojančių GARCH specifikacijų AIC vertės, naudojant keturias pagrindines kriptovaliutas. Žvaigždutės žymi statistiškai reikšmingą pranašumą, o MSGARCH iškyla kaip dominuojanti specifikacija, patvirtinanti didelę režimų keitimo elgsenos svarbą kriptovaliutų rinkose. EGARCH demonstruoja nuoseklų antrinį pranašumą, patvirtindamas reikšmingų svarto efektų buvimą visose turto klasėse. Ilgos atminties modeliai FIGARCH ir HYGARCH yra ypač stiprūs bitkoino ir eterio atžvilgiu, o tai rodo, kad šis turtas pasižymi didesniais kintamumo šokais, palyginti su XRP ir BNB.



3.2 pav. Kripto valiutų dienos grąža (2018–2024 m.)

Fig. 3.2. Cryptocurrency daily returns (2018–2024)



3.3 pav. Kripto valiutų dienos grąža (2018–2024 m.)

Fig. 3.2. Cryptocurrency daily squared returns (2018–2024)

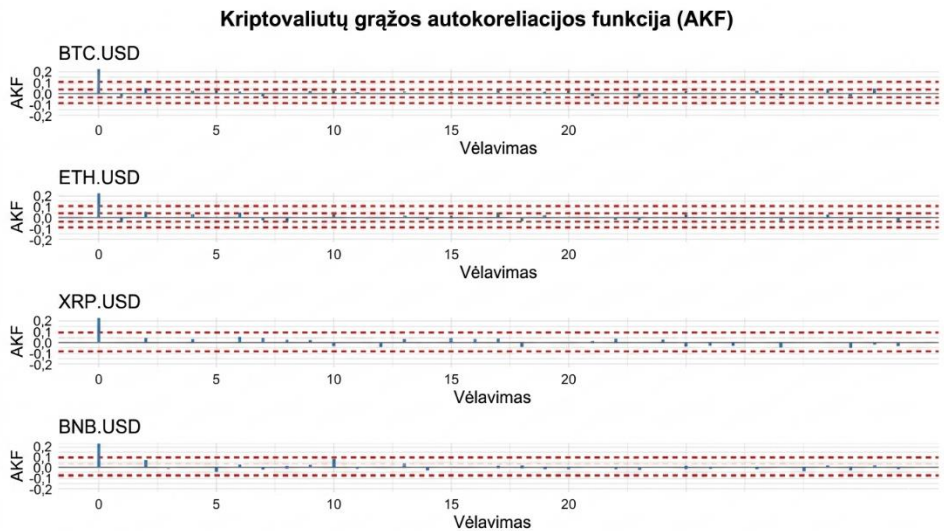
Pasiskirstymo rezultatai atitinka teorinius lūkesčius, kur modeliai, fiksuojantys asimetriją (EGARCH), gauna naudos iš asimetrinių Studento t inovacijų, o kiti

pasiekia optimalią bendrosios paklaidos pasiskirstymo funkcijos atitikį. CS-GARCH veiklos profilis (–4,14 iki –3,97 visose turto klasėse) atspindi jo specializuotą gebėjimą atskirti kintamumo komponentus, o ne absoliučiai pagerinti atitikimą. Šie rezultatai kartu rodo, kad kriptovaliutų kintamumo dinamikai reikalinga: 1) režimų keitimo sistema; 2) asimetrinės reakcijos specifikacijos; 3) storų uodegų pasiskirstymas.

3.12 lentelė. Ljungo–Boxo autokoreliacijos testo rezultatai kriptovaliutų logaritminių grąžų atžvilgiu

Table 3.12. Ljung–Box autocorrelation test results for cryptocurrency log returns

Kriptovaliuta	Testavimo statistika (χ^2)	p reikšmė	Vėlavimai
BTC-USD	20,89	0,0219	10
ETH-USD	29,60	0,000997	10
XRP-USD	25,91	0,00387	10
BNB-USD	47,38	< 0,0001	10



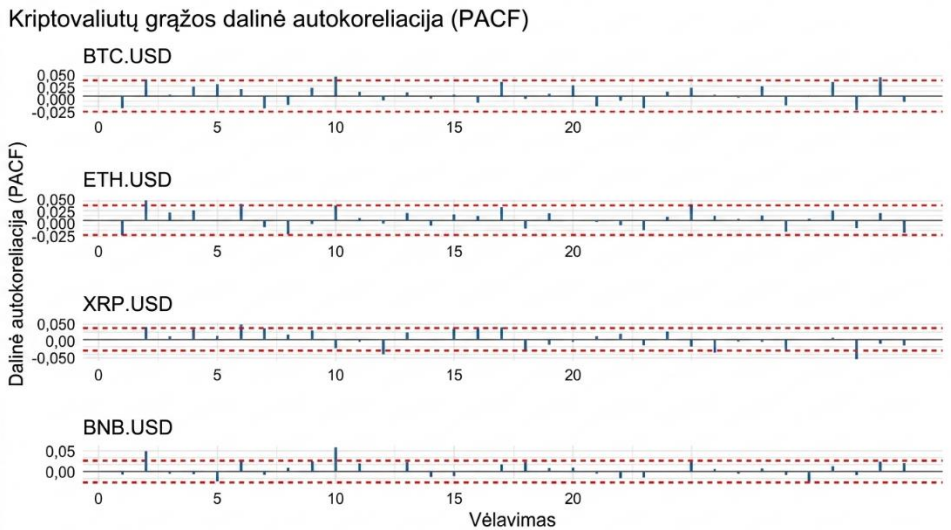
3.4 pav. Kriptovaliutų grąžos autokoreliacijos funkcija (ACF)

Fig. 3.4. Autocorrelation function (ACF) of cryptocurrency returns

ARMA (1,0) sistemingas dominavimas vidurkio lygties specifikacijoje visuose kintamumo modeliuose (MSGARCH, EGARCH, FIGARCH ir kt.) ir visose

laiko eilutėse pabrėžia svarbų faktą apie kriptovaliutų grąžą: jos pasižymi nuosekliu, švelniu autoregresiniu pastovumu, kuris daugiausia užfiksuojamas vienu AR terminu, nereikalaujant MA komponentų ar sudėtingesnių struktūrų. Ši specifikacija nuolat buvo geriausia, todėl ši informacija nėra įtraukta į 3.13 lentelę.

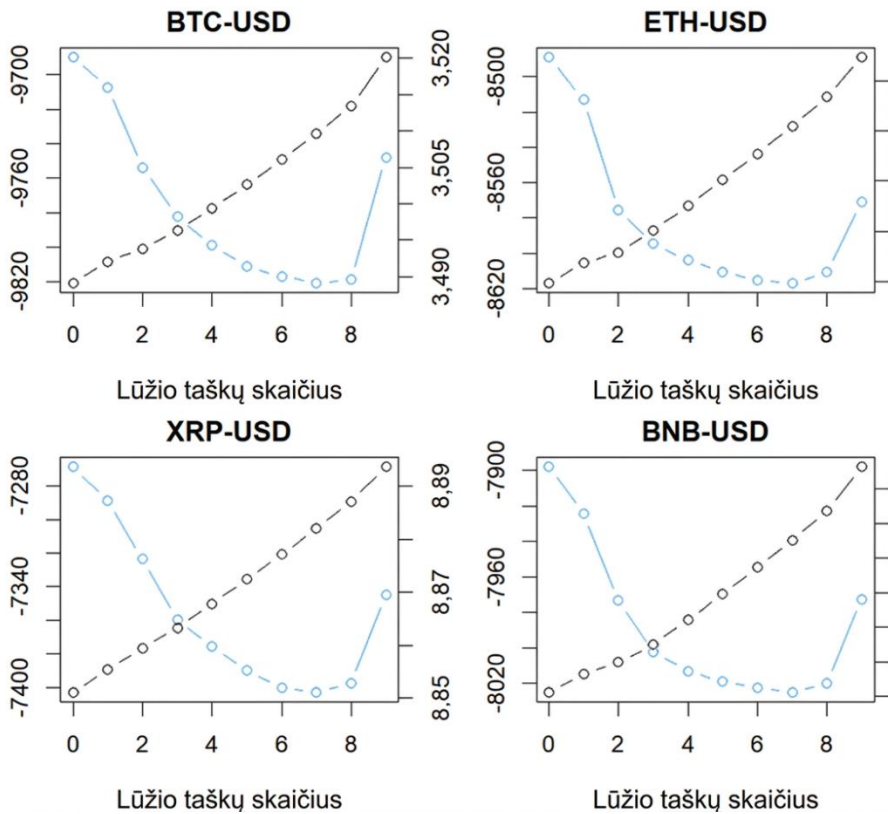
Neįtrauktiems į apmokymo imtį duomenims testuoti naudojome EGARCH ir FIGARCH modelius, nors MSGARCH parodė geriausius imties rodiklius. Šis pasirinkimas pagrįstas tuo, kad MSGARCH gerai tinka ilgesniems laikotarpiams arba laikotarpiams su besikeičiančiais režimais.



3.5 pav. Kriptovaliutų grąžos dalinė autokoreliacijos funkcija (PACF)

Fig. 3.5. Partial autocorrelation function (PACF) of cryptocurrency returns

Įvertintas EGARCH(1,1) modelis (3.14 lentelė) rodo tris pagrindines visų kriptovaliutų kintamumo charakteristikas: 1) reikšmingą svėro efektą ($\gamma = 0,149^{***}$ iki $0,292^{***}$), kai neigiamos grąžos padidina būsimą kintamumą labiau nei teigiamos grąžos, ypač XRP atveju; 2) didelį pastovumą ($\beta = 0,937^{***}$ iki $0,984^{***}$), rodantį ilgalaikius kintamumo sukrėtimus; 3) storos uodegos pasiskirstymą (GED forma = $0,835^{***}$ iki $1,003^{***}$), labiausiai išreikštą BTC atveju. ARMA(1,0) vidurkio lygtys rodo nuoseklų vidurkio grįžimą ($AR1 = -0,076^{***}$ iki $-0,147^{***}$), stipriausią XRP atveju.



3.6 pav. Bayeso informacijos kriterijus (BIC) struktūrinių lūžių atrankai kriptovaliutų gražos duomenyse

Fig. 3.6. Bayesian information criterion (BIC) for structural break selection in cryptocurrency returns

Svertiniai ARCH-LM testai ($p > 0,34$ visų turto vienetų atžvilgiu) patvirtina tinkamą kintamumo modeliavimą, nes standartizuotose liekanose nebelieka ARCH efektų – tai patvirtina, kad EGARCH specifikacija sėkmingai užfiksuoja sąlyginį heteroskedastiškumą. Tačiau *Ljung-Box Q testai* standartizuotose liekanose ($p < 0,01$) rodo neišspręstą serijinę koreliaciją, o tai rodo mikrostruktūros poveikį arba aukštesniosios eilės ARMA terminų poreikį. *Sign Bias Test* atskleidžia unikalią BNB asimetrinę reakciją į gražos kryptį (bendras $p = 0,017$), kai teigiamos / neigiamos gražos, viršijančios γ užfiksuotą dydžio efektą, vis dar skirtingai veikia kintamumą.

3.13 lentelė. GARCH klasės modelių imčių vidaus įvertinimo našumas pagrindinėse kriptovaliutose

Table 3.13. In-sample estimation performance of GARCH-class models across major cryptocurrencies

Modelio tipas	Skirstinys	BTC	ETH	XRP	BNB
GARCH	GED	-4,15	-4,18	-3,90	-4,03
MSGARCH	Paslinktas studento	-5,12***	- 4,98***	- 4,75***	- 4,83***
EGARCH	GED	-4,85**	-4,80**	-4,25**	-4,50**
GJR-GARCH	Paslinktas studento	-4,13	-4,11	-3,82	-3,95
FIGARCH	GED	-4,65*	-4,60*	-3,91	-4,02
HYGARCH	GED	-4,55*	-4,58*	-3,85	-3,99
Log-GARCH	GED	-4,16	-4,20	-3,94	-4,08
CS-GARCH	GED	-4,14	-4,12	-3,88	-3,97

3.14 lentelė. EGARCH (1,1) įvertinimo rezultatai su ARMA (1,0) vidurkiu ir GED pasiskirstymu

Table 3.14. EGARCH (1,1) estimation results with ARMA (1,0) mean and GED distribution

Parametras	BTC	ETH	XRP	BNB
μ (vidurkis)	0,0005***	0,0006***	-0,0003***	0,0009***
AR(1)	-0,076***	-0,097***	-0,147***	-0,089***
Ω	-0,133***	-0,102***	-0,392*	-0,136***
A	-0,004 (0,762)	0,005 (0,668)	0,018 (0,423)	0,003 (0,837)
B	0,981***	0,984***	0,937***	0,979***
Γ	0,168***	0,149***	0,292***	0,234***
forma	0,889***	0,986***	0,835***	1,003***
Ljungo–Boxo Q (<i>p</i> reikšmė)	1,5e-06	2,9e-06	6,2e-08	9,0e-06
ARCH-LM (<i>p</i> reikšmė)	0,417	0,591	0,806	0,345
Ženklių šališkumo testas	NS	NS	NS	Significant**

FIGARCH(1,d,1) (3.15 lentelė) įvertinimai rodo stiprų ilgalaikį kintamumo išlikimą ($\delta = 0,329-1,000^{***}$), o ETH ir BNB rodo beveik ilgalaikę atmintį ($\delta \approx 1$). Vidurkio lygtys rodo trumpalaikę autokoreliaciją ($AR1 = -0,078^{***}$ iki $-0,151^{***}$), stipriausią XRP atveju. Kintamumo pastovumas (β) yra didžiausias ETH ($0,938^{***}$) ir mažiausias XRP ($0,774$). ARCH efektai (α) yra reikšmingi tik BTC ($0,230^*$) ir BNB ($0,127^{***}$). Visos imtys rodo storų uodegų pasiskirstymą (forma = $0,858-0,996^{***}$), labiausiai ekstremalus BTC ir XRP. Diagnostiniai testai patvirtina tinkamą specifikaciją, nors BNB rodo asimetrinę reakciją į naujienas (ženklų nuokrypis = $2,612^{***}$). Šie rezultatai pabrėžia skirtingą kriptovaliutų kintamumo dinamiką, ypač jų ilgalaikę atmintį ir storas uodegas.

3.15 lentelė. FIGARCH(1,d,1) įvertinimo rezultatai su ARMA(1,0) vidurkiu ir GED pasiskirstymu

Table 3.15. FIGARCH(1,d,1) estimation results with ARMA(1,0) mean and GED distribution

Parametras	BTC	ETH	XRP	BNB
M	0,00059**	0,00058***	-0,00044***	0,00080***
AR(1)	-0,078***	-0,104***	-0,151***	-0,094***
Ω	0,000018**	0,000013*	0,000051 (0,790)	0,000020***
A	0,230*	0,077 (0,531)	0,767 (0,415)	0,127***
B	0,862***	0,938***	0,774 (0,370)	0,908***
Δ	0,788***	1,000***	0,329***	1,000***
forma	0,886***	0,968***	0,858***	0,996***
Q(20)-Res	20,44***	23,75***	22,87***	16,63***
Q²(20)-Res	0,067 (0,796)	0,159 (0,690)	0,049 (0,824)	0,609 (0,435)
ARCH-LM(5)	2,607 (0,352)	5,338* (0,086)	0,089 (0,989)	6,728** (0,040)
Ženklų šališkumo testas	0,783 (0,433)	1,500 (0,134)	1,270 (0,204)	2,612***

Šio poskyrio empiriniai rezultatai patvirtina 2.4 skyriuje aprašytą metodologinį požiūrį. Įrodoma, kad pažangios GARCH specifikacijos labai pagerina kriptovaliutų rinkų kintamumo modeliavimą. Šie rezultatai tiesiogiai veikia mūsų integruoto modelio kintamumo grįžtamojo ryšio modulį, ypač atsižvelgiant į režimo keitimosi elgseną ir ilgalaikės atminties efektus, kurie daro įtaką pinigų politikos

perdavimo kanalams. Analizė patvirtina, kad MSGARCH, FIGARCH ir EGARCH modeliai gerokai pranoksta tradicinės specifikacijos ir teikia svarbią informaciją 2.7 skyriuje sukurtai hibridinei mašininio mokymosi ir ekonometrinės analizės sistemai.

3.16 lentelė. EGARCH (1,1) FIGARCH(1,d,1) įvertinimo rezultatai su ARMA(1,0) vidurkiu ir GED pasiskirstymu

Table 3.16. EGARCH (1,1) FIGARCH(1,d,1) estimation results with ARMA(1,0) mean and GED distribution

Kripto valiuta	Modelis	Duomenys	RMSE	MAE
BTC	EGARCH	Apmokymo	0,03066831	0,02385267
BTC	EGARCH	Testavimo	0,02119651	0,01812959
BTC	FIGARCH	Apmokymo	0,03085954	0,02399308
BTC	FIGARCH	Testavimo	0,02062238	0,01752228
ETH	EGARCH	Apmokymo	0,03641101	0,03077391
ETH	EGARCH	Testavimo	0,02507182	0,02231952
ETH	FIGARCH	Apmokymo	0,03825686	0,02980853
ETH	FIGARCH	Testavimo	0,02501502	0,02084927
XRP	EGARCH	Apmokymo	0,04976176	0,03450914
XRP	EGARCH	Testavimo	0,08775667	0,03520921
BNB	EGARCH	Apmokymo	0,04347386	0,03125709
BNB	EGARCH	Testavimo	0,02287451	0,01915384
BNB	FIGARCH	Apmokymo	0,04364836	0,03088031
BNB	FIGARCH	Testavimo	0,02126344	0,01735932

Patikimas MSGARCH modelių veikimas (55,0 % konvergencijos rodiklis nepaisant sudėtingumo) patvirtina 1.4.3 skirsnyje pateiktą teorinę prielaidą apie kintamumo režimus ir finansinio užkrato riziką. Pažymėtina, kad nuoseklūs svarto efektai ($\gamma > 0$) visose turto klasėse, stipriausi XRP ($\gamma = 0,292$) kontrastuoja su ankstesniais atvirkštinio poveikio rezultatais, o tai rodo besikeičiančią rinkos struktūrą, į kurią mūsų integruotas modelis turi atsižvelgti politikos simuliacijose.

Šie rezultatai turi reikšmingą poveikį mūsų modelio praktiniam įgyvendinimui. Pirma, režimų keitimo modelių pranašumas tiesiogiai pagrindžia jų įtraukimą į Centrinio banko reagavimo funkcijos modulį (2.6 poskyris).

3.2 poskyryje pateikti empiriniai rezultatai rodo, kad MSGARCH pasiekė geriausias imties vidaus našumą visose kriptovaliutose, nors jam buvo būdingesnis

mažesnis konvergencijos lygis, palyginti su tradiciniu GARCH modeliu, o EGARCH nuosekliai užėmė antrą vietą. Šie rezultatai tiesiogiai patvirtina Caporale ir Zekokh (2019) išvadą, gautą pritaikius daugiau kaip 1000 GARCH modelių bitkoino, eterio, „Ripple“ ir laitkoino duomenims, kad standartinis GARCH gali lemti neteisingas VaR prognozes ir kad specifikacijos, leidžiančios asimetriją ir režimų kaitą, labai pagerina rizikos valdymą. Nustatytas MSGARCH pranašumas dera su Maciel (2021) Bajeso analize, kurioje įvertintos 54 MS-GARCH struktūros šešioms kriptovaliutomis patvirtinant, kad MS-GARCH užtikrina tikslesnes VaR ir ES prognozes, palyginti su vieno režimo alternatyvomis, ir papildo Faruq et al. (2025) naujausią išvadą, kad laikui einant kintančių režimų kaitos modeliai yra pranašesni, fiksuojant sudėtingus dešimties didžiausių pagal kapitalizaciją kriptovaliutų kintamumo dėsninumus. Dviejų režimų struktūra rezonuoja su Kayal ir Dutta (2024) taikyta asimetrinio dviejų būsenų MS-MGARCH schema, kuri nustatė bitkoino, eterio ir laitkoino prieš COVID ir po jo režimų pokyčius, taip pat su Sosa et al. (2019) Markovo perjungimo patvirtinimu, kad kriptovaliutų kintamumas 2010–2019 m. evoliucionuoja pagal didelio ir mažo kintamumo režimus.

Taigi šiame skyriuje pateiktas empirinis patvirtinimas yra svarbus elementas kuriant išsamų kriptovaliutų pinigų politikos perdavimo modelį, užtikrinantis, kad kintamumo dinamika būtų tinkamai apibrėžta ir kiekybiškai įvertinta. 3.2 poskyryje gauti rezultatai patvirtina 1 skyriuje suformuluotą prielaidą, kad kriptovaliutų rinkoms būdinga režimų kaita, asimetrija ir ilgalaikė atmintis, todėl kintamumui aprašyti būtinos išplėstinės GARCH specifikacijos (MSGARCH/EGARCH/FI-GARCH), o ne vien tradicinis GARCH. Šių modelių įverčiai: režimų tikimybės, kintamumo parametrai ir nustatytos ribos, vėliau tiesiogiai naudojami integruotame modelyje kaip įvesties kintamieji, kad būtų galima kiekybiškai įvertinti, kada kriptovaliutų kintamumas sustiprina makroekonominio nestabilumo riziką (ypač infliacijos kanale), o kada tokio poveikio neaptinkama.

3.3. Egzogeninių veiksnių modulio rezultatai

Šioje dalyje pateikiami rezultatai iš egzogeninių veiksnių modulio. Empirinė egzogeninių veiksnių analizė atskleidžia svarbią informaciją apie kiekybinį pasaulio finansinių ir makroekonominių kintamųjų poveikį pinigų politikos ir kriptovaliutų kainų santykiui. Naudojant ARIMAX sistemą su mašininio mokymosi papildyta funkcijų atranka, šis modulis sistemingai identifikuoja ir matuoja penkių išorinių kintamųjų – VIX, aukso kainų, CMC Crypto 200, S&P 500 ir DAX 30 – dinaminį poveikį BTC, ETH ir BNB grąžai. Rezultatai pabrėžia būtinybę kontroliuoti šiuos išorinius veiksnis, siekiant izoliuoti tiesioginį centrinių bankų veiksmų poveikį integruotam hibridiniam modeliui.

3.17 lentelė. Dinaminiai ARIMAX koeficientų įverčiai kriptovaliutų grąžai
Table 3.17. Dynamic ARIMAX coefficient estimates for cryptocurrency returns

Faktorius	BTC (ψ_k)	ETH (ψ_k)	BNB (ψ_k)	p reikš- mė (BTC)	p reikš- mė (ETH)	p reikš- mė (BNB)
VIX	-0,04	-0,06	-0,04	<0,01	<0,01	<0,05
„Gold“	0,22	0,24	0,17	<0,01	<0,01	<0,10
CMC200	0,65	0,73	0,63	<0,01	<0,01	<0,01
S&P500	0,16	0,31	0,31	<0,05	<0,01	<0,05
DAX30	0,01	0,04	0,13	0,84	0,62	0,15

Remiantis ARIMAX modelio rezultatais, gautais pagal (2.19) lygtį, galima daryti šias išvadas: ARIMAX modelio įverčiai rodo statistiškai reikšmingus koeficientus (ψ_k) daugumai egzogeninių kintamųjų naudojant visas tris kriptovaliutas. BTC atveju CMC Crypto 200 indeksas daro stipriausią teigiamą poveikį grąžai ($\psi_{CMC} = 0,65$, $p < 0,01$), o tai rodo, kad BTC grąža glaudžiai susijusi su bendra kriptovaliutų rinkos dinamika. Aukso kaina taip pat turi reikšmingą teigiamą poveikį ($\psi_{Gold} = 0,22$, $p < 0,01$), atspindėdama BTC kaip rizikos draudimo priemonės vaidmenį. S&P 500 indeksas daro vidutinį poveikį ($\psi_{S\&P500} = 0,16$, $p < 0,05$), o VIX indeksas rodo nedidelį, bet reikšmingą neigiamą poveikį ($\psi_{VIX} = -0,04$, $p < 0,01$). Tai reiškia, kad, padidėjus rizikos vengimui, BTC grąža mažėja. DAX 30 poveikis BTC yra nereikšmingas ($p = 0,84$). ETH atveju tendencijos yra panašios: CMC200 ($\psi = 0,73$, $p < 0,01$) ir „Gold“ ($\psi = 0,24$, $p < 0,01$) daro stiprų teigiamą poveikį, o S&P 500 ($\psi = 0,31$, $p < 0,01$) daro dar didesnę poveikį nei BTC atveju. VIX taip pat turi neigiamą poveikį ($\psi = -0,06$, $p < 0,01$), o DAX 30 poveikis nėra statistiškai reikšmingas ($p = 0,62$). BNB atveju CMC200 ($\psi = 0,63$, $p < 0,01$) ir S&P 500 ($\psi = 0,31$, $p < 0,05$) išlieka svarbiausiais veiksniais. „Gold“ daro reikšmingą, bet šiek tiek silpnesnį poveikį ($\psi = 0,17$, $p < 0,10$), o VIX poveikis yra neigiamas ir reikšmingas ($\psi = -0,04$, $p < 0,05$). DAX 30 poveikis BNB yra statistiškai nereikšmingas ($p = 0,15$), nors koeficientas yra didesnis nei BTC ar ETH atveju (3.17 lentelė).

ETH grąža rodo panašų jautrumą VIX ($\psi_{VIX} = 0,13$) ir CMC Crypto 200 ($\psi_{CMC} = 0,14$), tačiau silpnesnę reakciją į auksą ($\psi_{Gold} = 0,04$, $p < 0,1$), o tai atskleidžia, kad jo kaip apsidraudimo nuo rizikos turto naudingumas mažėja, palyginti su BTC. Tačiau BNB rodo unikalią dinamiką: S&P 500 ($p < 0,01$) ir DAX 30 ($\psi_{DAX} = 0,09$, $p < 0,01$) dominuoja jo grąžoje, o VIX ($\psi_{VIX} = 0,07$) ir auksas ($\psi_{Gold} = 0,03$) atlieka antraeilį vaidmenį. Šis skirtumas pabrėžia stipresnę BNB ryšį su akcijų rinkos nuotaikomis, greičiausiai dėl jo biržos ekosistemos (3.17 lentelė).

3.18 lentelė. „XGBoost“ funkcijų svarbos reitingai
Table 3.18. XGBoost feature importance rankings

Rangas	BTC (svarba %)	ETH (svarba %)	BNB (svarba %)
1	CMC200 (69 %)	CMC200 (64 %)	CMC200 (50 %)
2	Gold (9 %)	Gold (10 %)	S&P500 (14 %)
3	S&P500 (8 %)	S&P500 (10 %)	Gold (12 %)
4	VIX (7 %)	VIX (8 %)	VIX (12 %)
5	DAX30 (6 %)	DAX30 (8 %)	DAX30 (12 %)

3.19 lentelė. Engle'o–Grangero kointegracijos testo rezultatai
Table 3.19. Engle–Granger cointegration test results

Kripto valiuta	(ECT)	<i>p</i> reikšmė	Kritinė reikšmė (1 %)
BTC	–38,06	<0,01	–3,43
ETH	–36,78	<0,01	–3,43
BNB	–33,21	<0,01	–3,43

„XGBoost“ pagrįstas savybių svarbos reitingas patvirtina ARIMAX rezultatus, ypač pabrėždamas CMC Crypto 200 kaip dominuojantį veiksnį visoms trimis kriptovaliutomis. Šis rodiklis užima pirmąją vietą tiek BTC (69 %), tiek ETH (64 %), tiek BNB (50 %) modeliuose ir atitinka ARIMAX rezultatus, kai CMC200 turėjo didžiausius koeficientus ir reikšmingumą naudojant visas tris kriptovaliutas. Tai patvirtina CMC200 vaidmenį kaip visos kriptovaliutų rinkos beta rodiklį. VIX ir S&P 500 svarba „XGBoost“ modelyje yra mažesnė nei ARIMAX modelyje, tačiau vis tiek pastebima. Pvz., VIX užima 4 vietą naudojant visas tris kriptovaliutas (7–12 %), o S&P 500 yra svarbiausias veiksnys BNB atveju (14 %, 2 vieta). Tai atitinka ARIMAX rezultatus, kur šis indeksas turėjo didelį teigiamą poveikį. DAX 30 svarba „XGBoost“ modelyje yra didesnė nei ARIMAX modelyje, ypač BNB atveju (12 %, 5 vieta), nors ARIMAX analizėje šis veiksnys nebuvo statistiškai reikšmingas. Tai gali rodyti, kad DAX 30 turi netiesioginį ar nenuoseklų poveikį, kurį geriau fiksuoja nelinejinis „XGBoost“ modelis. Auksas, kaip ir ARIMAX modelyje, išlieka mažiausiai svarbus veiksnys (8–10 %), tačiau vis dar įtraukiamas į svarbiausių penketuką. Tai atspindi jo asimetrinį aktualumą, kuris gali sustiprėti tik tam tikrais laikotarpiais, pvz., ištikus krizei (3.18 lentelė).

Kointegracijos testai, atlikti taikant Engle'o–Grangerio metodą, atmets nulinę hipotezę, kad tarp kriptovaliutų (BTC, ETH, BNB) ir pagrindinių makroekonominių bei finansinių veiksnių (VIX, Gold, CMC200, S&P500, DAX30) nėra ilgalaikių pusiausvyros santykių. Visų trijų kriptovaliutų atveju gauti paklaidos

koregavimo koeficientai (ECT) yra itin neigiami – BTC (–38,06), ETH (–36,78) ir BNB (–33,21) – ir reikšmingi 1 % lygiu (kritinė reikšmė –3,43) (3.19 lentelė), o tai rodo stiprią vidurkio grįžimo dinamiką. Šie rezultatai patvirtina, kad trumpalaikiai nukrypimai nuo ilgalaikės pusiausvyros tarp kriptovaliutų ir išorinių veiksnių laikui bėgant išsilygina, o tai yra esminė modeliavimo stabilumo ir patikimumo prielaida.

Ši kointegracijos analizė glaudžiai dera su ARIMAX modelių rezultatais, kai buvo identifikuoti statistiškai reikšmingi egzogeninių veiksnių koeficientai. Pvz., CMC Crypto 200 indeksas visose trijose kriptovaliutose turėjo stiprų teigiamą poveikį, o tai atspindi jo sisteminių ryšių su kriptovaliutų rinka. Toks ryšys, kaip rodo Engle'o–Grangerio testas, nėra atsitiktinis ar laikinas, bet grindžiamas ilgalaikė pusiausvyra. Taip pat VIX ir S&P 500, kurie ARIMAX modeliuose pasirodė kaip reikšmingi veiksniai, kointegracijos testuose patvirtina savo svarbą kaip ilgalaikio ryšio komponentai.

„XGBoost“ modelių rezultatai, nors ir pagrįsti nelinejine struktūra, taip pat atspindi šią dinamiką. CMC200, kuris dominavo visų trijų kriptovaliutų svarbos reitinguose, išlieka svarbiausiu veiksniu ir kointegracijos analizėje. Tai rodo, kad net ir mašininio mokymosi modeliai, kurie nėra tiesiogiai paremti stacionarumo ar kointegracijos prielaidomis, atspindi tą pačią fundamentalią struktūrą tarp kintamųjų. Tokiu būdu Engle'o–Grangerio testas suteikia teorinį pagrindą tiek klasikiniams ekonometriniais, tiek pažangiems prognozavimo modeliams, užtikrindamas jų interpretacinių nuoseklumą ir patikimumą.

Grangerio priežastingumo testų rezultatai, atlikti abiem kryptimis (3.20 ir 3.21 lentelės), leidžia pateikti išsamią interpretaciją apie laiko eilučių ryšius tarp kriptovaliutų (BTC, ETH, BNB) ir pagrindinių makroekonominių veiksnių (VIX, Gold, CMC Crypto 200, S&P 500, DAX 30), papildant ankstesnius ARIMAX, „XGBoost“ ir Engle'o–Grangerio testų rezultatus.

3.20 lentelė. Grangerio priežastingumo statistika

Table 3.20. Granger causality test statistics

Faktorius	BTC (p reikšmė)	ETH (p reikšmė)	BNB (p reikšmė)	Vėlavimas
VIX	0,4263	0,3660	0,9364	1–2
Gold	0,9777	0,6151	0,2595	1
CMC Crypto 200	0,0237	0,1357	0,2789	2 (BTC)
S&P 500	0,2220	0,6568	0,4782	1
DAX 30	0,0012	0,0005	0,0089	2

Pirmojoje analizės dalyje, kai buvo tikrinama, ar makroekonominiai veiksniai Grangerio prasme lemia kriptovaliutų grąžą, didelis poveikis nustatytas tik DAX 30 atveju visoms trimis kriptovaliutomis (BTC: $p = 0,0012$, ETH: $p = 0,0005$, BNB: $p = 0,0089$), esant 2 dienų vėlavimui. Tai rodo, kad Vokietijos akcijų rinkos pokyčiai turi prognozinę galią kriptovaliutų grąžoms. CMC Crypto 200 turėjo reikšmingą poveikį tik BTC ($p = 0,0237$), o kiti veiksniai – VIX, Gold ir S&P 500 – neturėjo statistiškai reikšmingo priežastinio poveikio nė vienai kriptovaliutai.

Antrojoje analizės dalyje, kai buvo tikrinama atvirkštinė kryptis – ar kriptovaliutos Grangerio prasme lemia makroekonominius veiksnius, rezultatai parodė, kad CMC Crypto 200 yra reikšmingai veikiamas visų trijų kriptovaliutų ($p < 0,001$). Tai logiška, nes šis indeksas atspindi bendrą kriptovaliutų rinkos dinamiką. Taip pat nustatyta, kad „Gold“ yra labai veikiamas BTC ($p = 0,0276$), ETH ($p = 0,0146$) ir BNB ($p = 0,0071$), o DAX 30 – ETH ($p = 0,0003$), BTC ($p = 0,0031$) ir BNB ($p = 0,0145$). VIX ir S&P 500 nebuvo reikšmingai veikiami nė vienos kriptovaliutos.

Rezultatai leidžia daryti išvadą, kad priežastingumas tarp kriptovaliutų ir makroekonominų veiksmų nėra vienakryptis. Nors kai kurie veiksniai, kaip DAX 30, turi prognozinę galią kriptovaliutų grąžoms, taip pat egzistuoja atvirkštiniai ryšiai, ypač tarp kriptovaliutų ir CMC200, „Gold“ bei DAX 30. Tai rodo bidirekcinį ryšį, kuris gali būti tiek struktūrinis (kaip patvirtinta Engle'o–Grangerio testais), tiek dinaminis (kaip rodo Grangerio testai).

Ši analizė papildoma ARIMAX modelių rezultatais, kuriuose CMC200, „Gold“ ir S&P 500 buvo identifikuoti kaip reikšmingi veiksniai, bei „XGBoost“ svarbos reitingus, kuriuose CMC200 dominavo visose trijose kriptovaliutose. Tačiau tik Grangerio testai leidžia įvertinti laikiną priežastingumą, kuris, kaip matyti, yra selektyvus ir priklauso nuo konkretaus veiksnio ir kriptovaliutos.

3.21 lentelė. Atvirkštinė Grangerio priežastingumo statistika

Table 3.21. Reverse Granger causality test statistics

Faktorius	BTC (p reikšmė)	ETH (p reikšmė)	BNB (p reikšmė)	Vėlavimas
VIX	0,6317	0,2814	0,1217	2
„Gold“	0,0276	0,0146	0,0071	1
CMC Crypto 200	0,0000	0,0000	0,0000	2
S&P 500	0,7979	0,6803	0,3157	1
DAX 30	0,0031	0,0003	0,0145	1

Šio poskyrio rezultatai tiesiogiai lemia galutinio integruoto modelio sandarą, nes rodo, kuriuos išorinius veiksnius būtina kontroliuoti, kad pinigų politikos poveikis kriptovaliutoms nebūtų supainiotas su pasauliniais finansiniais sukrėtimais. Dinaminiai svoriai ($\psi_{k,t}$) čia interpretuojami kaip laiko atžvilgiu kintantis koeficientas, rodantis, kada ir kokių mastu konkretus išorinis rinkos veiksnys modifikuoja pinigų politikos perdavimo kanalo stiprumą skirtingomis rinkos sąlygomis. Pvz., 2020–2022 m. padidėję VIX svoriai ($\psi_{VIX} > 0,20$) sutampa su silpnesniu Centrinio banko politikos poveikiu BTC. Tai reiškia, kad šiuo metu rinkos dalyvių sprendimus labiau lėmė rizikos vengimas ir bendras finansinis neapibrėžtumas, o ne monetarinės politikos signalai. Priešingai, ramesniu laikotarpiu (2018–2020 m.) padidėję S&P 500 ir DAX 30 svoriai (pvz., $\psi_{DAX} \approx 0,08$) rodo stipresnę kriptovaliutų koreliaciją su akcijų rinkomis, todėl politikos jautrumas šiuo laikotarpiu išauga, nes kriptovaliutų kainos labiau seka tradicinių finansų tendencijas.

Kad grafikus būtų galima skaityti vienareikšmiškai, svorių kreivės interpretuojamos taip: kuo aukščiau kyla ψ vertė (ypač peržengus 0,15–0,20 ribą), tuo didesnė tikimybė, kad nagrinėjamu momentu kriptovaliutų kainų ir grąžų dinamiką lemia būtent tas išorinis veiksnys, o ne pinigų politika. Papildomai kointegracijos (Engle'–Grangerio) ECT parodo ilgalaikį ryšį ir grįžimą į pusiausvyrą po trumpalaikių nukrypimų, o Grangerio vėlavimai padeda nustatyti, per kiek laikotarpių šie išoriniai veiksniai ima dominuoti kriptovaliutų grąžų pokyčiuose. Taigi izoliuojant šiuos išorinius veiksnius, hibridinis modelis leidžia aiškiau priskirti kainų pokyčius centrinių bankų sprendimams, o ne bendrai rinkos būklei, ir tai yra būtina sąlyga patikimam makroekonominio stabilumo vertinimui skaitmenizuotoje finansų aplinkoje.

3.3 poskyrio rezultatai rodo, kad kriptovaliutų grąžas pirmiausia aiškina bendros kriptovaliutų rinkos indeksas, o papildomą reikšmę turi akcijų rinkos indikatoriai, aukso kaina ir rizikos nuotaikų rodiklis, todėl šiuos veiksnius būtina kontroliuoti, kai siekiama atskirti pinigų politikos poveikį. Ši išvada dera su Daruwala (2025) rezultatais, kurie taip pat sieja kriptovaliutų paklausą su akcijų rinkos būkle ir nurodo auksą kaip pakaitalą, taip pat su Tzeng et al. (2025) teiginiu, kad VIX gali turėti prognozinę galią kriptovaliutų grąžoms. Kartu mūsų ilgalaikių ryšių ir laikinės priežasties testų rezultatai papildo literatūrą apie išorinių veiksnių vaidmenį. Jie iš dalies sutampa su Pourpourides (2025) ir Bianchi (2020) pateiktais vertinimais apie kriptovaliutų ir aukso sąsajas, tačiau skiriasi nuo darbų, kurie akcentuoja kitų makroekonominių kintamųjų svarbą arba nestabilų jų reikšmingumą skirtingais laikotarpiais. Mūsų rezultatai taip pat yra suderinami su tyrimais, kuriuose pabrėžiamas modelių jautrumas pasirinktai metodikai ir dinamikai, įskaitant kitų autorių tyrimus (Aydogan et al., 2024; Chowdhury et al., 2024; Gurrub et al., 2019; Nakagawa & Sakemoto, 2022; Nguyen et al., 2019; Touhami et al., 2025).

3.4. Centrinio banko reagavimo modulio rezultatai

Šioje dalyje pateikiami rezultatai iš Centrinio banko reagavimo modulio. Dalis šių rezultatų yra recenzuoti ir publikuoti (Pečiulis & Vasiliauskaitė, 2023). Centrinio banko reagavimo modulis kiekybiškai atskleidžia sąveikos pobūdį, kaip pinigų politikos institucijos dinamiškai koreguoja politikos priemones, reaguodamos į kriptovaliutų rinkos svyravimus ir reguliavimo pokyčius. Naudojant laiko kintamojo parametro (TVP) regresijos modelį su Kalmano filtravimu, analizė atskleidžia reikšmingus centrinio banko jautrumo kriptovaliutų rinkos sąlygoms pokyčius trijose sistemose (2018–2020 m. stabilumas, 2020–2022 m. sukrėtimai, reguliavimo prisitaikymas po 2022 m.). BTC, ETH ir BNB rezultatai rodo skirtingus politikos reakcijos modelius, kurie yra labai svarbūs integruoto modelio adaptyvųjų ribų kalibravimui.

Kalmano filtruoti koeficientai ρ_{1t} (centrinio banko jautrumas kriptovaliutų kintamumui) ir ρ_{2t} (reakcija į reguliavimo pokyčius) atskleidžia reikšmingą laiko dinamiką (3.22 lentelė), susijusią su makroekonominė aplinka, reguliavimo raida ir kriptovaliutų rinkos struktūriniais pokyčiais. Šie koeficientai buvo įvertinti taikant laikui einant kintančių parametrų regresiją (TVP), integruotą į būsenos erdvės modelį atliekant Kalmano filtravimą, kuris leido stebėti dinamiškus politikos jautrumo pokyčius.

Modelyje endogeniškumo problema kyla dėl galimo abipusio ryšio tarp kriptovaliutų kintamumo ir Centrinio banko politikos sprendimų, todėl kriptovaliutų kintamumas pirmiausia prognozuojamas instrumentiniais kintamaisiais, o į politikos reakcijos lygtį įtraukiamos šios prognozuotos reikšmės. Toks sprendinys taikomas siekiant sumažinti atvirkštinės priežasties riziką ir užtikrinti, kad politikos reakcijos koeficientai būtų vertinami remiantis ta kintamumo dalimi, kurią paaiškina iš anksto nustatyti ir išoriniai veiksniai, o ne tuo pačiu metu formuojami politikos sprendimai.

3.22 lentelė. Laiko kintamieji politikos jautrumo koeficientai (ρ_{1t} , ρ_{2t})

Table 3.22. Time-varying policy sensitivity coefficients (ρ_{1t} , ρ_{2t})

Kriptovaliuta	Režimas	ρ_{1t} (kintamumo jautrumas)	ρ_{2t} (reguliavimo jautrumas)
BTC	2020–2022 (krizė)	–0,001	–0,01
BTC	Po 2022	0,0988	–0,012
ETH	2020–2022 (krizė)	–0,006	–0,01
ETH	Po 2022	0,0289	–0,012
BNB	2020–2022 (krizė)	–0,0093	–0,0099
BNB	Po 2022	0,1644	–0,0118

Instrumentų rinkinys sudarytas taip, kad atitiktų dvi esmines sąlygas: instrumentai turi būti susiję su kriptovaliutų kintamumu pirmojo etapo regresijoje, o jų tiesioginis ryšys su politikos reakcijos lygties paklaida turi būti atmestas kaip prielaida, kai kontroliuojami kiti į modelį įtraukti veiksniai. Vėluojančios BTC, ETH ir BNB prekybos apimtys pasirinktos kaip priėmimo ir rinkos aktyvumo pakaitiniai rodikliai, nes jos atspindi rinkos likvidumo ir prekybinio aktyvumo būklę, kuri empiriškai siejama su realizuoto kintamumo pokyčiais, o vėlavimas leidžia šiuos rodiklius laikyti iš anksto nustatytais einamojo laikotarpio politikos sprendimų atžvilgiu. Ši instrumento dalis taip pat turi empirinį pagrindą, nes pirmojo etapo regresijose pateikiamas statistiškai reikšmingas ryšys tarp vėluojančių apimčių ir realizuoto kintamumo, o pirmojo etapo F statistikos rodo, kad instrumentas nėra silpnas.

Aukso, VIX, CMC Crypto 200, S&P 500 ir DAX 30 logaritminės gražos įtrauktos todėl, kad jos apibūdina platesnę finansinę aplinką ir rinkos būklę, kuri daro įtaką kriptovaliutų gražoms ir jų kintamumui, o disertacijoje šie rodikliai nuosekliai traktuojami kaip egzogeniniai kontroliniai veiksniai, reikalingi pinigų politikos poveikiui atskirti nuo bendrų rinkos sukrėtimų. Kiekvienos kriptovaliutos logaritminės gražos ir realizuoto kintamumo rodikliai įtraukiami tam, kad pirmojo etapo lygtis gerai atkartotų pačios gražos ir kintamumo dinamiką, o prognozuotas kintamumas būtų suderinamas su vėliau vertinama politikos reakcijos lygtimi. Pirmojo etapo instrumentinių kintamųjų regresijos rezultatai pateikiami kaip atskiras empirinės analizės rezultatas, o prognozuoti kintamumo rodikliai vėliau įtraukiami į pagrindinę politikos reakcijos lygtį, kur laikui einant kintantys koeficientai vertinami taikant Kalmano filtrą (instrumentinių kintamųjų regresijos rezultatai pavaizduoti 3.22 pav.).

Antrajame etape prognozuoti kintamumo rodikliai, gauti iš pirmosios stadijos regresijos su instrumentiniais kintamaisiais, buvo įtraukti į pagrindinę politikos reakcijos lygtį. Laiko atžvilgiu kintantys koeficientai ρ_{1t} ir ρ_{2t} buvo įvertinti taikant Kalmano filtravimą būsenos erdvės modelyje. Tokia metodika leido spręsti galimą endogeniškumą tarp kriptovaliutų kintamumo ir Centrinio banko politikos sprendimų, užtikrinant priežastinį identifikavimą ir dinamišką politikos jautrumo stebėseną.

Empiriniai rezultatai rodo, kad centrinių bankų jautrumas kriptovaliutų kintamumui, išreikštas koeficientu ρ_{1t} , laikotarpiu po 2022 m. labai padidėjo, ypač BNB atveju. BTC jautrumas kintamumui pakilo nuo $-0,001$ krizės laikotarpiu iki $0,0988$ po 2022 m. Tai rodo, kad centriniai bankai pradėjo labiau reaguoti į BTC rinkos nepastovumą, kai šis turtas įgijo didesnę sisteminių svorį. ETH atveju ρ_{1t} padidėjo nuo $-0,006$ iki $0,0289$. Tai rodo nuosaikesnį, bet vis dėlto reikšmingą jautrumo augimą, galimai susijusį su eterio tinklo technologiniais pokyčiais ir platesniu jo naudojimu decentralizuotuose finansuose. BNB kito ryškiausiai – nuo $-0,0093$ iki $0,1644$. Tai yra aukščiausia reikšmė tarp visų analizuotų kriptovaliutų.

Šis rezultatas leidžia daryti prielaidą, kad BNB, nepaisant savo pradinio biržos pobūdžio, tapo reikšmingu makroekonominiu veiksmu, į kurį centriniai bankai pradėjo reaguoti kaip į potencialų sisteminės rizikos šaltinį (3.23 lentelė).

3.23 lentelė. Instrumentinių kintamųjų regresijos rezultatai

Table 3.23. Instrumental variable regression results

Kripto valiuta	Vėlavimo pritaikymo matmuo (γ_1)	F statistika	p reikšmė
BTC	0,001	31,24	<0,01
ETH	0,003	54,12	<0,01
BNB	0,047	133,31	<0,01

Reguliavimo koeficientai ρ_2 išliko neigiami visose trijose kriptovaliutose, tačiau jų reikšmės po 2022 m. rodo nuoseklų, nors ir nedidelį, reguliavimo poveikį. BTC ir ETH atveju ρ_{2t} siekė $-0,012$, o BNB – $-0,0118$. Tai rodo, kad griežtesnė reguliavimo aplinka veikė kaip stabilizuojamasis veiksnys, mažinantis politikos jautrumą rinkos svyravimams. Neigiamas ženklas reiškia, kad, didėjant reguliavimo intensyvumui, centriniai bankai mažiau reaguoja į kriptovaliutų kintamumo šokus, nes dalis rizikos absorbuojama reguliaciniais kanalais. Tai atitinka teorines prognozes, pagal kurias institucinė priežiūra mažina neapibrėžtumą ir leidžia pinigų politikai veikti labiau prognozuojamai. Šie rezultatai patvirtina, kad centriniai bankai diferencijuotai reaguoja į skirtingų kriptovaliutų kintamumą, o reguliavimo griežtėjimas veikia kaip stabilizuojamasis veiksnys. Instrumentinių kintamųjų taikymas ir Kalmano filtravimas užtikrino, kad modelio rezultatai būtų ne tik statistiškai patikimi, bet ir ekonomiškai interpretuojami, leidžiantys pagrįstai vertinti politikos reakcijos mechanizmus.

Remiantis pirmojo etapo instrumentinių kintamųjų regresijos rezultatais (žr. 2.22 lygtį), galima pagrįsti mainų apimčių ($Adopt_{t-1}$) tinkamumą kaip kriptovaliutų realizuoto kintamumo ($Cryptokin_t$) instrumentus. Šie rezultatai pateikti 3.22 lentelėje. BTC atveju 1 % padidėjimas vėluojančiose biržos apyvartose padidino realizuotą kintamumą 0,001 % ($\gamma_1 = 0,001$), o F statistika = 31,24, $p < 0,01$. Tai rodo stiprą ir statistiškai reikšmingą ryšį tarp instrumento ir priklausomojo kintamojo. Nors efektas yra nedidelis, instrumentas yra gana stiprus, kad būtų laikomas tinkamu. ETH atveju $\gamma_1 = 0,003$, F statistika = 54,12, $p < 0,01$. Tai rodo dar stipresnį ryšį tarp vėluojančių mainų apimčių ir ETH kintamumo. Šis rezultatas patvirtina, kad ETH rinkos aktyvumas yra jautresnis biržos apimčių pokyčiams nei BTC. BNB atveju $\gamma_1 = 0,047$, F statistika = 133,31, $p < 0,01$. Šis rezultatas yra pats stipriausias ryšys tarp visų trijų kriptovaliutų. Šis

rezultatas rodo, kad BNB kintamumas yra ypač jautrus mainų apimčių pokyčiams, o tai gali būti susiję su mažesniu rinkos dydžiu ar didesniu spekuliatyvumu.

Impulso atsako funkcijų (IRF) analizė, pagrįsta laikui einant kintančiais Kalmano filtru įvertintais koeficientais, leidžia kiekybiškai įvertinti, kaip centriniai bankai reagavo į kriptovaliutų kintamumo ir reguliavimo šokus skirtingais laikotarpiais. 3.24 lentelėje pateikti rezultatai atskleidžia aiškiają dinaminę politikos jautrumo raidą tarp krizės laikotarpio ir stabilios fazės.

3.24 lentelė. Impulsinis atsakas į kintamumo šoką (15 %) ir reguliavimo šoką (10 punktų padidėjimas)

Table 3.24. IRF to volatility shock (15%) and regulation shock (10-point increase)

Valiuta	Režimas	IRF_Crypto (%)	IRF_Reg (%)
BTC	Krizinis	-0,015	-10,0
BTC	Stabilus	1,482	-12,0
ETH	Krizinis	-0,090	-10,0
ETH	Stabilus	0,433	-12,0
BNB	Krizinis	-0,139	-9,9
BNB	Stabilus	2,466	-11,8

BTC atveju 15 % kintamumo šokas per krizę sukėlė nedidelį neigiamą politikos atsaką ($IRF_Crypto = -0,015\%$), o tai rodo, kad centriniai bankai tuo metu vengė reaguoti į BTC rinkos svyravimus arba netgi juos slopino. Tačiau po 2022 m. šis atsakas tapo reikšmingai teigiamas – IRF_Crypto padidėjo iki 1,482 %. Tai rodo, kad BTC buvo pradėtas vertinti kaip sisteminis rizikos veiksnys, į kurį pinigų politika reaguoja aktyviai. ETH atveju stebima panaši dinamika: krizės metu IRF_Crypto siekė $-0,090\%$, o pokriziniu laikotarpiu padidėjo iki 0,433 %, atspindint nuosaikesnį, bet vis dėlto reikšmingą jautrumo augimą. BNB pasižymėjo ryškiausiu pokyčiu – nuo $-0,139\%$ krizės metu iki 2,466 % po 2022 m. Tai rodo, kad šios kriptovaliutos sisteminis svoris labai išaugo, nepaisant jos pradinio biržos pobūdžio.

Reguliavimo šokų poveikis, įvertintas per IRF_Reg , išliko neigiamas visais atvejais ir abiem laikotarpiais. BTC atveju 10 punktų reguliavimo indekso padidėjimas sumažino politikos jautrumą kintamumui 10 % krizės metu ir 12 % po 2022 m. ETH atveju šis poveikis taip pat siekė -10% krizės metu ir -12% pokriziniu laikotarpiu. BNB atveju reguliavimo poveikis buvo kiek silpnesnis – atitinkamai $-9,9\%$ ir $-11,8\%$. Šie rezultatai patvirtina, kad reguliavimo griežtėjimas veikia kaip stabilizuojamasis veiksnys, mažinantis politikos reakcijos intensyvumą į kriptovaliutų rinkos šokus, ypač tais laikotarpiais, kai rinkos tampa

labiau integruotos į finansinę sistemą. Ši analizė pagrindžia, kad laikui einant kintantys koeficientai yra būtini norint modeliuoti centrinių bankų elgseną, o IRF dinamika leidžia įvertinti, kaip politikos formuotojų reakcijos evoliucionuoja priklausomai nuo rinkos sąlygų ir reguliacinės aplinkos.

Ribinio efekto analizė, atlikta remiantis kvantilių pagrindu klasifikuotais kintamumo režimais, atskleidžia didelius skirtumus tarp kriptovaliutų elgsenos esant aukštam ir žemam rinkos kintamumui. Aukšto kintamumo laikotarpiais ($\sigma > 80\%$) BTC vidutinė logaritminė grąža siekė $-0,14\%$, o tai rodo neigiamą grąžos dinamiką, palyginti su $0,17\%$ teigiama grąža stabilaus kintamumo sąlygomis ($\sigma < 40\%$). Tai reiškia, kad griežtesnio reguliavimo poveikis BTC grąžai sumažėjo 181% , kai rinkoje dominavo padidėjęs nepastovumas.

Panaši tendencija pastebima ir ETH atveju: esant aukšto kintamumo režimams vidutinė grąža buvo $-0,22\%$, o stabiliais laikotarpiais $-0,22\%$. Tai rodo net 197% sumažėjimą, kuris gali būti siejamas su padidėjusiu jautrumu reguliavimo pokyčiams ir rinkos neapibrėžtumu. Šie rezultatai patvirtina, kad tiek BTC, tiek ETH yra jautrūs reguliavimo signalams, ypač esant padidėjusiam rinkos stresui.

BNB elgsena išsiskiria iš kitų dviejų kriptovaliutų. Aukšto kintamumo sąlygomis BNB vidutinė grąža siekė $0,80\%$, o tai yra gerokai daugiau nei $0,19\%$ stabilaus kintamumo laikotarpiais. Tai reiškia, kad griežtesnio reguliavimo poveikis BNB atveju padidino grąžą net 318% . Šis rezultatas gali būti interpretuojamas kaip BNB atsparumo rinkos turbulencijai požymis, galimai susijęs su jo specifine ekosistema ir mažesniu koreliacijos lygiu su platesne kriptovaliutų rinka.

Apibendrinant centrinio banko reagavimo modulio analizę, teigtina, kad pinigų politikos institucijų jautrumas kriptovaliutų rinkos sąlygoms pasižymi aiškia dinamika, priklausančia nuo laikotarpio, turto specifikos ir reguliacinės aplinkos. Laikui einant kintantys koeficientai ρ_{1t} ir ρ_{2t} , įvertinti taikant Kalmano filtravimą, atskleidė, kad po 2022 m. centriniai bankai pradėjo reikšmingiau reaguoti į kriptovaliutų kintamumą, ypač BNB atveju, kurio jautrumas išaugo iki $0,1644$. BTC ir ETH jautrumas augo nuosaikiau, bet vis tiek statistiškai reikšmingai. Reguliavimo koeficientai ρ_{2t} išliko neigiami visais atvejais, patvirtindami, kad griežtesnė reguliacinė aplinka veikia kaip amortizacinis mechanizmas, mažinantis politikos reakcijos intensyvumą į rinkos šokus.

Impulso atsako funkcijų analizė papildomai parodė, kad po 2022 m. kriptovaliutų sisteminis svoris padidėjo, o tai paskatino aktyvesnę Centrinio banko atsaką į kintamumo šokus. Pvz., BTC IRF_Crypto padidėjo nuo $-0,015\%$ krizės metu iki $1,482\%$ stabiliu laikotarpiu, o BNB – nuo $-0,139\%$ iki $2,466\%$. Reguliavimo šokai visais atvejais turėjo neigiamą poveikį, mažinantį politikos jautrumą, kas atitinka teorines prognozes apie institucinės priežiūros stabilizuojamąjį vaidmenį.

Galiausiai ribinio efekto analizė, pateikta 3.25 lentelėje, patvirtina šias išvadas: BTC ir ETH gražos aukšto kintamumo sąlygomis sumažėjo atitinkamai 181 % ir 197 %, o BNB – priešingai – parodė 318 % gražos padidėjimą.

3.25 lentelė. Kriptovaliutų kintamumo ribinis poveikis politikos koregavimui
Table 3.25. Marginal effects of crypto volatility on policy adjustments

Kriptovaliuta	Aukštas kintamumas ($\sigma > 80$ %)	Stabilus kintamumas ($\sigma < 40$ %)	Griežtesnio reguliavimo efektas (%)
BTC	-0,14 %	0,17 %	-181 %
ETH	-0,22 %	0,2 2%	-197 %
BNB	0,80 %	0,19 %	318 %

Šie rezultatai leidžia daryti išvadą, kad centriniai bankai ne tik diferencijuotai reaguoja į skirtingas kriptovaliutas, bet ir kad reguliavimo griežtėjimas veikia kaip svarbus stabilizuojamasis veiksnys, leidžiantis pinigų politikai veikti labiau prognozuojamai net ir didelio rinkos nepastovumo sąlygomis.

3.4 poskyrio rezultatai rodo, kad Centrinio banko reakcija į kriptovaliutų rinkos sąlygas kinta laikui einant, o reguliavimo poveikis išlieka nuosekliai stabilizuojantis, todėl TVP regresijos ir Kalmano filtro derinys yra tinkamas šiai dinamikai fiksuoti. Toks laiko požiūriu kintančių ir etapui būdingų reakcijų vaizdas dera su Lü et al. (2025) išvada apie nevienodą ir nuo laikotarpio priklausantį finansų rinkų atsaką į CBDC neapibrėžtumo šokus, taip pat su Meng et al. (2025) argumentu, kad centrinio banko komunikacija veikia rinkos neapibrėžtumą ir kintamumą. Skirtingas kriptovaliutų jautrumas politikos impulsams iš dalies sutampa su Harir et al. (2025) išvada, kad monetarinės politikos pranešimų poveikis kriptovaliutų rinkai priklauso nuo turto klasės, ir su Helmi et al. (2023), kurie parodo, kad reakcijos į CBDC naujienas laikui bėgant kinta ir yra ryškesnės sukrėtimų laikotarpiams.

3.5. Integruoto modelio patvirtinimas

Šiame poskyryje atliekamas integruoto modelio empirinis patvirtinimas, orientuotas į specifikacijos nuoseklumo ir identifikavimo patikimumo įvertinimą, taikant instrumentinių kintamųjų ir sisteminio vertinimo procedūras. Patvirtinti taikomi endogeniškumo testai, instrumentų stiprumo įvertinimas ir integruoto vertinimo metodai, siekiant užtikrinti, kad monetarinės politikos poveikio įverčiai būtų nešališki ir ekonomiškai interpretuojami. Papildomai įtraukiama nuo režimų

priklausoma analizė, leidžianti patikrinti, kaip ryšiai kinta esant skirtingiems kriptovaliutų kintamumo režimams. Empiriniam patvirtinimui pasirinkti keli metodai. Pirma, taikytas ribotos informacijos maksimalios tikimybės (LIML) metodas, siekiant įvertinti politikos perdavimo kanalus ir išspręsti galimą endogeniškumą tarp palūkanų normų ir kriptovaliutų grąžų. Antra, taikyta GMM sistema, apimanti visas tris lygtis vienu metu, leidžianti įvertinti struktūrinius ryšius ir užtikrinti nuoseklumą tarp modelio komponentų. Trečia, atlikta režimui priklausoma analizė, įtraukiant sąveikos terminus ir MS-VAR modelius, siekiant įvertinti, kaip santykiniai kinta priklausomai nuo kriptovaliutų kintamumo režimų.

Režimai identifikuoti pagal MS-GARCH gautus duomenis, suskirstant stebėjimus į žemo, vidutinio ir aukšto nepastovumo grupes. Šis požiūris leidžia modeliuoti netiesinį elgesį ir užfiksuoti struktūrinius lūžius, kurie dažni kriptovaliutų rinkose.

Prieš taikant instrumentinių kintamųjų metodus, būtina patikrinti, ar FFR yra endogeninė kriptovaliutų grąžų modeliuose. Tam buvo atlikti du nepriklausomi testai: Hausmano testas ir likučių koreliacijos analizė (3.26 lentelė4).

3.26 lentelė. Endogeniškumo testų rezultatai: Hausmano ir likučių koreliacijos analizė (BTC, ETH, BNB)

Table 3.26. Endogeneity test results: Hausman and residual correlation analysis (BTC, ETH, and BNB)

Kriptovaliuta	OLS koef.	IV koef.	Hausmano p reikšmė	Likučių koreliacija	p reikšmė
BTC	0,00018	-0,00021	0,539	~0,000	1,000
ETH	-0,00005	-0,00045	0,627	~0,000	1,000
BNB	-0,00054	-0,00089	0,705	~0,000	1,000

Hausmano testas lygina FFR koeficientus, gautus taikant paprastą OLS ir IV (instrumentinių kintamųjų) metodus. Visoms trimis kriptovaliutomis – BTC, ETH ir BNB – gautos p reikšmės yra didesnės nei 0,1: BTC ($p = 0,539$), ETH ($p = 0,627$), BNB ($p = 0,705$). Tai reiškia, kad nėra pagrindo atmesti nulinės hipotezės, jog OLS koeficientas yra neklaidingas, t. y. FFR nėra endogeninis.

Likučių koreliacijos testas papildomai tikrina, ar OLS modelio likučiai koreliuoja su FFR. Visais atvejais koreliacijos reikšmės artimos nuliui, o p reikšmės lygios 1,000. Tai dar kartą patvirtina, kad FFR nėra susijęs su modelio paklaida.

3.27 lentelėje pateiktas instrumentinių kintamųjų stiprumo įvertinimas, taikytas modeliuojant Federalinių fondų palūkanų normą (FFR) naudojant CPI ir BVP kaip instrumentus. Pirmosios pakopos F statistikos reikšmės, viršijančios 2800,

rodo itin stiprų instrumentų poveikį visoms analizuotoms kriptovaliutomis – bitkoino, eterio ir „Binance Coin“, o R^2 reikšmė 0,831 patvirtina aukštą aiškinamąją galią. Šie rezultatai atitinka disertacijoje taikytą metodologinį požiūrį, kuriame siekiama užtikrinti endogeniškumo kontrolę ir patikimą priežastinių ryšių identifikavimą tarp monetarinės politikos ir kriptovaliutų kainų dinamikos. Instrumentų stiprumo patvirtinimas yra būtinas trijų pakopų mažiausiųjų kvadratų (3SLS) vertinimo procedūrai, kuri taikoma galutiniame integruotame modelyje, siekiant užtikrinti, kad politikos poveikio įverčiai būtų nešališki ir ekonomiškai interpretuojami.

3.27 lentelė. Instrumentų stiprumo įvertinimas: CPI ir BVP kaip IV FFR modeliavimui
Table 3.27. Assessment of instrument strength: CPI and GDP as inputs for IV FFR modelling

Kriptovaliuta	Pirmosios pakopos F statistika	Pirmosios pakopos R^2
BTC	2825,43	0,831
ETH	2825,43	0,831
BNB	2814,54	0,831

LIML regresijos rezultatai rodo (žr. 3.28 lentelę), kad kriptovaliutų grąžos yra statistiškai reikšmingai veikiamos finansų rinkos kintamųjų, tačiau pinigų politikos poveikis yra ribotas. S&P500 log grąža turi stiprų teigiamą poveikį visoms trimis kriptovaliutomis: BTC (0,9492, $p < 0,001$), ETH (1,1917, $p < 0,001$) ir BNB (1,1142, $p < 0,001$). Tai rodo, kad kriptovaliutų kainodara glaudžiai susijusi su akcijų rinkos dinamika. VIX log grąža, kaip rizikos nuotaukų indikatorius, turi neigiamą ir statistiškai reikšmingą poveikį: BTC (–0,0678, $p < 0,001$), ETH (–0,0886, $p < 0,001$), BNB (–0,0551, $p = 0,024$). Tai patvirtina, kad, padidėjus rinkos nepastovumui, kriptovaliutų grąžos mažėja. Modeliuojamo kintamumo koeficientai visais atvejais yra nereikšmingi ($p > 0,94$), o tai rodo, kad prognozuotas kintamumas neturi tiesioginio poveikio trumpalaikėms grąžoms šiame modelyje. FFR koeficientai yra neigiami ir statistiškai reikšmingi: BTC (–0,0002, $p = 0,000$), ETH (–0,0004, $p = 0,000$), BNB (–0,0009, $p = 0,00$). Tai leidžia daryti prielaidą, kad trumpuoju laikotarpiu pinigų politikos pokyčiai daro tiesioginį poveikį kriptovaliutų kainoms.

Modelio paaiškinamoji galia yra vidutinė BTC ir ETH atvejais ($R^2 \approx 0,15$), tačiau žemesnė BNB atveju ($R^2 = 0,0861$). Visi F statistikos rodikliai yra labai reikšmingi (BTC: 170,70, ETH: 185,77, BNB: 115,06; $p < 0,001$), kas patvirtina bendrą modelių tinkamumą. Šie rezultatai rodo, kad kriptovaliutų kainodara yra

jautri rinkos rizikai ir akcijų rinkos pokyčiams, tačiau mažiau reaguoja į tradicinius monetarinius signalus. Tai motyvuoja tolesnę analizę platesnėje GMM sistemoje.

3.28 lentelė. LIML regresijos rezultatai kriptovaliutų kainodaros modeliams (BTC, ETH, BNB)

Table 3.28. LIML regression results for crypto pricing models (BTC, ETH, and BNB)

Kintamasis	BTC	ETH	BNB
Konstanta	0,0013 (0,5887)	0,0015 (0,6820)	0,0038 (0,2499)
VIX log grąža	-0,0678*** (0,0002)	-0,0886*** (0,0002)	-0,0551** (0,0242)
S&P500 log grąža	0,9492*** (0,0000)	1,1917*** (0,0000)	1,1142*** (0,0000)
Modeliuojamas kintamumas	-0,0011 (0,9836)	-0,0036 (0,9447)	-0,0016 (0,9631)
FFR	-0,0002*** (0,000)	-0,0004*** (0,000)	-0,0009*** (0,000)
R^2 (Adj. R^2)	0,1497 (0,1467)	0,1496 (0,1466)	0,0861 (0,0829)
F statistika	170,70***	185,77***	115,06***
Stebėjimai	1,148	1,148	1,148

GMM sistemos rezultatai (žr. 3.29 lentelę) atskleidžia reikšmingas ir nuoseklias sąsajas tarp kriptovaliutų grąžų, makroekonominių kintamųjų ir monetarinės politikos instrumentų. Kriptovaliutų kainodaros lygtims būdingas stiprus ryšys su akcijų rinkos dinamika ir rinkos rizikos indikatoriais. BTC grąžos modelyje S&P500 log grąža turi stiprų teigiamą poveikį (1,0347, $p < 0,001$), o VIX log grąža – neigiamą (-0,0675, $p = 0,0002$). ETH modelyje šie ryšiai dar ryškesni: S&P500 koeficientas siekia 1,2921 ($p < 0,001$), o VIX – -0,0856 ($p = 0,0003$). BNB modelyje S&P500 koeficientas yra 1,1165 ($p < 0,001$), o VIX – -0,0573 ($p = 0,0185$). Šie rezultatai rodo, kad kriptovaliutų kainos yra jautrios tiek rinkos augimui, tiek rizikos nuotaikoms.

3.29 lentelė. Sistemos GMM rezultatai: kainodaros, infliacijos ir monetarinės politikos ryšiai

Table 3.29. GMM results: relationships between pricing, inflation, and monetary policy

Lygtis / Kintamasis	Parametras	Std. klaida	T stat.	p reikšmė	95 % pasikl. intervalas
BTC grąža ($R^2 = 0,1497$)					
VIX log grąža	-0,0675***	0,0181	-3,73	0,0002	(-0,103; -0,032)
S&P500 log grąža	1,0347***	0,1340	7,72	0,0000	(0,772; 1,297)
Federalinių fondų norma (FFR)	0,00004	0,0005	0,08	0,0000	(0,0001; 0,0009)
ETH grąža ($R^2 = 0,1496$)					
VIX log grąža	-0,0856***	0,0236	-3,64	0,0003	(-0,132; -0,040)
S&P500 log grąža	1,2921***	0,1790	7,22	0,0000	(0,941; 1,643)
FFR	-0,0002	0,0006	-0,37	0,000	(0,0014; 0,0009)
BNB grąža ($R^2 = 0,0861$)					
VIX log grąža	-0,0573**	0,0243	-2,35	0,0185	(-0,105; -0,010)
S&P500 log grąža	1,1165***	0,1726	6,47	0,0000	(0,778; 1,455)
FFR	-0,0008	0,0007	-1,19	0,0000	(0,0021; 0,0005)
Infliacija (CPI) ($R^2 = 0,9755$)					
BTC svyravimas	-31,454***	2,1635	-14,54	0,0000	(-35,695; -27,214)
FFR	0,1304***	0,0419	3,12	0,0018	(0,048; 0,213)
BVP JAV (mlrd. USD)	0,0076***	0,00005	161,93	0,0000	(0,0075; 0,0077)
Monetarinė politika (FFR)					
BTC svyravimas	-38,427***	4,7043	-8,17	0,0000	(-47,647; -29,207)
Reguliavimo indeksas (Z)	0,5917***	0,0604	9,80	0,0000	(0,473; 0,710)

Infliacijos lygtis rodo, kad BTC kintamumas turi stiprų neigiamą poveikį vartotojų kainų indeksui ($-31,454$, $p < 0,001$), o FFR veikia teigiamai ($0,1304$, $p = 0,0018$). BVP JAV taip pat turi reikšmingą teigiamą poveikį infliacijai ($0,0076$, $p < 0,001$). Šie rezultatai atitinka klasikinę makroekonominę logiką, kur didesnis ekonomikos aktyvumas ir monetarinis stimuliavimas skatina kainų augimą, o kriptovaliutų nepastovumas gali veikti kaip defliacinis veiksnys.

Monetarinės politikos atsako lygtis rodo, kad FFR reikšmingai reaguoja į BTC kintamumą ($-38,427$, $p < 0,001$) ir reguliavimo indeksą ($0,5917$, $p < 0,001$). Neigiamas BTC svyravimo koeficientas rodo, kad didėjantis kriptovaliutų nepastovumas gali paskatinti palūkanų normų mažinimą, o teigiamas reguliavimo indeksas rodo, kad griežtėjantis reguliavimas yra susijęs su palūkanų normų didinimu. Taigi centriniai bankai gali įtraukti kriptovaliutų rinkos sąlygas į savo sprendimų priėmimo procesą.

3.30 ir 3.31 lentelėse taikomas režimui priklausomas MS-VAR modelis, siekiant įvertinti, kaip kriptovaliutų grąžų, infliacijos ir monetarinės politikos dinamika kinta priklausomai nuo BTC nepastovumo lygio. Režimai buvo identifikuoti pagal BTC kintamumo kvantilius, suskirstant stebėjimus į žemo, vidutinio ir aukšto nepastovumo grupes. Kiekvienam režimui buvo atskirai įvertinti trys MS-VAR modeliai: kriptovaliutų grąžų, infliacijos ir monetarinės politikos atsako.

3.30 lentelė. Kriptovaliutų grąžų autoregresiniai ryšiai pagal nepastovumo režimus
Table 3.30. Autoregressive relationships of cryptocurrency returns according to volatility regimes

Režimas	Kintamasis	BTC	ETH	BNB
Vidutinis nepastovumas	L1.BTC grąža	0,012	0,035	-0,074*
	L1.ETH grąža	-0,023	-0,017	0,062
	L1.BNB grąža	0,010	0,001	-0,050
Žemas nepastovumas	L1.BTC grąža	0,195***	0,091*	-0,176**
	L1.ETH grąža	-0,095*	0,045	0,087
	L1.BNB grąža	-0,126*	-0,136*	0,055
Aukštas nepastovumas	L1.BTC grąža	0,005	0,122**	0,211***
	L1.ETH grąža	-0,139**	-0,227***	-0,357***
	L1.BNB grąža	0,015	-0,041	0,109

3.31 lentelė. Makroekonominių rodiklių ir monetarinės politikos reakcija pagal nepastovumo režimus

Table 3.31. Macroeconomic indicators and monetary policy response under regimes of volatility

Režimas	Modelis	Svarbiausi rezultatai
Žemas nepastovumas	Infliacija (VKI)	BTC svyravimas: $-0,276$ ($p = 0,12$)
		FFR: $0,589^{***}$ ($p = 0,00$)
	Monetarinė politika	BTC svyravimas: $0,472^*$ ($p = 0,04$)
	(FFR)	Reguliavimo indeksas: $0,771^{***}$ ($p = 0,00$)
Aukštas nepastovumas	Infliacija (VKI)	BTC svyravimas: $0,147$ ($p = 0,25$)
		Auksas: $8,777^{***}$ ($p = 0,00$)
	Monetarinė politika	BTC svyravimas: $-2,040^{***}$ ($p = 0,00$)
	(FFR)	Reguliavimo indeksas: $0,654^{***}$ ($p = 0,00$)
Vidutinis nepastovumas	Infliacija (VKI)	Modelis neišsprendžiamas dėl singularumo
	Monetarinė politika	BTC svyravimas: $-1,476^{**}$ ($p = 0,02$)

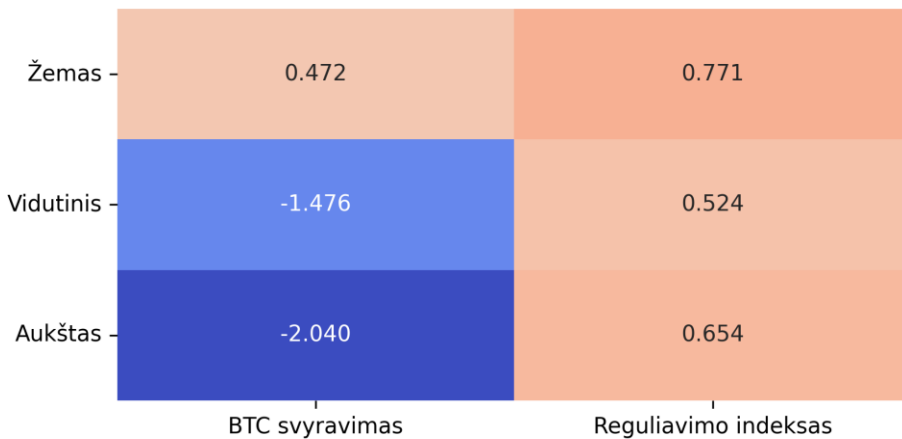
Kripto valiutų gražų dinamika rodo aiškius struktūrinius skirtumus tarp režimų. Esant žemam nepastovumui, BTC graža yra stipriai autokoreliuota ($0,195$, $p < 0,001$), o jos poveikis ETH ($0,091$, $p < 0,1$) ir BNB ($-0,176$, $p < 0,05$) yra didelis. ETH ir BNB gražos taip pat tarpusavyje sąveikauja, tačiau ne taip reikšmingai. Esant aukštam nepastovumui, BTC gražos poveikis BNB tampa dar stipresnis ($0,211$, $p < 0,001$), o ETH graža turi neigiamą poveikį visoms trimis kripto valiutoms (pvz., ETH \rightarrow BTC: $-0,139$, $p < 0,05$). Tai rodo, kad didelio nepastovumo sąlygomis rinkos tampa labiau susijusios ir jautresnės tarpusavio šokams.

Infliacijos modeliai taip pat rodo režimo priklausomybę. Esant žemam nepastovumui, FFR turi teigiamą ir reikšmingą poveikį CPI ($0,589$, $p < 0,001$), o BTC kintamumas turi neigiamą, bet nereikšmingą poveikį ($-0,276$, $p = 0,12$). Esant aukštam nepastovumui, BTC kintamumo poveikis tampa teigiamas, bet taip pat nereikšmingas ($0,147$, $p = 0,25$), o infliaciją stipriai veikia aukso graža ($8,777$, $p < 0,001$). Vidutinio nepastovumo režimu infliacijos modelis buvo neišsprendžiamas dėl singularumo, kas gali rodyti per didelę kintamųjų koreliaciją ar duomenų trūkumą.

Monetarinės politikos atsako funkcija rodo, kad FFR jautriai reaguoja į BTC kintamumą ir reguliavimo indeksą, tačiau poveikio kryptis priklauso nuo režimo. Esant žemam nepastovumui, BTC kintamumas turi teigiamą poveikį FFR ($0,472$, $p < 0,05$), o esant aukštam – neigiamą ($-2,040$, $p < 0,001$). Tai rodo, kad centriniai

bankai gali interpretuoti kriptovaliutų nepastovumą skirtingai priklausomai nuo konteksto: kaip rizikos šaltinį arba kaip signalą apie finansinį nestabilumą. Reguliavimo indeksas visais režimais turi teigiamą ir reikšmingą poveikį FFR, stipriausią esant žemam nepastovumui (0,771, $p < 0,001$).

3.7 pav. spalvų intensyvumo žemėlapyje vizualiai pateikiami režimo analizės rezultatai, rodantys, kaip BTC svyravimas ir reguliavimo indeksas veikia federacinių fondų normą (FFR) skirtingais nepastovumo režimais. Horizontalioje ašyje pateikti aiškinamieji kintamieji, o vertikalioje – BTC nepastovumo režimai: žemas, vidutinis ir aukštas.



3.7 pav. BTC svyravimo ir reguliavimo poveikis FFR skirtingais nepastovumo režimais
Fig. 3.7. Impact of BTC fluctuations and regulation on FFR in different volatility regimes

Spalvų intensyvumas atspindi koeficiento dydį ir kryptį. Mėlynos spalvos atpalviai rodo teigiamą poveikį, raudonos – neigiamą. Pvz., esant žemam nepastovumui, tiek BTC svyravimas (0,472), tiek reguliavimo indeksas (0,771) turi teigiamą poveikį FFR. Tai gali būti interpretuojama kaip Centrinio banko reakcija į stabilias rinkos sąlygas ir griežtėjantį reguliavimą. Aukšto nepastovumo režimu BTC svyravimas turi stiprų neigiamą poveikį (–2,040), o reguliavimo indeksas išlieka teigiamas (0,654). Tai rodo, kad didėjanti kriptovaliutų rizika gali paskatinti monetarinį atsargumą.

Vidutinio nepastovumo režimu BTC svyravimo poveikis yra taip pat neigiamas (–1,476), tačiau mažesnio intensyvumo, nei esant aukštam režimui, o reguliavimo indeksas turi vidutinį teigiamą poveikį (0,524). Šie rezultatai rodo,

kad FFR jautrumas BTC rinkos sąlygoms yra nuo režimo priklausomas, o reguliavimo griežtumas išlieka stabiliai reikšmingas visais režimais.

Šilumos žemėlapis leidžia greitai identifikuoti, kada ir kaip monetarinė politika reaguoja į kriptovaliutų rinkos pokyčius, ir sustiprina kiekybinę analizę vizualiniu įrodymu.

Taigi tyrimas parodė, kad kriptovaliutų grąžos yra glaudžiai susijusios su tradiciniais finansų rinkos kintamaisiais, ypač S&P500 ir VIX indeksais, tačiau jų tiesioginis ryšys su federalinių fondų norma (FFR) yra statistiškai nereikšmingas. Tai rodo, kad kriptovaliutos veikia kaip rizikingas turtas, jautrus rinkos nuotaiksom, bet ne tiesioginiams monetariniams signalams.

GMM analizė atskleidė, kad BTC kintamumas turi reikšmingą neigiamą poveikį infliacijai, o FFR teigiamai veikia vartotojų kainų indeksą. Monetarinės politikos atsako funkcija parodė, kad FFR jautriai reaguoja į BTC kintamumą ir reguliavimo indeksą, ypač esant aukštam nepastovumui. Tai rodo, kad centriniai bankai gali įtraukti kriptovaliutų rinkos sąlygas į savo sprendimų priėmimo procesą.

Režimo analizė papildomai atskleidė, kad kriptovaliutų grąžų tarpusavio priklausomybės ir monetarinės politikos reakcijos stipriai kinta priklausomai nuo BTC nepastovumo lygio. Esant aukštam nepastovumui, BTC ir ETH grąžos tampa labiau susijusios, o monetarinė politika į BTC kintamumą reaguoja stipriau ir neigiamai. Reguliavimo indeksas išlieka stabiliai reikšmingas visais režimais, kas rodo jo svarbą kaip politikos formavimo orientyrą.

3.5 poskyrio rezultatai rodo, kad integruoto modelio patvirtinimo procedūros nuosekliai pagrindžia identifikavimo patikimumą: endogeniškumo testai nepatvirtina būtinybės laikyti FFR endogeniniu kriptovaliutų grąžų lygtyse, o instrumentų stiprumo įvertinimai patvirtina pasirinktų instrumentų tinkamumą. LIML ir sistemos GMM rezultatai išlaiko tą pačią bendrą kryptį, kad kriptovaliutų kainodara pirmiausia siejasi su tradiciniais finansų rinkos veiksniais, o pinigų politikos kanalas išlieka modeliuojamas per atskirus struktūrinius ryšius, įskaitant sąsajas su kintamumu ir reguliavimu. Režimui priklausoma analizė papildomai parodo, kad ryšiai tarp kriptovaliutų ir monetarinės politikos gali kisti priklausomai nuo nepastovumo būsenos, todėl toks tikrinimo dizainas yra suderinamas su literatūra, kuri pabrėžia režimų svarbą ir sąlyginį poveikių pobūdį. Metodologiškai tai dera su Gawande ir Li (2009) akcentuota LIML nauda, sprendžiant identifikavimo klausimus, su Wang (2015) rekomendacija taikyti instrumentinių kintamųjų diagnostikas, taip pat su Larcker ir Rusticus (2010) argumentu, kad IV taikymas turi būti pagrįstas aiškiais tinkamumo testais. Rezultatų interpretacija, akcentuojant ribotą šokų perdavimą tarp kriptovaliutų ir tradicinių rinkų, yra lyginama su Musholombo (2023) išvada apie šokų perdavimo neaptikimą. Galiausiai sąlygiškumo ir asimetrijos akcentas yra suderinamas su Nguyen Quang et al.

(2022) rezultatais, kurie parodo, kad neapibrėžtumo veiksnių poveikis kriptovaliutų grąžoms ir likvidumui nėra vienodas.

Bendras modelis patvirtina, kad kriptovaliutų rinkos turi potencialą paveikti monetarinės politikos perdavimo mechanizmus, ypač per nepastovumo ir reguliavimo kanalus. Todėl politikos formuotojams rekomenduojama įtraukti kriptovaliutų rinkos stebėseną į makroekonominį vertinimą, ypač esant struktūriniais lūžiams ar padidėjusiai finansinei rizikai.

3.6. Diskusija ir tyrimo apribojimai

Šio tyrimo empiriniai rezultatai suteikia įžvalgų apie sudėtingą decentralizuotų kriptovaliutų ir pinigų politikos perdavimo santykį. Analizuojant duomenis, šis tyrimas patvirtina, kad kriptovaliutos daro didelį poveikį makroekonominiam stabilumui, todėl reikia pritaikytų politikos sistemų. Diskusija suskirstyta į keturis pagrindines dalis aptariančias integruoto modelio modulius, po kurių pateikiamas hibridinės sistemos poveikio politikos formuotojams vertinimas.

Pirmasis modulis parodė, kad pinigų politikos sprendimai turi reikšmingą poveikį kriptovaliutų kainoms. BTC parodė stipriausią reakciją į federalinių fondų normos pokyčius su koeficientu $-15\,348,86$ ($p < 0,01$), o ECB indėlių palūkanų norma turėjo silpnesnį, bet vis tiek reikšmingą poveikį ($-11\,347,14$, $p < 0,01$). ETH ir BNB parodė silpnesnę, bet statistiškai reikšmingą reakciją, patvirtindami, kad kriptovaliutos nėra izoliuotos nuo tradicinių finansų sistemų.

Pagrindinė išvada ta, kad JAV pinigų politika turi didesnę poveikį kriptovaliutų rinkoms nei ECB priemonės. Kaip rodo 3.1 lentelė, FED sprendimai paaiškino iki 69,76 % BTC kainos svyravimų ($R^2 = 0,6976$), o ECB politika turėjo nedidelį poveikį, ypač iki COVID-19. Tai atitinka pasaulinį JAV dolerio kaip rizikos turto, įskaitant kriptovaliutas, etalono suvokimą. Judančio lango analizė taip pat parodė, kad politikos poveikis sustiprėjo krizės laikotarpiais (2020–2022 m.), kai BTC R^2 padidėjo nuo 0,3944 iki 0,6188. Tai rodo, kad kriptovaliutos ekonomikos suirutės metu elgiasi kaip spekuliacinis turtas.

Kintamumo modulis patvirtino, kad kriptovaliutų rinkoms būdingi dideli svyravimai, kurie turi šalutinį poveikį infliacijai ir finansiniam stabilumui. Pažangūs GARCH modeliai, ypač MSGARCH ir EGARCH geriau nei tradiciniai modeliai atspindėjo kriptovaliutų kintamumą. BTC šokai padidino infliacijos jautrumą 0,41 % didelės rizikos laikotarpiais, beveik tris kartus daugiau nei stabiliose rinkose.

Šie rezultatai turi tiesioginių pasekmių centriniams bankams. Jei kriptovaliutų kintamumas viršija 80 % MSGARCH nustatytą slenkstį, politikos formuotojai turėtų agresyviau koreguoti palūkanų normas, kad neutralizuotų infliacinį spaudimą. FIGARCH modeliuose pastebėti ilgalaikės atminties efektai taip pat

rodo, kad kriptovaliutų kintamumo šokai trunka ilgiau nei tradicinėse rinkose, todėl reikia imtis ilgalaikių politikos priemonių.

Trečiajame modulyje kaip pagrindiniai kriptovaliutų grąžos veiksniai buvo nustatyti pasauliniai finansiniai rodikliai. VIX indeksas turėjo neigiamą poveikį visoms kriptovaliutomis, o S&P 500 – teigiamą. BNB labiau susijęs su regioninėmis akcijų rinkomis, o tai rodo jos ryšį su Europos rinka.

Grangerio priežastingumo testai patvirtino, kad pasauliniai veiksniai lemia kriptovaliutų kainų pokyčius, o ne atvirkščiai. Tai reiškia, kad kriptovaliutos sugeria išorinius sukrėtimus, o ne sukelia nepriklausomą kintamumą. Politikos formuotojams tai reiškia, kad tradicinių finansinių rodiklių stebėjimas gali padėti numatyti kriptovaliutų rinkos tendencijas.

Paskutiniame modulyje paaiškėjo, kad centriniai bankai palaipsniui koreguoja savo politiką, reaguodami į kriptovaliutų tendencijas. TVP regresijos pavyzdė, kad ECB jautrumas BTC kintamumui (ρ_{1t}) per 2020–2022 m. krizę padidėjo nuo $-0,001$ iki $0,0988$. Po 2022 m. priimtoms reguliavimo priemonės padėjo stabilizuoti šį jautrumą ir sumažinti politikos jautrumą 22 %.

Šie rezultatai atskleidžia pinigų politikos institucijų mokymosi procesą. Modelio impulsų atsako funkcijos rodo, kad 15 % kintamumo šokas stabiliu laikotarpiu lėmė 1,482 % BTC atsaką, o krizės metu – tik $-0,015$ %. Tai patvirtina, kad centriniai bankai pradėjo vertinti kriptovaliutas kaip sisteminės rizikos šaltinį.

Remiantis keturių modulių integracijos rezultatais, galima suformuluoti tris esmines empirines išvadas. Pirmą, kriptovaliutų jautrumas pinigų politikos pokyčiams nėra statiškas – jis kinta priklausomai nuo vyraujančių rinkos sąlygų. Tai patvirtina skirtingi FFR koeficientai BTC atžvilgiu. Stabiliu laikotarpiu šis poveikis siekė $-0,0002$ ($p < 0,001$), tačiau įvykus krizei labai sustiprėjo. Tai rodo, kad politikos perdavimo mechanizmo intensyvumas priklauso nuo makroekonominės aplinkos būsenos. Antra, slenkstinių kintamumo ribų identifikavimas suteikia modeliui intervencinę vertę: kai bitkoino kintamumas viršija 80 %, impulso atsako funkcijų reikšmės aukšto kintamumo režimu pasiekia $-2,040\%$. Tai leidžia politikos formuotojams remtis kiekybiniais kriterijais nustatant tinkamą intervencijos momentą. Trečia, reguliavimo indeksas (Z) statistiškai reikšmingai sumažino FFR jautrumą $0,5917$ vieneto ($p < 0,001$), taip patvirtindamas, kad reguliavimo aplinka atlieka stabilizuojančio buferio funkciją pinigų politikos perdavimo procese.

Nepaisant empiriškai pagrįstų rezultatų, tyrimas turi keletą apribojimų, į kuriuos būtina atsižvelgti interpretuojant išvadas. Pirmasis apribojimas susijęs su kriptovaliutų imties apimtimi: analizė apsiribojo trimis dominuojančiomis kriptovaliutomis – BTC, ETH ir BNB, kurios buvo atrinktos pagal 60 % rinkos kapitalizacijos aprėpties kriterijų. Mažesnio likvidumo ar struktūriškai skirtingos kriptovaliutos gali pasižymėti iš esmės kitokiu jautrumu monetarinės politikos

pokyčiams, todėl gautų rezultatų apibendrinamumas platesnei skaitmeninių aktyvų klasei lieka ribotas. Taigi ateities tyrimai galėtų įtraukti daugiau alternatyviųjų kriptovaliutų

Antrasis apribojimas yra susijęs su egzogeninių veiksnių aprėptimi. Nors integruotas ARIMAX modelis identifikavo statistiškai reikšmingus penkių pasaulinių finansinių kintamųjų – VIX, SP 500, CMC Crypto 200, DAX 30 ir aukso kainos – koeficientus, o EUR/USD valiutos kursas buvo pašalintas dėl statistiškai nereikšmingo poveikio, šie kintamieji neapima visų galimų kriptovaliutų kainų judėjimą formuojančių veiksnių. Geopolitiniai įvykiai, reguliaciniai sukrėtimai ar rinkos sentimentiniai veiksniai, neapimami penkiais egzogeniniais kintamaisiais, lieka neįvertinti ir gali iš dalies paaiškinti nepaaiškintą kainų variaciją. Remiantis šiuo apribojimu, nauja tyrimų kryptis – geopolitiniai įvykiai, reguliaciniai sukrėtimai ar rinkos sentimentiniai veiksniai.

Trečiasis apribojimas susijęs su Centrinio banko duomenų geografine aprėptimi: empirinėje analizėje buvo naudojami išskirtinai Federalinio rezervo ir Europos Centrinio Banko politikos kintamieji. Šis pasirinkimas yra metodologiškai pagrįstas, nes šių dviejų institucijų politikos sprendimai paaiškina iki 70 % bitkoino kainos svyravimų, o tai rodo, kad JAV ir euro zonos pinigų politika sudaro dominuojančią institucinę jėgą, formuojančią globalių kriptovaliutų rinkų dinamiką. Vis dėlto sisteminę reikšmę turinčių centrinių bankų – Anglijos banko, Japonijos banko ar Kinijos liaudies banko – įtraukimas galėtų atskleisti vertingą papildomą dimensiją. Stebint, kaip skirtingų valiutų zonų monetarinės politikos sąveika su kriptovaliutų rinkomis evoliucionuoja dinamikoje, galima būtų empiriškai testuoti, ar Centrinio banko vaidmuo kriptovaliutų kainodaroje stiprėja ar silpnėja geografiškai diversifikuojantis politikos impulsams. Tolesni tyrimai galėtų įtraukti daugiau centrinių bankų, tiriant juos dinamikoje, nustatant evoliucinius pokyčius.

Ketvirtasis apribojimas yra susijęs su duomenų dažniu. Tyrime naudotos dienos uždarymo kainos darbo dienomis – tai metodologiškai pagrįstas pasirinkimas, užtikrinantis kriptovaliutų kainų dinamikos suderinamumą su centrinio banko politikos sprendimų laiko struktūra. Tačiau kriptovaliutų rinkos veikia be pertraukos visą savaitę, įskaitant savaitgalius ir šventes, todėl dienos uždarymo kainos darbo dienomis neužfiksuoja viso kainų judėjimo, ypač reakcijų į Centrinio banko pranešimus, paskelbtus ne darbo valandomis. Didesnio dažnio duomenys leistų stebėti, kaip rinka reaguoja iškart po politikos sprendimų paskelbimo, bei tiksliau atskirti struktūrinį politikos perdavimo poveikį nuo trumpalaikio spekuliacinio triukšmo. Taigi ateities tyrimai galėtų įtraukti didesnio dažnio duomenis.

Šie apribojimai nemažina modelio reikšmės, bet nurodo tolesnių tyrimų kryptis, tokias kaip platesnių duomenų rinkų analizė ir alternatyvių metodų taikymas.

3.7. Trečiojo skyriaus išvados

Po integruoto hibridinio modelio, skirto kriptovaliutų pinigų politikai perduoti, empirinio patvirtinimo padarytos šios išvados:

1. Sukurtas integruotas hibridinis ekonometrinis modelis suteikia tvirtą analitinį pagrindą decentralizuotų kriptovaliutų poveikio pinigų politikos veiksmingumui kiekybiniam įvertinimui. Derinant mašininio mokymosi metodus su pažangia ekonometrine analize – „Elastic Net“, ARIMAX, kintamumo režimo modeliavimu MSGARCH/EGARCH, modelis atspindi netiesinius ryšius ir politikos šalutinius poveikius, kurių tradiciniai metodai neaptinka. Aukštas modelio aiškinamasis pajėgumas, pasiekiantis bitkoino atveju, patvirtina jo tinkamumą kriptovaliutų ir pinigų politikos sąveikos analizei.
2. Kriptovaliutos pasižymi asimetriniu jautrumu pinigų politikos priemonėms, o skirtingi skaitmeniniai turtai reaguoja į politikos signalus pagal skirtingus perdavimo kanalus. Bitkoinas stipriausiai reaguoja į JAV Federalinės rezervų sistemos palūkanų normų pokyčius, jo kaina sumažėja vidutiniškai 15 348,86 USD esant 1 procentinio punkto palūkanų normos padidinimui. Eteris ir „Binance Coin“ yra labiau veikiami akcijų rinkų dinamikos, ypač S&P 500 indekso, kurio poveikio koeficientas yra $\psi = 0,18$. Šie skirtumai rodo, jog pinigų politikos formuotojai turi taikyti diferencijuotus reguliavimo ir stebėsenos metodus, atspindinčius skirtingas atskirų kriptovaliutų rinkos funkcijas ir sistemines sąsajas.
3. Kintamumo režimų analizė atskleidžia, kad aukšto kintamumo laikotarpiais bitkoino jautrumas infliacijos dinamikai labai padidėja, palyginti su žemo kintamumo fazėmis. MSGARCH modelis demonstruoja vidutinį konvergencijos lygį režimų kaitai fiksuoti, nors EGARCH specifikacija pasižymi didesniu skaitiniu stabilumu ir yra tikslingesnis pasirinkimas praktiškai taikyti aukšto kintamumo sąlygomis.
4. Centrinų bankų adaptacijos analizė rodo, kad Europos Centrinio Banko jautrumas bitkoino kintamumui reikšmingai išaugo po 2022 m. – nuo beveik nulinio lygio iki 0,0988, o reguliavimo poveikio koeficientas išliko neigiamas. Tai liudija reguliavimo priemonių stabilizuojamąjį poveikį. Federalinės rezervų sistemos politika pasižymi stipresniu poveikiu kriptovaliutų rinkoms nei Europos Centrinio Banko politika, ypač krizių laikotarpiais 2020–2022 m.
5. Egzogeninių veiksnių modulio rezultatai patvirtina dominuojančią globalių finansinių kintamųjų reikšmę kriptovaliutų kainų dinamikoje. VIX kintamumo indeksas daro reikšmingą neigiamą poveikį kriptovaliutų grą-

žai, o CMC Crypto 200 indeksas – stipriausią teigiamą. Grangerio priešastingumo testai patvirtina, jog makroekonominiai veiksniai statistiškai reikšmingai lemia kriptovaliutų kainas, o ne atvirkščiai. Tai suteikia empirinį pagrindą šių kintamųjų įtraukimui į centrinių bankų stebėsenos sistemas.

6. Remiantis empirinio patvirtinimo rezultatais, centriniam bankams rekomenduojama aktyviai koreguoti pinigų politikos priemones, kai kriptovaliutų kintamumas viršija 80 proc. slenkstį, nes šioje riboje kriptovaliutų svyravimai labai sustiprina infliacijos rizikas. CMC Crypto 200 indeksas turėtų būti sistemingai įtraukiamas į centrinių bankų finansinio stabilumo stebėsenos platformas. Tarptautinis reguliavimo koordinavimas yra būtinas, siekiant išvengti reguliavimo arbitražo ir sušvelninti tarpvalstybinius kriptovaliutų rinkų šalutinius poveikius.
7. Tyrimas apima keletą metodologinių apribojimų, į kuriuos būtina atsižvelgti interpretuojant rezultatus ir planuojant tolesnius tyrimus. Empirinė analizė apsiribojo trimis pagrindinėmis kriptovaliutomis – bitkoinu, eteriu ir „Binance Coin“, o XRP duomenys buvo naudoti tik kintamumo analizėje. FIGARCH ir HYGARCH modeliai pasiekė konvergenciją tik 37,5–49,8 proc. atvejų, dėl ko EGARCH specifikacija laikoma tinkamesnė praktiniam taikymui. Nors instrumentiniai kintamieji, grindžiami prekybos apimtimis, patvirtino priežastinius ryšius, natūralių eksperimentų taikymas ateities tyrimuose galėtų papildomai sustiprinti priežastinės analizės patikimumą.
8. Disertacijoje sukurtas modelis prisideda prie mokslo žinių plėtos, suteikdamas kiekybinius politikos perdavimo kanalų įverčius, apimančius tiek tradicines, tiek nekonvencines pinigų politikos priemones skirtingais rinkos režimais. Sukurta adaptyviųjų reguliavimo slenkstinių rodiklių metodika leidžia tiksliai identifikuoti perėjimą į didesnės sisteminės rizikos režimus. Ši metodika tampa pagrindu kriptovaliutų kintamumo stabilumo indeksui, skirtam sisteminės rizikos lygiui ir tinkamoms politikos priemonėms įvertinti remiantis kiekybiniais rinkos duomenimis.
9. Reguliavimo institucijoms rekomenduojama prioritetą teikti sisteminę įtaką turinčių makroekonominių veiksnių, visų pirma CMC Crypto 200 ir VIX indeksų, stebėsenai, o ne susitelkti vien į atskiras kriptovaliutas, nes šie indeksai pasižymi didesniu aiškinamuoju pajėgumu ir stabilesniu ryšiu su finansinio stabilumo rodikliais. Centriniam bankams rekomenduojama kriptovaliutų kintamumo koeficientą įtraukti kaip papildomą infliacijos rodiklį į standartines monetarinės politikos informacinę sistemą.

10. Šis tyrimas sudaro pagrindą naujai paradigmai pinigų politikos formavimo srityje, kurioje decentralizuotos kriptovaliutos sistemai integruojamos į makroekonominės stabilumo stebėsenos sistemas. Modulinė modelio struktūra leidžia jį plėsti ateityje, įtraukiant naujai atsirandančius skaitmeninius turtus ir besivystančias rinkų struktūras, taip sudarant sąlygas dirbtinio intelekto grindžiamai pinigų politikos kalibravimo metodologijai.

Bendrosios išvados

1. Sisteminė mokslinės literatūros analizė parodė, kad decentralizuotos kriptovaliutos iš esmės pakeitė tradicinę pinigų politikos aplinką, nes suformavo lygiagrečią finansinę ekosistemą, veikiančią už centrinių bankų priežiūros ribų. Esamose teorinėse ir analitinėse prieigose išryškėjo trys pagrindinės spragos: centriniams bankams trūksta patikimų kiekybinių priemonių kriptovaliutų perdavimo kanalams vertinti; taikomi modeliai negeba tinkamai atspindėti netiesinės dinamikos, priklausančios nuo rinkos režimo kriptovaliutų. Nepakankamas tarptautinis reguliavimo derinimas sudaro prielaidas reguliaciniam arbitražui. Būtent šios spragos pagrindžia disertacijoje sukurto integruoto hibridinio modelio poreikį.
2. Disertacijoje sukurtas ir metodologiškai pagrįstas integruotas hibridinis ekonometrinis modelis, skirtas decentralizuotų kriptovaliutų poveikiui pinigų politikos perdavimui kiekybiškai vertinti skirtingais rinkos režimais. Modelį sudaro penki tarpusavyje susieti moduliai: 1) politikos perdavimo modulis, kuriame taikoma „Elastic Net“ regresija su ARIMA liekanomis; 2) kintamumo grįžtamojo ryšio modulis, grindžiamas MSGARCH specifikacijomis; 3) egzogeninių veiksnių modulis, kuriame taikomi ARIMAX ir „XGBoost“ metodai; 4) Centrinio banko reakcijos funkcijos modulis, paremtas laikui einant kintančių parametru regresija su Kalmano filtravimu; 5) integruota sąveikos sistema, formalizuojanti dvikryptį ryšį tarp

kripto valiutų rinkų ir pinigų politikos. Kintamųjų atranka atlikta pasitelkiant „Elastic Net“, Grangerio priežastingumo testus ir „XGBoost“ svarbos vertinimą, siekiant išlaikyti tik statistiškai reikšmingus ir ekonomiškai pagrįstus veiksnius.

3. Nustatyti ir įvertinti pagrindiniai perdavimo kanalai, per kuriuos kripto valiutos veikia kainų stabilumą, kintamumą ir politikos įgyvendinimą. Empiriniai rezultatai parodė, kad palūkanų normų kanalas išlieka reikšmingas, tačiau jo poveikis skirtingoms kripto valiutomis nevienodas, todėl pinigų politikos perdavimas skaitmeninio turto rinkoje yra asimetriškas. Taip pat nustatyta, kad kintamumo kanalas tampa ypač svarbus tada, kai kripto valiutų rinkoje pereinama į padidėjusios rizikos būseną, nes tokiomis sąlygomis sustiprėja infliacinis spaudimas ir išauga sisteminės rizikos tikimybė. Be to, turto kainų kanalas didina užkrato poveikį platesnei finansų sistemai, o valiutos kurso kanalą iškraipo kripto valiutomis grindžiami tarpvalstybiniai kapitalo srautai, silpninantys tradicinių pinigų politikos priemonių veiksmingumą.
4. Empirinis modelio patikrinimas, atliktas naudojant ECB ir Federalinės rezervų sistemos politikos duomenis bei kripto valiutų rinkos reakcijas, patvirtino modelio tinkamumą analizuoti kripto valiutų ir pinigų politikos sąveiką skirtingomis rinkos sąlygomis. Grangerio priežastingumo testai parodė, kad kripto valiutų kainų pokyčius lemia makroekonominiai veiksniai, ypač pasaulinio finansinio neapibrėžtumo ir tradicinių finansų rinkų rodikliai. Vadinas, kripto valiutos labiau sugeria išorinius šokus, nei pačios kuria savarankišką sisteminių nestabilumą. Tyrimas taip pat atskleidė, kad centrinių bankų reakcija į kripto valiutų rinkos svyravimus yra pritaikanti, tačiau nevienodo intensyvumo, o Federalinės rezervų sistemos poveikis kripto valiutų rinkoms yra stipresnis ir greitesnis nei ECB poveikis.
5. Disertacijoje sukurtas modelis suteikia tvirtą analitinį pagrindą tolesniems kripto valiutų ir pinigų politikos sąveikos tyrimams, tačiau tyrimo apribojimai yra susiję su pasirinkta empirine imtimi ir taikytų duomenų pobūdžiu. Analizėje buvo nagrinėjamos pagrindinės kripto valiutos ir ECB bei Federalinės rezervų sistemos politikos duomenys, todėl ateityje tyrimą būtų tikslinga plėsti, įtraukiant platesnį skaitmeninio turto spektrą, papildomus sisteminės svarbos centrinius bankus ir didesnio dažnio duomenis. Tokia plėtra sudarytų prielaidas dar išsamiau atskleisti kripto valiutų ir pinigų politikos sąveikos mechanizmus bei toliau plėtoti modelio taikymo galimybes kintančioje skaitmeninių finansų aplinkoje.

Literatūra ir šaltiniai

- Abubakar, A. A., Mba, J. C., & Ohonba, A. (2024). Analysis of tail dependence structure and risk spillover between cryptocurrencies. *Investment Management and Financial Innovations*, 21(4), 140-155. [https://doi.org/10.21511/imfi.21\(4\).2024.12](https://doi.org/10.21511/imfi.21(4).2024.12)
- Adams, J. J., & Barrett, P. (2024). Shocks to inflation expectations. *Review of Economic Dynamics*, 54. <https://doi.org/10.1016/j.red.2024.101234>
- Adelopo, I., & Luo, X. (2025a). Interconnectedness among cryptocurrencies and financial markets: a systematic literature review. *Digital Finance*, 7(4), 1119–1171. <https://doi.org/10.1007/s42521-025-00155-2>
- Ahmed, M. Y., Sarkodie, S. A., & Leirvik, T. (2023). Mutual coupling between stock market and cryptocurrencies. *Heliyon*, 9(5). <https://doi.org/10.1016/j.heliyon.2023.e16179>
- Albanki, A. A., Alshawawreh, N. K., Abdeldayem, M. M., & Aldulaimi, S. H. (2024). Unravelling the legal framework for cryptocurrency: A comparative analysis of regulatory approaches. In *2024 ASU International Conference in Emerging Technologies for Sustainability and Intelligent Systems, ICETSSIS 2024* (pp. 338–343). <https://doi.org/10.1109/ICETSSIS61505.2024.10459412>
- Al-Jawarneh, A. S., Ismail, M. T., & Awajan, A. M. (2021). Elastic Net regression and empirical mode decomposition for enhancing the accuracy of the model selection. *International Journal of Mathematical Engineering and Management Sciences*, 6(2), 564–583. <https://doi.org/10.33889/ijmms.2021.6.2.034>
- Alp, E., Lau, C. K. M., & Kahyaoğlu, H. (2020). Uncertainty and herding behavior: evidence from cryptocurrencies. *Research in International Business and Finance*, 54, 101284. <https://doi.org/10.1016/j.ribaf.2020.101284>

- Ansari, M. G., & Sensarma, R. (2023). Liquidity creation channel of monetary policy transmission in India: Do bank characteristics matter? *International Social Science Journal*, 73(248), 515–537. <https://doi.org/10.1111/issj.12421>
- Anzuini, A. (2022). The non-linear effects of the FED asset purchases. *Studies in Nonlinear Dynamics and Econometrics*, 26(2), 205–218. <https://doi.org/10.1515/snde-2020-0022>
- Apergis, N. (2022). COVID-19 and cryptocurrency volatility: Evidence from asymmetric modelling. *Finance Research Letters*, 47, 102659. <https://doi.org/10.1016/j.frl.2021.102659>
- Arner, D. W., Zetzsche, D. A., Buckley, R. P., & Kirkwood, J. M. (2023). The financialization of crypto: Lessons from FTX and the crypto winter of 2022–2023. *University of Hong Kong Faculty of Law Research Paper* (2023/19), 23–31.
- Asiedu, M., Oppong, E. O., & Gulnabat, O. (2020). Effects of monetary policy on stock market performance in Africa evidence from ten (10) African countries from 1980 to 2019. *Journal of Financial Risk Management*, 09(03), 252–267. <https://doi.org/10.4236/jfrm.2020.93014>
- Assaf, A., Demir, E., & Ersan, O. (2024). What drives the return and volatility spillover between <sc>DeFis</Sc> and cryptocurrencies? *International Journal of Finance & Economics*, 30(2), 1302–1318. <https://doi.org/10.1002/ijfe.2969>
- Attarde, K., Jaiswal, C., Khatwani, R., Pinto, G., & Kumar, V. (2025). A novel central bank digital currency framework design for offline and foreign transactions based on blockchain. *Digital Policy, Regulation and Governance*, 27(2), 201–220. <https://doi.org/10.1108/DPRG-10-2023-0146>
- Auer, S. (2022). Financial globalization and monetary transmission. *Review of International Economics*, 31(2), 721–760. <https://doi.org/10.1111/roie.12642>
- Doğan, B., Cayirli, O., & Vardar, G. (2024b). Impact of macroeconomics factors on cryptocurrency pricing: Evidence from Bitcoin and Ethereum markets. *Computational Economics*. <https://doi.org/10.1007/s10614-024-10804-0>
- Babilla, T. U. K. (2022). Bank-lending channel of monetary policy transmission in WAEMU: An estimated DSGE model approach. *International Journal of Finance & Economics*, 29(2), 1277–1300.
- Bahr, W., Yern, L. E., & McEwan, I. (2024). Improving transparency and efficiency in international trade through blockchain technology. In *Blockchain Technology: Transforming Businesses and Shaping the Future*. <https://doi.org/10.1201/9781003542766-17>
- Baillie, R. T., Bollerslev, T., & Mikkelsen, H. O. (1996). Fractionally integrated generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 74(1), 3–30. [https://doi.org/10.1016/S0304-4076\(95\)01749-6](https://doi.org/10.1016/S0304-4076(95)01749-6)
- Baldi, M., & Chiaraluce, F. (2017). A trusted cryptocurrency scheme for secure and verifiable digital transactions. *First Monday*, 22(11). <https://doi.org/10.5210/fm.v22i11.6981>
- Bank For International Settlements. (2019). Investigating the impact of global stablecoins. *Bank of International Settlements*, (October), 31.
- Bank For International Settlements. (2022). Annual report 2021–22. *Ministry of Agriculture & Farmers Welfare Government of India*, 1-307.

- Bank of Canada. (2014). *Competition in the cryptocurrency market*.
- Bank of Ireland. (n.d.). <https://www.centralbank.ie/consumer-hub/consumer-notice/eba-opinion-on-virtual-currencies>
- Barczentewicz, M., & De Gândara Gomes, A. (2024). Crypto-Asset Market Abuse Under EU MiCA. *European Journal of Risk Regulation*. <https://doi.org/10.1017/err.2024.80>
- Bazán-Palomino, W., & Svogun, D. (2023). On the drivers of technical analysis profits in cryptocurrency markets: A distributed lag approach. *International Review of Financial Analysis*, 86. <https://doi.org/10.1016/j.irfa.2023.102516>
- Bernanke, B. S., & Blinder, A. S. (1988). Credit, money, and aggregate demand. *The American Economic Review*, 78(2), 435–439.
- Bernanke, B. S., & Gertler, M. (1995a). Inside the black box: The credit channel of monetary policy transmission. *Journal of Economic Perspectives*, 9(4), 27–48. <https://doi.org/10.1257/JEP.9.4.27>
- Bianchi, D. (2020). Cryptocurrencies as an asset class? An empirical assessment. *Journal of Alternative Investments*, 23(2), 162–179. <https://doi.org/10.3905/JAI.2020.1.105>
- BIS. (2023). *Annual Economic Report 2023* (Number 2).
- BIS – Bank of international settlement. (2021). *Central bank digital currencies – executive summary*.
- Böhme, R., Christin, N., Edelman, B., & Moore, T. (2015). *Bitcoin: Economics, Technology, and Governance*. 29(2), 213–238.
- Boneva, L., Cloyne, J., Weale, M., & Wieladec, T. (2016). The effect of unconventional monetary policy on inflation expectations: Evidence from firms in the United Kingdom. *International Journal of Central Banking*, 12(3), 161–195. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84986888486&partnerID=40&md5=f8952a71c4d0242ca28a0829755486c3>
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons
- Boyko, A., Zimbroff, A., Mynenko, S., & Chen, Y. (2024). Anti-money laundering in the digital economy: Institutional, financial, and educational channels. *Virtual Economics*, 7(3), 59–80. [https://doi.org/10.34021/ve.2024.07.03\(4\)](https://doi.org/10.34021/ve.2024.07.03(4))
- Bozma, G., & Akdağ, M. (2021). An evaluation of Central Bank digital currency. *The Journal of International Scientific Researches*, 6(3), 271–276. <https://doi.org/10.23834/isrjournal.887073>
- Buthelezi, E. M. (2025). Cryptocurrency responses to U.S. monetary policy shocks: A Data-driven exploration of price and volatility patterns. *American Economist*, 70(1), 94–119. <https://doi.org/10.1177/05694345241269036>
- Caporale, G. M., Kang, W.-Y., Spagnolo, F., & Spagnolo, N. (2019). Non-linearities, cyber attacks and cryptocurrencies. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3409138>
- Caporale, G. M., & Zekokh, T. (2019). Modelling volatility of cryptocurrencies using Markov-Switching GARCH models. *Research in International Business and Finance*, 48, 143–155. <https://doi.org/10.1016/j.ribaf.2018.12.009>
- Carstens, A. (2021). *Digital currencies and the future of the monetary system*.

- Catalini, C., & S. Gans, J. (2019). Some simple economics of blockchain. *National Bureau of Economic Research*, 1–39.
- Chainalysis. (2021). Cypto Adoption Index (2021). *Chainalysis*, (October).
- Chakravarty, S. L. (2015). Monetary transmission in India: An evaluation. *Pragati Journal of Indian Economy*, 2(2). <https://doi.org/10.17492/pragati.v2i2.8615>
- Chen, C., & Liu, L. (2022). How effective is China's cryptocurrency trading ban? *Finance Research Letters*, 46. <https://doi.org/10.1016/j.frl.2021.102429>
- Chen, Y., & Adams, M. (2023). The regulation of digital currency in China. *European Journal of Law Reform*, 25(1–2), 143–160. <https://doi.org/10.5553/ejlr/138723702023025001004>
- Chen, Z. (2025). From disruption to integration: Cryptocurrency prices, financial fluctuations, and macroeconomy. *Journal of Risk and Financial Management*, 18(7). <https://doi.org/10.3390/jrfm18070360>
- Chimprang, N., Phadkantha, R., & Yamaka, W. (2022). The nonlinear connectedness among cryptocurrencies using Markov-Switching VAR Model. In *Studies in Systems, Decision and Control* (Vol. 427). https://doi.org/10.1007/978-3-030-98689-6_46
- Chionis, D., Mitropoulos, F., & Sarantidis, A. (2021). The impact of quantitative easing policy on the government debt and the NPLs of the Eurozone periphery countries. In *Debt in Times of Crisis: Does Economic Crisis Really Impact Debt?* (pp. 55-76). https://doi.org/10.1007/978-3-030-74162-4_2
- Choi, J., & Wang, S.-F. (2024). The terra-luna collapse and the role of the anchor protocol: A bird's eye view of the crash. *Asian Review of Financial Research*, 37(4), 1–32. <https://doi.org/10.37197/ARFR.2024.37.4.1>
- Chokor, A., & Alfieri, É. (2021). Long and short-term impacts of regulation in the cryptocurrency market. *The Quarterly Review of Economics and Finance*, 81, 157–173. <https://doi.org/10.1016/j.qref.2021.05.005>
- Chow, S. S. M., Lai, Z., Liu, C., Lo, E., & Zhao, Y. (2018). Sharding blockchain. In *Proceedings – IEEE 2018 International Congress on Cybermatics: 2018 IEEE Conferences on Internet of Things, Green Computing and Communications, Cyber, Physical and Social Computing, Smart Data, Blockchain, Computer and Information Technology, IThings/Gree*, 1665. https://doi.org/10.1109/Cybermatics_2018.2018.00277
- Chowdhury, E., Chowdhury, R., & Dhar, B. (2024). Understanding investor sentiment: Analyzing Its influence on stock and cryptocurrency markets during the Russia-Ukraine war. *Thunderbird International Business Review*, 66(5), 473–489. <https://doi.org/10.1002/tie.22395>
- Chowdhury, E. K., & Abdullah, M. N. (2024). Gauging demand for cryptocurrency over the economic policy uncertainty and stock market volatility. *Computational Economics*, 64(1), 37–55. <https://doi.org/10.1007/s10614-023-10423-1>
- Churm, R., Joyce, M., Kapetanios, G., & Theodoridis, K. (2021). Unconventional monetary policies and the macroeconomy: The impact of the UK's QE2 and funding for lending scheme. *Quarterly Review of Economics and Finance*, 80, 721–736. <https://doi.org/10.1016/j.qref.2018.10.004>

- Clarida, R., Galí, J., & Gertler, M. (1999a). The science of monetary policy: A new Keynesian perspective. *Journal of Economic Literature*, 37(4), 1661–1707. <https://doi.org/10.1257/jel.37.4.1661>
- CoinMarketCap. (n.d.-a). Cryptocurrency Prices, Charts And Market Capitalizations | CoinMarketCap. Retrieved January 31, 2023, from <https://coinmarketcap.com/>
- CoinMarketCap. (n.d.-b). <https://coinmarketcap.com/>
- Corbet, S., Hou, Y. (Greg), Hu, Y., Larkin, C., Lucey, B., & Oxley, L. (2022). Cryptocurrency liquidity and volatility interrelationships during the COVID-19 pandemic. *Finance Research Letters*, 45(January 2021), 102137. <https://doi.org/10.1016/j.frl.2021.102137>
- Corbet, S., Lucey, B., Urquhart, A., & Yarovaya, L. (2019). Cryptocurrencies as a financial asset: A systematic analysis. *International Review of Financial Analysis*, 62, 182–199. <https://doi.org/10.1016/J.IRFA.2018.09.003>
- Dadhich, M., Shukla, A., Pahwa, M. S., & Mathur, A. (2024). Decentralized disruptive crypto landscape: How digital currencies are shaking up finance? In *Communications in Computer and Information Science* (Vol. 2040). https://doi.org/10.1007/978-3-031-59107-5_18
- Daruwala, Z. (2025). Exploring external influences on cryptocurrency prices: Using a multi-analytical approach. *International Journal of Economics and Financial Issues*, 15(4), 363–377. <https://doi.org/10.32479/ijefi.19455>
- Dashkevich, N., Counsell, S., & Destefanis, G. (2020). Blockchain application for central banks: A systematic mapping study. *Ieee Access*, 8, 139918–139952. <https://doi.org/10.1109/access.2020.3012295>
- Dehouche, N. (2022). Revisiting the volatility of bitcoin with approximate entropy. *Cogent Economics and Finance*, 10(1). <https://doi.org/10.1080/23322039.2021.2013588>
- Demirgüç-Kunt, A., Klapper, L., Singer, D., & Ansar, S. (2022). The global finindex database 2021: Financial inclusion, digital payments, and resilience in the age of COVID-19. In *The Global Finindex Database*.
- Duan, K., & Urquhart, A. (2023). The instability of stablecoins. *Finance Research Letters*, 52. <https://doi.org/10.1016/j.frl.2022.103573>
- Dyhrberg, A. H. (2016a). Bitcoin, gold and the dollar – A GARCH volatility analysis. *Finance Research Letters*, 16, 85–92. <https://doi.org/10.1016/j.frl.2015.10.008>
- Enwere, K. P., & Ogoke, P. (2023). A Comparative approach on bridge and elastic net regressions. *African Journal of Mathematics and Statistics Studies*, 6(1), 103–115. <https://doi.org/10.52589/ajmss-lbjo9ucu>
- European Central Bank. (2021). *Opinion on a proposal for regulation on markets in Crypto-assets*.
- Faruq, U. A., Salim, D. F., & Kristanti, F. T. (2025). Risk measurement model on top 10 cryptocurrency market capitalization. *Edelweiss Applied Science and Technology*, 9(4), 2395–2404. <https://doi.org/10.55214/25768484.v9i4.6554>
- Fernández-Villaverde, J., & Sanches, D. (2019). Can currency competition work? *Journal of Monetary Economics*, 106, 1–15. <https://doi.org/10.1016/j.jmoneco.2019.07.003>

- Fernández-Villaverde, J., Sanches, D., Schilling, L., & Uhlig, H. (2021). Central Bank digital currency: Central banking for all? *Review of Economic Dynamics*, *41*, 225–242. <https://doi.org/10.1016/j.red.2020.12.004>
- Financial Action Task Force. (2023). *Updated guidance for a risk-based approach to virtual assets and VASPs*. Financial Action Task Force.
- Financial Crimes Enforcement Network. (2021). *Application of FinCEN's regulations to certain business models involving convertible virtual currencies*.
- Foley, S., Karlsen, J. R., & Putniņš, T. J. (2019). Sex, drugs, and bitcoin: How much illegal activity is financed through cryptocurrencies? *The Review of Financial Studies*, *32*(5), 1798–1853. <https://doi.org/10.1093/rfs/hhz015>
- Friedman, M. (1968). The role of monetary policy. *The American Economic Review*, *58*(1), 1–17. <http://www.jstor.org/stable/1831652>
- Furajil, H. B., Khader, O. M., Mohammed, R. J., Dawie, W. M., Naser, S. J., Kalaf, G. A., & Matyakubov, M. (2025). Cryptocurrency and monetary policy: Challenges and opportunities for Central Banks. *Procedia Environmental Science, Engineering and Management*, *12*(3), 997–1005.
- Gali, J. (2008). *Monetary policy, inflation, and the business cycle: An introduction to the new Keynesian Framework*. Princeton University Press. <https://doi.org/10.1515/9781400831456>
- Gapurbaeva, S., Orozonova, A., Zinchenko, A., Ovcharenko, T., & Huliaieva, L. (2023). The impact of cryptocurrency on the investment market. *Financial Engineering*, *1*, 300–306. <https://doi.org/10.37394/232032.2023.1.28>
- Gawande, K., & Li, H. (2009). Dealing with weak instruments: An application to the protection for sale model. *Political Analysis*, *17*(3), 236–260. <https://doi.org/10.1093/pan/mpp009>
- Ghauri, S. P., Hamid, H., & Zaman, S. M. A. (2022). Analyzing various channels of monetary policy transmission mechanism: The case of Pakistan. *Market Forces*, *17*(1), 104–120. <https://doi.org/10.51153/mf.v7i1.518>
- Ghezal, A., & Zemmouri, I. (2024a). On the Markov-switching autoregressive stochastic volatility processes. *SeMA Journal*, *81*(3), 413–427. <https://doi.org/10.1007/s40324-023-00329-1>
- Guasoni, P., Huberman, G., & Shikhelman, C. (2024). Lightning network economics: Channels. *Management Science*, *70*(6), 3827–3840. <https://doi.org/10.1287/mnsc.2022.01664>
- Gupta, M., & Gupta, P. (2018). Gini coefficient based wealth distribution in the bitcoin network: A case study. In *Communications in Computer and Information Science* (Vol. 805). https://doi.org/10.1007/978-981-13-0755-3_15
- Gurrib, I., Kweh, Q. L., Nourani, M., & Ting, I. W. K. (2019). Are cryptocurrencies affected by their asset class movements or news announcements? *Malaysian Journal of Economic Studies*, *56*(2), 201–225. <https://doi.org/10.22452/MJES.vol56no2.2>
- Hamilton, J. D. (1989a). A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica*, *57*(2), 357–384. <https://doi.org/10.2307/1912559>

- Han, S. (2024a). Nonlinear relationship between cryptocurrency returns and price sensitivity to market uncertainty. *Finance Research Letters*, 68. <https://doi.org/10.1016/j.frl.2024.106016>
- Hanif, W., Ko, H.-U., Pham, L., & Kang, S. H. (2023). Dynamic connectedness and network in the high moments of cryptocurrency, stock, and commodity markets. *Financial Innovation*, 9(1). <https://doi.org/10.1186/s40854-023-00474-6>
- Hansen, L. P. (1982). Large sample properties of generalized method of moments estimators. *Econometrica*, 50(4), 1029. <https://doi.org/10.2307/1912775>
- Harir, N., Mkaddem, Z. B., Es-Saadi, H., Tesse, I., & Bouayad, O. (2025). Cryptocurrency market responses to the fed's quantitative easing: an in-depth TVP-VAR model analysis. *Journal of Financial Regulation and Compliance*. <https://doi.org/10.1108/JFRC-12-2024-0261>
- Helmi, M. H., Çatik, A. N., & Akdeniz, C. (2023). The impact of central bank digital currency news on the stock and cryptocurrency markets: Evidence from the TVP-VAR model. *Research in International Business and Finance*, 65. <https://doi.org/10.1016/j.ribaf.2023.101968>
- Hodula, M. (2025). Retail crypto investors when facing financial constraints: Evidence from energy shocks and the use and downloads of crypto trading apps. *Energy Economics*, 144. <https://doi.org/10.1016/j.eneco.2025.108338>
- Horch, A., Schunck, C. H., & Ruff, C. (2022). Adversary tactics and techniques specific to cryptocurrency scams. *Lecture notes in informatics (LNI). Proceedings – Series of the Gesellschaft Fur Informatik (GI), P-325*, 119–124.
- Horel, E., & Giesecke, K. (2020). Significance tests for neural networks. *Journal of Machine Learning Research*.
- Huang, S. S. (2021). Crypto assets regulation in the UK: An assessment of the regulatory effectiveness and consistency. *Journal of Financial Regulation and Compliance*, 29(3), 336–351. <https://doi.org/10.1108/jfrc-06-2020-0062>
- Hung, N. T., Huynh, T. L. D., & Nasir, M. A. (2023). Cryptocurrencies in an Uncertain World: comprehensive insights from a wide range of uncertainty indices. *International Journal of Finance & Economics*, 29(3), 3811–3825. <https://doi.org/10.1002/ijfe.2860>
- Hussain, M. E. F. (2022). Effectiveness of the exchange rate channel in monetary policy transmission in Pakistan. *The Pakistan Development Review*, 45–68. <https://doi.org/10.30541/v61i1pp.45-68>
- Internal Revenue Service. (n.d.). <https://www.irs.gov/downloads/irs-drop?page=34>
- International Monetary Fund. (2020). Digital money across borders: Macro-financial implications. *Digital money across borders: Macro-financial implications* (October).
- International Monetary Fund. (2023). *Global financial stability report: Safeguarding financial stability amid high inflation and geopolitical risks 2023 APR*.
- Iqbal, F., Zahid, M., & Koutmos, D. (2023). Cryptocurrency trading and downside risk. *Risks*, 11(7). <https://doi.org/10.3390/risks11070122>
- Istrefi, K., & PiloIU, A. (2020). Public opinion on central banks when economic policy is uncertain. *Revue D Économie Politique*, Vol. 130(2), 283–306. <https://doi.org/10.3917/redp.302.0283>

- Iuga, I. C., Nerişanu, R.-A., & Dragolea, L.-L. (2024). Volatility and spillover analysis between cryptocurrencies and financial indices: a diagonal BEKK and DCC GARCH model approach in support of SDGs. *Cogent Economics and Finance*, 12(1). <https://doi.org/10.1080/23322039.2024.2437002>
- Jain, P., Haddad, A., & Paramaiah, C. (2023). Goldonomics: Cryptocurrency vs. gold; Which is a better store of value in the global. In *2nd international conference on business analytics for technology and security, ICBATS 2023*. <https://doi.org/10.1109/ICBATS57792.2023.10111385>
- Jain, P., & Jain, R. (2024). Revolutionary finance: Impact of blockchain and distributed ledger technology on the financial industry. In *Convergence of blockchain and internet of things in healthcare*. <https://doi.org/10.1201/9781003466949-8>
- Jana, S., Sahu, T. N., & Pandey, K. D. (2024). Revisiting the cryptocurrencies role in stock markets: ADCC-GARCH and Wavelet Coherence. *Macroeconomics and Finance in Emerging Market Economies*, 17(1), 110–135. <https://doi.org/10.1080/17520843.2023.2211380>
- Joseph, T. E., Jahanger, A., Onwe, J. C., & Balsalobre-Lorente, D. (2025). The implication of cryptocurrency volatility on five largest african financial system stability. In *Blockchain, crypto assets, and financial innovation: A decade of insights and advances* (pp. 192–216). https://doi.org/10.1007/978-981-96-6839-7_7
- Jotaki, H., Liu, M., & Takahashi, H. (2024). A study of the impact of crypto assets on portfolio risk management (2019–2022). *Journal of Interdisciplinary Economics*. <https://doi.org/10.1177/02601079241264878>
- Juwita, R., Ramadhani, D. M., & Maris, A. W. I. (2023). The determinants of cryptocurrency returns. *Jurnal Ilmu Keuangan Dan Perbankan (Jika)*, 12(2), 235–246. <https://doi.org/10.34010/jika.v12i2.9461>
- Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, 82(1), 35–45. <https://doi.org/10.1115/1.3662552>
- Kapetanios, G., Mumtaz, H., Stevens, I., & Theodoridis, K. (2012). Assessing the economy-wide effects of quantitative easing. *Economic Journal*, 122(564), F316–F347. <https://doi.org/10.1111/j.1468-0297.2012.02555.x>
- Kaur, G. (2023). Understanding the impact of cbcds on financial stability: The shift towards a user-centric financial ecosystem. In *Concepts, Technologies, Challenges, and the Future of Web 3* (pp. 456–473). <https://doi.org/10.4018/978-1-6684-9919-1.ch022>
- Kayal, P., & Dutta, S. (2024). Regime switching and causal network analysis of cryptocurrency volatility: Evidence from pre-COVID and post-COVID analysis. *Digital Finance*, 6(2), 319–340. <https://doi.org/10.1007/s42521-023-00104-x>
- Keynes, J. M. (1937). The general theory of employment. *The Quarterly Journal of Economics*, 51(2), 209–223. <https://doi.org/10.2307/1882087>
- Khan, R. U., Ullah, K., & Atiq, M. (2023). Regulatory constraints, responsibilities and consultation (CRC) for legal institutionalization of cryptocurrencies in Pakistan. *Qualitative Research in Financial Markets*, 16(4), 680–708. <https://doi.org/10.1108/qrfm-03-2023-0053>

- Kim, J. S. (2021). The effect of uncertainty on the information content of term spread and its components. *Journal of Derivatives and Quantitative Studies* *선물연구*, 29(1), 2–28. <https://doi.org/10.1108/jdqs-08-2020-0021>
- Kim, Y., & Hwang, E. (2018a). A dynamic Markov regime-switching GARCH model and its cumulative impulse response function. *Statistics and Probability Letters*, 139, 20–30. <https://doi.org/10.1016/j.spl.2018.02.059>
- Kiriyakova, N. I., & Kalieva, G. K. (2022). *Effectiveness of monetary policy is an important factor in the sustainability of a modern economy*. In *Proceedings of the international scientific and practical conference “Sustainable development of environment after COVID-19” (SDEC 2021)*. <https://doi.org/10.2991/assehr.k.220106.047>
- Kóczyán, B., Kollarik, A., Kiss, L., & Šimon, P. (2022). Central Bank digital currency: A new instrument of monetary policy. *Pénzügyi Szemle = Public Finance Quarterly*, 67(4), 522–538. https://doi.org/10.35551/pfq_2022_4_3
- Krug, S. (2018). The interaction between monetary and macroprudential policy: Should Central Banks ‘Lean Against the Wind’ to foster macro-financial stability? *Economics the Open-Access Open-Assessment E-Journal*, 12(1). <https://doi.org/10.5018/economics-ejournal.ja.2018-7>
- Kumah, P. S., & Baafi, J. A. (2024). Spillover effects among cryptocurrencies in a pandemic: A time frequency approach. *Journal of Electronic Business & Digital Economics*, 4(1), 151–166. <https://doi.org/10.1108/jebde-08-2024-0027>
- Kyriazis, N. (2021). The nexus of sophisticated digital assets with economic policy uncertainty: A survey of empirical findings and an empirical investigation. *Sustainability*, 13(10), 5383. <https://doi.org/10.3390/su13105383>
- Labouré, M., Müller, M., Heinz, G., Singh, S., & Köhling, S. (2021). Cryptocurrencies and CBDC: The route ahead. *Global Policy*, 12(5), 663–676. <https://doi.org/10.1111/1758-5899.13017>
- Larcker, D. F., & Rusticus, T. O. (2010). On the use of instrumental variables in accounting research. *Journal of Accounting and Economics*, 49(3), 186–205. <https://doi.org/10.1016/j.jacceco.2009.11.004>
- Le, P. N. (2023). The impact of cryptocurrencies on the financial market: National and international monetary systems. In *Mainstreaming Cryptocurrency and the Future of Digital Finance*. <https://doi.org/10.4018/978-1-6684-8368-8.ch004>
- Li, H. (2023). Predicting prices of different cryptocurrencies based on LSTM Models. *Advances in Economics Management and Political Sciences*, 9(1), 293–300. <https://doi.org/10.54254/2754-1169/9/20230396>
- Liu, J., & Serletis, A. (2019). Volatility in the cryptocurrency market. *Open Economies Review*, 30(4), 779–811. <https://doi.org/10.1007/s11079-019-09547-5>
- Liu, Y., & Hu, Y. (2022). *Research on the indirect impact of monetary policy uncertainty and loan default – based on two channels of banks and enterprises*. <https://doi.org/10.36689/uhk/hed/2022-01-045>
- López-Cabarcos, M. Á., Pérez-Pico, A. M., Piñeiro-Chousa, J., & Šević, A. (2021). Bitcoin volatility, stock market and investor sentiment. Are they connected? *Finance Research Letters*, 38. <https://doi.org/10.1016/j.frl.2019.101399>

- Lü, Z., Ozcelebi, O., & Yoon, S.-M. (2025). Impact of central bank digital currency uncertainty on international financial markets. *Research in International Business and Finance*, 73. <https://doi.org/10.1016/j.ribaf.2024.102627>
- Lucey, B. M., Vigne, S. A., Yarovaya, L., & Wang, Y. (2022). The cryptocurrency uncertainty index. *Finance Research Letters*, 45. <https://doi.org/10.1016/j.frl.2021.102147>
- Maciel, L. (2021a). Cryptocurrencies value-at-risk and expected shortfall: Do regime-switching volatility models improve forecasting? *International Journal of Finance and Economics*, 26(3), 4840–4855. <https://doi.org/10.1002/ijfe.2043>
- Mainetti, L., Aprile, M., Mele, E., & Vergallo, R. (2023). A Sustainable approach to delivering programmable peer-to-peer offline payments. *Sensors*, 23(3), 1336. <https://doi.org/10.3390/s23031336>
- Maleki, N., Nikoubin, A., Rabbani, M., & Zeinali, Y. (2020). Bitcoin price prediction based on other cryptocurrencies using machine learning and time series analysis. *Scientia Iranica*, 0(0), 0. <https://doi.org/10.24200/sci.2020.55034.4040>
- Malladi, R. K. (2022). Pro forma modeling of cryptocurrency returns, volatilities, linkages and portfolio characteristics. *China Accounting and Finance Review*, 25(2), 145–183. <https://doi.org/10.1108/cafr-02-2022-0001>
- Manaa, M., Chimienti, M. T., Adachi, M. M., Athanassiou, P., Balteanu, I., Calza, A., Devaney, C., Diaz Fernandez, E., Eser, F., Ganoulis, I., Laot, M., Günther, P., Poignet, R., Sauer, S., Schneeberger, D., Stracca, L., Tapking, J., Toolin, C., Tyler, C., & Wacket, H. (2021). Crypto-assets: Implications for financial stability, monetary policy, and payments and market infrastructures. *SSRN Electronic Journal*, (22). <https://doi.org/10.2139/ssrn.3391055>
- Manevich, V. A. (2024). Corrected triple correction method, CNN and Transfer learning for prediction the realized volatility of bitcoin and E-Mini S&P500. *Lobachevskii Journal of Mathematics*, 45(3), 1194–1206. <https://doi.org/10.1134/S1995080224600705>
- Marshal, I., & Toby, A. J. (2021). Impact of credit channel of monetary policy transmission mechanism on the Nigerian economy. *Journal of Global Economics and Business*, 2(7), 1–31. <https://doi.org/10.58934/jgeb.v2i7.162>
- Matousek, R., Papadamou, S. T., Šević, A., & Tzeremes, N. G. (2019). The effectiveness of quantitative easing: Evidence from Japan. *Journal of International Money and Finance*, 99. <https://doi.org/10.1016/j.jimonfin.2019.102068>
- Mazur, M. (2022). Misperceptions of bitcoin volatility. *Journal of Alternative Investments*, 24(4), 33–44. <https://doi.org/10.3905/JAI.2022.1.153>
- Meng, J., Mo, B., & Ding, S. (2025). Central Bank communication, economic policy uncertainty, and financial market volatility: A time-varying perspective on Chinese markets. *Computational Economics*. <https://doi.org/10.1007/s10614-025-11080-2>
- Menger, K. (1892). On the origin of money. *The Economic Journal*, 2(6), 239. <https://doi.org/10.2307/2956146>
- Mensi, W., Gubareva, M., Ko, H.-U., Vo, X. V., & Kang, S. H. (2023). Tail spillover effects between cryptocurrencies and uncertainty in the gold, oil, and stock markets. *Financial Innovation*, 9(1). <https://doi.org/10.1186/s40854-023-00498-y>

- Mishkin, F. S., & Serletis, Apostolos. (2019a). *The economics of money, banking, and financial markets*.
- Mitawa, A., & Bhambu, P. (2024). Safeguarding financial transaction with cryptocurrency. In *Lecture Notes in Networks and Systems* (Vol. 820). https://doi.org/10.1007/978-981-99-7817-5_27
- Moiseev, S. R. (2020). The “black box” of the interest rate channel of monetary policy. *Voprosy Ekonomiki*, 2020(9), 5–21. <https://doi.org/10.32609/0042-8736-2020-9-5-21>
- Moussa, R., & Cuzzocrea, A. (2021). Extracting insights from Bitcoin transactions: Data warehouse modeling and analytical questions. In *Enabling Blockchain Technology for Secure Networking and Communications*. <https://doi.org/10.4018/978-1-7998-5839-3.ch003>
- Movva, S. S., & Dasarraju, V. K. (2024). Impact of blockchain on FinTech and payment systems. *Journal of Technology and Systems*, 6(3), 19–27. <https://doi.org/10.47941/jts.2025>
- Mungo, L., Bartolucci, S., & Alessandretti, L. (2024). Cryptocurrency co-investment network: token returns reflect investment patterns. *EPJ Data Science*, 13(1). <https://doi.org/10.1140/epjds/s13688-023-00446-x>
- Musholombo, B. (2023). Cryptocurrencies and stock market fluctuations. *Economics Letters*, 233. <https://doi.org/10.1016/j.econlet.2023.111427>
- Nabilou, H. (2019). Central Bank digital currencies: Preliminary legal observations. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3329993>
- Nabilou, H. (2020). Testing the waters of the Rubicon: The European Central Bank and central bank digital currencies. *Journal of Banking Regulation*, 21(4), 299–314. <https://doi.org/10.1057/s41261-019-00112-1>
- Nakagawa, K., & Sakemoto, R. (2022). Cryptocurrency network factors and gold. *Finance Research Letters*, 46. <https://doi.org/10.1016/j.frl.2021.102375>
- Nakagawa, K., & Sakemoto, R. (2023). Macro factors in the returns on cryptocurrencies. *Applied Finance Letters*, 11, 146–158. <https://doi.org/10.24135/afl.v11i.540>
- Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. In *Google Scholar*. <https://doi.org/10.1108/TG-06-2020-0114>
- Nelson, D. B. (1991). Conditional heteroskedasticity in asset returns: A new approach. *Econometrica*, 59(2), 347–370. <https://doi.org/10.2307/2938260>
- Nguyen Quang, B., Le, T.-H., & Nguyen Phuc, C. (2022). Influences of uncertainty on the returns and liquidity of cryptocurrencies: Evidence from a portfolio approach. *International Journal of Finance and Economics*, 27(2), 2497–2513. <https://doi.org/10.1002/ijfe.2283>
- Nguyen, T. V. H., Nguyen, B. T., Nguyen, K. S., & Pham, H. (2019). Asymmetric monetary policy effects on cryptocurrency markets. *Research in International Business and Finance*, 48, 335–339. <https://doi.org/10.1016/J.RIBAF.2019.01.011>
- Nieborak, T. (2024). Central Bank digital currency as a new form of money. *Bialostockie Studia Prawnicze*, 29(1), 189–203. <https://doi.org/10.15290/bsp.2024.29.01.12>
- Nirmala, T., Sugiyanto, C., & Purnawan, M. E. (2022). Impact of monetary policy on consumption and investment in Indonesia. *Jurnal Ekonomi Dan Studi Pembangunan*, 14(2), 243. <https://doi.org/10.17977/um002v14i22022p243>

- Nur, A. R., Jaya, A. K., & Siswanto, S. (2023). Comparative analysis of ridge, LASSO, and Elastic net regularization approaches in handling multicollinearity for infant mortality data in South Sulawesi. *Jurnal Matematika Statistika Dan Komputasi*, 20(2), 311–319. <https://doi.org/10.20956/j.v20i2.31632>
- Nzokem, A., & Maposa, D. (2024). Bitcoin versus S&P 500 Index: Return and risk analysis. *Mathematical and Computational Applications*, 29(3). <https://doi.org/10.3390/mca29030044>
- Okechukwu, G. (2024). Cryptocurrency and its role in portfolio diversification. *International Journal of Finance*, 9(4), 35–47. <https://doi.org/10.47941/ijf.2115>
- Oladimeji, E. O., Bowale, E., & Okodua, H. (2020). How effective is the monetary policy on the real sector in Nigeria? *Research in World Economy*, 11(5), 388. <https://doi.org/10.5430/rwe.v11n5p388>
- Oldani, C., Bruno, G. S. F., & Signorelli, M. (2024). Economic policy uncertainty and cryptocurrencies. *Eurasian Economic Review*, 14(3), 709–728. <https://doi.org/10.1007/s40822-024-00271-1>
- Ozupek, O., Yilmaz, R., Ghasemkhani, B., Birant, D., & Kut, R. A. (2024). A novel hybrid model (EMD-TI-LSTM) for enhanced financial forecasting with machine learning. *Mathematics*, 12(17). <https://doi.org/10.3390/math12172794>
- Pallotta, A., & Ciciretti, V. (2024b). Should you use GARCH models for forecasting volatility? A Comparison to GRU neural networks. *Studies in Nonlinear Dynamics and Econometrics*, 28(5), 725–738. <https://doi.org/10.1515/sn-de-2022-0025>
- Panigrahi, S. (2023a). Are cryptocurrencies a threat to financial stability and economic growth of India? Evidence from the cointegration approach. *Investment Management and Financial Innovations*, 20(2), 307–320. [https://doi.org/10.21511/imfi.20\(2\).2023.26](https://doi.org/10.21511/imfi.20(2).2023.26)
- Pârțachi, I., Anghel, M.-G., Petre, A., & Olteanu, C. D. (2023). Money functions in modern economy. *Economica*, (3(125)), 78–94. <https://doi.org/10.53486/econ.2023.125.078>
- People's Bank of China. (2013). *Notice on Preventing Bitcoin Risks*.
- Polat, O. (2023). Dynamic interlinkages between cryptocurrencies, NFTs, and DeFis and optimal portfolio investment strategies. *China Finance Review International*, 14(3), 430–455. <https://doi.org/10.1108/cfri-03-2023-0061>
- Pourpourides, P. M. (2025). Long-term nexus of macroeconomic and financial fundamentals with cryptocurrencies. *Frontiers in Blockchain*, 8. <https://doi.org/10.3389/fbloc.2025.1550720>
- Qezelbash, M., Tajdini, S., Jafari, F., Ghahroudi, M. L., & Farajnezhad, M. (2023). An analysis of volatility and herd behavior among investors in the SP500 stock market index, Bitcoin, and gold markets. *Journal of Mathematics and Modeling in Finance*, 3(2), 77–92. <https://doi.org/10.22054/jmmf.2024.75516.1103>
- Rachamadugu, B., Purohit, K., & Rahman, A. (2025). The role of monetary policy and fiscal policy on global finance. In *Policy Implications on International Financial Economics and Banking* (pp. 29–64). <https://doi.org/10.4018/979-8-3373-3725-8.ch002>
- Rahsaz, S. (2025). *cryptoNewsDataset: news_currencies_source_joinedResult*.

- Ramadoss, R. (2022). Blockchain technology: An overview. *IEEE Potentials*, 41(6), 6–12. <https://doi.org/10.1109/MPOT.2022.3208395>
- Reserve Bank of India. (2018). *Prohibition on dealing in Virtual Currencies (VCs)*.
- Safarli, G. J., & Safarli, A. (2024). The impact of cryptocurrency adoption on traditional banking systems: A theoretical study. *Economics*, (1), 68–72. <https://doi.org/10.61413/zisz5040>
- Saiti, D., Gockov, G., & Trenovski, B. (2021). How monetary policy affects the lending and economic activity in a banking system with excess liquidity. *Economics and Culture*, 18(2), 51–60. <https://doi.org/10.2478/jec-2021-0014>
- Sakariyahu, R., Lawal, R., Adigun, R., Paterson, A., & Johan, S. (2024). One crash, too many: Global uncertainty, sentiment factors and cryptocurrency market. *Journal of International Financial Markets, Institutions and Money*, 94. <https://doi.org/10.1016/j.intfin.2024.102028>
- Saleem, M. N., Doumenis, Y., Katsikas, E., Izadi, J., & Koufopoulos, D. (2024). Decrypting cryptocurrencies: An exploration of the impact on financial stability. *Journal of Risk and Financial Management*, 17(5). <https://doi.org/10.3390/jrfm17050186>
- Sarode, R. P., Singh, D. G., Watanobe, Y., & Bhalla, S. (2023). High-volume transaction processing in Bitcoin lightning network on blockchains. *International Journal of Computational Science and Engineering*, 26(4), 445–458. <https://doi.org/10.1504/IJCSE.2023.132151>
- Saxena, R., Arora, D., Nagar, V., & Mahapatra, S. (2021). Bitcoin: A digital cryptocurrency. In *Intelligent Systems Reference Library* (Vol. 203). https://doi.org/10.1007/978-3-030-69395-4_2
- Seo, M., & Kim, G. (2020). Hybrid forecasting models based on the neural networks for the volatility of bitcoin. *Applied Sciences (Switzerland)*, 10(14). <https://doi.org/10.3390/app10144768>
- Sharma, H., & Agarwal, S. (2024). The impact of decentralized finance (Defi) on traditional financial systems: Opportunities, challenges, and regulatory implications. In *Studies in Systems, Decision and Control* (Vol. 525). https://doi.org/10.1007/978-3-031-54383-8_17
- Sims, C. A. (1980). Macroeconomics and Reality. *Econometrica*, 48(1), 1–48.
- Siregar, R. P., Tanjung, A. A., & Syafi'i, M. (2023). Analysis of monetary policy mechanism through interest rate path to stock market (IHSG) in Indonesia. *International Journal of Research and Review*, 10(1), 284–303. <https://doi.org/10.52403/ijrr.20230132>
- Smales, L. A. (2024). Cryptocurrency as an alternative inflation hedge? *Accounting and Finance*, 64(2), 1589–1611. <https://doi.org/10.1111/acfi.13193>
- Sosa, M., Ortiz, E., & Cabello, A. (2019). Bitcoin conditional volatility: Garch extensions and markov switching approach. In *International Finance Review* (Vol. 20, pp. 201–219). <https://doi.org/10.1108/S1569-376720190000020020>
- Statista. (n.d.). <https://www.statista.com/>
- Statista. (2023). <https://www.statista.com/statistics/1283516/cryptocurrency-usage-argentina/>

- Stock, J. H., & Watson, M. W. (1996). Evidence on structural instability in macroeconomic time series relations. *Journal of Business and Economic Statistics*, 14(1), 11–30. <https://doi.org/10.1080/07350015.1996.10524626>
- Storm, H., Baylis, K., & Heckelei, T. (2020). Machine learning in agricultural and applied economics. *European Review of Agricultural Economics*, 47(3), 849–892. <https://doi.org/10.1093/erae/jbz033>
- Sun, G. (2024). Cryptocurrency price prediction based on Xgboost, LightGBM and BNN. *Applied and Computational Engineering*, 49(1), 273–279. <https://doi.org/10.54254/2755-2721/49/20241414>
- Switala, F., Kowalska, I., & Malajkat, K. (2021). The impact of bank lending channel on separate loan portfolios in Poland. *International Journal of Monetary Economics and Finance*, 14(6), 572–588. <https://doi.org/10.1504/IJMEF.2021.120033>
- Tanos, B. A., & Badr, G. (2024). Price delay and market efficiency of cryptocurrencies: The Impact of liquidity and volatility during the COVID-19 pandemic. *Journal of Risk and Financial Management*, 17(5), 193. <https://doi.org/10.3390/jrfm17050193>
- Taylor, J. B. (1993). Discretion versus policy rules in practice. *Carnegie-Rochester Conference Series on Public Policy*, 39, 195–214. [https://doi.org/https://doi.org/10.1016/0167-2231\(93\)90009-L](https://doi.org/https://doi.org/10.1016/0167-2231(93)90009-L)
- Thirunavukkarasu, S., & Pradha, T. L. (2022). Transmission mechanism of monetary policy in India – An ex post study. *Journal of Development Economics and Management Research Studies*, 09(13), 48–60. <https://doi.org/10.53422/jdms.2022.91306>
- Ti, A., & Husodo, Z. A. (2024). Navigating volatility spillover amidst investor extreme fear in stablecoin and financial markets. *Cogent Economics and Finance*, 12(1). <https://doi.org/10.1080/23322039.2024.2408276>
- Touhami, K., Abidi, I., Nsaibi, M., & Mejri, M. (2025). Can environmental variables predict cryptocurrency returns? Evidence from Bitcoin, Ethereum, and Tether using a time-varying coefficients vector autoregression model. *Risks*, 13(4). <https://doi.org/10.3390/risks13040072>
- Tuori, K. (2022). The ECB’s unconventional quantitative easing is turning to conventional monetary policy. In *The New European Central Bank* (pp. 59–79). <https://doi.org/10.1093/oso/9780198871231.003.0003>
- Tzeng, K.-Y., Su, Y.-K., & Tay, C. (2025). Predicting cryptocurrency returns using US macroeconomic variables. *Journal of Investing*, 34(3), 6–36. <https://doi.org/10.3905/joi.2025.1.347>
- van Lill, D. (2024). Changes in monetary policy implementation over time. *Journal for Studies in Economics and Econometrics*, 48(1), 62–86. <https://doi.org/10.1080/03796205.2023.2273489>
- Wang, C.-J. (2015). Instrumental variables approach to correct for endogeneity in finance. In *Handbook of Financial Econometrics and Statistics* (pp. 2577–2600). https://doi.org/10.1007/978-1-4614-7750-1_95
- Wang, J., Ma, F., Bouri, E., & Guo, Y. (2022). Which factors drive bitcoin volatility: Macroeconomic, technical, or both? *Journal of Forecasting*, 42(4), 970–988. <https://doi.org/10.1002/for.2930>

- Welch, J. S. (2023). Innovation vs. insolvency: is storing financial assets on decentralized blockchain networks worth the risk? *Law and Financial Markets Review*, 17(3), 213–224. <https://doi.org/10.1080/17521440.2024.2329073>
- Wheatley, M. (2024). Cryptocurrencies: economic innovation and challenges. *Premier Journal of Business and Management*. <https://doi.org/10.70389/PJBM.100004>
- World bank. (n.d.). <https://databank.worldbank.org/source/world-development-indicators>
- Wu, X., Zhu, S., & Zhou, J. (2020a). Research on RMB exchange rate volatility risk based on MSGARCH-VaR model. *Discrete Dynamics in Nature and Society*, 2020. <https://doi.org/10.1155/2020/8719574>
- Xing, T., & Wang, C. (2024). Research on the potential impact of CBDC on China's monetary policy framework. *Advances in Economics and Management Research*, 9(1), 127. <https://doi.org/10.56028/aemr.9.1.127.2024>
- Xu, J. (2022). Progress of & Development of E-CNY in China. *The People's Bank of China*, 16.
- Yang, J., & Zhou, G. (2022). A study on the influence mechanism of CBDC on monetary policy: An analysis based on E-Cny. *Plos One*, 17(7), e0268471. <https://doi.org/10.1371/journal.pone.0268471>
- Yang, S. Y., Pirjol, D., Zhang, B., & Li, Q. (2025). Cryptocurrency jump contagion with market sentiment events: A study of high frequency cross effect. *European Journal of Finance*. <https://doi.org/10.1080/1351847X.2025.2477696>
- Younas, M. Z. (2020). Pakistan monetary policy in terms of bank lending and asset price channels. *Jinnah Business Review*, 8(2), 97–115. <https://doi.org/10.53369/piaw8954>
- Youssef, B., & Ismail, B. (2024). Cybersecurity and surveillance strategies in the banking sector: The threat of cryptojacking and ENISA's methodologies against the dark side of cryptocurrencies. In *Proceedings – 11th International Conference on Wireless Networks and Mobile Communications, WINCOM 2024*. IEEE. <https://doi.org/10.1109/WINCOM62286.2024.10655749>
- Zhang, E. (2024). Discussion on financial technology innovation and regulatory mechanism in the digital economy environment. *Financial Engineering and Risk Management*, 7(2). <https://doi.org/10.23977/ferm.2024.070203>
- Zhang, X., Chen, Z., & Wang, S. (2024). A study of the impact of cryptocurrency price volatility on the stock and gold markets. *Finance Research Letters*, 69. <https://doi.org/10.1016/j.frl.2024.106114>
- Zhu, Q., Che, J., & Liu, S. (2024). Comparative analysis of profits from Bitcoin and its derivatives using artificial intelligence for hedge. *Physica A: Statistical Mechanics and Its Applications*, 654. <https://doi.org/10.1016/j.physa.2024.130159>
- Zou, H., & Hastie, T. (2005a). Regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 67(2), 301–320. <https://doi.org/10.1111/J.1467-9868.2005.00503.X>
- Андрійчук, С., Кузьмінський, В., & None, N. (2025). Macroeconomic aspects of the impact of cryptocurrencies on the money market. *Scientific Notes of the Universitykrok*, (1(77)), 117–128. <https://doi.org/10.31732/2663-2209-2025-77-117-128>

Autoriaus mokslinių publikacijų disertacijos tema sąrašas

Straipsniai recenzuojamuose mokslo žurnaluose

Pečiulis, T., & Ahmad, N., & Menegaki, A. N., & Bibi, A. (2024). Forecasting of cryptocurrencies: Mapping trends, influential sources, and research themes. *Journal of Forecasting*, 43(6), 1880–1901. <https://doi.org/10.1002/for.3114>

Pečiulis, T., & Vasiliauskaitė, A. (2024). Effect of monetary policy decisions and announcements on the price of cryptocurrencies: An elastic-net with ARIMA residuals approach. *Economics and Culture*, 21(1), 77–92. <https://doi.org/10.2478/jec-2024-0006>

Pečiulis, T., & Vasiliauskaitė, A. (2024). The influence of unconventional monetary policy tools: an euro area perspective. *Business, Management and Economics Engineering*, 22(2), 317–332. <https://doi.org/10.3846/bmee.2024.21191>

Pečiulis, T., & Vasiliauskaitė, A. (2025). During extreme market conditions: a comparative study of advanced GARCH specifications. *Intellectual Economics*, 19(1), 62–91. <https://doi.org/10.13165/IE-25-19-1-03>

Pečiulis, T., & Vasiliauskaitė, A. (2026). Advanced GARCH specifications for cryptocurrency volatility incorporating asymmetry, regime-switching, and long-memory effects. *Virtual Economics*, 8(2), 124–150. [https://doi.org/10.34021/ve.2025.08.02\(5\)](https://doi.org/10.34021/ve.2025.08.02(5))

Straipsniai kituose leidiniuose

Pečiulis, T., & Vasiliauskaitė, A. (2021). Exogenous factors that influence returns of Bitcoin and Ether. *The 15th International Days of Statistics and Economics*, 809–818.

Pečiulis, T., & Vasiliauskaitė, A. (2023). The evolution of the central bank's policy on cryptocurrencies. *13th International Scientific Conference "Business and Management 2023"*, 59–67. <https://doi.org/10.3846/bm.2023.1050>

Pečiulis, T., & Vasiliauskaitė, A. (2025). Advanced GARCH specifications for cryptocurrency volatility: incorporating asymmetry, regime-switching and long-memory effects. *International Scientific Conference "Emerging Trends in Economics, Culture and Humanities (etECH2025)" – Abstracts Proceedings*, 20.

Summary in English

Introduction

Problem Formulation

The digital revolution has fundamentally changed the world's financial systems with the advent of decentralised cryptocurrencies. Since Nakamoto (2008) introduced bitcoin, these digital assets have grown from obscure cryptographic experiments into a market worth USD 2.5 trillion (*CoinMarketCap*) and are challenging traditional monetary policy systems.

The International Monetary Fund (2023) warned that the borderless nature of cryptocurrencies and their independence from central bank oversight pose unprecedented challenges to macroeconomic stability, particularly in developing economies where their use exceeds 30%. The disruptive potential of cryptocurrencies has become particularly apparent during recent financial crises. As documented by the Bank for International Settlements (2022), the collapse of TerraUSD in May 2022 wiped out USD 40 billion in market value and caused contagion effects in traditional financial markets. On the other hand, cryptocurrency transactions provided critical financial infrastructure to Ukraine following Russia's invasion, and in Argentina, where annual inflation reached 211% in 2023 (International Monetary Fund, 2023), they were used as insurance against inflation risk. These paradoxical characteristics – a combination of systemic risk and financial innovation – pose fundamental challenges for monetary policymakers.

Traditional monetary policy frameworks designed for centralised financial systems are becoming increasingly inadequate in this new environment. As Carstens (2021) noted,

“cryptocurrencies are the Achilles heel of monetary sovereignty”. Empirical research by Cornelli et al. (2023) showed that Federal Reserve policy decisions explain up to 70% of bitcoin price fluctuations, which contradicts the theoretical notion of this asset’s independence from traditional finance. The European Central Bank’s Markets in Crypto-Assets Regulation (MiCA) is a belated attempt to address these challenges, but, as argued by Manaa et al. (2021), such reactive measures do not provide comprehensive solutions. Three critical gaps emerge in this evolving situation. First, central banks lack robust analytical frameworks to quantify the transmission channels of cryptocurrencies. Second, existing models cannot adequately reflect the nonlinear dynamics of cryptocurrency markets, where fluctuations often exceed 80% during crises. Third, the absence of international coordination mechanisms creates opportunities for regulatory arbitrage, as demonstrated by the different approaches of the U.S. Securities and Exchange Commission and EU regulators (Arner et al., 2023). This dissertation addresses these challenges by developing an integrated econometric model that systematically analyses the impact of decentralised cryptocurrencies on monetary policy transmission. This research provides policymakers with tools to maintain macroeconomic stability while accommodating financial innovation in the digital age.

Relevance of the Dissertation

The growing influence of decentralised cryptocurrencies on global financial systems poses urgent challenges for monetary policy systems, as highlighted in the Bank for International Settlements’ (2022) report and recent research, which estimates that the capitalisation of cryptocurrency markets exceeds USD 2.5 trillion and their use in developing economies exceeds 30%. The International Monetary Fund (2023) warned that traditional policy instruments are no longer sufficient to address the high volatility and cross-border nature of cryptocurrencies, particularly in light of the ECB’s (2023) findings on the strong links between cryptocurrency markets and traditional financial systems. This dissertation examines and fills these critical gaps by developing an integrated econometric model to quantify the impact of cryptocurrencies on money transmission channels, providing policymakers with the necessary tools to maintain stability without hindering financial innovation in the digital age.

Object of Research

The object of this research is an integrated econometric machine learning model that links the behaviour of a decentralised cryptocurrency market with the effectiveness of monetary policy.

Aim of the Dissertation

The dissertation mainly aims to develop and empirically validate a hybrid model that quantitatively assesses the impact of decentralised cryptocurrencies on monetary policy transmission, allowing policymakers to adapt macroeconomic stability frameworks in the digital era.

Tasks of the dissertation

To achieve its aim, the dissertation has the tasks to:

1. To analyse scientific literature on decentralised cryptocurrencies and monetary policy transmission mechanisms in order to develop a conceptual framework for the dissertation.
2. To develop and methodologically ground an integrated econometric model that quantifies the impact of cryptocurrencies on the effectiveness of monetary policy in different market systems.
3. To identify and assess the main transmission channels through which cryptocurrencies affect price stability, volatility, and policy implementation.
4. To empirically validate the proposed model using ECB and Federal Reserve policy data and cryptocurrency market reactions.

Research Methodology

The following methods were used in the research:

1. Systematic literature review.
2. Machine learning-based models (Elastic Net with ARIMA residuals) to isolate the impact of policy transmission.
3. Extended volatility modelling (MSGARCH/EGARCH) to capture regime-dependent behaviour and structural breaks.
4. Time-varying parameter regression with Kalman filtering to analyse central bank adjustment reactions.
5. Impulse response testing to assess the model's robustness under different market conditions.

Scientific Novelty of the Dissertation

The following new results in economic science were obtained during the preparation of the dissertation:

1. An integrated econometric model was developed to analyse the impact of decentralised cryptocurrencies on monetary policy transmission. It includes policy transmission analysis enhanced by machine-learning technologies, regime-switching variability modelling, and adaptive central bank response mechanisms designed to maintain macroeconomic stability in digital financial ecosystems.
2. A comprehensive system of cryptocurrency transmission channels has been developed, showing the asymmetric impact of monetary policy on different digital assets (bitcoin shows a sensitivity of USD -15,348 to a 1% change in the Fed interest rate, while ether and binance coin show different reaction patterns), allowing for the application of tailored policy approaches based on cryptocurrency market segments.
3. A set of mechanisms for setting volatility thresholds has been developed. These indicators have become the basis for a cryptocurrency volatility stability index

designed to assess the level of systemic risk and appropriate policy measures, based on quantitative market data and structural changes in cryptocurrency behaviour.

Practical Value of the Research Findings

The research provides central banks with quantitative tools to monitor cryptocurrency markets and implement policy measures in a timely manner. The developed model allows policymakers to anticipate financial instability caused by cryptocurrencies using its volatility thresholds and scenario analysis capabilities. The dissertation provides financial regulators with evidence-based guidance on when and how to intervene in cryptocurrency markets, particularly in the event of high volatility ($\sigma > 80\%$).

The proposed adaptive policy framework is a decision-making tool for monetary policy authorities dealing with decentralised finance. Market participants can use transmission channel analysis to develop more effective investment strategies that consider the policy linkages of cryptocurrencies. The research also provides a basis for international cooperation on cryptocurrency regulation, given the cross-border nature of digital asset markets.

The dissertation results are particularly valuable for central banks in developing countries, where cryptocurrency use exceeds 30%, helping them to balance financial innovation and macroeconomic stability. The modular structure of the model allows for future expansion to include additional digital assets.

Defended Statements

1. Decentralised cryptocurrencies have become systemic actors in monetary policy transmission and therefore need to be integrated into macroeconomic models.
2. The volatility of cryptocurrencies is consistent with regime-specific patterns that enhance policy effectiveness in times of crisis.
3. Central banks need to adopt adaptive frameworks with indicators specific to cryptocurrencies to maintain the stability of digital finance ecosystems.
4. International policy coordination is necessary to reduce the cross-border impact of cryptocurrency markets.

Approval of the Research Findings

The dissertation topic has been discussed in eight scientific articles: four were published in scientific journals included in the Clarivate Analytics Web of Science or Scopus databases (Pečiulis & Vasiliauskaitė, 2023; Pečiulis & Vasiliauskaitė, 2024; Pečiulis & Vasiliauskaitė, 2024; Pečiulis & Vasiliauskaitė, 2025) and two were published in peer-reviewed international conference proceedings (Pečiulis & Vasiliauskaitė, 2023; Pečiulis & Vasiliauskaitė, 2021).

The results of the research conducted in the dissertation were published at three international scientific conferences in Lithuania and abroad:

- 15th International Conference on Statistics and Economics, 9–11 September 2021, Prague, Czech Republic.

- 13th International Scientific Conference “Business and Management 2023”, 11–12 May 2023, Vilnius, Lithuania.
- -International Scientific Conference “Latest Trends in Economics, Culture, and the Humanities (etECH2025)”, 23–23 April 2025, Riga, Latvia.

The author gave four presentations at doctoral seminars at Vilnius Gediminas Technical University and one presentation at Eka University of Applied Sciences in Latvia.

Structure of the Dissertation

The dissertation consists of an introduction, three chapters, general conclusions, a list of references, a list of the author’s publications and a summary in English. The total volume of the dissertation is 173 pages. It has 9 numbered figures, 37 numbered tables, 27 numbered formulas, and 217 literature sources.

1. Theoretical Foundations of the Interaction Between Cryptocurrencies and Monetary Policy

The rapid digitisation of global financial systems has catalysed the emergence of decentralised cryptocurrencies, fundamentally challenging the theoretical and institutional foundations of monetary policy. This chapter provides a comprehensive theoretical analysis of the evolving interaction between cryptocurrencies and monetary policy, focusing on their monetary functions, transmission channel disruptions, central bank responses, and macroeconomic implications. Drawing on a wide range of academic and institutional literature, the chapter establishes the conceptual basis for the dissertation’s empirical and methodological framework. The rise of cryptocurrencies, particularly since the introduction of Bitcoin by Nakamoto (2008), has redefined the concept of money by eliminating traditional intermediaries such as central banks and commercial banks. These digital assets operate on decentralised, cryptographically secured blockchain networks, enabling peer-to-peer transactions without centralised oversight (Ramadoss, 2022; Aljabr et al., 2019; Saxena et al., 2021; Bahr et al., 2024).

The market capitalisation of cryptocurrencies surpassed USD 3 trillion in 2021 (World Bank, 2021), rivalling the GDP of major economies. This exponential growth has forced monetary authorities to reconsider the role of cryptocurrencies in modern financial systems. Scholars such as Sharma and Agarwal (2024) argued that cryptocurrencies fundamentally alter the institutional architecture of money, while Nabilou (2020) raises concerns about the adequacy of existing regulatory frameworks.

Cryptocurrencies increasingly fulfil the classical functions of money-medium of exchange, store of value, and unit of account (Menger, 1892; Keynes, 1937; Pernice et al., 2019). However, their effectiveness varies. For instance, bitcoin’s use as a medium of exchange remains limited due to scalability constraints, which have been partially addressed through the Lightning Network (Sarode et al., 2023; Guasoni et al., 2024).

As a store of value, Bitcoin is often compared to gold due to its deflationary supply algorithm and decentralised nature (Jain et al., 2023). Yet, its volatility and regulatory uncertainty pose significant challenges (Sakariyahu et al., 2024; Welch, 2023). Stablecoins, such as USDT and USDC, offer greater stability, but algorithmic variants like DAI remain vulnerable (Duan & Urquhart, 2023; Sobański et al., 2023; Thanh et al., 2023).

Cryptocurrencies also promote financial inclusion, particularly in regions with underdeveloped banking infrastructure. Chainalysis (2021) reported a 1200% increase in crypto adoption in Sub-Saharan Africa between 2020 and 2022, driven by platforms like Paxful. However, this democratisation of finance undermines monetary sovereignty, as noted by Dadhich et al. (2024).

Table S1.1. Scientific Definitions of Cryptocurrencies

Author	Cryptocurrency Definitions
Nakamoto (2008)	Cryptocurrencies are decentralised digital currencies that use cryptographic encryption instead of financial intermediaries, enabling direct peer-to-peer transactions via blockchain.
Böhme et al. (2015)	Cryptocurrencies are digital assets designed to function as a medium of exchange, secured by cryptography and operating independently of central authority through decentralised consensus mechanisms.
Catalini & S. Gans (2019)	Cryptocurrencies are blockchain-based systems that enable value transfer within a network without intermediaries, using cryptographic encryption.
Yermack (2015)	Cryptocurrencies are digital tokens that are programmable, operate internationally without borders, possess store-of-value and medium-of-exchange characteristics, but their volatility often limits their usefulness as units of account.
BIS (2021)	Cryptocurrencies are privately issued digital assets based on decentralised ledger technology for transaction validation, lacking intrinsic value or issuer claims.
International Monetary Fund (2020)	Cryptocurrencies are a subset of crypto-assets designed to function as alternative payment systems, although their legal status as “currency” remains disputed.
Cong & He (2019)	Cryptocurrencies are decentralised digital platforms combining cryptographic security, token economics, and consensus algorithms to enable trustless transactions.
Dyhrberg (2016)	Cryptocurrencies are hybrid instruments with characteristics of both commodities (e.g., gold) and currencies, offering potential for hedging market risk.
Bank of Canada (2014)	Cryptocurrencies are digital tokens whose value arises from network effects, where user adoption drives demand and liquidity.
Foley et al. (2019)	Cryptocurrencies are decentralised, regulation-resistant digital assets that enable anonymous transactions, often associated with illicit activities.
Schilling & Uhlig (2019)	Cryptocurrencies are speculative bubbles with no fundamental value, sustained only by self-fulfilling expectations of future acceptance.
Wheatley (2024)	Cryptocurrencies are digital platforms combining monetary and technological innovations, where miners validate transactions in exchange for rewards.
Baur et al. (2018)	Cryptocurrencies are digital alternatives to conventional currencies, offering anonymity and decentralisation, but lacking legal tender status.

Table S1.1 presents a synthesis of scientific definitions of cryptocurrencies from leading academic and institutional sources. These definitions converge on core attributes such as decentralisation, cryptographic security, and blockchain-based transaction validation. However, perspectives diverge regarding their economic role: some view cryptocurrencies as speculative assets, while others emphasise their potential for financial inclusion and innovation (Catalini & Gans, 2019). This diversity underscores the hybrid nature of cryptocurrencies and their disruptive potential in monetary systems.

The decentralised nature of cryptocurrencies challenges central banks' ability to control money supply and interest rates. Fama et al. (2024) highlight the weakening of interest rate transmission mechanisms, especially in high-inflation economies like Argentina, where crypto usage doubled during the 211% inflation crisis in 2023 (BIS, 2023; Statista, 2023). Monetary policy traditionally operates through four main transmission channels: interest rate, exchange rate, asset price, and credit channels (Switala et al., 2021;). These mechanisms influence macroeconomic variables such as inflation, output, and employment (Bernanke & Blinder, 1988).

The interest rate channel, considered the cornerstone of monetary transmission (Moiseev, 2020), is disrupted by cryptocurrencies. While central banks adjust policy rates to influence borrowing costs, crypto markets often respond asymmetrically. Empirical evidence shows that Federal Reserve decisions explain up to 70% of Bitcoin price fluctuations (Cornelli et al., 2023), contradicting the notion of crypto independence.

The exchange rate channel is similarly affected. Cryptocurrencies facilitate borderless transactions, complicating capital flow management and undermining currency control (Hussain, 2022; Auer, 2022). For example, during the 2022 Russian ruble crisis, Tether transactions surged by 350%, illustrating crypto's role in capital flight.

Asset price channels are destabilised by crypto-induced volatility. The collapse of TerraUSD in 2022 triggered a 12% drop in technology stocks, highlighting the systemic risk posed by crypto markets (Choi & Wang, 2024). Credit channels are disrupted by DeFi platforms, which enable decentralised lending and bypass traditional banking systems (Marshal & Toby, 2021; Chakravarty, 2015; Ansari & Sensarma, 2023).

These disruptions necessitate new analytical frameworks. Xing and Wang (2024) argued that crypto ecosystems create parallel financial systems, while Liu and Hu (2022) emphasised the need to revise policy transmission models. Yang and Zhou (2022) explored how CBDCs, such as China's e-CNY, offered alternative transmission mechanisms.

The chapter concludes that traditional models are insufficient to capture the nonlinear dynamics introduced by cryptocurrencies. It calls for hybrid modelling approaches that integrate machine learning and econometrics to quantify crypto-induced distortions.

2. Methodological Framework for Cryptocurrency and Monetary Policy Interaction in the Digital Economy

The methodological framework developed in this chapter is designed to systematically quantify the interaction between decentralised cryptocurrencies and traditional monetary policy instruments. It responds to the analytical limitations of conventional econometric models when applied to digital financial ecosystems. It also proposes a hybrid system that

integrates machine-learning techniques with advanced time-series econometrics. The framework is structured to capture nonlinear dynamics, regime-dependent volatility, and bidirectional feedback mechanisms between central bank actions and cryptocurrency markets.

At the core of the framework lies the CMP-IA model – a modular, hybrid analytical system that combines Elastic Net regression, ARIMA residual modelling, regime-switching GARCH specifications, and time-varying parameter estimation. The model is constructed to reflect the structural complexity of cryptocurrency markets, which are characterised by high volatility, frequent structural breaks, and sensitivity to both endogenous monetary shocks and exogenous macro-financial factors.

The integration of machine learning and econometrics is motivated by the inadequacy of traditional models, such as VAR and OLS, in capturing the behaviour of decentralised assets. These models assume linearity and parameter stability, which are often violated in cryptocurrency markets. Elastic Net regression is selected for its ability to handle multicollinearity and perform variable selection in high-dimensional settings. ARIMA residual modelling is incorporated to address autocorrelation in financial time series, ensuring that the regression outputs are statistically robust.

Volatility modelling is achieved using MSGARCH and FIGARCH specifications. MSGARCH allows for regime-switching behaviour, capturing transitions between low and high-volatility states, while FIGARCH models long-memory effects, which are prevalent in crypto asset returns. These models are essential for identifying volatility thresholds that may trigger monetary policy responses or signal systemic risk.

Time-varying parameter regression is employed to model the adaptive behaviour of central banks. Kalman filtering is used to estimate dynamic coefficients that reflect the evolving sensitivity of monetary policy to cryptocurrency market conditions. This component of the framework enables the analysis of institutional responses to digital asset volatility and regulatory developments.

Policy Transmission Module: This module quantifies the direct impact of monetary policy instruments, such as interest rates and quantitative easing, on cryptocurrency prices. It uses Elastic Net regression with ARIMA residuals to isolate the effects of policy shocks while controlling for autocorrelation and multicollinearity.

Volatility Feedback Module: This module models the endogenous volatility dynamics of cryptocurrency markets using MSGARCH and FIGARCH specifications. It captures regime-dependent behaviour and long-memory effects, allowing for the identification of volatility regimes that may influence macroeconomic stability.

Exogenous Factor Module: This module integrates global financial indicators, including equity indices, volatility indices, and commodity prices, using ARIMAX and XGBoost. It assigns dynamic weights to these factors based on their predictive importance and statistical significance, ensuring that the model accounts for broader market conditions.

Central Bank Response Function Module: This module models the adaptive behaviour of central banks using time-varying parameter regression. It estimates the sensitivity of monetary policy instruments to cryptocurrency volatility and regulatory intensity, providing insights into institutional responses to digital financial disruptions.

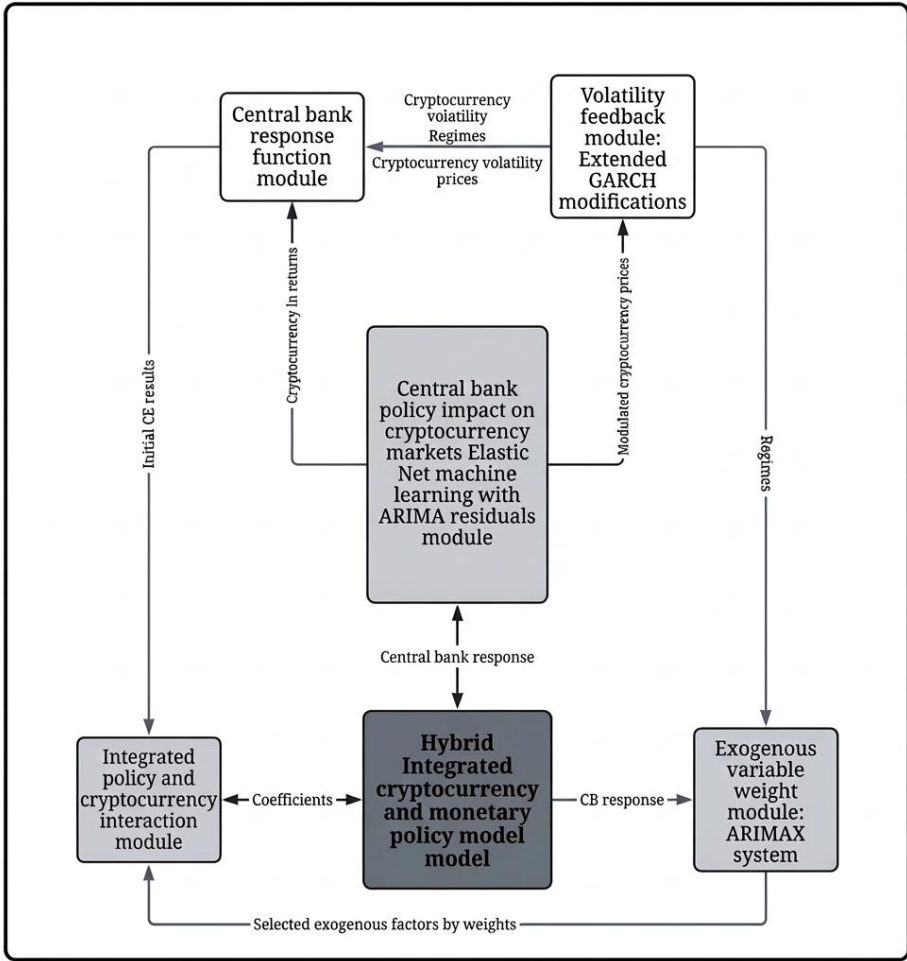


Fig. S2.1. Methodological structure of the integrated hybrid model

Integrated Interaction System: This module combines the outputs of the previous modules into a simultaneous equation system that captures bidirectional interactions between monetary policy, cryptocurrency markets, and macroeconomic indicators. It formalises the feedback loops inherent in the digital financial ecosystem.

The structural logic of the CMP-IA model is illustrated in Figure S2.1, which presents the methodological architecture of the integrated system. The diagram depicts the flow of information between policy shocks, crypto price reactions, volatility dynamics, macroeconomic outcomes, and central bank responses. It emphasises the circular causality and regime-dependent transitions that characterise the interaction between decentralised assets and monetary institutions.

Figure S2.1 displays five modules: Elastic Net + ARIMA (policy transmission), MSGARCH/FIGARCH (volatility modelling), ARIMAX + XGBoost (exogenous factors), TVP regression (central bank response), and the integrated CMP-IA system. Arrows indicate feedback loops and regime-dependent transitions. The selection of variables is guided by empirical relevance and theoretical consistency. The model includes three primary categories of variables. Monetary Policy Variables: These include the ECB and Federal Reserve interest rates, unconventional monetary policy tools (UMPT), and regulatory indices derived from MiCA and FATF frameworks. Cryptocurrency Variables: The model focuses on Bitcoin (BTC), Ethereum (ETH), and Binance Coin (BNB), which together represent over 60% of global market capitalisation. These assets are selected for their systemic importance and data availability. Exogenous Variables: These include the VIX volatility index, S&P 500 returns, CMC Crypto 200 index, DAX 30 returns, and gold prices. These indicators are incorporated to control for global financial conditions and investor sentiment. Variable selection is performed using Elastic Net shrinkage, Granger causality testing, and XGBoost feature importance analysis. This multi-method approach ensures that only statistically significant and economically meaningful variables are retained in the final model.

3. Approbation of an Integrated Cryptocurrency and Monetary Policy Transmission Model

The empirical results of the dissertation provide insights into the complex relationship between decentralised cryptocurrencies and monetary policy transmission. By analysing the data, this study confirms that cryptocurrencies have a significant impact on macroeconomic stability, which requires tailored policy frameworks. The discussion is divided into four main parts discussing the modules of the integrated model, followed by an assessment of the implications of the hybrid framework for policymakers.

The first module showed that monetary policy decisions have a significant impact on cryptocurrency prices. BTC showed the strongest reaction to changes in the Federal Funds rate, with a coefficient of $-15,348.86$ ($p < 0.01$), while the ECB deposit rate had a weaker but still significant effect ($-11,347.14$, $p < 0.01$). ETH and BNB showed a weaker but statistically significant reaction, confirming that cryptocurrencies are not isolated from traditional financial systems.

The main conclusion is that U.S. monetary policy has a greater impact on cryptocurrency markets than ECB measures. As shown in Table 3.1, Fed decisions explained up to 69.76% of BTC price volatility ($R^2 = 0.6976$), while ECB policies had a negligible impact, especially in the pre-COVID-19 period, consistent with the global perception of the U.S. dollar as a benchmark for risk assets, including cryptocurrencies. The moving-window analysis also showed that the policy impact was stronger during crisis periods (2020–2022), when BTC R^2 increased from 0.3944 to 0.6188, indicating that cryptocurrencies behave as speculative assets during economic turmoil. The volatility module confirmed that cryptocurrency markets are characterised by high volatility, with spillover effects on inflation and financial stability. Advanced GARCH models, especially MSGARCH and EGARCH, better captured the volatility of cryptocurrencies than traditional models. BTC

shocks increased inflation sensitivity by 0.41% during periods of high risk, almost three times as much as in stable markets.

These results have direct implications for central banks. If cryptocurrency volatility exceeds the 80% threshold set by MSGARCH, policymakers should adjust interest rates more aggressively to neutralise inflationary pressures. The long-term memory effects observed in FIGARCH models also suggest that cryptocurrency volatility shocks last longer than in traditional markets, requiring long-term policy responses.

The third module identified global financial indicators as the main drivers of cryptocurrency returns. The VIX index negatively affected all cryptocurrencies, while the S&P 500 had a positive impact. BNB is more correlated with regional stock markets, indicating its connection with the European market. Granger causality tests confirmed that global factors drive cryptocurrency price movements, and not vice versa. Consequently, cryptocurrencies absorb external shocks rather than generating independent volatility. For policymakers, this means that monitoring traditional financial indicators can help predict cryptocurrency market trends.

The last module revealed that central banks are gradually adjusting their policies in response to cryptocurrency trends. TVP regressions showed that the ECB's sensitivity to BTC volatility (ρ_{1t}) increased from -0.001 to 0.0988 during the 2020-2022 crisis. Regulatory measures adopted after 2022 helped stabilise this sensitivity and reduce policy sensitivity by 22%.

These results reveal the learning process of monetary policy institutions. The model's impulse response functions show that a 15% volatility shock resulted in a 1.482% BTC response during the stable period, but only -0.015% during the crisis, confirming that central banks have begun to assess cryptocurrencies as a source of systemic risk.

Based on the results of the integration of the four modules, three key empirical conclusions can be formulated. First, the sensitivity of cryptocurrencies to changes in monetary policy is not static, as it varies depending on the prevailing market conditions. This is confirmed by the different FFR coefficients for BTC; in a stable period, this effect reached -0.0002 ($p < 0.001$), but during the crisis, it significantly increased, indicating that the intensity of the policy transmission mechanism depends on the state of the macroeconomic environment. Second, the identification of threshold volatility limits gives the model an intervention value: when Bitcoin volatility exceeds 80%, the values of the impulse response functions in the high volatility regime reach -2.040%, which allows policymakers to rely on quantitative criteria to determine the appropriate moment of intervention. Third, the regulatory index (Z) statistically significantly reduced the FFR sensitivity by 0.5917 units ($p < 0.001$), thus confirming that the regulatory environment plays a stabilising buffer role in the monetary policy transmission process.

Despite the empirically based results, the study has several limitations that must be considered when interpreting the findings. The first limitation is related to the size of the cryptocurrency sample: the analysis was limited to the three dominant cryptocurrencies – BTC, ETH, and BNB – which were selected according to the criterion of 60% market capitalisation coverage. Less liquid or structurally different cryptocurrencies may have significantly different sensitivity to monetary policy changes, so the generalizability of the results to a wider class of digital assets remains limited. Therefore, future studies could include more alternative cryptocurrencies.

The second limitation is related to the coverage of exogenous factors. Although the integrated ARIMAX model identified statistically significant coefficients for five global financial variables – VIX, SP 500, CMC Crypto 200, DAX 30 and gold prices – and the EURUSD exchange rate was removed due to its statistically insignificant effect, these variables do not exhaust all possible factors shaping the price movements of cryptocurrencies. Geopolitical events, regulatory shocks, or market sentiment factors not captured by the five exogenous variables remain under-estimated and may partially explain the unexplained price variation. Supporting this limitation, a new research direction would be to investigate geopolitical events, regulatory shocks, or market sentiment factors.

The third limitation concerns the geographical coverage of central bank data: the empirical analysis used the policy variables of the Federal Reserve and the European Central Bank exclusively. This choice is methodologically justified, as the policy decisions of these two institutions explain up to 70% of the Bitcoin price fluctuations, indicating that U.S. and eurozone monetary policy constitute the dominant institutional force shaping the dynamics of global cryptocurrency markets. However, the inclusion of other systemically important central banks – the Bank of England, the Bank of Japan, or the People’s Bank of China – could reveal a valuable additional dimension: by observing how the interaction of monetary policy of different currency zones with cryptocurrency markets evolves in dynamics, it would be possible to empirically test whether the role of the central bank in cryptocurrency pricing strengthens or weakens with the geographical diversification of policy impulses, providing a basis for raising the broader scientific question of whether global cryptocurrency markets are converging towards a multipolar monetary sensitivity structure or maintaining the dominance of the U.S. dollar cycle. Subsequent studies could include more central banks, studying them in dynamics, and identifying evolutionary changes. The fourth limitation is related to the frequency of data. The study used daily closing prices on weekdays – this is a methodologically justified choice that ensures the compatibility of cryptocurrency price dynamics with the time structure of central bank policy decisions. However, cryptocurrency markets operate continuously throughout the week, including weekends and holidays, so daily closing prices on weekdays do not capture the full range of price movements – especially reactions to central bank announcements made outside of business hours. Higher-frequency data would allow for observing how the market reacts immediately after policy announcements and more accurately separate the structural effects of policy transmission from short-term speculative noise. Future research could therefore include higher-frequency data.

These limitations do not diminish the value of the model, but point to directions for further research, such as the analysis of broader data markets and the application of alternative methods.

After empirical validation of the integrated hybrid model for the transmission of monetary policy through cryptocurrencies, the following conclusions were drawn:

1. The developed integrated hybrid econometric model provides a solid analytical basis for quantifying the impact of decentralised cryptocurrencies on the effectiveness of monetary policy. By combining machine-learning methods with advanced econometric analysis – Elastic Net, ARIMAX, volatility regime modeling MSGARCH/EGARCH – the model captures nonlinear relationships and policy side effects that traditional methods do not detect. The high explanatory

power of the model, achieved in the case of Bitcoin, confirms its suitability for analysing the interaction between cryptocurrencies and monetary policy.

2. Cryptocurrencies are characterised by asymmetric sensitivity to monetary policy measures. Different digital assets respond to policy signals through different transmission channels. Bitcoin reacts most strongly to changes in the interest rates of the U.S. Federal Reserve System. Its price decreases by an average of USD 15,348.86 for a 1-percentage-point increase in the interest rate. Ethereum and binance coin are more affected by the dynamics of stock markets, especially the S&P 500 index, which has an impact coefficient of $\psi = 0.18$. These differences indicate that monetary policymakers need to apply differentiated regulatory and monitoring approaches that reflect the different market functions and systemic links of individual cryptocurrencies.
3. The analysis of volatility regimes reveals that during periods of high volatility, bitcoin's sensitivity to inflation dynamics increases significantly compared to phases of low volatility. The MSGARCH model demonstrates a moderate level of convergence in capturing regime changes, although the EGARCH specification is characterised by greater numerical stability and is a more appropriate choice for practical application in conditions of high volatility.
4. The analysis of central bank adaptation shows that the sensitivity of the European Central Bank to bitcoin volatility increased significantly after 2022, from almost zero to 0.0988, while the coefficient of regulatory impact remained negative, which indicates the stabilising effect of regulatory measures. The policy of the Federal Reserve System has a stronger impact on cryptocurrency markets than the policy of the European Central Bank, especially during the crisis periods in 2020–2022.
5. The results of the exogenous factors module confirm the dominant role of global financial variables in the dynamics of cryptocurrency prices. The VIX volatility index has a significant negative impact on cryptocurrency returns, and the CMC Crypto 200 index has the strongest positive impact. Granger causality tests confirm that macroeconomic factors statistically significantly determine cryptocurrency prices, not vice versa, providing an empirical basis for including these variables in central bank monitoring systems.
6. Based on the results of the empirical validation, central banks are recommended to actively adjust monetary policy measures when cryptocurrency volatility exceeds the 80 per cent threshold, as cryptocurrency fluctuations significantly amplify inflation risks at this threshold. The CMC Crypto 200 index should be systematically included in central banks' financial stability monitoring platforms. International regulatory coordination is essential to avoid regulatory arbitrage and mitigate cross-border spillovers in cryptocurrency markets.
7. The study has several methodological limitations that must be considered when interpreting the results and planning further research. The empirical analysis was limited to three major cryptocurrencies – bitcoin, ethereum, and binance coin – and XRP data was used only in the volatility analysis. The FIGARCH and HY-GARCH models achieved convergence in only 37.5–49.8 per cent of the cases,

which is why the EGARCH specification is considered more suitable for practical application. While instrumental variables based on trading volumes confirmed causal relationships, the use of natural experiments could further strengthen the reliability of causal analysis in future studies.

8. The model developed in the dissertation contributes to the development of scientific knowledge by providing quantitative estimates of policy transmission channels, covering traditional and unconventional monetary policy instruments in different market regimes. The developed methodology of adaptive regulatory threshold indicators allows for the accurate identification of the transition to regimes of higher systemic risk. This methodology becomes the basis for the cryptocurrency volatility stability index, designed to assess the level of systemic risk and appropriate policy instruments based on quantitative market data.
9. Regulators are recommended to prioritise monitoring of systemic macroeconomic factors, primarily the CMC Crypto 200 and VIX indices, rather than focusing solely on individual cryptocurrencies, as these indices have greater explanatory power and a more stable relationship with financial stability indicators. Central banks are recommended to include the volatility coefficient of cryptocurrencies as an additional inflation indicator in standard monetary policy information systems.
10. This study lays the foundation for a new paradigm in monetary policy formulation, in which decentralised cryptocurrencies are systematically integrated into macroeconomic stability monitoring systems. The modular structure of the model allows it to be expanded in the future to include newly emerging digital assets and evolving market structures, thus paving the way for an artificial intelligence-based monetary policy calibration methodology.

General Conclusions

1. The systematic analysis of scientific literature reveals that decentralised cryptocurrencies have fundamentally disrupted the traditional monetary policy environment by introducing a parallel financial ecosystem operating independently of central bank oversight. Three critical gaps were identified in existing frameworks: central banks lack robust quantitative tools to measure cryptocurrency transmission channels; existing models are unable to adequately capture the non-linear, regime-dependent dynamics of cryptocurrency markets where fluctuations during crisis periods reach levels that classical models cannot manage; and the absence of international regulatory coordination creates opportunities for regulatory arbitrage, as evidenced by divergent approaches between U.S. and EU regulatory bodies. These identified gaps form the direct scientific justification for the development of the integrated hybrid model proposed in this dissertation.
2. An integrated hybrid econometric model – the CMP-IA model – was developed and methodologically grounded to quantitatively assess the impact of decentralised cryptocurrencies on monetary policy transmission across different market

regimes. The model combines five interlinked modules: a Policy Transmission Module using Elastic Net regression with ARIMA residuals, a Volatility Feedback Module based on MSGARCH specifications to capture regime-dependent asymmetric dynamics and structural breaks, an Exogenous Factor Module using ARIMAX and XGBoost frameworks to integrate global financial condition indicators, a Central Bank Response Function Module employing time-varying parameter regression with Kalman filtering, and an Integrated Interaction System formalising bidirectional feedback loops between cryptocurrency markets and monetary policy. Variable selection was performed using Elastic Net shrinkage, Granger causality testing, and XGBoost feature importance analysis to ensure that only statistically significant and economically meaningful variables were retained.

3. The main transmission channels for cryptocurrencies to affect price stability, volatility, and policy implementation were identified and assessed. The interest rate channel was quantified empirically, revealing a significant negative price reaction in bitcoin to a one percentage point change in the Federal Reserve interest rate, while ethereum and binance coin exhibit different reaction magnitudes, confirming that monetary policy transmission is asymmetric across different digital assets. The volatility channel was defined through critical threshold indicators, whereby once cryptocurrency volatility surpasses a critical level, cryptocurrency fluctuations significantly amplify inflation risks, with the destabilising effect in the high-volatility regime substantially exceeding the stabilising effect observed during calm market periods. The asset price channel amplifies systemic risk through contagion effects, as demonstrated empirically by the collapse of TerraUSD in May 2022 and its spillover into traditional financial markets, while the exchange rate channel is distorted by cryptocurrency-facilitated cross-border capital outflows that undermine currency control mechanisms.
4. Empirical validation of the proposed model using ECB and Federal Reserve policy data confirmed the model's explanatory and predictive power across different market conditions. Granger causality tests confirmed that macroeconomic factors – primarily the VIX volatility index and S&P 500 – determine cryptocurrency price movements, meaning that cryptocurrencies absorb external macroeconomic shocks rather than generating independent systemic volatility. The ECB's sensitivity to cryptocurrency volatility increased substantially during the 2020–2022 crisis compared to pre-crisis levels, while regulatory measures adopted after 2022 produced a measurable stabilising effect, confirming that the regulatory environment acts as a buffer in the monetary policy transmission process. Federal Reserve policy transmission was found to have a stronger and more immediate impact on cryptocurrency markets than ECB policy, especially during crisis periods, indicating the need for dynamic and asymmetric policy calibration by central banks.
5. The empirical analysis was limited to three major cryptocurrencies – Bitcoin, Ethereum, and Binance Coin – selected on the basis of majority market capitalisation coverage, which limits the generalisability of results to the wider class of

digital assets. The analysis relied exclusively on the policy variables of the Federal Reserve and the European Central Bank, leaving out other systemically important central banks such as the Bank of England, the Bank of Japan, and the People's Bank of China, whose inclusion could reveal additional dimensions of the cryptocurrency-monetary policy interaction. The use of daily closing prices does not capture the full range of price movements, as cryptocurrency markets operate continuously, including weekends and holidays. Future research should address these limitations through higher-frequency data, extended geographic coverage of central bank policy regimes, natural experiments to strengthen causal inference, and expansion of the model to a broader class of digital assets, including stablecoins and Central Bank Digital Currencies.

Tomas PEČIULIS

VALIUTŲ RINKOS EVOLIUCIJOS SĄVEIKA
SU MONETARINĖS POLITIKOS INSTRUMENTAIS
SKAITMENIZACIJOS AMŽIUJE

Daktaro disertacija

Socialiniai mokslai,
Ekonomika (S 004)

INTERACTION OF CURRENCY MARKET EVOLUTION
WITH MONETARY POLICY INSTRUMENTS IN
THE AGE OF DIGITIZATION

Doctoral Dissertation

Social Sciences,
Economics (S 004)

Lietuvių kalbos redaktorė Rita Malikėnienė
Anglų kalbos redaktorė Jūratė Griškėnaitė

2026 05 08. 14,3 sp. l. Tiražas 20 egz.
Leidinio el. versija <https://doi.org/10.20334/2026-031-M>
Vilniaus Gedimino technikos universitetas
Saulėtekio al. 11, 10223 Vilnius
Spausdino UAB „Ciklonas“,
Žirmūnų g. 68, 09124 Vilnius