СОФИЙСКИ УНИВЕРСИТЕТ „СВ. КЛИМЕНТ ОХРИДСКИ“ основан 1888 г.

СТОПАНСКИ ФАКУЛТЕТ

АВТОРЕФЕРАТ

МИКРО- И МАКРОИКОНОМИЧЕСКИ ФАКТОРИ, ВЛИЯЕЩИ НА ЦЕНОВАТА ДИНАМИКА НА КРИПТО АКТИВИ

за присъждане на образователна и научна степен „Доктор”

Направление 3.8. Икономика: Икономика и управление (индустрия)

Кандидат: Димитър Шалварджиев

Научен ръководител: Проф. д. ик. н. Антон Герунов

София, 2025

Дисертационният труд на тема „Икономически фактори, влияещи върху динамиката на цените на криптоактивите“ се състои от 138 страници, от които 117 страници представляват основният текст, приложенията и библиографията. Основната част е структурирана в увод, четири глави и заключение. Дисертацията съдържа 23 фигури, 17 таблици и 67 уравнения. Общо 189 научни източника — книги и статии в рецензирани списания, всички на английски език — са цитирани и включени в библиографията.

По темата на дисертацията са публикувани две статии в научни списания. Основните резултати от изследването са дискутирани както с практици, така и с учени в областите на микроикономиката, макроикономиката и финансите.

Авторът е задочен докторант в Катедра „Икономика и управление по отрасли“ на Стопанския факултет на Софийския университет „Св. Климент Охридски“.

Съдържание

Съкращения и абревуиатури **5**

Въведение ***6***

Актуалност на изследването **6**

Цели на изследването **7**

Предмет и обект на изследването **8**

Изследователски хипотези **9**

Изследователски цели и задачи **10**

Методология **11**

Първа глава: Криптовалути: комплексни, слабо регулирани и нестабилни ***13***

1.1. Значими особености на криптовалутите **14**

1.2. Фундаментална стойност на криптовалутите **14**

1.3. Криптовалутите: Транзакционно или инвестиционно средство? **15**

1.4. Макроикономически въздействия **16**

1.5. Микроикономически въздействия **17**

1.6. Блокчейн активи отвъд валутите: Собственост и незаменимост (non-fungibility) **19**

1.7. Риск при крипто активи **20**

1.8. Основни пропуски в литературата и насоки за бъдещи изследвания **21**

Втора глава: Състояние на пазара на крипто активи ***22***

2.1. Описание на пазара на криптоактиви в развитие **23**

2.2. Стационарност и сезонност на доходността от крипто активи **24**

2.3. Дефиниции и предпоставки за обобщен скрит Марков модел (CMM) **27**

2.4. Оценка на модела и първични изводи **28**

2.5. Икономическа значимост и интерпретация 32

Трета глава: Макроикономически ефекти върху ценовата динамика 32

3.1. Моделиране на пазара на крипто активи чрез макроикономически показатели 33

3.2. Хроничната инфлация като определител на пазарното търсене 38

3.3. Ефекта на Spot ETF на Биткойн върху цената на актива 39

3.4 Икономическа значимост и интерпретация 42

Четвърта глава: Микроикономически влияния върху ценовата динамика 43

4.1. Как потребителските нагласи определят ценовата динамика 44

4.2. Прогнозиране на ценова нестабилност и възвръщаемост чрез потребителски нагласи 48

4.3. Потребителски настроения отвъд Биткойн 50

4.4. Частният случай на мемевалутите 51

4.5. Практически съображения, критика и потенциал на реализация 53

Заключение и научни приноси 54

Научни приноси 55

Списък с публикации по темата на дисертационния труд 56

Списък с публикации извън темата на дисертационния труд 56

Бъдещи насоки на изследване 56

Съкращения и абревиатури

AIC	Информационен критерий на Akaike
AML	Борба с прането на пари
ADF	разширен тест на Дики–Фулър
BIC	Информационен критерий на Bayes
BTC	Биткойн
CBDC	Дигитални валути, създадени от централна банка
CDF	Cumulative Density Functions
CeFi	Централизирани финансови услуги
CLI	Композитен водещ индикатор
CTF	Борба с финансирането на тероризъм
DCF	Дисконтиран паричен поток
DeFi	Децентрализирани финанси (и свързани услуги)
ECB	Европейска Централна Банка
EM	Алгоритъм за максимизация на очакванията
EPU	Несигурност на икономическата политика
ES	Expected Shortfall
ETH	Етер, криптовалута
FRED	Икономически данни на Федералния резерв на САЩ
FZL	Fissler and Ziegel joint loss dynamic models
GARCH	Generalized Autoregressive Conditional Heteroskedasticity
HC3	Heteroskedasticity-consistent standard error estimator
HMM	Скрита верига (модел) на Марков
ICO	Първоначално предлагане на криптоактив
IV	Instrumental Variable
KPSS	Kwiatkowski-Phillips-Schmidt-Shin (KPSS) tests
M1, M3	Обем на парични агрегати M1 и M3 Volume (нормализирани в $)
MAE	Средна абсолютна грешка
MPT	Модерна теория за управление на портфолио
MSTL	Multiple Seasonal–Trend decomposition using Loess
NFT	Non-fungible Tokens
OECD	Организацията за икономическо сътрудничество и развитие
OLS	регресия по метода на най-малките квадрати
PCA	Principal Component Analysis
PDF	Probability Density Function
PoS	Proof-of-Stake
PoW	Proof-of-Work
Prophet	Модел за предвиждания от Taylor & Letham
RMSE	Средна квадратична грешка
SARIMA	Seasonal Autoregressive Integrated Moving Average
SARIMAX	Seasonal ARIMA with eXogenous variables
SVM	Машина с поддържащ вектор
TBATS	Trigonometric, Box-Cox transformation, ARMA errors, Trend, Seasonal components
TVS	Скок на обема съобщения в Туитър
USDT	Тетер, стабилна валута, базирана на щатски долар
VaR	Value at Risk
VAR	Векторна авторегресия
VECM	Vector Error Correction Mode
WUI	Световен индекс на несигурността (средна, претеглена спрямо БВП)

Въведение

Криптовалутите се утвърждават като явление в съвременните финанси, преминавайки от нишов експеримент към актив, чиято капитализация съперничи на средно големи национални фондови борси. Ценовите им траектории остават известни със своята силна дисперсия и получават само частично обяснение от класическите теории за оценка на активи. Настоящата дисертация цели да попълни именно тази празнина, като изследва икономическите влияния – макроикономически, микроикономически и поведенчески – формиращи оценката на цифровите активи. Изследването отговаря на потребността от научна теория на инвеститори, регулатори и учени, изправени пред пазар, който се развива по-бързо от наличния аналитичен инструментариум. Бързото разрастване на криптоактивите, тяхната способност да предават шокове в по-широката финансова система и политическият императив за ефективен надзор правят настоящото изследване едновременно академично навременно и практически значимо.

Актуалност на изследването

Дисертационният труд разглежда клас активи, чиято пазарна капитализация нараства рядко срещани при традиционните инструменти темпове, но чието ценово поведение остава силно променливо и епизодично. Тази комбинация от бърз растеж и турбулентни колебания изисква задълбочен икономически анализ, тъй като инвеститорите, регулаторите и администрацията не могат да се опират на изградената си интуиция или аналогии с традиционните пазари при оценката на активи, за да участват, облагат или регулират дигиталния пазар.

Съществуващата икономическа рамка не отразява в достатъчна степен децентрализирания характер на блокчейна: графикът на емитиране, механизмите на управление и информационните потоци се различават фундаментално от суверенните фиатни системи; вследствие на това конвенционалните инструменти за оценка на риск често погрешно характеризират криптоактивите, както и интерпретират грешно системните външни ефекти. Настоящето изследване запълва критична концептуална празнина и поставя аналитична основа за бъдещи емпирични и регулаторни трудове, като систематично разширява икономическата и финансова теория с дигиталните механизми на предлагане и разплащания, основани на блокчейн, както и базираните на потребителски настроения шокове в търсенето.

Значимостта на изследването е висока и заради все по-тясното преплитане на дигитални активи с традиционната финансова система: интеграциите с борсово търгувани продукти, с платежни услуги и институционални портфейли създават канали, през които турбуленцията на криптопазара може да се прехвърли към банковия, пенсионния и застрахователния сектор. Затова детайлното проучване на икономическите влияния е ключово за централните банки и надзорните органи, които целят да формулират пропорционална, основана на доказателства политика, която да съхрани стопанската активност, без да задушава иновациите или да ограничава инвестициите.

Технологичните нововъведения като платформи за „умни“ договори и програмируеми пари разширяват значението отвъд стандартното оценяване на активи, като показват потенциал за развитие в областта на разплащанията, финансирането на вериги за доставки и цифровата идентичност. Оценката на влиянието на тези технологии върху формирането на стойност предоставя по-ясна представа на икономисти и технолози къде могат да се реализират производителни печалби от една страна и къде биха могли да възникнат нови форми на системен риск – от друга.

Накрая, дисертацията запълва емпирични пропуски в досегашната литература, като интегрира макроикономически показатели, регулаторни променливи и високочестотни поведенчески данни в единна иконометрична рамка, базирана на машинно обучение. Подобна холистична перспектива е необходима, за да се разграничат правилно причинно-следствените отношения на икономическите агенти. Разграничават се припокриващи се ефекти като хеджиране срещу инфлация, политически шокове и потребителски нагласи, и се постигат статистически устойчиви резултати, които са едновременно и релевантни за академичните среди, инвеститорите и регулаторите, занимаващи се с този все още еволюиращ клас активи.

Цели на изследването

Основната цел на дисертацията е да разкрие и обясни икономическите механизми, които определят колебанията в цените на криптовалутите, като по този начин се преодолее разрива между абстрактната теория за оценка на активи и практическата действителност на този силно турбулентен новосформиран пазар. Изследването се стреми да създаде доказателствена база, която регулатори, инвеститори и учени могат да използват при тълкуване на пазарните движения, формулиране на политики и усъвършенстване на модели за оценка.

Първата конкретна цел е да се измери как измененията в инфлацията влияят върху търсенето, а оттам и върху ценообразуването на водещите криптовалути. Проучването проверява дали нарастващите потребителски ценови индекси във фиатните икономики систематично водят до по-широка употреба на криптоактиви и по-високи стойности на основните крипто валути, разглеждайки цифровите активи като потенциални хеджове или „убежища“. Международни данни позволяват съпоставяне на инфлационни траектории с промени в доходността на криптовалутите, като така се улавят различията между отделни парични режими.

Втората цел е да се изолират ефектите от държавните политики – от проактивно регулиране до ограничения върху капиталовите пазари – върху пазарната стабилност и търговското поведение. Сравнявайки строги, либерални и хибридни регулаторни режими и анализирайки епизоди на капиталови потоци, породени от санкции, изследването цели количествено да оцени политическите шокове и да открои каналите, през които официалните действия усилват или отслабват колебливостта на криптопазара.

Третата цел е да се измери как промените в колективните потребителски нагласи влияят върху краткосрочното формиране на цените. Техники за обработка на естествен език се прилагат върху социални медии, новинарски източници и пазарни коментари, за да се създадат индекси на нагласите, чиято прогностична сила спрямо доходността и риска се оценява спрямо пазарния фундамент.

Предмет и обект на изследването

Обект на настоящото изследване е наблюдаваната ценова динамика на най-големите и най-ликвидни криптовалути, търгувани на световните борси, докато предметът е по-тесен и аналитичен: разглежда се съвкупността от икономически сили, които влияят на тази ценова динамика. Конкретно дисертационният труд приема три категории въздействия за централен предмет на анализа — трайния инфлационен натиск във фиатните икономики, структурата и времевата последователност на регулаторните или санкционните политики, обкръжаващи пазарите на цифрови активи, както и колективната потребителска нагласа на пазарните участници, отразена в публичното пространство. Фокусирайки се върху тези движещи сили, а не върху самите критпоактиви, изследването третира цените на валутите като зависима променлива, чието поведение може да бъде частично обяснено чрез взаимодействието между

макроикономически стрес, институционално нормотворчество и групова психология в условията на децентрализирана финансова среда.

В този смисъл, обектът се конкретизира чрез измерими величини: международни индекси на потребителските цени и неочаквани инфлационни отклонения; законодателни промени и регулаторни действия, които преначертават правната среда за търговия с криптовалути; както и показатели за потребителски нагласи, извлечени от социални медии, медийно отразяване и пр. Всеки от тези фактори се изследва за неговата самостоятелна и съвместна способност да обяснява или прогнозира ценовите движения на биткойн, етер и представителна кошница от високо капитализирани валути.

Изследователски хипотези

Дисертационният труд превежда тематичните си цели в шест ясни, проверими твърдения, които заедно формират основните изследователски хипотези. Всяко твърдение очертава конкретен икономически фактор, предвижда ефект върху цените на криптовалутите и задава основа за статистическо изпитване.

Първа хипотеза: Дигиталните активи могат да се използват като хедж инструменти, подобно на злато или фиатни валути. Подобно наблюдение може да се направи, в случай, че ценовата динамика на крипто активи има обратна корелация с традиционните пазари - особено в случаите, в които традиционните пазари са изправени пред системен риск и неопределеност.

Втора хипотеза: Дигиталните активи, по подобие на борсовите, имат сезонност и „скрити“ пазарни състояния, които определят ценовата им динамика и риск. Подобна сезонност може да влияе и „прикрива“ по-слабо изразени макро- и микроикономически влияния.

Трета хипотеза: Продължително високата инфлация във фиатните икономики повишава привлекателността на водещите криптовалути като алтернативни средства за съхранение на стойност. Очаква се положителна връзка между трайно високата инфлация и степента на приемане, от една страна, и пазарната стойност на основните блокчейн валути – от друга.

Четвърта хипотеза: Структурираните финансови инструменти (напр. Spot ETF фондове) влияят върху ценовата динамика на дигитални активи. Подобна връзка следва да се

проучи двупосочно, за да се изясни влиянието на пазарни шокове от и към традиционните финансови пазари.

Пета хипотеза. За разлика от традиционните очаквания, широките макроикономически показатели в ключови юрисдикции – като производствени разриви, равнища на лихвения процент или тенденции в безработицата – нямат статистически значимо влияние върху динамиката на цените на криптовалутите. Ако бъде потвърдено, това би свидетелствало за функционално отделяне на децентрализираните цифрови активи от цикличните сили, които управляват повечето ценни книжа.

Шеста хипотеза. Краткосрочното формиране на цени се определя от изменения в колективната потребителска нагласа. Положителните колебания в нагласите, извлечени чрез обработка на естествен език от новинарски потоци и социални медии, предхождат измерими нараствания на доходността, докато негативните настроения вещаят понижения, като мащабът на реакцията варира според текущия пазарен режим.

За всяко твърдение отхвърлянето на нулевата хипотеза постановява незначителен от статистическа гледна точка ефект. Статистическите проверки – регресии по метода на най-малките квадрати за инфлацията, модели със смяна на режими и векторна авторегресия за макропроменливите, както и прогностични модели с включени показатели за настроение – са разработени да приемат или да отхвърлят тези хипотези при общоприети нива на доверие.

Изследователски цели и задачи

Главната цел на дисертационния труд е да открие и анализира икономическите двигатели, които влияят върху ценовите колебания на криптовалутите, като по този начин обогати научното разбиране за начина, по който макроикономическите фактори, институционалните условия и психологията на инвеститорите взаимодействат при формирането на пазарната динамика.

За постигането на тази цел първата задача е систематичното изграждане на изчерпателен корпус от данни. Това включва събиране на високочестотни серии за цени на криптовалути, обеми на търговия и пазарна капитализация, както и трансгранични инфлационни показатели, по-широки макроикономически индекси и масиви от данни за пазарни настроения, извлечени от социални мрежи, информационни агенции и аналитични доклади.

Втората задача е прилагането на устойчиви статистически методи към този корпус, с цел количествено определяне на връзката между инфлацията и цените на криптовалутите и проверка дали макроикономическата нестабилност подтиква инвеститорите да третират цифровите активи като алтернативни хранилища на стойност.

Третата, тясно свързана, задача е да се изследва по-широкият набор от макроикономически сили – като лихвени равнища, производствени разриви и политическа несигурност – и да се оцени чрез иконометрично моделиране дали тези променливи оказват значимо влияние върху ценовата динамика на криптовалутите или предизвикват краткотрайни ефекти, свързани с потока на пазарни новини. От микроикономическа гледна точка ще бъдат приложени съвременни методи за обработка на естествен език и анализ на настроенията, за да се измери как промените в колективното настроение се отразяват в пазарните цени.

Четвъртата задача е разработването и валидирането на интегрирани иконометрични и машинно-обучаващи се модели, които съчетават икономически индикатори с показатели за настроения, за да прогнозират движението на цените на криптовалутите. Тези модели ще бъдат подложени на тестване с данни извън извадката и на кръстосана валидация, така че тяхната прогностична точност и надеждност да бъдат оценени холистично.

Накрая, изводите от анализа на данните и резултатите от моделите ще бъдат синтезирани в интерпретативна рамка, която изяснява каналите, чрез които външни икономически фактори, регулаторни интервенции и поведенчески реакции влияят върху пазара на криптовалути. Документирането на тези резултати завършва изследователската програма и предоставя практически насоки както за инвеститорите, така и за регулатори.

Методология

Емпиричната работа започва с изграждането на многомерна архитектура на данните. Високочестотни редове за цени, обеми и пазарна капитализация на Bitcoin, Ethereum и кошница от други високо капитализирани валути са извлечени от водещи борси; събран е панел от макроикономически данни, включващ над двадесет показателя – парично предлагане, реален растеж на БВП, безработица, индекси за политическа несигурност и реални лихвени проценти за водещите икономики; събрани са данни за регулаторни интервенции, международни санкции и нетни потоци към борсово търгувани фондове

(ETF) към спот пазара. Данните от социални мрежи и новинарски източници са събрани чрез програмни интерфейси (API) и формират набор данни за анализ на пазарните настроения. Всички първични файлове се хармонизират към обща времева рамка, почистват се от атипични стойности и се обединяват в релационна база, готова за статистическа обработка.

Предварителните диагностични проверки отчитат дистрибуционните характеристики на възвръщаемостта от криптоактиви. Стационарността е проверена чрез разширения тест на Дики–Фулър (ADF) и KPSS; сезонността е изследвана с MSTL, TBATS и Prophet-разлагания. Тестовете на Ljung–Box, Shapiro–Wilk и Breusch–Pagan потвърждават, че изчистените серии запазват „тежки опашки“ и хетероскедастичност – факт, който предопределя избора на по-устойчиви модели и използването на хетероскедастично-коригирани стандартни грешки.

Макрофинансовите данни се моделират в йерархична иконометрична рамка. Общ скрит Марков модел с Гаусови емисии, оценен чрез алгоритъма за максимизация на очакването, засича латентни режими на неопределеност. Дългосрочните и краткосрочните отношения между цените на криптоактивите и макроикономическите променливи се оценяват чрез коинтегриран векторен авторегресионен модел и векторен модел за корекция на грешки; причинно-следствените връзки се изследват с тестове на Грейнджър, а регресии по метода на най-малките квадрати изолират ефекта на хроничната инфлация върху употребата на крипто активи.

Поведенческата динамика е изследвана чрез алгоритми за обработка на естествен език, който разделя данните на токъни, отстранява шума и оценява всяко мнение по оста позитивно–негативно. За краткосрочно прогнозиране се обучават класификатори „машина на опорните вектори“ и „случайна гора“; ефективността на моделите се оценява чрез извънизвадкови стойности на RMSE, MAE и показатели за точност на посоката.

След утвърждаване на методологията, преминаваме от абстрактния дизайн към конкретните резултати. Следва последователното рапортуване на четирите същински глави, представени в общия план на дисертацията, като всяка следваща надгражда предходната – от базовата характеристика на пазара, през макроикономическата проверка и микро-поведенческия анализ, до синтеза на интегрирана прогностична архитектура. Проследяването на главите в посочения ред ще демонстрира как теоретичните основания и резюмираните тук методи се превръщат в конкретни открития, кумулативни изводи и, в крайна сметка, научни приноси.

Първа глава: Криптовалути: комплексни, слабо регулирани и нестабилни

В оригиналната си статия Сатоши Накамото (Nakamoto, 2008) описва първия криптографски актив – Биткойн – като „система за електронни плащания с директен превод“ – децентрализиран механизъм за финансови транзакции, който дава тласък за появата на широк спектър цифрови активи. В периода 2014–2017 г. се появяват допълнителни блокчейни и криптовалути. С течение на времето криптоактивите надхвърлят първоначалната си роля на заместител на традиционните пари и се превръщат в многопосочни инструменти на дигитализираната икономика, най-вече преносители на стойност (Baur, Hong, & Lee, 2018). 2020 година е характеризира с възхода на децентрализираните финанси (DeFi), които започват да използват умни договори за предоставяне на директни децентрализирани услуги (peer-to-peer), дотогава запазени за банки и други лицензирани институции (Aramonte, Huang, & Schrimpf, 2021). През 2021 г. се утвърждават незаменяемите токъни (NFT) – нов вид цифров актив, удостоверяващ собственост върху уникални обекти чрез технологията на блокчейн, и бързо печелят популярност (Yilmaz, Sagfossen, & Velasco, 2023). Концепцията за метавселената допълнително разширява обхвата на блоковите вериги и дигиталните активи – а заедно с това и търсенето – чрез виртуална реалност и цифрови икономики. (Davies, Sharifi, Lyons, Forster, & Elsayed, 2024)

Днес цифровите активи обхващат разнообразни форми: токъни, представящи материални активи, инструменти за управление на права и инвестиционни активи. Приложенията им са многобройни и засягат сектори от финанси до интелектуална собственост (Huang, Deng, & Chan, 2023). При анализа на икономическите фактори, оформящи ценовата динамика на тези активи, е важно да се осъзнае многопластовата им роля (Baur, Hong, & Lee, 2018). Разбирането на допълнителните ползи и по-широките последствия от навлизането на цифрови активи подготвя основата за холистична оценка на икономическото им въздействие и на факторите, влияещи върху пазарното им поведение.

Биткойн, първата създадена криптовалута, продължава да задържа най-голямата пазарна капитализация, като представлява приблизително 50 % от целия криптопазар. Неговото фиксирано предлагане, неутрална инфлация и ниският транзакционен капацитет обаче го правят атипичен актив. Затова читателят следва да отделя изводите, специфични за Биткойн, от изследванията на по-широкия пазар; ако не е посочено

друго, Биткойн се разглежда единствено като представител на криптовалутната вселена.

1.1. Значими особености на криптовалутите

Криптовалутите функционират върху децентрализирани мрежи, които намаляват зависимостта от централни финансови органи, като понижават транзакционните разходи, ускоряват преводите и разширяват финансовото приобщаване. Тези активи съществуват изцяло в цифров вид, което ги отличава от физически активи като пари в брой, недвижими имоти или суровини, и позволява бързи глобални преводи без физическите ограничения, характерни за традиционните активи. Широко е възприемането, че блокчейнът и производните ѝ криптовалути предоставят псевдонимност, а не пълна анонимност (Halpin & Piekarska, 2017; Malinova & Park, 2017). Дигиталната им природа обаче поражда и регулаторни предизвикателства – защитата на потребителите, мерките срещу изпирането на пари (AML) и финансирането на тероризъм (CTF) изискват глобално сътрудничество за ефективно управление (Arner, Zetzsche, Buckley, & Kirkwood, 2024). Макар регулациите да се развиват в опит да адресират тези проблеми, правният статут на цифровите активи остава динамичен и подложен на промени с развитието на нормативната рамка.

Цените на цифровите активи са подложени на резки колебания, а ликвидността варира значително, което повишава разходите за търговия и пазарната нестабилност. Липсата на ликвидност – водеща до невъзможност за търговия без съществен ценови влияния – се дължи на ниски обеми и фрагментирани борси с различна дълбочина, ликвидни „басейни“ и ограничен достъп, което поражда междуплатформени ценови отклонения (Gandal & Halaburda, 2016). Освен това младостта на пазара засилва риска от манипулации и спекулативни ценови скокове (Gandal, Hamrick, Moore, & Oberman, 2018). Дори водещите активи могат да търпят негативи в случаи на неопределеност (Gerunov, 2022) , така че липсата на ликвидност остава ключово предизвикателство за стабилността както за инвеститорите, така и за регулаторите.

1.2. Фундаментална стойност на криптовалутите

Ранните опити за оценяване разглеждат „фундаменталната полезност“ на криптовалутите като нищожна и третират цената им като спекулативен балон (Cheah and Fry, 2015). Дали Биткойн е пари или само спекулативен актив остава спорно: за да съперничи на парите, той трябва да изпълнява функции на разчетна единица, средство за размяна и средство за съхранение на стойност, ала спекулантите на пазара

доминират (European Central Bank, 2012; Dwyer, 2014; Shiller, 2005; Weber, 2014). Критиците изтъкват, че без държавна подкрепа и статус на платежно средство Биткойн не може да претендира за присъща стойност (Van Alstyne, 2014). Според теорията за парите като бъдещи вземания Биткойн представлява социално отношение – бъдещо вземане към емитента; освен това той може да се разглежда като законно платежно средство по отношение на принудителните плащания на дългове и данъчни задължения (Bell, 2001; Dequech, 2013; Ingham, 2004). Въпреки това, данъчните органи се разминават в оценката си: САЩ третират Биткойн като облагаемо имущество, докато Германия го признава за отчетна единица (Van Alstyne, 2014). Въпросът за използването на криптовалутите като законно платежно средство и широкият спектър регулаторни фактори, включително данъчното третиране, са съществени за ценовата динамика и ще бъдат разгледани отделно.

Конвенционалните модели за оценяване се оказват недостатъчно описателни за особеностите на повечето криптовалути, тъй като те не генерират стабилни парични потоци и нямат истински съпоставими аналози (García-Monleón et al., 2021). Затова изследователите прибягват до косвени подходи. При метода на „програмируемите разходи“ присъщата стойност е нищожна – подобно на фиата, чиято материална себестойност е незначителна спрямо номинала. В рамката на „разходите за копаене“ (Hayes, 2017), производствените разноски (≈ 40 000 щ.д. през 2021 г.) се съпоставят с пазарните цени (≈ 53 000 щ.д.), но разходите за копаене следват, а не определят цената. По-натоварен с предположения е моделът на дисконтиран паричен поток, основан на транзакции и съхранение (Mitchnick & Athey, 2018), който комбинира осем параметъра за прогноза на общата стойност, но е силно податлив на екстремни стойности. Други модели, основани на интуиция – например приравняване на Биткойн към злато – стигат до хипотетични цени до 609 000 щ.д., докато пълна глобална валутна замяна поражда оценки около 4,4 млн. щ.д. Всеки подход е крайно чувствителен към заложените предпоставки и предоставя , в най-добрия случай, груба, приблизителна оценка на стойността.

1.3. Криптовалутите: Транзакционно или инвестиционно средство?

Криптовалутите се проявяват едновременно като възможност за инвестиция и като средство за разплащане, но доминиращата им употреба остава на силно ценово нестабилни активи, а не на платежно средство. Ранно изследване в Университета Гьоте – Франкфурт (Zimmermann & Weber, 2014) показва, че през 2011–2013 г. повечето нови потребители търгуват Биткойн с цел печалба, а приблизително 70 % от монетите остават неизползвани, свидетелствайки за поведение, типично за актив. Baur et al.

(2018) впоследствие потвърждават едва слаби корелации с традиционни активи и минимална функция на „убежище“, въпреки трансграничния характер и устойчивостта срещу цензура.

Стабилните валути (stablecoins), проектирани да поддържат ценова стабилност, се появяват като решение на ценовата дисперсия и за повишаване на пазарната ефективност чрез осигуряване на ликвидност и улесняване на арбитража (Li et al., 2024; Zhang & Li, 2021). Те също така подпомагат DeFi услугите и трансграничните плащания, служейки и като временно убежище (Mita et al., 2019; Catalini et al., 2022). Въпреки потенциала си, алгоритмичните разновидности се сринаха през 2021–2022 г. под натиска на огромни по обем изходящи потоци (Saengchote & Samphantharak, 2024), като дори обезпечените със залог стабилни валути носят риск от загуба на стойността (MacDonald & Zhao, 2022). Така стабилните валути се сблъскват с трилема – децентрализирана верификация, суверенитет и стабилност на покупателната способност – което не може да бъде напълно съвместено (Koutsoupakis, 2021).

Дигиталните валути на централните банки (CBDC) са в пилотна фаза сред множество емисионни институции (Ozili, 2021) под формата на цифрови дългови инструменти с окончателно сетълментно действие и механизъм на валутна еквивалентност, но дизайнът им трябва да балансира поверителност, регулаторно съответствие и оперативна съвместимост (Claeys et al., 2018). Анализи и модели сочат, че CBDC могат да засилят паричния контрол и финансовото приобщаване, но увеличават риска от банкови паники при неправилно олихвяване (Yao, 2018; Ahnert et al., 2023).

1.4. Макроикономически въздействия

Цените на криптовалутите се движат съвместно с макроикономически променливи – парична политика, инфлация, растеж, геополитически риск и регулации – главно чрез канали на ликвидност и нагласа към риск. Интересът към частни криптоактиви и CBDC нараства (Ozili, 2021), , подтиквайки политиците да разглеждат CBDC като инструмент за финансово приобщаване и валутна еквивалентност, макар да възникват компромиси между поверителност и изискванията за AML/KYC (Claeys et al., 2018). Фискални мерки като данъчно облагане или субсидиране на криптотранзакции – също се показват като потенциални двигатели на търсенето, а потенциални решения за създаването на CBDC биха повлияли върху приемането им и стабилността на банковия сектор (Yao, 2018; Ahnert et al., 2023).

Емпирични доказателства, като приемането на Биткойн в Ел Салвадор, разкриват както ползи свързани с ефективността, така и предизвикателства по линия на равнопоставеността, тъй като чуждестранни инвеститори и местни елити се облагодетелстват повече от уязвимите групи. Геополитически шокове – войни, санкции и търговски напрежения – предизвикват краткотрайни скокове на дисперсията (Araujo et al., 2023; Zhou, 2022), докато измененията в митата между САЩ и Китай и несигурността на икономическата политика се свързват с колебания в стабилността и потенциала за капиталово разпределение на криптопортфейли (Kurihara, 2022; Hung et al., 2023).

Динамиката на енергийните цени влияе върху разходите за копаене и екологичните ефекти: поскъпването на електроенергията увеличава производствените разходи и трудността на мрежата, а шоковете в цените на петрола корелират умерено с възвръщаемостта на криптовалути в средносрочен хоризонт (Corbet et al., 2021; Bani-Khalaf & Taspinar, 2022). Обратните преливания обаче са слаби, а тестове на Грейнджър отхвърлят силна двупосочна причинно-следствена връзка (Gurrib, 2019).

1.5. Микроикономически въздействия

Микроикономическите фактори – демографски особености на инвеститорите, техните предпочитания, използвани инструменти и психология – определят в решаваща степен търсенето на криптоактиви, тяхната несигурност и пазарната им ефективност (Baur & Dimpfl, 2018). В тази секция разглеждаме характеристиките на потребителите / инвеститорите в криптовалути и техните предпочитания.

Глобалните притежатели на криптовалути са предимно млади мъже. Поколението на родените в период 1981-2000 преобладава числено, но управлява по-малки портфейли; то търси иновации и висока възвръщаемост, докато по-възрастните инвеститори отдават приоритет на историческото представяне и доходност (Jin, 2024) Финансовата грамотност и степента на опит насърчават дългосрочни вложения в технологии на разпределената счетоводна книга (DLT), а начинаещите търгуват импулсивно, водени от краткосрочната ценова динамика (Fujiki, 2020). Половите различия се запазват: мъжете проявяват по-голямо доверие в потенциала на блокчейн, дори след като се изгладят апетита за риск и образование. (Alonso, Jorge-Vazquez, Rodriguez, & Hernandez, 2023). Детерминантите на инвестиционното поведение се различават по възрастови групи: по-младите по-лесно приемат висок риск и търсят слабата корелация между криптоактиви и традиционна икономика, като същевременно изразяват песимизъм за бъдещето си в „реалната“ икономика (Colombo & Yarovaya, 2024; Martins, 2024). По-

възрастните проявяват по-силна зависимост от собствената си толерантност към риск и по-голям оптимизъм към икономическия макро фундамент.

Потребителите посочват сложността на частните ключове, погрешни очаквания за анонимност и недостатъчните инструменти като основни рискове за сигурността (Kowalski, Green, Lilley, & Panourgias, 2023). Липсата на доверие, ограниченото приемане от търговци, безпокойствата за поверителност и сигурност и фрагментираната регулация възпрепятстват масовото използване и ограничават мрежовите ефекти (Mahsatan, Sangari, & Deghani, 2022; O'Dair, 2019; Jonker, 2019). Пазарната неопределеност, минали пазарни сривове и правните неясноти около статуса на валутите допълнително подкопават увереността (Gorman & Tigwell, 2023; Sheoran, Gupta, & Karanjule, 2023; Alekseenko, 2023). Още пречки внасят липсата на единен на „бранд“, проблемите на механизма „доказателство за работа“ (PoW) по отношение на мащабируемост и енергийна консумация, както и ниската финансова грамотност на някои групи потребители (Kowalski, Green, Lilley, & Panourgias, 2023; Mai, Pfeffer, Gussenbauer, Weippl, & Krombholz, 2020).

Регулираните „мостове“ между традиционната и цифрова икономика, например борсово търгуваните фондове (ETF) върху спот биткойн, смекчават горните бариери. Анализите, основани на индекса CRIX, показват, че основните активи (BTC, ETH) запазват устойчивост в рамката на ETF, подобрявайки ликвидността и намалявайки търговските разходи (Häusler, 2022) (Kim, Lee, Yim, An, & Choi, 2022; Deville, Gresse, & de Severac, 2009). Пускането на ETF обикновено повишава цените и обемите на съответните жетони, като ефектът е по-силен при слабо търгувани валути (De Winne, Gresse, & Platten, 2012; Madura & Ngo, 2008). Последните развития – продукти на Wells Fargo и Merrill Lynch, както и над 400 институционални участници в iShares Bitcoin Trust на BlackRock – потвърждават, че инвеститорите предпочитат позната, добре регулирана инфраструктура..

Анкетни данни свързват положителното инвеститорско настроение с о§акванията за положителни възвръщаемости на криптовалутите (Anamika, Chakraborty, & Subramaniam, 2023). Това настроение се формира от новинарски и социалномедийни сигнали, които имат доказана прогностична, а понякога и пазарни манипулации (Chalkiadakis, Zaremba, Peters, & Chantler, 2022; Serada, 2023). Вълнови (wavelet) изследвания показват, че индексите на потребителски нагласи обясняват дългосрочни ценови цикли и резки спадове, макар реакцията да е разнородна при различните валути (Nasution, Noviasari, Nasution, & Melinda, 2022; Anamika, Chakraborty, & Subramaniam, Does Sentiment Impact Cryptocurrency?, 2023; Anamika & Subramaniam, Do news headlines matter in the cryptocurrency market?, 2022). Следователно методите за обработка на естествен

език, приложени към заглавия и публикации, са съществени за прогнозирането (AlNemer, Hkiri, & Khan, 2021; Dwivedi & Vemareddy , 2023). Еуфоричното настроение създава ценови балони, а неговият спад повишава неопределеността (Alanazi, 2022). При мащабни сривове емоции като страх, гняв и тъга увеличават потребителските нагласи и увеличават неопределеността, подчертавайки нуждата от по-силни предпазни механизми (Chen & Hafner, 2019). Анализи регистрират необичайни възвръщаемости около фалити на дружества, а „страхът да не изпуснеш възможност“ (FOMO) стимулира търсенето на алткойни и първични предложения на жетони (ICO) – до 25 % дял в портфейлите – особено при високи нива на разполагаем доход (Choi & Shin, 2023; Bo, 2023; Waghmare, Bansod;, & Patil, 2022; Gerrans, Abisekaraj, & Liu, 2023; Karkkainen, 2022).

1.6. Блокчейн активи отвъд валутите: Собственост и незаменимост (non-fungibility)

Незаменяемите токъни (NFT) представляват нов клас криптоактиви, който разширява приложението на блоковата верига отвъд традиционните криптовалути. NFT-тата са уникални, неделими жетони, които записват произхода и пътя си през блокчейн, позволявайки на създателите пряко да монетизират творбите си и да получават дивидент при всяка следваща препродажба чрез смарт договори (Falk, Tsoukalas, & Zhang, 2022; Cheung & Keung, 2022). Поделеното притежание прави достъпни иначе неликвидни активи като изкуство, музика или виртуална земя.

Цените на NFT-тата отразяват тяхната полезност (напр. Привилегии в компютърни игри, приходи от отдаване под наем), алгоритмичния недостиг и пазарните настроения. Рядкостта води до по-високи постойност, но по-редки като честота на сключване сделки: по-редките NFT се продават на по-високи цени, търгуват се по-рядко, но осигуряват по-голяма възвръщаемост и по-нисък риск (Mekacher, et al., 2022). Тъй като интересът към незаменяемите токъни (NFT), както и техните ценови равнища, се изменя във времето, началното им ценообразуване и лицензионните възнаграждения (дивиденти) могат да се разглеждат като инструмент за управление на риска. Когато и двете страни са боязливи, споделената собственост им позволява да поделят несигурността, произтичаща от бъдещата ценова несигурност. Този механизъм повишава вероятността за успешни транзакции и увеличава общата търговия.

По този начин съчетаването на лицензионни възнаграждения и първоначалната ценова дискриминация според степента на рядкост се развива във времето чрез динамично

ценообразуване, основано на информационна асиметрия. Чрез описания механизъм, незаменяемите токъни съдействат за по-ефективна, успешна и справедлива търговия на NFT-пазара. (Falk, Tsoukalas, & Zhang, 2022). Социалните мрежи и онлайн общности увеличават търсенето – например броят последователи в „Туитър“ и „Дискорд“ значително повишава оценките на NFT (Alon, Bretas, & Katrih, 2023; Cho, Jensen, Mahanti, & Kim, 2023). Човешките мрежови ефекти представляват важен определител на ценовата динамика, към който ще се върнем при разглеждането на риска. Накрая, пазарните условия в по-широката криптовалутна екосистема също оказват съществено влияние, тъй като се използва обща инфраструктура. Общият контекст на криптопазара има значение: високите такси за газ в мрежата Ethereum или рязкото нарастване на обемите в BTC/ETH охлаждат продажбите на NFT, разкривайки тесните инфраструктурни зависимости (Dagli, Pehlivan, & Ozbay, 2023)

1.7. Риск при крипто активи

Рискът в криптопазарите се характеризира с негаусови разпределения на възвръщаемостите, които проявяват изразена асиметрия и „дебели опашки“, недоловими за стандартните нормални модели. Затова се прилагат приближения на разпределенията с дебели опашки – например смеси от асиметрични Лапласови скали (ASLM) – за по-точно моделиране на плътността на възвръщаемостите (Punzo & Bagnato, 2022). ед избора на адекватна плътност могат да се изчислят очакваната възвръщаемост $\mathbb{E}[R]$ и риск σ , оето позволява оценката на стойност под риск (VaR) и очаквана загуба (ES) при зададено доверително ниво α. Съвместната оценка чрез функцията на загуба на Fissler–Ziegel (FZL) допълнително изостря прогнозите за VaR + ES (Fissler & Ziegel, 2016). Емпирични данни показват, че показателите VaR/ES за криптоактиви са приблизително двойно по-високи от тези на най-рисковите традиционни активи, ала инвеститорите приемат този повишен риск срещу по-голяма$\mathbb{E}[R]$ и диверсификационни ползи (Kopityn et al., 2018; Jeegers, 2023).

Ефективността, коригирана за риск, обикновено се обобщава чрез коефициента на Шарп, който съчетава $\mathbb{E}[R]$ и σ в един показател. Биткойн и Етериум често превъзхождат акциите по историческия Шарп, въпреки ликвидните триения – факт, породил коригирани варианти, отчитащи разходите за търговия (Hodoshima & Otsuki, 2019; Gerunov, 2022). в един показател. Биткойн и Етериум често превъзхождат акциите по историческия Шарп, въпреки ликвидните триения – факт, породил коригирани варианти, отчитащи разходите за търговия (Bouri et al., 2017; Dyhrberg, 2016), но функцията „убежище“ се оказва зависима от кризисния контекст (Baur & Lucey, 2015; Wang et al., 2019). Потенциалът за инфлационен хедж се основава на ограничената

емисия на валутата – така Биткойн се оприличава на „дигитално злато“ – ала емпиричните доказателства остават смесени и все още оскъдни поради младостта и нестабилността на пазара (Baur, Hong, & Lee, 2018; Alvarez & Argente, 2019).

Накрая, мрежовите и поведенческите ефекти се признават като основни двигатели на риска и възвръщаемостта. Прозрачността на блоковата верига позволява детайлен анализ – напр. съгласуване на ценови и социални фрактали (Kirichenko et al., 2017) и промени в настроенията, движени от инфлуенсъри в сегметни от мрежата (Yamamoto et al., 2019) – но манипулируемостта на данните и зависимостта от прокси-показатели (туитове, споделяния) затрудняват строгото картографиране. Въпреки това мрежовото влияние остава осезаемо на множество нива, оформяйки както спекулативните балони, така и възможностите за диверсификация (Stylianou et al., 2021). Затова количественото картографиране на тези динамики – и на техния потенциал за системен риск – остава ключов изследователски дефицит.

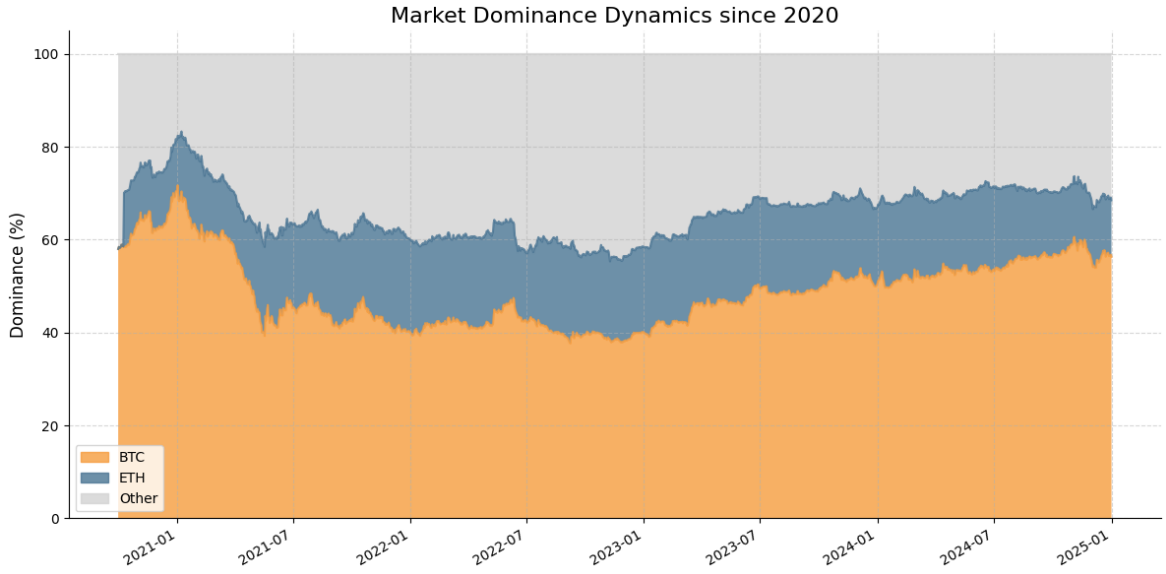

Фигура 1.1: Доминация на Биткойн според общата пазарна капитализация

1.8. Основни пропуски в литературата и насоки за бъдещи изследвания

Съществуват съществени изследователски пропуски. Доказателствата, че криптовалутите могат да хеджират ценовата инфлация, остават смесени и силно зависими от националния контекст; задълбочени многостранни панели с детайлни данни за паричните режими са рядкост (Corbet, Lucey, Urquhart, & Yarovaya, 2019; Bouri, Molnar, Azzi, Roubaud, & Hagfors, 2017). Регулаторните шокове раздвижват пазарите (Auer & Claessens, 2018) , но сравнителните анализи между хетерогенни регулаторни рамки –

и върху това как санкциите изменят каналите на търсене и предлагане – са ограничени (Foley, Karlsen, & Putnins, 2019). Изследванията с обработка на естествен език се концентрират върху краткотрайни реакции (Chen & Hafner, 2019), докато дългосрочните цикли на настроенията, технологично обусловените промени в нагласите и медийната динамика остават слабо проучени.

Запълването на тези празнини изисква междудисциплинарни подходи: обединяване на макроикономически панели от данни, данни от блокчейна и данни от социални медии; прилагане на усъвършенствана икометрия, методи за машинно самообучение и качествен контекст, за да се картографират връзката „инфлация – цена“, регулаторната хетерогенност и потребителските нагласи с по-голяма прецизност.

Втора глава: Състояние на пазара на крипто активи

Цел на главата е разработката устойчив модел, който да обясни как цените на криптовалутите се развиват под влиянието на микро- и макроикономически сили. Пазарите на криптоактиви са силно динамични, като поведението им може внезапно да премине от спокойно и устойчиво нарастване към експлозивен ръст или рязък срив. На микроикономическо равнище, блокчейн активността, ликвидността на борсите и общата потребителска нагласа играят решаваща роля за краткосрочната ценова динамика. Едновременно с това макроикономически фактори – съобщения за лихвени проценти, промени в глобалния апетит към риск и решенията на централните банки – нерядко задействат по-широки пазарни движения, които директно влияят върху настроенията и капиталовите потоци към цифровите активи. Съвкупността от тези сили поражда сложни взаимодействия, които стандартните времеви модели трудно улавят, особено ако предполагат един-единствен режим или относително стабилно разпределение на възвръщаемостите във времето.

Скритият Марков модел (СММ) улавя тази комплексност, като позволява възвръщаемостта да се прехвърлят между латентни състояния, всяко със собствена средна стойност, дисперсия и асиметрия. Разширяването на СММ с микро-показатели (мрежова употреба, обем) и макро-индикатори (инфлация, индекси на риска) (i) свързва смяната на режими с икономически задействащи събития и (ii) подобрява прогнозната точност. Идентифицирането на текущото или предстоящо състояние насочва алокацията на капитали, хеджирането и управлението на риска, осигурявайки по-

адаптивен поглед върху динамиката на криптоактивите в сравнение с еднорежимните времеви методи.

2.1. Описание на пазара на криптоактиви в развитие

За да изследваме пазарното поведение през периода 2014 – 2024 г., изграждаме криптоиндекс, подобен на борсовите пазарни индекси, но съобразен със спецификите на дигиталния пазар. Подборът на съставните активи се основава на четири критерия (Chan, 2021; O'Donnell, 2022):

Представителност – Покритието расте с броя активи, ала ползите намаляват, след като най-капитализираните монети – Биткойн и Етериум – все още превишават 70 % от пазарната стойност.

Ликвидност – Участниците трябва да показват достатъчен месечен обем, за да се избегнат „изстисквания" и схеми тип „помпа и изпускане"; токъните с малка капитализация често не издържат този тест.

Риск – Макар да не участва пряко във формулата, дисперсията измерва размера на ценовите разсейки във времето.

Отклонение при проследяване (*Tracking Error*) – Игнорира се тук, тъй като разходите по репликацията са извън обхвата на изследването..

Предишни проучвания показват, че за конструиране на всеобхватен пазарен индекс може да се използват само пет актива (Shah, Chauhan, & Chaudhury, 2021). За да избегнем капаните на прекомерната ценова нестабилност, потенциалните проблеми с ликвидността и технологичните рискове на отделни блокчейни (Chen, Chang, & Yang, 2023; Gerunov, 2022), настоящото изследване определя индексната кошница да съдържа дванадесет съставни актива.

Стабилните валути се изключват, тъй като те са закачени към американския долар и не добавят стойност по отношение на ценова динамика. Макар да осигуряват доларова ликвидност и такси, те не носят възвръщаемост и биха изкривили представянето на индекса.

Пазарно-капитализационно претеглен индекс базиран на дванадесет криптоактива се изгражда чрез определяне на общата пазарна стойност на всеки актив към даден момент. За да остане кошницата актуална, балансът се преразпределя ежемесечно. Актуализираните количества автоматично се отразяват в капитализацията на всеки

актив; валутите, загубили ликвидност или значение, се заменят. След всяко ребалансиране индексът се ре-нормализира към базовата дата/стойност, така че да остане непрекъснат. Дори промените в състава на индекса да причинят скок в общата капитализация, това съотношение запазва представителството, като същевременно позволява индексът да еволюира с пазарните условия. За да проверим предположението, че състоянието на криптопазара е адекватно описано, използваме корелацията между индекса и общата пазарна капитализация. Значителна аномалия е липсата на стабилни валути, но корелацията показва пренебрежим ефект.

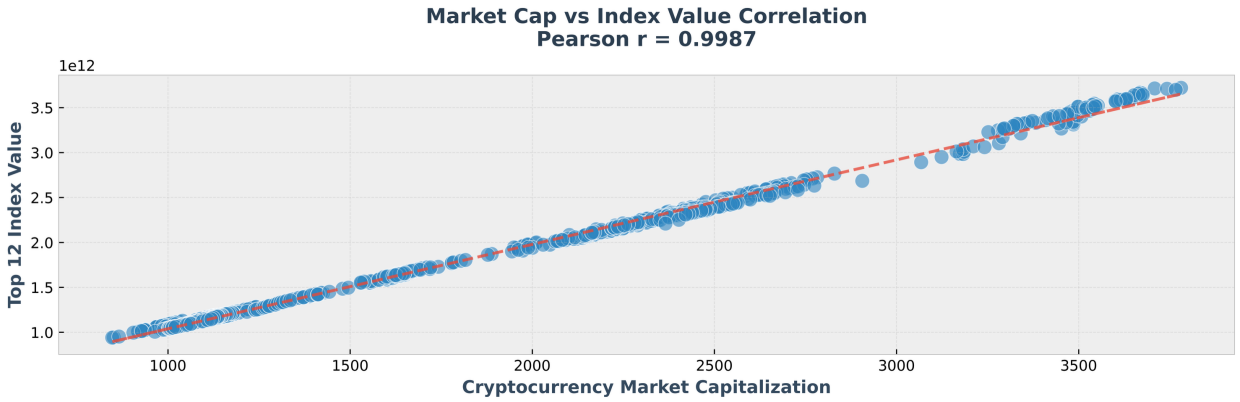

Фигура 2.1: Корелация между общата пазарна капитализация и стойността на индекса Топ 12

Корелационен метод	Стойност
Pearson	0.9987
Spearman	0.9979
Kendall	0.9696

Таблица 2.1: Стойности на корелация от Фигура 2.1

2.2. Стационарност и сезонност на доходността от крипто активи

Финансовите модели разчитат на доходност – не цени – защото доходността е (i) без мащаб, (ii) обичайно стационарна, и (iii) поддържа събирателното свойство. Алтернативно, множество финансови анализи използват постоянно увеличаващи се (или логаритмични) възвръщаемости. Най-важното предимство на тази метрика е събирателното свойство във времето: сумата от отделните логаритмични възвръщаемости дава общата възвръщаемост за няколко периода. Това свойство опростява агрегирането на резултатите и повишава аналитичната пригодност на редица финансови модели. Освен това, тъй като възвращаемостта е отношение между началната и крайна цена, то позволява сравнение на активи с различни ценови мащаби

– решаващо условие при оценка на рисковия профил. Фундаменталните модели разчитат на допускането, че именно възвръщаемостите (и техните статистически характеристики – вариация, ковариация) са подходящата мярка за инвестиционна ефективност.

Първо сравняваме стационарността – наред с други статистически свойства – на възвръщаемостта, за да установим основата на по-нататъшното изследване и да информираме избора (или да обясним ограниченията) на използваните модели. Прилагаме както разширения тест на Дики–Фулър (ADF), така и теста KPSS – взаимно допълващи се инструменти - при граница на значимост 0,05. И двата теста доказват стационарност след логаритмуване – предпоставка, която трябва да бъде удовлетворена преди последващото моделиране със скрит Марков модел.

	ADF STATISTIC	ADF P-VALUE	ADF 1%	ADF 5%	ADF 10%	ADF STATIONARY
BTC.RETURNS	-12.7912	0.0	-3.4797	-2.8832	-2.5783	Yes
CRYPTOINDEX.RETURNS_LOG	-8.7587	0.0	-3.4797	-2.8832	-2.5783	Yes

	KPSS STATISTIC	KPSS P-VALUE	KPSS 2.5%	KPSS 5%	KPSS 10%	KPSS STATIONARY
BTC.RETURNS	0.135	0.1	0.574	0.463	0.347	Yes
CRYPTOINDEX.RETURNS_LOG	0.103	0.1	0.574	0.463	0.347	Yes

Таблица 2.2: Резултати от ADF, KPSS тестове за стационарност

Дори стационарните възвръщаемости могат да съдържат календарна повторяемост (сезонност), които изкривяват краткосрочните анализи (вж. раздел 3.3 „Влияние на спот-ETF-ите върху цената на базовия актив“). Затова изследваме сезонността при три хоризонта – седмичен, месечен и годишен. Понеже възвръщаемостите нямат установена тренд компонента, класическото разлагане е неприложимо; вместо това настройваме сезонен ARIMA модел. SARIMA разширява ARIMA, включвайки сезонни параметри (Korstanje, 2021). Значими сезонни коефициенти биха наложили ограничаване на сезонността преди по-нататъшно моделиране; при липса на такива можем да използваме нетрансформирана („чиста“) възвръщаемост. Така ограничаваме истинските смени на режими за анализа със скрит Марков модел и същевременно съхраняваме високочестотната информация, нужна за по-късните тестове на микро-структурата. Моделирането на годишна сезонност е сложно и заради възможните циклични модели, затова прилагаме редове на Фурие (Iwok, 2016) , подходящи за сложни сезонни модели като настоящия.

SARIMAX надгражда SARIMA, добавяйки променливи – фиктивни регресори и хармонизации на Фурие – и по този начин отстранява сезонността от стационарни възвръщаемости. Комбинацията използва свойствата на възвръщаемостите, богатата извадка и способността на модела да улавя периодични тенденции (De Livera, Hyndman, & Snyder, 2011; Alharbi & Csala, 2022). При SARIMAX не се открива съществена седмична, месечна или годишна сезонност: BTC-възвръщаемостите остават непредсказуеми при тези хоризонти, а диагностиката показва ненормално разпределени, хетероскедастични остатъци – признак за „тежки опашки“ и променлива дисперсия. Литературата е разделена по въпроса (Mueller, 2024; Cheng, Tiwari, Khaled, Mahendru, & Shahzad, 2024), затова подхождаме предпазливо и ограничаваме евентуална остатъчна сезонност с три допълнителни метода: MSTL, TBATS и Prophet.

Прилагаме MSTL (Multiple Seasonal-Trend decomposition via Loess) към реда на лог-цените, за да изолираме тренда и няколко сезонни наслоявания – дневно, седмично, годишно – след което диференцираме, за да получим сезонно изгладени възвръщаемости. Таблица 2.3 показва, че MSTL-десезонираните възвръщаемости минават ADF-теста – трендът и сезонността са премахнати – но не издържат Ljung-Box при лагове 7 и 30 дни, т.е. остава автокорелация. Shapiro-Wilk отхвърля нормалността, а Breusch-Pagan разкрива хетероскедастичност, което потвърждава тежкоопашатата, променлива във времето дисперсия. Необходимо е допълнително моделиране (напр. GARCH).

При анализ по метода TBATS (De Livera, Hyndman, & Snyder, 2011) се премахва седмичната и месечната автокорелация, но ненормалните и хетероскедастични остатъци остават, поради което са нужни адаптивни методи. TBATS улавя по-добре седмично-годишните цикли, ала дефектите в разпределението се запазват (таблица 2.3).

Prophet (Taylor & Letham, 2018), създаден за редове с множествена сезонност и нелинейни смени, декомпозира лог-цените на тренд $T(t)$, сезонност $S(t)$, почивни дни $H(t)$, и остатъчна грешка ε_t. Моделът Prophet генерира остатъчна грешка, която е стационарна и не показва съществена автокорелация при седмични и месечни интервали. Подобно на TBATS, остатъчната грешка при Prophet запазва ненормалност на разпределението и хетероскедастичност, отразявайки присъщите характеристики на финансовите възвръщаемости. При сравнение между двата подхода именно Prophet осигурява по-чисто разделяне на тренда и сезонността и постига сходна статистическа пригодност при по-ниска сложност, като същевременно премахва седмичната/месечната автокорелация. Затова го възприемаме за всички последващи ограничения на сезонноста, например за моделирането на ефекта от Bitcoin ETF (вж. табл. 2.3).

Независимо че ненормалността и хетероскедастичността се запазват и след десезонирането, тези особености са добре документирани и характерни за възвръщаемостите на финансови активи, особено в контекста на силно нестабилни ценово пазари като криптовалутите. (López-Martín, Arguedas-Sanz, & Benito Muela, 2022).

ТЕСТ >>>		**AUGMENTED DICKEY-FULLER**	**LJUNG-BOX 7D**	**LJUNG-BOX 30D**	**SHAPIRO-WILK**	**BREUSCH-PAGAN**
МЕТОД	**характеристика**	**Стационарност**	**Автокорелация на ниво седмица**	**Автокорелация на ниво месц**	**Нормалност на разпределението**	**Вариация**
MSTL	**test statistic**	-11.424	222.977	540.301	0.949	23.553
	p-value	0.000	0.000	0.000	0.000	0.000
TBATS	**test statistic**	-61.999	10.799	39.673	0.906	6.662
	p-value	0.000	0.148	0.111	0.000	0.001
PROPHET	**test statistic**	-62.173	11.372	42.845	0.908	6.134
	p-value	0.000	0.123	0.061	0.000	0.013

Таблица 2.3: Статистически тестове на времеви редици възвръщаемост без сезонност при методите MSTL, TBATS и Prophet

2.3. Дефиниции и предпоставки за обобщен скрит Марков модел (СММ)

Скритият Марков модел описва наблюденията X_t като „емисии“ от ненаблюдавани (скрити) състояния S_t които следват Марковска верига. Моделът се определя от началното разпределение π и матрицата на преходите A. Във всеки момент текущото скрито състояние генерира наблюдение съгласно специфично за това състояние вероятностно разпределение B (Rabiner, 1989; Somani, Talele, & Sawant, 2014; Hassan & Nath, 2005) . Началното разпределение π_i определя с каква вероятност системата стартира във всяко възможно състояние. Матрицата на преходите a_{ij} задава вероятностите за преминаване от едно състояние в друго в следващия момент. Накрая, емисионните разпределения $b_j(x)$ описват как се генерират наблюденията. Чрез комбиниране на тези три компонента рамката на скрития Марков модел определя съвместното вероятностно разпределение на последователността от скрити състояния и на наблюдаваната последователност от данни.

Инференцията при скритите Маркови модели разчита на алгоритъма „напред–назад“ (Forward-Backward), който изчислява вероятността на наблюдаваните данни, като маргинализира по всички възможни пътища на скритите състояния. Алгоритъмът също така предоставя апостериорните вероятности за всяко скрито състояние във всеки времеви момент, при условие че цялата последователност от наблюдения е известна.

Напред-алгоритъмът описва пълната наблюдавана поредица $X_1, \dots, X_T$ като първо инициализира и след това рекурсивно изчислява напред-променливата $\alpha_t(i)$.

Стандартният СММ приема, че наблюденията са независими при фиксирано скрито състояние – опростяване, което реалните финансови възвръщаемости често нарушават поради серийна корелация и клъстериране на дисперсията. За да се преодолее това, практиката вгражда GARCH-динамика или дебелоопашати емисионни разпределения вътре в СММ, но цената е по-висока изчислителна сложност. Оценяването на параметрите чрез ЕМ-процедурата (*Baum–Welch*) крие риск от „заклещване“ в локални оптимуми. Освен това, при избор на твърде голям брой състояния, моделът може да се нагажда прекомерно спрямо ограничените данни; критериите на информацията (AIC**,** BIC) подпомагат избора на оптимален брой режими. Накрая, изведените режими невинаги се съотнасят еднозначно към икономическата реалност без експертно тълкуване, а пренебрегването на ключови ковариати (напр. лихвени проценти) може да прикрие факторите, които задвижват преходите. Интегрирането на външни променливи в преходните или емисионните функции може да засили обяснителната мощ, но допълнително усложнява модела.

2.4. Оценка на модела и първични изводи

Въпреки изразените „тежки опашки“, прилагаме скрит Марков модел с Гаусово емисионно разпределение към числовите редици на възвръщаемост от криптовалути, за да разкрием латентни режими. Макар възвръщаемостите да показват тежки опашки, използването на нормално разпределени състояния балансира аналитичната простота на алгоритъма с достатъчна описателна сила. Наблюденията с висока неопределеност се категоризират към режим на рязка промяна, който апроксимира дебелоопашатите ефекти без да усложнява параметричната форма. Всеки режим се характеризира с присъщата му средна стойност и дисперсия на възвръщаемостта, което позволява интуитивна интерпретация (напр. „ниска ценова дисперсия“ срещу „срив“). Макар разпределения като student-*t* да описват по-точно поведението на времевия ред, те добавят допълнителни параметри, които са трудни за интерпретиране и изчисление, и усложняват калкулациите в реално време. СММ с Гаусово разпределение предлага опростена, но ефективна рамка за отчитане на ключовите промени в поведението на крипто пазара.

В тази конфигурация всяко състояние се характеризира със специфична средна стойност и дисперсия на възвръщаемостите, а преходните вероятности определят шанса системата да преминава между определени състояния. За оценка на параметрите

използваме алгоритъма на максимизация на очакванията (EM), като параметризираме броя на скритите състояния от две до пет. За всеки модел изчисляваме ключови показатели като информационен критерий на Акаике (AIC) и Байес (BIC), за да достигнем оптимален брой състояния без свръхнагаждане. За допълнителна проверка на прецизността на резултатите прилагаме извънизвадково тестване с разделяне 80–20.

Моделът с две състояния различава режими на ниска и висока ценова нестабилност, като и двата показват умерена средна възвръщаемост. Моделът с три състояния улавя по-фини изменения в средната стойност и дисперсия (Фигура 2.4). Състояния 1 и 2 се сменят често – Състояние 1 има ниска средна стойност и най-малка дисперсия („стабилен, но ограничен растеж“); Състояние 2 показва умерено положителна средна и умерена дисперсия („по-малко спокоен растеж“); Състояние 3 е устойчиво, със отрицателна средна стойност и най-голяма дисперсия („турбулентна, спекулативна фаза“).

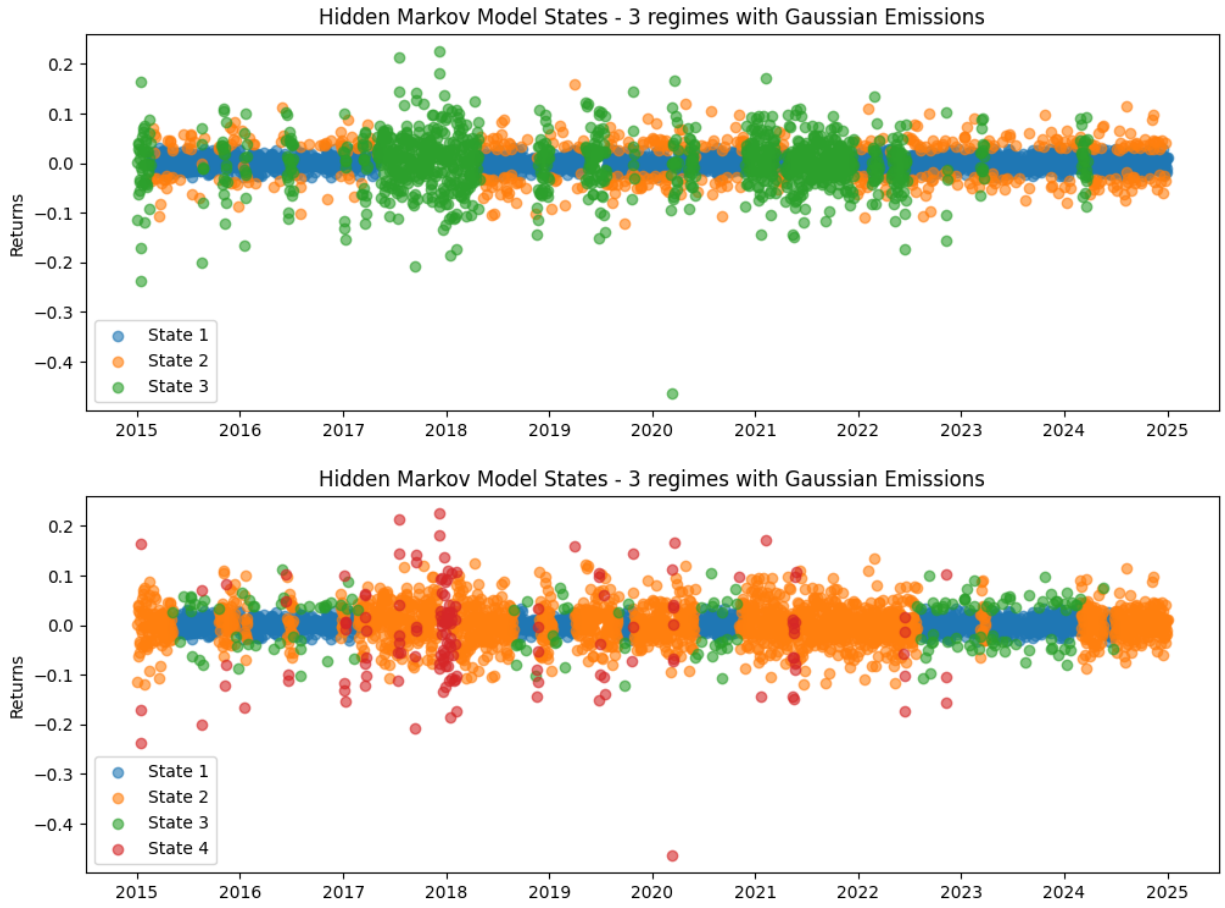

Фигура 2.4: Визуализация на режимното разпределение при 3 и 4 режима на СММ

Накрая, модел с четири състояния допълнително прецизира класификацията, отличавайки допълнителен режим, който показва уникално поведение по отношение на средните възвръщаемости и ценова нестабилност. Състояние 1, с много ниска дисперсия, е умерено устойчиво, но има 26,5 % вероятност да премине към състояние 3 – друг режим с „умерена“ средна стойност и умерена към ниска дисперсия. Състояние 2 има умерено висока средна стойност и умерена дисперсия („ръстов“ режим), докато последното състояние се характеризира със силно отрицателна средна стойност и най-висока дисперсия – „кризисен“ режим.

Моделите с повече от четири състояния добавят сложност без ясна възможност за интерпретация. Метриките за прилягане – прецизността при обучение и извънизвадкова точност на прогнозиране, AIC и BIC – показват сходни стойности и много ограничена полза отвъд модел с четири режима. При въвеждане на наказанията за сложност, те често неутрализират малките подобрения в точността, така че по-простият модел с три състояния остава фаворит. От статистическа гледна точка конфигурацията с четири състояния постига най-висока прецизност и най-добри стойности на AIC/BIC, като ясно изолира режим с високи ценови колебания и отрицателна средна стойност.

Скорошни изследвания (Koki, Leonardos, & Piliouras, 2022) също идентифицират подобни разпределения с четири състояния - растеж, спад, и две състояния на минимални промени - използвайки различни методи и по-малко наблюдения. Нашият Гаусов CMM, при двойно по-голям обем данни, постига малко по-висока прогностична точност с три състояния, въпреки че не може да прогнозира посоката на движенията.

Реалните финансови данни често преминават между латентни режими; чрез прогнозирането на разпределението на състоянията изпробваме дали тренираните преходи и емисии остават полезни отвъд една стъпка. Стабилното моделиране на режими би трябвало да води до постепенно нарастващи грешки с увеличаване на хоризонта; рязък растеж на грешките може да означава липсващи фактори (напр. външни шокове или нестационарност) и би подсказал възможности за усъвършенстване на модела (повече състояния, дебелоопашати разпределения, ковариати).

Модел	RMSE за ден напред	MAE за ден напред	RMSE за 5 дни напред	MAE за пет дни напред	RMSE за 10 дни напред	MAE за 10 дни напред

СММ с две състояния	0.022972	0.017872	0.022951	0.017722	0.024093	0.018697
СММ с три състояния	0.021598	0.016739	0.022167	0.016941	0.023521	0.018206
СММ с четири състояния	0.021599	0.017911	0.022209	0.016999	0.023581	0.018669
СММ с пет състояния	0.023026	0.017981	0.023006	0.017797	0.024139	0.018755
ARIMA	0.022734	0.01762	0.02265	0.017455	0.02372	0.01835
SARIMAX	0.022693	0.017577	0.022526	0.017365	0.023557	0.018198
Prophet	0.023175	0.018255	0.02328	0.018316	0.024378	0.019125
Векторна авторегресия	0.022663	0.017577	0.02265	0.017453	0.02372	0.01835
Експоненциално изглаждане	0.022718	0.017633	0.02265	0.017455	0.02372	0.01835
Невронна мрежа с двойна памет (LSTM)	0.023037	0.018105	0.02313	0.017978	0.024253	0.018866

Таблица 2.5: Грешки при прогнозирането за всеки СММ; червеният цвят показва по-голяма грешка, а зеленият – по-малка.

За да оценим прогнозните способности на СММ за възвръщаемостта (размер и посока), извършваме многостъпкови прогнози на 1-, 5- и 10-дневни хоризонти, оценявайки както квадратичната грешка (RMSE), така и абсолютната (MAE). Сравнението между RMSE и MAE предоставя балансиран поглед върху прогнозните грешки – RMSE подчертава големите отклонения, а MAE отразява средната величина на неточността. Критично значение имат стационарността и стабилността на режимите в рамките на тестовия хоризонт: структурни прекъсвания или промени в преходните/емисионните параметри нарушават основното допускане на модела на Марков.

Сравняваме СММ с класически и нелинейни времеви модели – ARIMA, SARIMAX, векторна авторегресия (VAR), експоненциално изглаждане и Prophet с „плъзгащи“ тренд и сезонност – използвайки идентични едномерни (или малки многомерни за VAR) серии от възвръщаемости и прогнозни хоризонти (1, 5, 10 дни). Линейните авторегресивни и изглаждащи методи улавят устойчивост и сезонни ефекти (в SARIMAX чрез екзогенни регресори), докато Prophet се адаптира към промени в тренда и особеностите на почивните дни. Техните показатели за грешка се групират близко, което подсказва, че стандартната динамика обяснява голяма част от краткосрочното поведение на възвръщаемостта на криптовалути. СММ с три състояния превъзхожда останалите

модели при всички хоризонти. Добавянето на повече скрити състояния или прилагането на „плъзгащи“ декомпозиции не подобрява точността, което потвърждава, че трите режима оптимално балансират гъвкавостта (улавяне на нелинейност и внезапни смени) и ограничената сложност (избягване на свръхнагаждане). Интерпретацията на режимите съответства на реални явления – напр. скокове на интереса при крайни клиенти, ликвидни шокове, колебания в потребителските нагласи.

Бъдещи усъвършенствания могат да интегрират екзогенни индикатори за настроения или многомерни режимни процеси, за да се повиши устойчивостта на многостъпковите прогнози.

2.5. Икономическа значимост и интерпретация

Глава втора показа, че пазарите на криптовалути проявяват дискретни смени на режими и етапи на риск и неопределеност, различни от плавните корекции, обичайни за традиционните финансови пазари. Чрез прилагане на обобщен скрит Марков модел (СММ) разкриваме латентни състояния, които съответстват на внезапни промени в пазарните настроения, ликвидността и външните шокове. Докато конвенционалните модели предполагат непрекъсната динамика, СММ открива устойчиви фази на неопределеност – които подчертават спекулативния характер на криптоактивите в определени периоди и тяхната склонност за отклонение от стандартните икономически фундаменти. Засичането на режими има значими икономически последици: с нарастващата интеграция на цифровите активи в глобалните финанси, внезапните изменения в цените на крипто активи могат да предизвикат вълнообразни ефекти върху традиционните пазари. Инвеститори и законотворци не могат да разчитат единствено на традиционни техники за управление на риска; необходимо е да възприемат адаптивни стратегии, които да взимат предвид възможността за бързи преходи между различни режими. Освен това устойчивостта и интензитета на високорисковото скрито състояние предполагат, че регулаторните рамки трябва да бъдат специално адаптирани за криптопазарите, а не просто транспонирани от конвенционалните класове активи.

Трета глава: Макроикономически ефекти върху ценовата динамика

Целта в тази глава е да установим дали традиционните макроикономически показатели – като инфлация, растеж на БВП, държавен и индивидуален дълг, лихвените проценти на централните банки – имат системна връзка с динамиката на цените на криптовалутите. Установяването на подобни зависимости може да покаже дали цифровите активи служат като „сигурни убежища“, диверсификатори на портфолио или хеджове срещу конвенционални пазарни рискове, подлагайки на съмнение схващането, че криптопазарите функционират напълно независимо от глобалните икономически условия.

От началото на 2020 г. безпрецедентни макроикономически шокове силно измениха финансовите пазари. Пандемията от COVID-19 предизвика съществени фискални стимули и безпрецедентни монетарни облекчения, заставяйки централните банки да намалят драстично лихвите и да разширят програмите за количествено облекчаване (QE). С напредването на възстановяването нарастващата инфлация принуди големите централни банки в САЩ, ЕС и Китай да преминат към затягаща политика. Едновременно с това геополитическото напрежение и прекъсванията във веригите за доставки засилиха несигурността и ценовата нестабилност. Тези процеси създават уникална среда, в която да се наблюдава как политическите интервенции и системните шокове влияят върху възвръщаемостите на криптоактивите.

За да уловим тези влияния, изграждаме прогностични модели, които интегрират стандартни макроикономически променливи с числовите редовете на възвръщаемост. Нашата централна хипотеза гласи, че въпреки широкоразпространеното убеждение за откъснатост на криптовалутите от традиционните финанси, основни икономически сили – промени в паричната политика, динамика на пазара на труда и индикатори за настроенията – оказват измерим ефект върху ценовите движения на криптоактивите. Като изясним тези взаимоотношения, целим да разширим икономическата рамка за разбиране и управление на риска на тези активи.

3.1. Моделиране на пазара на крипто активи чрез макроикономически показатели

С оглед съществуващата литература, повечето изследвания за макроикономическите влияния върху криптовалутите се фокусират върху това как дискретни шокове – като изненадващи политически решения или геополитически събития – се предават на пазарите на цифрови активи, а не върху трайни връзки с по-бавно развиващи се икономически фундаменти. Въпреки това, тъй като криптовалутите стават по-тясно преплетени с основните финансови пазари, тяхната възвръщаемост демонстрира нарастващи корелации с акции и облигации от 2020 г. насам, което подсказва, че

широките парични и фискални тенденции може да оказват пряко влияние върху цените на криптоактивите, вместо те да бъдат изцяло идиосинкратични или пасивно повлияни от хеджиране срещу традиционните рискове.

Предишни изследвания прилагат инструменти от векторни авторегресии и динамични факторни модели до събитийни изследвания и GARCH анализи, често на високочестотно ниво, за да изолират въздействието на шоковете. Например, доклад на МВФ от 2023 г. установява, че еднопроцентно неочаквано увеличение на лихвата от Фед понижава агрегирания крипто-фактор с около 0,15 стандартни отклонения, паралелно с ефектите върху акциите и облигациите. Обратно, изследване на Федералния резерв на Ню Йорк документира силно ограничен до нищожен ефект на цената на Биткойн при планирани макроикономически новини от САЩ, подчертавайки понякога ултра-краткосрочни „разкъсвания“, които оспорват традиционните наративи за тясна зависимост от централните лихви. Въпреки това, консенсусът клони към твърдението, че затягането (или облекчаването) на паричната политика се предава на криптовалутите по подобие на другите рискови активи. (Che, Copestake, Furceri, & Terracciano, 2023; Benigno & Rosa, 2023).

Основна пречка пред установяването на дългосрочни макро връзки се корени в различните времеви мащаби: криптовалутите проявяват екстремна дневна дисперсия, докато макро показателите се променят плавно, и то на месечна или тримесечна база. За да приравним тези честоти, уеднаквяваме мащаба на двете променливи до месечен. Друго предизвикателство произтича от глобалния обхват на търговията с криптовалути спрямо специфичния за отделните държави характер на повечето макро индикатори. Подхождаме към това, като се съсредоточаваме върху шестте най-големи икономики в света – САЩ, Китай, Япония, Корея, Германия и Франция – които заедно генерират значителна част от глобалната макроикономическа динамика. Този подбор осигурява прокси за по-широката икономическа среда.

Използваният набор от данни включва над двадесет месечни индикатора. Тези променливи обхващат условията на ликвидност, фискалното здраве и поведенчески показатели на потребителите, като осигуряват цялостна основа за проверка дали и как традиционните икономически сили упражняват влияние върху ценовата динамика на криптоактивите:

	Източник	**Глобално**	**САЩ**	**Китай**	**Япония**	**Корея**	**Германия**	**Франция**

Несигурност на икономическата политика	EPU		X	X	X	X	X	X
Несигурност на икономическата политика с претеглен доход на глава от населението	EPU	X						
Глобална несигурност на икономическите политики	EPU	X						
Индекс на глобална несигурност на икономическите политики	FRED		X	X	X	X	X	X
10Y реален лихвен процент	National Bank		X	X	X	X	X	X
BBK Real GDP Change	National Bank		X	X	X	X	X	X
Правителствен (публичен) дълг	National Bank		X	X	X	X	X	X
Правителствен дефицит	National Bank		X	X	X	X	X	X
Government Funds Effective Rate	National Bank		X	X	X	X	X	X
Несигурност на фискалната политика	HRS		X	X	X	X	X	X
Индекс на потребителската инфлация	IMF		X	X	X	X	X	X
Безработица	IMF		X	X	X	X	X	X
Доверие на бизнеса	OECD		X	X	X	X	X	X
Потребителско доверие	OECD		X	X	X	X	X	X
Composite Leading Indicator	OECD		X	X	X	X	X	X
M1 обеми (USD)	OECD		X	X	X	X	X	X
M3 обеми (USD)	OECD		X	X	X	X	X	X
Световен индекс на несигурност, претеглен по БВП	WUI	X						

Таблица 3.1: Наличност на месечни данни за икономически фактори

В процеса на инженерството на признаците (feature engineering) макроикономическите променливи бяха разширени със водещи и изоставащи версии, за да се уловят по-бавно

действащите ефекти върху възвръщаемостта. Изоставащите признаци моделират въздействия, които се разгъват в рамките на няколко месеца, докато водещите търсят пазарните движения, изпреварили измерването на индикатора. Чрез въвеждане на времево изместени променливи моделът получава по-богат времеви контекст, като подобрява способността си да открива причинно-следствени връзки.

За да обхванем както линейни, така и нелинейни зависимости, оценяваме широк спектър от модели. Стандартните линейни регресии (Ridge, Lasso, ElasticNet) осигуряват интерпретируеми основни положения, като присвояват директни тегла на отделните показатели. Базираните на дървета ансамблови модели (Random Forests, Gradient Boosting) адаптивно разделят признаците и техните комбинации, за да уловят промени на режими и нелинейности в дисперсията. Тествахме също векторни машини, k-най-близки съседи и невронни мрежи, всеки от които може да усвои сложни взаимодействия без предварително зададени функционални форми. Намаляването на размерността чрез главни компонентни анализи допълнително смекчава мултиколинеарността и съсредоточава прогностичната мощ върху латентни фактори.

Оценяваме общото качество на моделите чрез коефициента R^2, който оличествява вариацията на възвръщаемостите, обяснена от нашите предиктори спрямо базова прогноза по средна стойност. По-висок R^2 оказва, че комбинираните регресори по-ефективно обясняват наблюдаваните месечни колебания на целевата променлива. Въпреки недостатъците си в нелинейни настройки или при сравнение на модели с различна сложност, R^2 остава стандартизирана мярка за оценка на обяснителната сила при нестабилни криптовалути и стабилни икономически данни. Допълнително сравняваме осреднените стойности за R^2в условия на различни извадкови данни. Чрез този CVScore можем да оценим умението на модела да се справи с данни, които не се използвани за трениране (тоест, умението на модела да генерализира).

Прогнозна точност	**50:50**	**80:20**	**90:10**
3 години (2022-2024)	CVScore = -0.0198 R^2 = -0.035	CVScore = -0.0201 R^2 = -0.029	CVScore = -0.0184 R^2 = -0.040
2 години (2022-2023)	CVScore = -0.0166 R^2 = -0.097	CVScore = -0.0217 R^2 = -0.059	CVScore = -0.0151 R^2 = -0.042
2 години (2023-2024)	CVScore = -0.0181 R^2 = -0.020	CVScore = -0.0170 R^2 = -0.017	CVScore = -0.0140 R^2 = -0.014
1 година (2022)	CVScore = -0.006 R^2 = -0.0176	CVScore = -0.0334 R^2 = -0.005	CVScore = -0.0299 R^2 = -0.236
1 година (2023)	CVScore = -0.0124 R^2 = -0.011	CVScore = -0.009 R^2 = -0.031	CVScore = -0.0104 R^2 = -0.014
1 година (2024)	CVScore = -0.0222 R^2 = -0.026	CVScore = -0.005 R^2 = -0.044	CVScore = -0.019 R^2 = -0.108

Легенда (най-точен модел):

- Ансамбълен модел със Случайна гора
- Ансамбълен модел с линейна SVR
- Ансамбълен модел със Случайна гора и линейна SVR
- Ансамбълен модел с Gradient Boost
- Ансамбълен модел с линеен SVR и Gradient Boost
- Ансамбълен модел с регресия с гребен и дърво на решенията

Таблица 3.2: CVScore и R^2 резултати за най-добре представилите се модели след 20 поколения на пермутация от 100 варианта на модел; целева променлива: пазарна капитализация на крипто пазара

При всички разделения на извадката – дори при обхват от една до три години данни – бяха получени отрицателни стойности на кръстосаната валидация и коефициента R^2, което показва, че нито един модел не превъзхожда ориентировъчния бенчмарк с константна средна стойност. Бяха оценени ансамблови техники, съчетаващи случайни гори, Gradient Boosting, линеен поддържащ вектор, Ridge регресии, но никой от тях не постигна положителна прогностична сила на месечна възвръщаемост или обща пазарна капитализация.

При наличие на достатъчно данни (напр. разделение 80:20) Gradient Boosting даде най-добри резултати благодарение на поетапната си оптимизация. При ограничена обучителна извадка обаче рискът от преобучаване се увеличава, а случайните гори се оказаха по-стабилни поради осредняването на дърветата. Тези резултати подсказват, че стандартните макроикономически показатели обясняват недостатъчна част от вариацията на възвръщаемостта, вероятно поради високата дисперсия и идиосинкратичните пазарни фактори, което води до необходимост от алтернативни източници на данни или подходи за моделиране.

3.2. Хроничната инфлация като определител на пазарното търсене[1]

Криптоактивите дълго време се разглеждаха като хедж срещу инфлацията, но емпирични изследвания не откриват системна връзка между обемите на търговия със стейбълкойни и обезценяването на фиатните валути (Ofele, Baur, & Smales, 2025) или между индекса на потребителски цени (CPI) и Биткойн (Rodriguez & Colombo, 2025).

За да проверим дали трайната инфлация стимулира използването на криптовалути, данни за крипто собственост на годишна база в 50 държави за пет години бяха съпоставени с 45-годишни инфлационни данни. Регресията беше оценена чрез метода на обикновените най-малки квадрати (OLS), а статистическата ѝ валидност се оценява със стандартни t-тестове за коефициентите и F-тест за общата значимост.

Емпиричните резултати от OLS регресията показват, че средният инфлационен коефициент (β_1) е оценен на −0.0017 (p = 0.028), докато индикаторът за хронична инфлация (β_2) е изчислен на 0.2581 (p < 0.001), което показва, че докато средната инфлация оказва леко отрицателно въздействие, хронично високата инфлация значително увеличава приемането на криптовалути.

Наблюдения	**56**	**Skew**	**1.322**
Модел	**OLS**	**Kurtosis**	**5.148**
R^2	**0.469**	**Adjusted R^2**	**0.449**
AIC	**-183.2**	**Log-likelihood**	**94.596**
BIC	**-177.1**		
Durbin-Watson	**1.821**	**Jarque-Bera**	**27.080**

Таблица 3.3.: Резултати от регресията чрез най-малки квадрати

[1] Хроничната инфлация се характеризира от дълги периоди (десетилетия) на висока и постоянна инфлация спрямо развитите страни (Pazos, 1972). Използваме термина „хронична инфлация“ със специфичната дефиниция за годишна инфлация над 17.5% за период от поне 5 години.

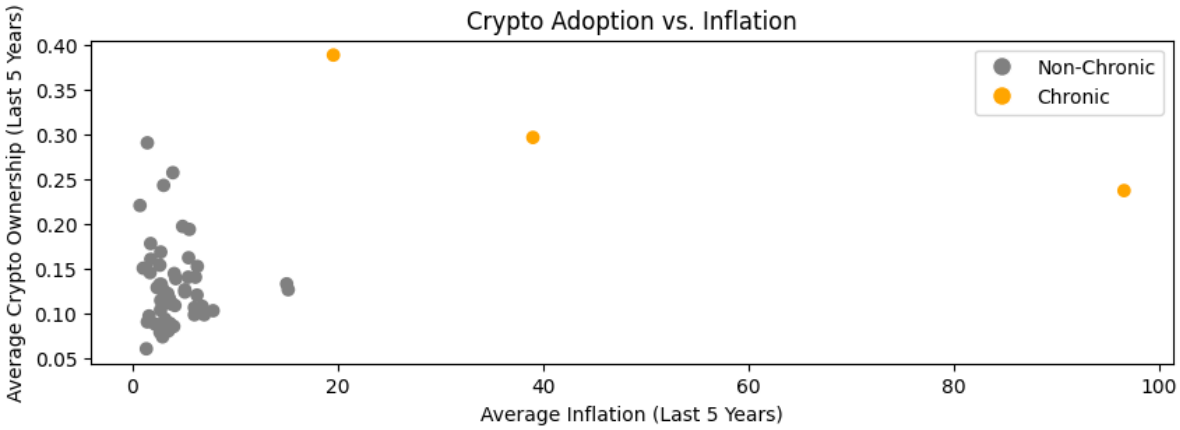

Фигура 3.1: Резултати от регресията

Беше предоставено статистически значимо доказателство, че хроничната инфлация се асоциира с повишени нива на употреба на крипто активи, макар ценовата динамика да не може да бъде количествено оценена и да се отнася предимно до стейбълкойни, обезпечени в щатски долари (както съобщават Ofele, Baur и Smoles през 2025 г.). Традиционните капиталови ограничения се заобикалят чрез услуги от децентрализираните финанси, което потенциално допълнително подкопава паричната стабилност в страната. Ето защо се препоръчват мерки за засилен фискален контрол – като задължително отчитане на големи трансфери в криптовалути и изисквания за лицензиране на борси и доставчици на дигитални портфейли. Интегрирането на крипто транзакциите в съществуващите валутни ограничения би подобрило и контрола върху трансграничните капиталови потоци.

3.3. Ефекта на Spot ETF на Биткойн върху цената на актива

Одобрението на BTC Spot ETF на 10 януари 2024 г. се счита за инфлексна точка в развитието на пазара: през следващите два месеца цената на биткойн достигна от приблизително 45 000 USD до 70 000 USD, под натиска на институционален капитал. Предоставяйки регулиран канал, ETF продуктите демонстрират способността да интегрират криптоактивите в традиционните финансови потоци, излагайки ги на макроикономически динамики като ликвидни условия, промени в паричната политика и инвеститорски риск-сентимент. В този смисъл, Биткойн беше повторно концептуализиран като нестандартен хедж, чийто профил на ценова нестабилност и баланс на риск–възвръщаемост се модулира както от микроикономически влияния, така и от мащабни икономически сили.

Съществуващите изследвания върху влиянието на деривативни инструменти се концентрират предимно върху фючърси: ранни анализи определят спот пазарите като основни за ценообразуването (Baur & Dimpfl, 2018) , докато други коментират потенциала на фючърс пазарите да определят цените (Karkkainen, 2022) или да увеличават ценовата нестабилност (Corbet, Lucey, Urquhart, & Yarovaya, 2019); от друга страна, при определени условия, фючърсите подобряват пазарната ефективност (Augustin, Rubtsov, & Shin, 2020; Jalan, Matkovskyy, & Urqhuart, 2019). В контраст на това, директното въздействие на спот ETF остава недостатъчно изследвано, въпреки потенциала им да генерират автокорелационни епизоди и ценови корекции на базовия актив при значителни институционални постъпления или отливи. Поради това ролята на BTC Spot ETF следва да се определи като критична макросила, оформяща ценовата динамика на криптоактивите.

С цел разширяване на научните познания бяха събрани високочестотни данни за приток към ETF и цената на биткойн, за да се изследва тяхното динамично взаимодействие чрез векторна авторегресия (VAR). Използвани са нетни постъпления в ETF (в милиони USD) в периода януари-октомври 2024 и ценови равнища на Биткойн (почасово от януари 2023). Приложен е векторен модел за корекция на грешки (VECM), за да се отчете както краткосрочната динамика, така и дългосрочното равновесие между възвръщаемостите на биткойн (y_t) и нетните постъпления в ETF (x_t). Проведени са тестове за установяване на причинно-следствена връзка на Грейнджър за определяне на посоката на влияние. Установено е, че ETF постъпленията значимо влияят на непосредствената възвръщаемост на биткойн (т.е. влиянието е ETF → BTC), докато възвръщаемостта не определя постъпленията (тоест, обратната зависимост липсва). Тази асиметрия води до извода, че капиталовите движения влияят на краткосрочната ценова динамика, но възвръщаемостта на Биткойн няма коригиращ ефект в обратната посока.

ЛАГ (H)	AIC	BIC	FPE	HQIC
0	24.92	**24.92***	6.618e+10	**24.92***
1	24.91	24.93	6.608e+10	24.92
2	24.91	24.93	6.612e+10	24.92
3	24.92	24.94	6.619e+10	24.92
4	**24.91***	24.94	**6.603e+10***	24.92
5-72	24.91-24.92	24.94-24.99	6.603e+10-6.643e+10	24.92-24.94

Таблица 3.4: Оптимален избор на забавяне – най-голяма ефект между 1 и 5 часа

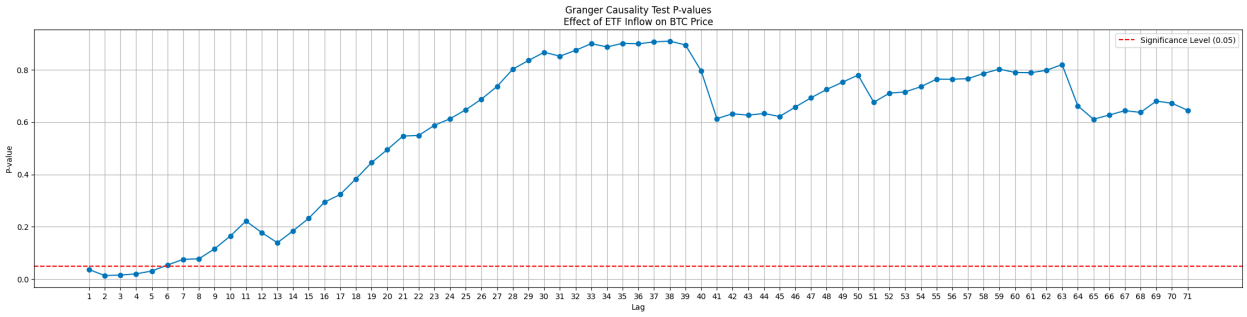

Фигура 3.2:Причинно-следствена връзка по Грейнджър показва краткосрочни ценови ефекти

КОМПОНЕНТ	ПАРАМЕТЪР	СТОЙНОСТ	Z-STAT	P-VALUE
Скорост на адаптиране $\boldsymbol{\alpha}$	Δ BTC.returns	− 0.859	− 9.57	< 0.0001
	Δ BTC.ETF.inflow	4.82×10^{9}	6.80	< 0.0001
Коинтегриращ вектор $\boldsymbol{\beta}$	BTC.returns	1	-	-
	BTC.ETF.inflow	-3.88×10^{-11}	− 3.97	< 0.0001
Грешка $\boldsymbol{\varepsilon}$	Constant	7.46×10^{-5}	1.02	0.309

Таблица 3.5: Коефициенти на дългосрочно равновесие при VECM

Тестът на Йохансен с проследяване потвърждава наличието на дългосрочно равновесие между почасовите възвръщаемости на Биткойн и паричните потоци към ETF. Оценението коефициент на корекция в уравнението за възвръщаемостите ($\alpha = -0.859$, $p < 0.0001$) показва, че приблизително 86 % от всяко отклонение от равновесието се коригира в рамките на един час, докато ETF паричните потоците се приспособяват бавно ($\alpha = 4.82 \times 10$, $p < 0.0001$). С други думи, паричните потоците действат като форсиращата променлива (както видяхме и в тестовете по Грейнджър). Краткосрочната динамика показва, че първите десет почасови лага на ETF потоците на пари оказват съществено отрицателно влияние върху възвръщаемостта, което съответства на пазарния принцип „купувай слухове, коригирай при потвърждението“ (Wald тест $F = 2.27$, $p = 0.011$). Възвръщаемостта нито предсказва бъдещи парични потоци, нито влияе върху корекцията към равновесие ($p = 0.28$), подчертавайки асиметрия, при която цените бързо елиминират неравновесията, докато създаването и изкупуването на ETF дялове реагират по-бавно.

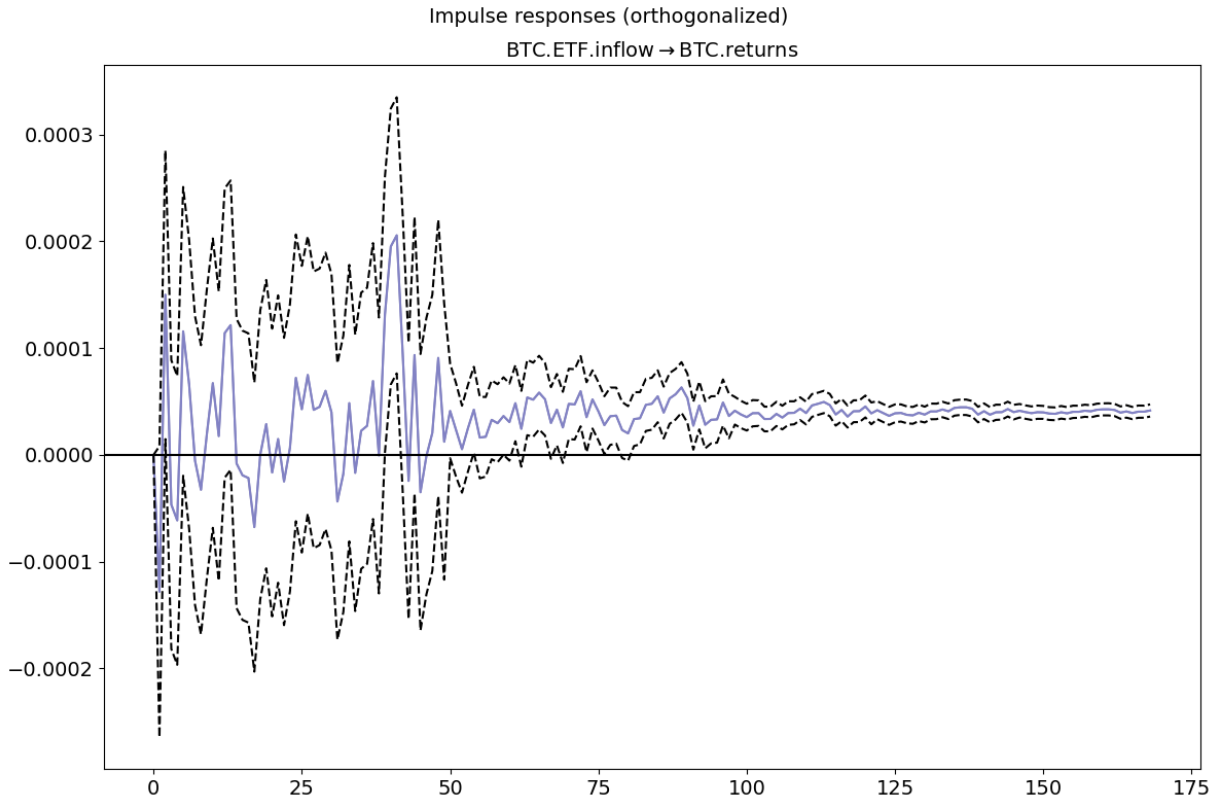

Фигура 3.3: VECM Функция на импулсния отговор, ETF Inflow -> Returns

Функцията на импулсен отговор на VECM (шок от едно стандартно отклонение) в паричните потоци към ETF показва умерени, редуващи се по знак колебания на възвръщаемостите през първите ~50 часа, последвани от затихване към нула и едва слаб, отложен положителен ефект. Малък пик около 48-ия час вероятно отразява взаимодействието между ограничените търговски часове на традиционните борси и 24/7 пазара на Биткойн.

В икономически план тези резултати подсказват, че Spot ETF-ите върху Биткойн насочват значителен институционален капитал към пазара, усилвайки краткосрочните ценови движения, но не променят устойчивото дългосрочно равновесие, поддържано от децентрализираната търговска среда. Като мост между традиционните финансови потоци и крипто инфраструктурата, ETF предизвикват преходни вливания на ликвидност, които временно движат цените, преди фундаменталната динамика отново да се наложи.

3.4 Икономическа значимост и интерпретация

В края на главата е формулирана унифицирана прогностична рамка, която интегрира вероятностите за смяна на режими от СММ с три състояния и паричните потоци към ETF, обясняваща възвръщаемостта в следващия период. Докато вероятностите от СММ улавят латентните „преходни“ и „турбулентни“ фази, идентифицирани в Глава 2, параметърът за ETF въплъщава институционалните капиталови потоци, разгледани в Глава 3. Остатъчната вариация (ε) се предполага, че включва допълнителни микроструктурни премии – като осигуряване на ликвидност от борсите и блокчейн активност – въпреки че тези елементи не са формално тествани в обхвата на настоящето изследване.

Отличаваме три основни приноса: първо, СММ с три състояния постига оптимален баланс между обяснителна мощ и сложност, превъзхождайки както модели с по-малко, така и с повече състояния. Второ, дълготрайната висока инфлация има положителен ефект спрямо разширеното използване на крипто активи. Трето, паричните потоци към ETF има краткосрочно положителен ефект върху ценовата динамика на Биткойн.

Икономическият анализ демонстрира, че възвръщаемостите на криптовалутите произтичат от съвпадението на дискретни пазарни фази, институционални капиталови потоци и някои макроикономически показатели. Макар да е доказано, че хронично високата инфлация стимулира приемането на криптовалути – особено под формата на стейбълкойни – нейното пряко влияние върху ценовите равнища остава неясно. Краткосрочната ценова динамика е най-чувствителна към непосредствени макроикономически новини и вливания на ликвидност, като парични потоци към ETF, докато нискочестотните пазарни основи се проявяват едва при по-дълги хоризонти. Тази двойственост оспорва представата за криптовалутите като изцяло спекулативен актив и позиционира цифровите активи като хибридни инструменти, отразяващи едновременно традиционни финансови сили и нови пазарни механики.

Четвърта глава: Микроикономически влияния върху ценовата динамика

Микроикономическата активност на криптопазарите може да се наблюдава с висока честота – често на часови или минутен интервал – благодарение на прозрачността на публичните блокчейни. Търговският обем, който отразява скоростта, с която се извършват сделките за покупка и продажба, обикновено се използва като индикатор за

ликвидност и активност на пазара. Въпреки това, понеже обемните стойности могат да бъдат изкривени от фиктивна търговия, суровите метрики могат да надценят реалната дълбочина на пазара и да заблудят анализа на потребителските нагласи.

Метриките от борси и от блокчейн дават по-дълбока представа за ликвидността, но също следва да се използват предпазливо. Ликвидността и разликата в курсовете купува–продава са често използвани за оценка на устойчивостта и ефективността на пазара, ала фалшиви поръчки — големи заявки за покупка или продажба, които се отменят бързо — могат симулативно да увеличат привидната дълбочина и да стеснят спредовете (Esparcia et al., 2024). Нетните потоци към крипто борсите (депозити минус тегления) и блокчейн показателите (активни адреси, брой транзакции) също претендират да водят до промени на търсенето и предлагането, но вътрешни трансфери, депозитни ребаланси и MEV или ботове за фиктивна търговия могат да изкривят тези данни (Cui & Gao, 2023; Chen et al., 2022).

В Ethereum мрежата таксите за газ – които следят транзакционните разходи и се покачват спрямо използването на инфраструктурата – често се тълкуват като индикатори за търсене на мрежата (Jain et al., 2023). Въпреки това инфраструктурни атаки, фронтръннинг и други MEV извличания могат изкуствено да увеличат таксите, създавайки подвеждащи сигнали за органично използване. С оглед на тези рискове от манипулация (Hsieh & Brennan, 2022) микроикономическите показатели на криптопазарите трябва винаги да се ревалидират от множество източници и да се филтрират строго, за да се различи автентичната активност от режисирания шум.

4.1. Как потребителските нагласи определят ценовата динамика

Изследването на микроикономическото влияние върху ценовата динамика, започва с анализ на ролята на сигналите, базирани на потребителски нагласи, за прогнозиране на краткосрочните възвръщаемости и ценовата нестабилност на биткойн. Целта е да установим дали сигнали, извлечени от коментари в социални мрежи и публични форуми могат да се използват за предсказване на ценови движения или ценова нестабилност. Извлечен е високочестотен набор от данни с почасови наблюдения за цената на Биткойн от една страна и метрики за потребителски нагласи в социалните медии от друга, за да се оценят микроикономическите влияния при краткосрочна възвръщаемост и пазарна несигурност. За всеки час е изчислена нетна мярка за потребителска нагласа, а върху кратки (6 ч), средни (24–72 ч) и дълги (168 ч) прозорци са извлечени плъзгащи статистики (средни, стандартни отклонения и z-стойности).

Допълнителен индикатор – tweet volume spike indicator (TVS) – улавя промените и аномалиите в броя коментари.

Въпреки подробното инженерство на признаци и изследването на методи за контролирано обучение – включително ансамблови модели, съобразени с режима, предназначени да се адаптират към преобладаващи състояния на ценова нестабилност – повечето линейни регресии дадоха незначителен R^2, индикирайки, че влиянието върху почасовото ценово формиране не може да бъде уловено само от линейни модели, тоест се променя във времето. Този резултат подчертава присъщия шум, автокорелацията и податливостта към външни шокове при високочестотните данни за криптопазара, както и ограничените възможности на чисто линейното прогнозиране при този времеви резолюция.

Като следваща стъпка беше приложен Gradient Boosting регресор върху пълния набор данни. Този непараметричен ансамбълен модел, базиран на дървета, даде R^2=0.0503 и RMSE = 0.0052, което показва скромно, но измеримо подобрение спрямо линейните модели. Подобрението подсказва, че взаимодействия от по-висок порядък и съществуват нелинейности между променливите. Въпреки това, моделът се проваля в периодична повишена несигурност или мащабни макроикономически събития, подчертавайки крехкостта на прогностичната връзка. Този резултат едновременно демонстрира наличието на фин нелинеен ефект и необходимостта моделът да се съобразява с текущите пазарни режими, за да се стабилизира и подобри надеждността на прогнозата.

МОДЕЛ	R^2 РЕЗУЛТАТ	КВАДРАТИЧНА ГРЕШКА
Линейна регресия	0.000	0.0055
Gradient Boosting (пълна извадка)	0.050	0.0052
Gradient Boosting (режим на ниска дисперсия)	0.201	0.0014

Таблица 4.1: Регресионни резултати (линейна регресия и gradient boosting) и ключови метрики

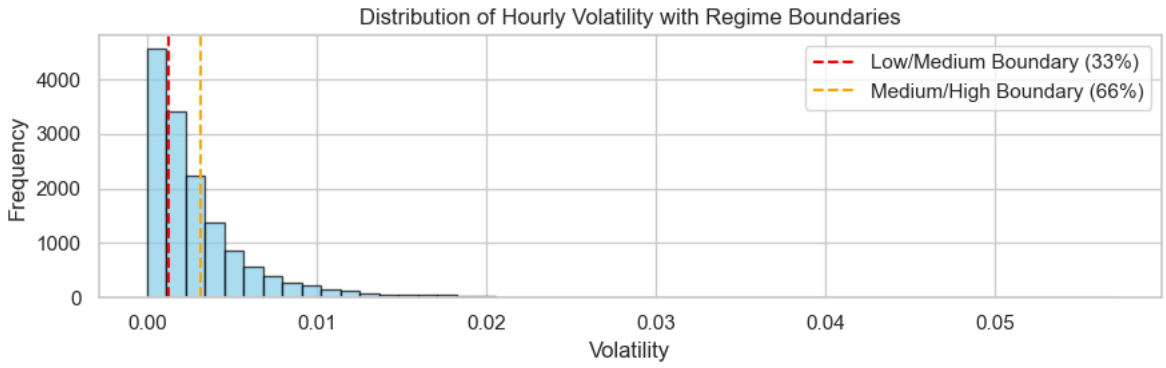

Фигура 4.1: Разпределение и честота на пиковете на дисперсия

Пазарните наблюдения биват разделени на три режима на несигурност – ниска, средна и висока – чрез разделяне на разпределението на дисперсията на терцили (вж. Фигура 4.1) и категоризиране на всяко наблюдение според праговете на 33-ия и 66-ия персентил. Впоследствие, за всеки еднороден режим се създава отделен прогнозен модел, за да се провери прогнозната точност на потребителско настроение във всеки режим. Чрез изолирането на сегменти с ниска, средна и висока дисперсия анализът цели да смекчи зашумяването от смесени пазарни състояния и да позволи изграждането на ансамблова прогноза, базирана на пазарния режим.

Gradient Boosting регресори бяха обучени отделно за сегментите с ниска, средна и висока дисперсия за да се оцени специфичната за режима прогностична сила. В режима на стабилно ценово ниво, представянето на модела беше значително по-добро ($R^2 \approx 0.201$, RMSE ≈ 0.00137), докато при средна дисперсия се наблюдаваха умерени нива ($R^2 \approx 0.041$, RMSE ≈ 0.00245), а при висока - се получи едва ограничено превъзходство спрямо базовия модел ($R^2 \approx 0.066$, RMSE ≈ 0.00836). Анализът на важността на признаците чрез пермутации разкри, че при спокойни пазарни условия най-влиятелният предиктор е часът на денонощието – последван от средни стойности на потребителските нагласи за дълъг хоризонт, пикове в обема на туитовете и съотношения нагласа / внимание. За разлика от това, по време на турбулентни периоди доминира тричасовият импулс на потребителска нагласа, заедно с пиковете в обема на туитовете и взаимодействията между настроение и ценова стабилност, което подсказва, че бързите промени в колективното настроение движат краткосрочното ценово поведение, когато дисперсията е повишена.

РЕЖИМ	ИНДИКАТОР	ЗНАЧИМОСТ
Стабилна цена	hour	0.0378
	tweet_volume_rolling_mean_168h	0.0137
	tweet_volume_rolling_mean_72h	0.0050

Умерена нестабилност	hourly_sent_rolling_mean_6h	0.0214
	tweet_volume_rolling_mean_168h	0.0039
	sentiment_rolling_momentum_3h	0.0038
Висока нестабилност	hourly_sent_rolling_mean_6h	0.0319
	hour	0.0270
	tweet_volume_rolling_std_24h	0.0119

Таблица 4.2: Водещи 3 променливи при прогнозиране на всеки режим

В резултат на анализа дотук е реализирана двустъпкова ансамбълна прогностична система, съобразена с режимите на пазарен риск. В първата стъпка се обучава класификатор в момент t, който прогнозира текущия режим на дисперсия (нисък, среден или висок), като използва показатели, наблюдаеми в реално време – например скорошна ценови колебания, z-стойности на настроението, пикови обеми на туитове и индикатори за часа на деня. Във втората стъпка предсказаният режим определя кой от трите специализирани Gradient Boosting регресора ще се използва за генериране на едночасова прогноза за възвръщаемостта.

Архитектурата на системата балансира сложност и прецизност на прогнозата в зависимост от пазарните условия: когато дисперсията е ниска и влиянието на потребителската нагласа е водещо, се прилага моделът за нисък режим; при турбулентност се избира високият режим, в който пазарната инерция и бързите промени в нагласата са от значение. Чрез насочване на прогнозите през класификационен „вход“, моделът запазва точност във всички пазарни състояния, избягвайки недостатъците на отделните си компоненти.

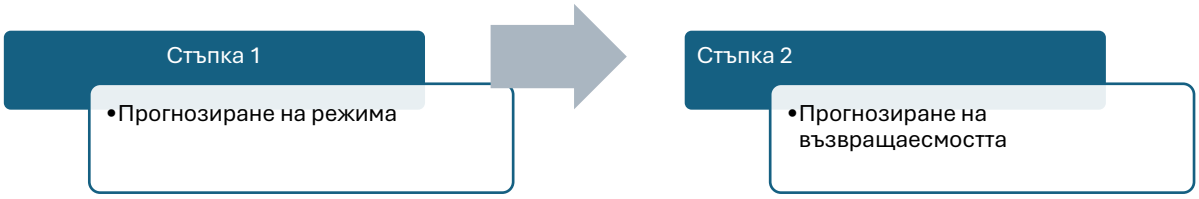

Фигура 4.2: Ансамблов модел с две стъпки

Въпреки теоретичните предимства на ансамбловия подход, той се осланя на прецизността на първата стъпка. Gradient Boosting класификаторът постига обща точност от 74.6 % (macro-F1 ≈ 0.75) при предсказване на следващия пазарен режим, което предопределя и агрегираната прогноза точност от едва R^2 ≈ 0.0305 и RMSE ≈ 0.00508. Макар точността на общия модел да не бива подобрена, условното прогнозиране чрез ансамблов модел има значителен потенциал .

МОДЕЛ/РЕЖИМ	R^2 SCORE	RMSE
Общ модел	0.050	0.0052

Ансамблов модел	0.031	0.0051
Стабилна цена	0.201	0.0014
Умерена нестабилност	0.041	0.0025
Висока нестабилност	0.066	0.0084

Таблица 4.3: Резултати в различни пазарни състояния и ключови метрики

4.2. Прогнозиране на ценова нестабилност и възвръщаемост чрез потребителски нагласи

За постигането на по-висока точност, може да бъде въведена процедура за количествено оценяване на прогнозната несигурност чрез използване на изходните вероятности на класификатора за режими. Като се третират тези вероятности като показатели за доверие и се прилага минимален праг на увереност, системата може да бъде конфигурирана да издава прогнози само когато е постигната достатъчна сигурност.

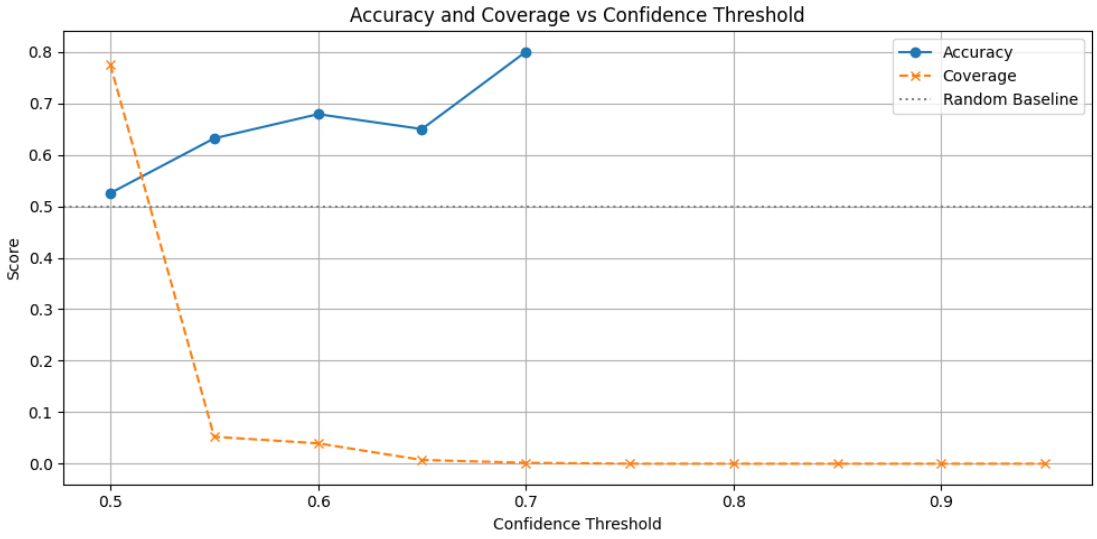

Фигура 4.3: Прецизност и покритие като функция на минималния доверителен праг

Както е показано на Фигура 4.3, при стандартен праг от 0.5, прогнозите на ансамбъла за режими постигат точност 49.4 % при 81 % обхват. Повишаването на прага води до умерено увеличение на точността за сметка на рязко намален обхват, илюстрирайки класическия компромис при селективното прогнозиране. Този механизъм позволява вземане на решения, претеглени по увереност, като прогнозите на модела могат да се реализират пазарно в съответствие с толерантността към риск на потребителя.

Моделът за прогнозиране на ценовата стабилност – също изграден с Gradient Boosting Regressor – постига $R^2 \approx 0.123$ and RMSE near 0.0037, което потвърждава, че почасовата дисперсия е по-предсказуема от възвръщаемостта, когато се използват делта на потребителските нагласи и индикатори за аномалии в броя коментари. Заедно тези разширения осигуряват както прогноза за възвръщаемост, претеглена спрямо вероятността за реализация (чрез филтриране по вероятности на класификацията), така и явна оценка за стабилност, предоставяйки на потребителя едновременно поглед върху очакваната доходност и риск – които позволяват взимането на по-информирано и съобразено с апетита към риск решение.

Фигура 4.4: Модел на многостъпково прогнозиране

Така е изградена цялостна, модулна прогностична верига, обхващаща класификация на режими, ансамблова прогноза на възвръщаемостите, оценка на ценовата стабилност и филтриране на прогнозите на базата на коефициент на увереност. Въпреки това, тези резултати се основават изключително на исторически данни и кръстосана валидация, като реалното извънизвадково представяне остава непроверено. Моделите с часова гранулярност могат да пропуснат по-високочестотни микроструктурни ефекти, а метриките за потребителски настроения отразяват само едно подмножество от пазарните участници. Независимо от тези ограничения, рамката демонстрира използваема структура чрез методи, съобразени с ценовата нестабилност и водени от потребителските нагласи, предоставяйки основа за разширения към мултимодални

режими, междупазарен анализ на потребителски нагласи или интеграция с данни от блокчейн.

4.3. Потребителски настроения отвъд Биткойн

Описаната рамка бе приложена и към Ethereum (ETH), Solana (SOL) и Ripple (XRP), за да се провери нейната обща приложимост извън Биткойн. Почасовите данни за всеки актив – включително възвръщаемост, ценова стабилност, показатели за потребителска нагласа и внимание – бяха обработени аналогично: класификация на режимите, ансамблова регресия, специфична за режима, прогнозиране на ценовата стабилност и филтриране на базата на увереност. Това допълнение има за цел да установи дали зависимостта на предсказуемостта от режима и водещата роля на настроенията, наблюдавани при BTC, се запазват при други криптовалути с висока ликвидност, степен на употреба и профил в социалните медии. Съответстващи модели биха подсказали универсална роля на предложения модел за прогнозиране, докато съществени различия биха откроили специфични микроструктурни или поведенчески влияния при съответните активи.

АКТИВ	ЦЕНОВА НЕСТАБИЛНОСТ	ПРОГНОЗИРАНА ВЪЗВРЪЩАЕМОСТ (R^2)	ПРОГНОЗИРАНА ВЪЗВРЪЩАЕМОСТ (RMSE)	ПРОГНОЗИРАНА ДИСПЕРСИЯ (R^2)	ПРОГНОЗИРАНА ДИСПЕРСИЯ (RMSE)
BTC	Ниска	0.2006	0.00137	0.1226	0.00372
BTC	Средна	0.0406	0.00245	0.1226	0.00372
BTC	Висока	0.0660	0.00836	0.1226	0.00372
ETH	Ниска	0.0687	0.00111	0.0777	0.00451
ETH	Средна	0.0235	0.00288	0.0777	0.00451
ETH	Висока	0.0362	0.01037	0.0777	0.00451
SOL	Ниска	0.2449	0.00267	0.0793	0.00693
SOL	Средна	0.0787	0.00528	0.0793	0.00693
SOL	Висока	0.0284	0.01623	0.0793	0.00693
XRP	Ниска	0.1944	0.00144	0.1970	0.00655
XRP	Средна	0.0239	0.00323	0.1970	0.00655
XRP	Висока	-0.0810	0.01398	0.1970	0.00655

АКТИВ	АНСАМБЪЛНА ПРОГНОЗА (R^2)	АНСАМБЪЛНА ПРОГНОЗА (RMSE)	ТОЧНОСТ НА КЛАСИФИКАЦИЯТА НА РЕЖИМА (%)
BTC	0.0305	0.00508	74.6
ETH	0.0408	0.00606	71.0
SOL	0.0260	0.00941	72.0
XRP	0.0201	0.00877	72.0

Таблица 4.4. a,b: Сравнение на моделите при високоликвидни активи

За ETH прогнозите за възвръщаемост при ниска дисперсия постигат $R^2 \approx 0.0687$, RMSE ≈ 0.00111, прогнозите за ценова стабилност - $R^2 \approx 0.078$, резултат при ансамбловия модел $R^2 \approx 0.0408$, и точност на класификатора на режим от 71%. Тези резултати сочат по-слаба прогностична сила, базирана на потребителски нагласи, отколкото при Биткойн, което може да отразява по-широките DeFi приложения на Ethereum.

SOL демонстрира ярко изразена зависимост от режимите: в спокойни периоди прогнозите за възвръщаемост достигат пик от $R^2 \approx 0.2448$, докато при средна и висока дисперсия грешките значително нарастват. Ансамбловият модел за SOL постигна $R^2 \approx 0.0260$, а точността на класификатора остава силна – 72 %. По-силният сигнал при ниска ценова нестабилност и по-високият шум при висока ценова нестабилност вероятно произтичат от по-новата, с по-ниска ликвидност пазарна структура на Solana и активността около мемкойни.

XRP показва при ниска ценова нестабилност $R^2 \approx 0.1944$ и RMSE от 0.00144 що се отнася до възвръщаемост а при прецизна прогноза за ценова стабилност постигна най-силни резултати с$R^2 \approx 0.197$, но представянето се срина при високо несигурни режими ($R^2 \approx -0.081$). Тази картина вероятно отразява регулаторната несигурност и спорадичните новинарски шокове, характерни за Ripple. Друго възможно обяснение е покритието на данните – потребителските нагласи обхващат единствено английски език, докато XRP има голяма и активна потребителска общност в Далечния Изток.

От научна гледна точка, тези резултати частично подкрепят универсалната роля на модела – особено в стабилни режими – като същевременно подчертават, че специфичните за актива ликвидност, движещи иновациите фактори и поведенческите особености на общността модулират силата и устойчивостта на прогностичните зависимости. Ограниченията включват по-кратките исторически серии за по-новите активи, не моделирани външни събития и скромна прогностична сила на почасова база, но моделът (Фигура 4.4) остава работеща основа за бъдещи изследвания в областта на прогнозирането на динамиката на крипто активи.

4.4. Частният случай на мемевалутите

Към класа на „мемкойните“ спадат Dogecoin (DOGE), Shiba Inu (SHIB) и Pepe (PEPE), чиято стойност се генерира почти изцяло от социални феномени – мрежови ефекти, вирусно разпространение и динамика на наратива – а не от присъща полезност или парични потоци. Цените на тези валути се движат от рефлексивни обратни връзки: нарастващото внимание поражда повишаване на цените, което от своя страна привлича

допълнително внимание. Това прави мемкойните архетипни „активи на вниманието“, силно чувствителни към промени в потребителското настроение и склонни към спекулативни балони, съответстващи по-скоро стадно поведение и „динамиката на по-големия глупак“, отколкото на традиционните фундаментални методи за оценка.

За да се провери дали прогностичния модел, базиран на потребителска нагласа, е приложим и при тези активи, прилагаме същата методология към DOGE, SHIB и PEPE. Така изследваме дали откритите при Биткойн и други основни криптовалути зависимости, се запазват или напълно се разрушават при екстремните социотехнически условия, характерни за пазарите на мемкойни.

АКТИВ	ЦЕНОВА НЕСТАБИЛНОСТ	ПРОГНОЗИРАНА ВЪЗВРЪЩАЕМОСТ (R^2)	ПРОГНОЗИРАНА ВЪЗВРЪЩАЕМОСТ (RMSE)	ПРОГНОЗИРАНА ДИСПЕРСИЯ (R^2)	ПРОГНОЗИРАНА ДИСПЕРСИЯ (RMSE)
DOGE	Ниска	-0.0018	0.00128	0.1568	0.00766
DOGE	Средна	-0.0211	0.00397	0.1568	0.00766
DOGE	Висока	0.0267	0.01611	0.1568	0.00766
SHIB	Ниска	-0.0279	0.00158	0.1791	0.01008
SHIB	Средна	-0.0138	0.00423	0.1791	0.01008
SHIB	Висока	0.0008	0.01697	0.1791	0.01008
PEPE	Ниска	-0.1070	0.00326	0.1277	0.01069
PEPE	Средна	-0.1123	0.00722	0.1277	0.01069
PEPE	Висока	-0.0362	0.02451	0.1277	0.01069

АКТИВ	АНСАМБЪЛНА ПРОГНОЗА (R^2)	АНСАМБЪЛНА ПРОГНОЗА (RMSE)	ТОЧНОСТ НА КЛАСИФИКАЦИЯТА НА РЕЖИМА (%)
DOGE	-0.0088	0.00941	75.3
SHIB	0.0395	0.01014	77.9
PEPE	0.0811	0.01501	79.1

Таблица 4.5. a,b: Сравнение на моделите при мемевалути

Прогнозирането на възвръщаемост се оказа невъзможно в частния случай на мемкойни, със стойности на R^2 под нулата дори в състояния на ниска ценова нестабилност (напр. PEPE, където $R^2 \approx -0.107$ в режима на ниска дисперсия и $R^2 \approx -0.112$ при средна). За разлика от това, прогнозите за едночасова дисперсия постигат R^2 между 0.1277 и 0.1791 за DOGE, SHIB, и PEPE, превъзхождайки много от активите с висока капитализация. При всички мемкойни индикаторът за пикове в обема на туитове се оказа доминиращ предиктор на бъдещата нестабилност. Тези резултати подсказват, че стандартната мярка за нетно настроение ΔS вероятно не успява да улови езиково богатия, често ироничен и саркастичен дискурс, движещ цените на мемкойни, правейки моделите за възвръщаемост неефективни. Дисперсията обаче остава отчасти предсказуема чрез внезапни изблици на коментари в социалните медии, което предполага, че мемкойните

се държат като „активи на вниманието“, чиято риск-динамика — но не и посоката на възвръщаемостта — може да бъде предвидена чрез наблюдение на социалните медии.

За адресирането на това ограничение би могъл да бъде въведен по-усъвършенстван модел за анализ на сантимента, например чрез засичане на ирония и сарказъм (напр. чрез допълнително обучение на NLP класификатори върху крипто-специфичен корпус); анотация на емоции извън двоичните позитивно/негативно (напр. възбуда, страх, удовлетворение, ирония); или моделиране на теми за разграничаване на ценово значими споменавания от несвързаните дискусии. Такива подобрения биха намалили системната грешка - въведена от опростените мерки за потребителска нагласа - при работа с културно натоварени активи като мемкойните. По-нататъшни изследвания следва да се фокусират върху по-богати методи за текстов анализ за насочени сигнали, като в същото време се използват пиковете в обема на туитове като универсален прогностик на ценова нестабилност.

4.5. Практически съображения, критика и потенциал на реализация

Изградена е пълна, модулна прогнозна верига – обхващаща класификация на режими, прогнозиране на възвръщаемост и дисперсия, и филтриране, претеглено с увереност в прогнозата – но внедряването на модела към трейдинг в реално време носи допълнителни предизвикателства. Историческите бек тестове и кръстосаната валидация (напр. R^2 и RMSE) не гарантират представяне при нестационарност, концептуален дрейф или структурни прекъсвания. В практиката, моделите трябва да се наблюдават чрез извънизвадкова валидация, плъзгащо се преобучаване и статистическо откриване на дрейф, като данните се разделят на обучителни, валидационни и прозорци за симулация на живо.

В реална ситуация, явления като приплъзване на цената, разширяване на спреда и латентност на търговията – изискват допълнително нагласяне чрез модел на транзакционни разходи и динамично определяне на размера на позициите с помощта на прогнози за ценовата стабилност, отразяващи апетита към риск за всяка сделка. Настоящата архитектура поддържа разширения към други активи или портфолио от множество активи. Въпреки това, преди реално тестване, е от съществено значение да се осигури солидна инженерна поддръжка – например, нисколатентни двупосочни потоци от данни.

Заключение и научни приноси

Настоящата дисертация предоставя изчерпателно изследване на икономическите сили, определящи ценовата динамика на криптовалутите, чрез интегриране на теоретичен синтез, стриктен емпиричен анализ и методологични иновации. Първата глава включва критичен преглед на литературата, синтезиращ познание от финансовата икономика, монетарната теория и иконометрията. Подчертани са ограниченията на конвенционалните модели за оценка на активи при прилагането им към дигитални валути – по-специално по отношение на децентрализираните емисионни механизми, тежкоопашатите разпределения на възвръщаемост и липсата на анализ на поведенческите нагласи в близко до реалното време – и така се установи интелектуалната основа и изследователските пропуски, мотивиращи изследването.

Втора глава развви този преглед, като подробно описва методологията и източниците на данни. Формулиран е холистичен подход, съчетаващ иконометрични техники за анализ на времеви редове – включително оценки на стационарността, векторни авторегресии и модели на корекция на грешки за дългосрочна и краткосрочна динамика, както и скрити Марковски модел за идентификация на латентни състояния. Документирани са подходи за предварителна обработка, критерии за избор на модели и диагностични тестове за устойчивост, за да се гарантира възпроизводимост на резултатите и статистическа валидност.

Третата глава прави задълбочено проучване на основните пазари на криптовалути. Емпиричните анализи потвърждават ключови факти: тежкоопашати разпределения на възвръщаемостите, клъстериране на ценовата несигурност и прекъснати промени на режими. Оценките на взаимните корелации с конвенционални активи подчертават частичното откъсване на дигиталните активи от утвърдените пазари, оправдавайки необходимостта от специализирани подходи за оценка и прогнозиране. Главата допълнително разгледа макроикономическите детерминанти чрез векторни авторегресионни и коректни за грешки модели. Чрез включване на индикатори като реален растеж на БВП, лихвени проценти и индекси на икономическа несигурност (EPU) количествено се определят както дългосрочните равновесни връзки, така и краткосрочната корективна динамика на цените на криптовалутите, като се предоставят доказателства за определени макроикономически влияния.

Четвърта глава изследва микроикономическите и поведенчески двигатели на цените на криптоактивите, показвайки, че извлечения то социални мрежи сигнал за потребителска нагласа, носи слаб, но приложим сигнал за прогнозиране на почасовата

възвръщаемост и ценова стабилност на Биткойн, след като се отчетат нелинейните връзки и периодичните смени на режими. Създаден е спомагателен модел и цялостна прогностична рамка на ценовата динамика и стабилност, за постигането на информирано, ориентирано към апетита към риск вземане на решения. Приложението на рамката върху Ethereum, Solana и Ripple потвърждава, че връзките между потребителска нагласа и цена са системни, но специфични за всеки актив, като прогностичната сила е най-голяма в режими на ниска нестабилност и отслабва в зависимост от ликвидността, предназначението и особеностите на общността. Задълбоченото изследване на мемкойните (Dogecoin, Shiba Inu, Pepe) показва, че тяхната рефлексивна, водена от вниманието динамика до голяма степен прави невъзможно прогнозиране на възвръщаемостта, но оставя възможност за прогнозиране на ценовата стабилност, подчертавайки как екстремните повествователни активи натоварват традиционните моделни допускания.

В заключение, чрез адресиране както на теоретичните, така и на емпиричните измерения – и чрез комбиниране на иконометричната прецизност с модерни техники за машинно обучение - дисертацията допринася за разбирането на оценката и управлението на риска при криптовалути. Тя полага здрава основа за бъдещи изследвания на мрежовите ефекти, портфолио анализа и анализа на макроикономическите интервенции, а нейните приноси имат потенциала да информират инвестиционни стратегии, регулаторни политики и продължаващия академичен диалог по икономика на дигиталните активи.

Научни приноси

Научните приноси могат да бъдат обобщени в три основни групи:

- Научни
    - Дисертацията изследва и оличествява авторегресионните свойства и сезонната динамика на ценовото поведение на крипто активи
    - Предоставени са доказателства, че промените в лихвените проценти и публичният дълг, безработицата, потребителското доверие, инфлацията и други стандартни макроикономчески променливи имат незначителен ефект върху ценовата динамика на крипто активи, но хроничната инфлация оказва статистически значим, положителен ефект върху употребата им
    - Идентифицирани са потребителските настроения като водещ фактор и е оличествен потенциалния им ефект върху ценовата динамика
- Научно-приложни

    - Дисертацията формулира рамка за ценови анализ на крипто активи, която формално свързва външни шокове, макроикономически фактори и поведенчески фактори в рамките на единен иконометричен модел; моделът е със значително подобрена точност на прогнозиране, предлагайки на инвеститорите възможност за управление на портфолиото и пазарните рискове
- Методологични
    - Анализира се и е оценена предвиждащата способност на 108 модела и комбинации от модели, базирани на машинно самообучение, като показва как те могат да бъдат използвани за прогнозиране на ценовата динамика на крипто активи

Списък с публикации по темата на дисертационния труд

1. Shalvardjiev, Dimiter. "Asset Hedging via Digital Asset Indices." Икономически изследвания 1 (2025): 63-88.
2. Shalvardjiev, Dimiter. "How Bitcoin Etfs Affect Spot Prices." Available at SSRN 5115838. Accepted for publication in Икономически изследвания

Списък с публикации извън темата на дисертационния труд

1. Gerunov, A., Atanasov, I., Yanchev, M., Shalvardjiev, D., Mengov, G., Egbert, H., Dineva, L., Pantcheva, R., Korcheva, A. (2024). Drivers of perceptions towards euro adoption among the young: evidence from Bulgaria. Access to science, business, innovation in the digital economy, ACCESS Press, 5(2), 185-206, https://doi.org/10.46656/access.2024.5.2(1).
2. Shalvardjiev, D. (2020). Chapter 8: Technological aspects of personal data protection. Chapter 8 in Shalvardjiev, et al. (Eds.), Privacy by Design: Principles, practices, and technologies. Sofia University “St. Kliment Ohridski”, Faculty of Economics and Business Administration. ISBN: 978-954-9399-59-2.

Бъдещи насоки на изследване

Бъдещите изследвания следва да разширят и прецизират съществуващите модели, като отстранят техни ограничения и включат допълнителни фактори, например on-chain

метрики и показатели за активност в мрежата, като така усъвършенстват оценката на фундамента, но и динамиката във времето. Разширяването на макроикономическите ковариати с детайлни политически интервенции – като пилотни проекти на централни банк цифрови валути – и прилагането на техники с инструментални променливи биха могли да засилят причинно-следствените изводи. Методологично, интегрирането на дълбоки невронни архитектури за анализ на текст и графови невронни мрежи за взаимодействия между валути може да улови сложни нелинейности и междувалутни преливания. Освен това изследване на въздействието на политиките в условия на жив експеримент или чрез събитийни анализи на регулаторни анонси, може да се предложат практически подходи за регулиране на пазара. Чрез следване на тези насоки учените могат допълнително да подобрят приложимостта на прогнозните рамки в динамичната и сложна област на икономиката на дигиталните активи.