

Київський національний університет імені Тараса Шевченка

Економічний факультет

Кафедра економічної кібернетики

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

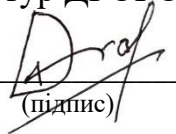
Економіко-математичне моделювання динаміки ринку криптовалют

студента 2 курсу магістратури
спеціальності 051 «Економіка»
ОНП «Економічна кібернетика»
денної форми навчання
Дрогомерецького Артура
Володимировича

Науковий керівник:

докторка економічних наук,
професорка
Ляшенко Олена Ігорівна

Засвідчую, що в цій роботі немає
запозичень із праць інших авторів без
відповідних посилань
Артур ДРОГОМЕРЕЦЬКИЙ


(підпис)

Роботу допущено до захисту перед ЕК
рішенням кафедри економічної кібернетики
від 13 травня 2024 р., протокол № 13

Завідувачка кафедри:
докторка економічних наук, професорка
Олена ЛЯШЕНКО _____
(підпис)

КИЇВ – 2024

РЕФЕРАТ

Кваліфікаційна робота магістра містить 59 ст., 18 рис., 9 табл., 44 джерела.

Ключові слова: прогнозування курсів криптовалют, фрактальний аналіз, ARIMA, LSTM, гібридна модель, лінійна регресія.

Об'єктом дослідження є процес прогнозування динаміки ринку криптовалют.

Предметом дослідження є моделі прогнозування курсів криптовалют на основі ARIMA, рекурентних нейронних мереж LSTM та фрактального аналізу.

Мета дослідження: аналіз теоретико-методологічної бази, використання ARIMA та LSTM моделей в поєднанні з фрактальним аналізом часових рядів для прогнозування курсів криптовалют, а також розробка гібридної моделі на їх основі, порівняльний аналіз застосованих моделей та оцінка результатів прогнозування.

Наукова новизна: розробка гібридної моделі на основі ARIMA та LSTM удосконаленої показником фрактального аналізу.

Практична цінність полягає у використанні гібридної моделі за допомогою якої можна прогнозувати курси криптовалют на основі історичних даних

RESUME

Taras Shevchenko National University of Kyiv,

Faculty of Economics, Department of Economic Cybernetics

Keywords: cryptocurrency forecasting, fractal analysis, ARIMA, LSTM, hybrid model, linear regression.

The graduation research of a student Artur Drohomeretskyi deals with application and development of hybrid economic-mathematical models for forecasting the dynamics of the cryptocurrency market.

The work is interesting for scientists, investors and traders.

Pages 59, tables 9, bibliog. 44.

ЗМІСТ

ВСТУП.....	5
РОЗДІЛ 1. ВИЗНАЧЕННЯ СУТНОСТІ РИНКУ КРИПТОВАЛЮТ	8
1.1 Особливості ринку криптовалют	8
1.2 Особливості блокчейну та його порівняння з традиційними фінансовими системами	9
1.3. Огляд літератури	14
1.4. Постановка задачі	15
Висновки до розділу 1	16
РОЗДІЛ 2. МЕТОДОЛОГІЧНІ ЗАСАДИ МОДЕЛЮВАННЯ ДИНАМІКИ РИНКУ КРИПТОВАЛЮТ	17
2.1. Фрактальний аналіз та показник Херста	17
2.2. Модель ARIMA.....	23
2.3. Опис моделей глибинного навчання	24
2.3.1 Модель на основі LSTM шарів	25
2.4. Метрики для оцінки точності моделей.....	27
Висновки до розділу 2.....	28
РОЗДІЛ 3. МОДЕЛЮВАННЯ ТА АНАЛІЗ РЕЗУЛЬТАТІВ	30
3.1. Збір та обробка даних.....	30
3.2. Характеристика та розробка параметрів для наборів даних	32
3.3. Імплементация та налаштування LSTM моделі.....	35
3.4. Імплементация та налаштування ARIMA моделі	39
3.5. Результати моделей ARIMA та LSTM.....	41
3.6. Розробка гібридної моделі на основі LSTM та ARIMA та оцінка результатів	47

	4
3.7. Опис програмного забезпечення для дослідження	54
Висновки до розділу 3	56
ВИСНОВКИ	58
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	60

ВСТУП

Актуальність теми прогнозування ринку криптовалют постає необхідною у зв'язку зі швидкими темпами зростання цього сектору та його впливом на економічну та фінансову систему. Розвиток технологій та ринку криптовалют в цілому, ставить перед сучасним суспільством питання про роль і перспективи широкого впровадження технології блокчейн. Однак, неоднозначність у правовому статусі криптовалют та значні коливання їх курсів призводять до великих ризиків інвестування в ці активи. Внаслідок цього, розробка ефективних методів прогнозування динаміки показників криптовалют стає актуальною проблемою як для наукової спільноти, так і для фінансових аналітиків, інвесторів та трейдерів.

Часові ряди криптовалют характеризуються складною динамікою, екстремальними спостереженнями та високим ступенем волатильності. Вони також є нестационарними, фрактальними та мають негаусівський розподіл [1]. Ці особливості ринку ускладнюють використання традиційних методів прогнозування.

Тому актуальність розробки моделей для точного прогнозування динаміки ринку криптовалют стає надзвичайно важливою у зв'язку зі швидким розвитком цього сектору. Для досягнення таких прогнозів необхідно удосконалювати методи аналізу та моделювання динаміки криптовалютного ринку, враховуючи складність його структури та високий рівень невизначеності.

Об'єктом дослідження є процес прогнозування динаміки ринку криптовалют.

Предметом дослідження є моделі прогнозування курсів криптовалют на основі ARIMA, рекурентних нейронних мереж LSTM та фрактального аналізу.

Мета дослідження: аналіз теоретико-методологічної бази, використання ARIMA та LSTM моделей в поєднанні з фрактальним аналізом часових рядів для прогнозування курсів криптовалют, а також розробка гібридної моделі на їх

основі, порівняльний аналіз застосованих моделей та оцінка результатів прогнозування.

Для досягнення мети дослідження сформовані наступні **завдання**:

- визначити сутність ринку криптовалют та технології блокчейн;
- проаналізувати стан наукової думки про методи прогнозування динаміки ринку криптовалют;
- описати моделі ARIMA та LSTM для прогнозування динаміки ринку криптовалют;
- визначити місце фрактального аналізу часових рядів та поєднати його з LSTM моделлю;
- налаштувати та провести тренування розроблених моделей;
- розробити гібридну модель, скомбінувавши моделі ARIMA та LSTM;
- здійснити прогнозування криптовалют за допомогою розроблених моделей;
- проаналізувати та оцінити результати прогнозування.

Методи дослідження: фрактальний аналіз, показник Херста, розширений тест Дікі-Фуллера, тест Харке-Бера, модель авторегресійного інтегрованого ковзного середнього (ARIMA), нейронна мережа довгої короткочасної пам'яті (LSTM), метрики для оцінки точності: MAE, MAPE, MSE, RMSE, R^2 .

Наукова новизна: розробка гібридної моделі на основі ARIMA та LSTM удосконаленої показником фрактального аналізу.

Практична цінність полягає у використанні гібридної моделі за допомогою якої можна прогнозувати курси криптовалют на основі історичних даних.

Інформаційна база дослідження складається із літературних та бібліографічних джерел, а також інтернет-ресурсів, посилання на які наведено в списку використаних джерел.

Структура роботи: Робота складається із вступу, трьох розділів, висновку та додатку, загалом 59 сторінок. У першому розділі визначено особливості ринку

криптовалют та технології блокчейн, а також сформовано постановку задачі дослідження. Другий розділ визначає методологічні засади підходів до прогнозування криптовалют за допомогою моделей ARIMA та LSTM на основі показників фрактального аналізу.

В третьому розділі висвітлюється застосування обраних моделей та створення гібридної моделі на їхній основі. Подані результати прогнозування п'яти криптовалют, визначено точність моделей та проведено їхнє порівняння. У роботі представлено 18 рисунків, які візуалізують та підкріплюють висновки, а також наявні 9 таблиць.

РОЗДІЛ 1. ВИЗНАЧЕННЯ СУТНОСТІ РИНКУ КРИПТОВАЛЮТ

1.1 Особливості ринку криптовалют

Швидкі темпи зростання криптовалютного ринку та його взаємодія з економічними, фінансовими та іншими системами вимагають глибокого аналізу цього явища. Особливу увагу привертає той факт, що ведуться активні дискусії щодо легалізації криптовалют та їхнього використання в економічній діяльності на національних та міжнародному рівнях. Незважаючи на різноманітність поглядів експертів на цю проблему, ринок криптовалют стрімко розвивається, проявляючи свою персистентність навіть у змінному регулятивному середовищі. Це свідчить про його потужний потенціал і здатність адаптуватися до змін, що відбуваються в економіці та фінансовій сфері.

Щодо майбутньої ролі криптовалют в економіці, їх прогнозування стає важливим для розуміння напрямків розвитку фінансових та технологічних інновацій. Прогнози допомагають компаніям та урядам готуватися до змін у фінансовій системі та відповідати на виклики, що виникають у зв'язку з цими нововведеннями. Крім того, вони визначають можливості для нових бізнес-моделей та стратегій інвестування. Точне прогнозування також сприяє збереженню фінансової стабільності та захисту інвесторів у цьому швидкозмінному середовищі та допомагає сприяти розумінню можливих впливів криптовалют на глобальну економіку та суспільство в цілому. Гроші все більше переходять у цифрову форму, поєднуючись з новими технологіями, що призводить до появи нових криптовалют та загального розвитку ринку. Різниця між криптовалютами та традиційними валютами настільки велика, що багато людей поки що не розуміють їхньої суті.

Щодо аналізу волатильності та прогнозування цін на криптовалюти, у роботі [2] виділяють три зовнішні впливи, що впливають на ціни криптовалют. Це сам ринок криптовалют, до якого відносяться популярність, ринкові тенденції та спекуляції; макрофінансові впливи, тобто акції, обмінні курси, ціна золота, процентні ставки та ін. А також політичні, тобто легалізація, обмеження чи

заборони та зовнішні ринки. Основними факторами є попит та пропозиція, вартість транзакцій, система винагород, хешрейт та обіг монет [3]. Змінні, пов'язані з ринком криптовалют, такі як обсяги торгів і невизначеність, як короткострокова, так і довгострокова, а також сильна волатильність біткоіна, значно впливають на курси всіх криптовалют [4].

Криптовалюта покладається на автоматизовану технологію блокчейн. Впроваджуючи механізм управління доступом, ця система забезпечує дотримання конфіденційності та захисту даних користувачів [5]. Цей ринок відрізняється від традиційних фінансових ринків через свою унікальну природу та високу волатильність, що і буде розглянуто в наступному підрозділі.

Такі особливості криптовалютного ринку породжують необхідність впровадження механізмів прогнозування, які потенційно були б корисними для інвесторів, трейдерів та урядових установ.

1.2 Особливості блокчейну та його порівняння з традиційними фінансовими системами

Концепція блокчейну була запропонована Сатоші Накамото в 2008 році [6]. Автори Ахмад Ф. та ін. зазначають, що біткоін є децентралізованою криптовалютою та однією з найбільш провідних технологій блокчейну [7]. Згідно з документом [8], технологія блокчейн є однією з важливих новітніх технологій, яка використовується не лише центральним банком країни, але й широко використовується комерційними банками країни для захисту своїх щоденних транзакцій.

Технічно кажучи, типовий блокчейн складається з однорангової мережевої системи, керованої комп'ютерами, яка підтримує децентралізований обмін і зберігає записи фінансових транзакцій [9].

Загалом, систему блокчейн можна уявити як послідовність блоків, які розподілені між користувачами на основі пірингової мережі. Кожний блок має унікальний цифровий індикатор, який називається хеш-сумою. Блоки

упорядковані згідно з математичною функцією, яка забезпечує визначену послідовність.

Блокчейн можна лише читати та створювати, але немає можливості редагувати після завершення фінансової операції. Для забезпечення такої поведінки та підтримки надійності мережі в цілому використовуються два основних механізми консенсусу блокчейн: Proof of Work та Proof of Stake .

У методі PoW, тобто доказу виконаної роботи, мережа вимагає від учасників виконувати складні обчислювальні завдання, які називаються майнінгом, для валідації та обробки нових блоків даних. Учасникам, які успішно виконують ці завдання, надається право додати новий блок до ланцюжка блоків, отримуючи за це винагороду у формі криптовалюти. Загалом ця система дуже енергозатратна, оскільки з усіх агентів, які проводять обчислення, право створити новий блок є лише у одного. Тому величезна кількість енергії витрачається марно, також утворюючи відходи в вигляді обладнання [10].

У методі PoS, тобто доказу частки володіння, учасники мережі, які володіють певною кількістю криптовалюти, можуть ставити її у заставу, тобто так званий стейкінг, для отримання права на обробку та підтвердження нових блоків даних. Шанс на обрання учасників для підтвердження блоків пропорційний кількості криптовалюти, яку вони мають у заставі, проте не є гарантованим. PoS сприяє енергоефективності та економічній ефективності, оскільки не потребує великої кількості обчислювальних ресурсів, а також стимулює учасників зберігати криптовалюту на довгостроковий період для підтримки мережі. Основним недоліком системи є унеможливлення виведення коштів зі стейкінгу до визначеного терміну [11].

Згідно з дослідженням Кейроша М. Та ін. [12], кожен раз, коли в системі відбувається нова транзакція, кожен учасник мережі отримує копію цієї транзакції. Дослідження також вказує на те, що мережі блокчейн не можна контролювати однією особою, але кожен учасник мережі отримує однакову інформацію, оскільки ця система побудована спеціально для забезпечення чіткості та прозорості у фінансовій системі. Завдяки розподіленій мережі

технології блокчейн у ній існує різна кількість копій, що робить її більш безпечною та аудитованою.

Також Фріццо-Баркер та ін. [13] досліджують детальніше ідею про копії фінансових транзакцій розподілених серед учасників мережі та неможливість зміни чи підробки існуючих транзакцій, а також незаконного додавання нових. Перевірена інформація про фінансові транзакції не може бути видалена, ще їх дослідження підкреслює, що технологія блокчейн надає хронологічну історію фінансових транзакцій. Крім того, вони аргументують, що спроба додати або видалити дані про транзакції вимагатиме атаки на тисячі транзакцій, що недосяжно для однієї особи чи групи осіб.

Порівнюючи блокчейн із традиційною банківською системою, в якій достовірність переказів регулюється інституціями, тобто банками, в яких можуть допускатися помилки, транзакції в блокчейні будуються на основі інших блокчейнів, формуючи ланцюжок. За час існування біткоїн були лише успішні хакерські атаки на місця, де зберігались токени, з метою заволодіти ними, але не на сам блокчейн.

Гуо Ю. та Лян С. [14] критично аналізують існування монополії банківського сектору та зростаючий попит споживачів на криптовалютні біржі через вимоги до мінімального балансу та великі комісії банків. Вони стверджують, що технологія блокчейн виступає як конкурент традиційних банків, пропонуючи необмежений доступ до фінансів, що дозволяє клієнтам проводити транзакції без перешкод за допомогою мобільних пристроїв. Гірченко та ін. [15] додатково підкреслюють, що система реєстрації блокчейн значно зменшує ризик шахрайства, надійно реєструючи фінансові транзакції в окремих блоках.

Традиційні банківські системи базуються на централізованому управлінні, де фінансові транзакції контролюються і підтверджуються центральними органами, такими як банки або фінансові установи. В цьому випадку довіра споживачів покладається на інституції, які виступають посередниками. Натомість, блокчейн технологія пропонує децентралізований підхід до

збереження та підтвердження фінансових транзакцій. У блокчейні кожна транзакція підтверджується розподіленою мережею комп'ютерів, а не централізованим органом. Крім того, блокчейн забезпечує безпеку та недоторканність даних за рахунок криптографічного захисту та децентралізованої природи мережі.

Ключовою перевагою блокчейну можна вважати його прозорість та невідворотність. Це створює додатковий рівень довіри серед учасників фінансових операцій.

До основних переваг блокчейн технології можна віднести:

- Децентралізація, яка є однією з ключових характеристик, що визначає криптовалюту та блокчейн технологію. Відмінність від традиційних фінансових систем полягає в тому, що жодна установа не має повного контролю над мережею. Замість цього, криптовалютні мережі підтримуються спільнотою програмістів та управляються відкритою мережею спеціалізованих комп'ютерів. Це забезпечує більшу незалежність в контролі своїх активів, в порівнянні з традиційними банківськими системами.

Наприклад, біткоїн розв'язує проблему подвійних витрат електронних валют, яка полягає у можливості легкого копіювання та повторного використання цифрових активів, за допомогою оригінальної комбінації криптографії та економічних стимулів.

У традиційних фінансових системах функцію захисту валюти виконують банки, що надає їм контроль над операціями у цій системі. У випадку з біткоїнами, цілісність транзакцій підтримується розподіленою та відкритою мережею. Це створює додатковий рівень безпеки та довіри серед користувачів, що використовують криптовалюту та блокчейн.

- Обмеженість токенів. Фіатні валюти мають необмежену пропозицію, це означає, що на їх випуск впливають лише центральні банки, при такому підході значно збільшується ризик знецінення валюти через надмірну пропозицію.

У свою чергу згідно з протоколом біткоїна, максимальна кількість токенів, яку можна створити, складає 21 мільйон монет. Ця обмежена кількість була

встановлена з метою контролю за валютою і уникнення її знецінення. Так, нові біткоїни створюються через процес, який відомий як майнінг. Майнінгові системи проводять складні математичні обчислення, що перевіряють транзакції та додають їх до блокчейну. Кожну годину генерується лише обмежена кількість нових біткоїнів. Також з часом обчислення стають складнішими, що призводить до зменшення швидкості видобутку. Ще для контролю курсу біткоїна проводиться халвінг, після якого винагорода за кожний видобутий блок стає меншою вдвічі. Все це робить біткоїн привабливішим як актив. У разі зростання попиту і незмінності пропозиції його вартість зростає.

- Анонімність у блокчейні є ключовою перевагою, яка забезпечує захист особистої інформації та конфіденційності учасників мережі. Кожний агент здійснює операції за допомогою свого відкритого ключа, але система не передає особисту інформацію від цих ключів. Проте важливо відзначити, що транзакції в системі є публічними. Тому за ключем можна отримати доступ до поточного стану його рахунку та історії транзакцій. Тому принцип анонімності в блокчейні дозволяє користувачам проводити транзакції, не розголошуючи своєї особистої інформації, та сприяє створенню довіри серед учасників мережі.

Серед недоліків блокчейну та криптовалют можна виділити значно вищу волатильність активів в порівнянні з іншими фінансовими ринками. Спершу може здатися, що це гарний спосіб заробити на стрімких змінах курсів криптовалют. Проте це лише прояв нестабільності та мінливості, при якому легко втратити активи.

До ще одного недоліку криптовалютних систем можна віднести відсутність достатнього правового регулювання у цій сфері. Тому при здійсненні неправильної транзакції ніхто не буде намагатись повернути кошти. Також жодний уряд не контролює ринок криптовалют, тому тут здійснюється багато шахрайських фінансових операцій з відмивання коштів, фінансування тероризму чи наркотрафіку.

Отже, біткоїн, технологія блокчейн та криптовалютний ринок в цілому представляють собою надійну та стабільну фінансову систему з великими

перспективами розвитку, тому задача моделювання та прогнозування її динаміки постає особливо актуальною проблемою в наші дні.

1.3. Огляд літератури

Використання передових методів машинного навчання дало новий поштовх для здійснення фінансових прогнозів в останні роки. Два значних підходи в цій галузі – це традиційна модель авторегресії з інтегрованим ковзним середнім ARIMA та модель глибинного навчання з довготривалою короткочасною пам'яттю LSTM. Модель ARIMA добре вловлює минулі закономірності за допомогою своїх авторегресивних та ковзних середніх компонентів. З іншого боку, модель LSTM відмінно справляється з розумінням динаміки послідовних даних, особливо складних тимчасових залежностей, використовуючи свої керовані комірки пам'яті.

У 2020 році у дослідженні [16] представлено комплексне дослідження прогнозування часових рядів для цін на біткоїн, використовуючи високорозмірні ознаки та моделі машинного навчання. Серед чотирьох методів машинного навчання таких як: штучні нейронні мережі, самонавчальні нейронні мережі, метод опорних векторів та моделей з довгою короткостроковою пам'яттю LSTM, останні показали найкращі результати на вибірці даних з 2013 року по 2019 рік з показником MAPE до 4,10%.

У дослідженні [17] автори Яо та ін. запропонували прогнозувати ціну криптовалюти, використовуючи ширший набір даних, який включає не тільки ціни, але також ринкову капіталізацію, обсяг, максимальну пропозицію. На основі отриманих ними результатів з використанням методів глибинного навчання RNN та LSTM точність прогнозування становила 59% при використанні лише цін та до 75% на розширеному наборі даних.

У дослідженні [18] автори надали всебічний аналіз ефективності моделей LSTM та ARIMA у прогнозуванні короткострокових значень Bitcoin. Це дослідження використовує набір даних з історичними цінами закриття, який

охоплює період одного року. Дані збиралися з інтервалом у 10 хвилин. Результати дослідження надають цікаві спостереження щодо поведінки кожної моделі. Модель ARIMA краще справляється з фіксацією зростаючого тренду Bitcoin, що відповідає характеристикам моделі ARIMA. Важливо зазначити, що ефективність ARIMA може спадати при початку спадаючого тренду. З іншого боку, LSTM виділяється як найкраща модель, досягаючи точності прогнозування 99,73%.

У праці [19] дослідники об'єднали методології машинного навчання з аналізом настроїв через соціальні мережі, щоб забезпечити багатовимірну перспективу формування цін на криптовалюти. У дослідженні використовували два набори даних: історичні дані були отримані з бірж криптовалют та набір даних отриманих з Twitter, і пости, отримані з Reddit. Включення цієї комбінації додало соціальної складової у процес прогнозування. Набір даних розділено на тренувальну та тестову вибірки 70% та 30% відповідно. Порівняльна оцінка моделі ARIMA та LSTM проводиться за допомогою метрики середньоквадратичної помилки (RMSE). Модель LSTM продемонструвала чудову продуктивність з точки зору значень RMSE: 198,4 для лише ціни закриття та 197,5 для всього набору даних, на відміну від значення RMSE моделі ARIMA, що склало 209,2.

1.4. Постановка задачі

Складну динаміку та значний рівень волатильності динаміки ринку криптовалют, часові ряди їх курсів, які є нестационарними, фрактальними та мають негаусівський розподіл вимагають застосування належних методів для прогнозування. Також було розглянуто праці Мадан І. та співавторів [20], які використовували різні методології машинного навчання, такі як узагальнені лінійні моделі та випадковий ліс, для вирішення завдання прогнозування криптовалюти біткоїн; Джіанга, С. [21], що запропонував методи глибокого навчання для прогнозування ціни криптовалют. Його дослідження показує, що

мережа з довготривалою та короткотривалою пам'яттю (LSTM) надає найкращий прогноз. Можемо сформулювати постановку задачі прогнозування курсів криптовалют на основі моделей ARIMA та LSTM з додаванням показників фрактального аналізу, а також розробки гібридної моделі за допомогою лінійної регресії, яка об'єднує переваги обох моделей, з метою збільшення її точності в порівнянні з цими ж моделями по окремоті.

Висновки до розділу 1

В розділі представлено короткий опис ринку криптовалют, який стрімко розвивається. Висвітлено принцип роботи блокчейн та механізми консенсусу в цій технології, які забезпечують її надійність. Проаналізовано роботи авторів, які доводять неможливість зміни чи підробки транзакцій в блокчейн. А також наведено порівняння блокчейн із традиційними фінансовими системами. Розглянуто недоліки криптовалютного ринку у вигляді високої волатильності, і на основі цього сформовано постановку задачі, яка пояснює важливість прогнозування динаміки криптовалют. Для цього використаємо моделі ARIMA та LSTM з додаванням показників фрактального аналізу, методологія яких і буде розкрита в наступному розділі.

РОЗДІЛ 2. МЕТОДОЛОГІЧНІ ЗАСАДИ МОДЕЛЮВАННЯ ДИНАМІКИ РИНКУ КРИПТОВАЛЮТ

2.1. Фрактальний аналіз та показник Херста

У сучасному світі криптовалютний ринок став об'єктом інтенсивного дослідження та уваги, особливо через його значну волатильність та непередбачуваність. За останні роки, зростаюча популярність криптовалют, таких як Bitcoin, Ethereum та інших, зумовила потребу у розвитку нових методів аналізу та передбачення їхньої цінової динаміки. Один з таких методів – використання фрактального аналізу для вивчення ринку криптовалют. Фрактальний аналіз є потужним інструментом для аналізу нелінійних систем, що дозволяє виявляти складність та фрактальну природу часових рядів. Ключовим показником у фрактальному аналізі є показник Херста, який використовується для визначення ступеня фрактальної структури ряду.

З дослідження автора про використання фрактального аналізу для часових рядів [22] можемо узагальнити, що у контексті ринку криптовалют, де відбуваються швидкі та значні зміни цін, застосування R/S-аналізу та показника Херста стає особливо актуальним. Розуміння цих фрактальних властивостей може допомогти трейдерам та інвесторам приймати кращі рішення щодо торгівлі та управління портфелем, а також покращити передбачуваність цінових тенденцій на ринку криптовалют.

У дослідженні використано R/S-аналіз та показник Херста для аналізу часового ряду курсу Bitcoin. Метод R/S-аналізу дослідження фрактальних часових рядів був запропонований Б. Мандельбротом [23] і базується на дослідженнях, проведених англійським дослідником Г. Херстом. Він базується на співвідношенні розмаху накопиченого відхилення часового ряду та середньоквадратичного відхилення. Херст ввів таке поняття, як показник Херста. Для проведення даного розрахунку не потрібно мати глибоке розуміння системи, що досліджується, також на основі цього показника можна визначити тип та наявність ефекту пам'яті в часових рядах [24].

Показник Херста можна розрахувати за формулою:

$$R / S = (aN)^H, \text{ звідки:}$$

$$H = \frac{\log(R/S)}{\log(aN)},$$

де H – показник Херста; S – середньоквадратичне відхилення; R – розмах накопиченого відхилення; N – кількість періодів спостереження; a – задана константа, додатне число [25].

Показник Херста є статистичним індикатором, який використовується для визначення ступеня самоподібності та ефекту пам'яті в часових рядах. Значення вище 0,5 підтверджує наявність довгострокової пам'яті ринку: теперішнє залежить від минулого, а майбутнє – від теперішнього[26].

Отже R/S-аналіз та показник Херста є корисними інструментами для дослідження ринку криптовалют, визначення тенденцій в часових рядах, оцінки ризику пов'язані з інвестуванням. Проте, окрім методів фрактального аналізу, доцільно використовувати інші види аналізу для забезпечення комплексного підходу та більш точних результатів досліджень.

Також для проведення цілісного фрактального аналізу, окрім фрактальності необхідно дослідити дві інші ключові характеристики вхідних даних, а саме:

- Визначення закону розподілу курсу криптовалют. Необхідно враховувати, що зазвичай курси криптовалют не мають нормального розподілу, що важливо при моделюванні.

- Перевірка ряду на стаціонарність. Загалом, стаціонарність вказує на те, що статистичні властивості часового ряду не змінюються від часу, що робить його більш прогнозованим та дозволяє застосовувати класичні методи аналізу.

Для визначення закону розподілу обчислимо: коефіцієнт асиметрії S , він вказує на те, наскільки розподіл відрізняється від симетричного розподілу навколо його середнього значення. Якщо коефіцієнт дорівнює нулю, розподіл симетричний. Позитивне значення вказує на те, що правий хвіст розподілу

більший, ніж лівий, тоді як негативне значення вказує на обернену ситуацію; коефіцієнт ексцесу, тобто відстані, на яку розподіл відрізняється від нормального розподілу. Коефіцієнт відображає форму хвостів розподілу. Позитивне значення вказує на більш гостроспрямований або «конусоподібний» розподіл, тоді як негативне значення вказує на більш плоский.

$$S = \frac{\mu_3}{T(\sigma')^3},$$

$$K = \frac{\mu_4}{T(\sigma')^4},$$

де μ_3 – третій центральний момент, μ_4 – четвертий центральний момент.

$$\sigma' = \sigma \sqrt{\frac{T-u}{T}} - \text{стандартне відхилення.}$$

Також для перевірки на нормальність розподілу часового ряду курсу криптовалют використаємо тест Харке-Бера (Jarque-Bera, JB):

$$JB = \frac{T-k}{6} \left[S^2 + \frac{1}{4}(K-3)^2 \right]$$

де T – кількість спостережень; k – кількість доданків регресії, ($k = 0$, при використанні тесту для часових рядів). При використанні тесту Харке-Бера для часових рядів, можна визначити, чи спостережувані значення мають нормальний розподіл, тобто нульова гіпотеза H_0 , чи ж альтернативні гіпотези H_α .

$$H_0: S = 0, K = 3; H_\alpha: S \neq 0, K \neq 3$$

Проведемо тест Харке-Бера для часових рядів курсів обраних криптовалют за ціною закриття:

Тест Харке-Бера

Криптовалюта	Jarque-Bera	p-value	Skewness	Kurtosis
Bitcoin	131,089306	3,42E-29	0,561625	2,321518
Ethereum	94,978526	2,38E-21	0,451822	2,343424
BNB	80,191145	3,86E-18	0,274026	2,132214
Solana	541,250285	2,94E-118	1,391895	3,996044
XRP	945,219625	5,60E-206	1,400336	5,138437

Аналізуючи часові ряди курсів обраних криптовалют за останні 5 років, можемо інтерпретувати наступні результати тесту Харке-Бера так: якщо p-value більше ніж 0,05, а значення показника Харке-Бера досить низьке, тоді ми можемо розглядати нульову гіпотезу про нормальність розподілу. В даному випадку для усіх досліджуваних криптовалют ("BTC-USD", "ETH-USD", "BNB-USD", "SOL-USD", "XRP-USD") p-value нижче заданого рівня значимості 0,05, а показник Харке-Бера є досить високим.

Якщо показник асиметрії skewness > 0 , то розподіл скошений вправо, тобто більше великих значень, якщо skewness < 0 , то розподіл скошений вліво, тобто більше малих значень, якщо skewness = 0, то розподіл симетричний. Як можна бачити з табл. 2.1, усі криптовалюти мають більше великих значень у рамках досліджуваного періоду.

Значення ексцесу (kurtosis) менше 3 для Bitcoin, Ethereum та BNB, це свідчить про те, що їх розподіл має більше високих «хвостів» та вузький пік, тобто захоплює вибірку з більшими високими значеннями. В свою чергу для Solana та XRP цей показник більше 3, відповідно розподіл має менше високих хвостів, ширший пік та захоплює вибірку з меншими високими значеннями.

Тому з отриманих результатів можемо зробити висновок, що кожний досліджуваний часовий ряд курсу криптовалют не має нормального розподілу.

Перевірка часового ряду на стаціонарність є важливим етапом у аналізі часових даних. Ряд можна вважати стаціонарним, за умові, якщо його середнє значення та дисперсія, залишаються стабільними з часом, і майбутня поведінка ряду може бути передбачена на основі його минулої поведінки. Для визначення

стаціонарності часто використовується розширений тест Дікі-Фуллера (ADF), який досліджує наявність одиничного кореня шляхом визначення нульової та альтернативної гіпотез у часовому ряді [27]. Якщо обчислене значення p -value нижче визначеного рівня значущості, це означає, що результат значно відрізняється від того, що можна було б очікувати при випадковому розподілі. За такої умови нульова гіпотеза не підтверджується, а часовий ряд є стаціонарним. В протилежному випадку приймається альтернативна гіпотеза, що вказує на стаціонарність часового ряду. Нульова гіпотеза стверджує про присутність одиничного кореня, що і вказує на нестаціонарність часового ряду.

Також існують інші методи перевірки на стаціонарність:

- Ковзне середнє (Moving Average) полягає в графічній оцінці за допомогою ковзних середніх або стандартних відхилень та дозволяє виявити наявність тренду або сезонності в часовому ряді.

- Звичайний тест Дікі-Фуллера (Dickey-Fuller test) один з найпоширеніших тестів на стаціонарність. Він перевіряє наявність одиничних коренів в авторегресійній моделі (AR).

- Тест KPSS (Kwiatkowski-Phillips-Schmidt-Shin test): цей тест також використовується для перевірки стаціонарності. Він порівнює статистику тесту між нульовою гіпотезою про стаціонарність та альтернативною гіпотезою про нестаціонарність.

- Автокореляційна функція (ACF) та часткова автокореляційна функція (PACF): Аналіз ACF та PACF дозволяє виявити наявність автокореляції в часовому ряді, яка свідчатиме про стаціонарність.

Ці методи допомагають аналізувати та інтерпретувати стаціонарність часового ряду.

Проведемо розширений тест Дікі-Фуллера та тест KPSS для часових рядів курсів обраних криптовалют за ціною закриття:

Розширений тест Дікі-Фуллера та тест KPSS

Криптовалюта	Dickey-Fuller	p-value	KPSS	p-value
Bitcoin	-1,0526	0,7336	2,2490	>0,0100
Ethereum	-1,3957	0,5844	2,8875	>0,0100
BNB	-1,3384	0,6114	3,2776	>0,0100
Solana	-1,7443	0,4085	0,7614	>0,0100
XRP	-2,9219	0,0429	1,2015	>0,0100

Джерело: розрахунки автора

Інтерпретуючи отримані результати, можемо зробити висновок, що часові ряди Bitcoin, Ethereum, BNB та Solana є нестационарними, оскільки показник Дікі-Фуллера має від'ємне значення, а p-value більше порогового значення 0,05. XRP може бути стаціонарним. За тестом КПСС усі ряди є нестационарними, оскільки показник КПСС перевищує критичне значення 0.216 для рівня значущості 0.01.

Фрактальна розмірність є ключовим поняттям у фрактальній геометрії та аналізі. Вона визначається як міра складності фрактальної структури та дозволяє кількісно оцінити складність або розмір фрактального об'єкта. У роботі дослідимо вплив фрактальної розмірності на часові ряди курсів криптовалют.

Фрактальна розмірність визначає структурну складність фрактального часового ряду. Чим вище фрактальна розмірність, тим більша структурна складність та непередбачуваність ряду. Висока фрактальна розмірність може вказувати на наявність складних нелінійних взаємозв'язків у часовому ряді, що робить його важким для прогнозування та моделювання. З іншого боку, низька фрактальна розмірність вказує на простоту та регулярність у ряді, що робить його більш передбачуваним та легшим для аналізу.

2.2. Модель ARIMA

Модель ARIMA широко використовується, оскільки вона є простою лінійною регресією для прогнозування часових рядів. Вона найбільше підходить для даних з високою та стійкою кореляцією, оскільки робить регресію на основі своїх власних минулих даних. Моделі ARIMA складаються з трьох компонентів: авторегресії (AR), інтеграції (I) та ковзного середнього (MA). Компонента AR прогнозує майбутні значення часового ряду на основі минулих значень, компонента MA передбачає майбутні значення на основі залишкових значень минулих спостережень, а компонента I використовується для видалення сезонності чи тенденцій з даних часових рядів. Модель ARIMA (p, d, q) визначається наступним рівнянням:

$$Y_t = c + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t,$$

де Y_t – значення часового ряду в момент t ,

c – стала,

φ – коефіцієнт авторегресії (AR),

ε_t – білий шум з нульовим середнім та однаковою дисперсією,

θ – коефіцієнти ковзного середнього (MA)

Параметри p , d і q відповідають порядку авторегресії, ступеню різниці та порядку компонентів ковзного середнього відповідно. [28]

ARIMA – це потужна модель, яка може давати кращі результати, ніж моделі глибокого навчання на фондовому ринку. Проте, коли мова йде про ринок криптовалют, модель ARIMA не може ефективно враховувати тенденції та сезонність. Це може потребувати ретельного налаштування параметрів та глибокого розуміння даних. Ще однією обмеженістю є те, що вона може не помічати нелінійний характер руху цін, що призводить до неточних прогнозів.

Дослідження Л. Фелізаро та ін. показало, що моделі глибокого навчання виявилися кращими з точки зору точності, ніж модель ARIMA, яка мала найвищі показники помилок серед усіх моделей [29]. Також в іншому дослідженні було

поєднано ARIMA з LSTM та запропоновано нову модель під назвою «LSTM-AR(2)». Їх результати показують, що ця модель перевершує інші моделі, включаючи LSTM та ARIMA [30].

2.3. Опис моделей глибинного навчання

Глибинне навчання представляє собою сучасну концепцію в галузі штучного інтелекту, яка використовує нейронні мережі. Цей підхід існує вже понад 70 років, починаючи з 1944 року, коли два дослідники з Чиказького університету Воррен Маккалох і Волтер Пітс вперше створили концепцію нейронних мереж.

Нейронні мережі – це засіб машинного навчання, у якому комп'ютер вчиться виконувати певне завдання, аналізуючи навчальні приклади [31]. Зазвичай приклади заздалегідь визначені вручну. Нейронні мережі використовують паралельне розподілення простих обчислювальних одиниць, які називаються нейронами або оброблювальними одиницями, для досягнення високої продуктивності. Вони здатні навчатися і узагальнювати патерни, що робить їх подібними до мозку за їх здатністю адаптуватися та набирати знання з навколишнього середовища.

Аналізуючи статтю Ларрі Хардесті для MIT News Office можна узагальнити, що нейронна мережа, змодельована на основі людського мозку, складається з тисяч або навіть мільйонів простих обробних вузлів, які щільно пов'язані одне з одним. Здебільшого сучасні нейронні мережі складаються із вузлів, які є «прямими», тобто дані проходять їх тільки у визначеному напрямку. Один вузол такої нейронної мережі поєднується із певною кількістю вузлів попереднього шару, з яких надходить інформація та із певною кількістю вузлів наступного шару, яким він подає інформацію.

Кожен вузол мережі має свою унікальну ідентифікаційну мітку, відому як «вага», для кожного вхідного з'єднання. Під час активації мережі кожен вузол отримує вхідні дані у вигляді окремих чисел через кожне з'єднання та множить

їх на визначений ваговий коефіцієнт. Далі результати підсумовуються, утворюючи загальне число. Якщо воно менше заданого порогу, вузол не виконує передачі даних на наступний рівень. Однак при перевищенні порогового значення, вузол «активується» та передає суму зважених вхідних сигналів через всі свої вихідні зв'язки.

В процесі навчання нейронної мережі всім її початковим параметрам присвоюються випадкові значення вагів та порогів. Навчальні дані потрапляють на вхідний шар далі проходячи через послідовні шари, піддаючись різним обчислювальним операціям, поки не досягають вихідного шару, де вони суттєво змінюються. Протягом процесу навчання вагові коефіцієнти та порогові значення постійно підбираються так, щоб однакові навчальні дані видавали схожі результати [31].

Тому алгоритми глибинного навчання є однією з найпотужніших категорій алгоритмів машинного навчання, які успішно застосовуються в широкому спектрі комерційних застосувань. Моделі з довгою короткостроковою пам'яттю LSTM та згорткові нейронні мережі, ймовірно, є найпопулярнішими, успішними та широко використовуваними техніками глибинного навчання.

2.3.1 Модель на основі LSTM шарів

Моделі з довгою короткостроковою пам'яттю (Long Short-Term Memory, LSTM) складають особливий тип глибоких нейронних мереж, які здатні навчатися довгостроковим залежностям, використовуючи зворотні зв'язки для «запам'ятовування» попередніх станів мережі. Ці мережі стали дуже популярними після успішного застосування в широкому спектрі задач та показали вражаючі результати у прогнозуванні часових рядів. Зокрема, мережі LSTM складаються з клітин пам'яті, входу, виходу та забуття. Вхідний гейт контролює нову збережену інформацію в клітині пам'яті, тоді як гейт забуття відповідає за інформацію, яка повинна зникнути. Нарешті, вихідний гейт контролює остаточне значення вихідної інформації, яка надходить після

затримки у використанні гейтів входу та забуття за допомогою зворотного зв'язку. В свою чергу, клітина моделі може пам'ятати свій попередній стан завдяки нелінійним бар'єрам, які регулюють потік нових даних в клітину, дозволяючи мережі захоплювати довгострокові залежності та складні шаблони в даних. Вихідний бар'єр керує формуванням кінцевого виходу на основі входу та поточного стану клітини пам'яті. Таким чином, LSTM може створювати контрольований потік інформації, фільтруючи непотрібну інформацію та досягаючи можливості вивчення довгострокових залежностей. Це робить LSTM більш підходящою для прогнозування цін криптовалют, оскільки нейронна мережа добре працює з високою волатильністю та нелінійною динамікою ринку криптовалют.

Формули обчислення:

$$\begin{aligned}
 i_t &= (W_i x_t + U_c h_{t-1} + b_c), \\
 f_t &= \sigma(W_f x_t + U_f h_{t-1} - 1 + b_f), \\
 \bar{c}_t &= \tanh(W_c x_t + U_c h_{t-1} + b_c), \\
 c_t &= f_t \cdot c_{t-1} + i_t \cdot \bar{c}_t, \\
 o_t &= \sigma(W_o x_t + U_o h_{t-1} + b_o), \\
 h_t &= o_t \cdot \tanh(c_t),
 \end{aligned}$$

де x_t – вхідний вектор на кроці часу t ,

h_{t-1} – вектор прихованого стану на попередньому кроці часу,

c_{t-1} – вектор комірки пам'яті на попередньому кроці часу,

i_t, f_t, o_t – гейти входу, забуття та виходу відповідно (Input, Forget, Output gates),

σ – сигмоїдна функція активації,

W, U – вагові коефіцієнти матриці,

\bar{c}_t – кандидат для нового значення пам'яті,

c_t – оновлений вектор пам'яті,

h_t – оновлений вектор прихованого стану.

2.4. Метрики для оцінки точності моделей

В оцінці ефективності моделей або аналізу даних ключовим завданням є вимірювання рівня точності цих моделей. Для цього використовуються різноманітні метрики, серед яких обрано для дослідження середню абсолютну похибку, середнє квадратичне відхилення, квадратичне кореневе середнє відхилення, коефіцієнт детермінації та середню абсолютну відсоткову похибку [44].

MAE вимірює середню абсолютну похибку між прогнозованими і спостережуваними значеннями, іншими словами, MAE вказує на середню абсолютну величину похибок прогнозування моделі. Чим нижче значення цієї похибки, тим точніше прогнози моделі. Розраховується за формулою:

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_i - \hat{Y}_i|$$

MSE – це метрика, яка вимірює середнє квадратичне відхилення між прогнозованими та фактичними значеннями. Вона використовується для оцінки загальної помилки прогнозування моделі, при цьому більш важливі помилки враховуються більше, оскільки вони підносяться до квадрата. Чим нижче значення MSE, тим точніше прогнози моделі. Розраховується за формулою:

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2$$

RMSE визначається як корінь з MSE, є широко використовуваною метрикою, оскільки вона виражається в одних і тих самих одиницях, що і самі дані. Вона використовується для вимірювання середнього розміру похибок прогнозування моделі, враховує як важливі помилки, так і їхні розміри, оскільки обчислює квадратний корінь з середнього значення квадратів різниць між прогнозованими та фактичними значеннями. Чим нижче значення RMSE, тим точніше прогнози моделі. Розраховується за формулою:

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

Коефіцієнт детермінації (R^2) використовується для вимірювання того, яка частина варіації залежної змінної пояснюється незалежними змінними моделі. Він виражає відсоток дисперсії залежної змінної, який може бути пояснений незалежними змінними. Чим ближче значення R^2 до 1, тим краще модель відповідає даним, тобто має кращий ступінь відповідності. Розраховується за формулою:

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2}$$

MAPE – це метрика, яка вимірює середню відсоткову різницю між прогнозованими та фактичними значеннями. Вона використовується для визначення середньої точності прогнозів моделі в відсотковому вираженні. Чим нижче значення MAPE, тим точніше прогнози моделі.

$$MAPE = \frac{1}{N} \sum_{i=1}^N |Y_i - \hat{Y}_i| \times 100$$

Обрані метрики точності дозволяють оцінити точність моделей прогнозування, а також допоможуть зрозуміти, яка модель краще адаптується до даних та забезпечує кращі результати.

Висновки до розділу 2

В даному розділі розглянуто методологію фрактального аналізу часових рядів, який є потужним інструментом для аналізу нелінійних систем, що дозволяє виявляти складність, персистентність та фрактальну природу часових рядів. Ключовим показником у фрактальному аналізі є показник Херста, який розраховується на основі R/S-аналізу та використовується для визначення ступеня самоподібності та ефекту пам'яті в часових рядах. Значення вище 0,5

підтверджує наявність довгострокової пам'яті ринку: теперішнє залежить від минулого, а майбутнє – від теперішнього [26].

Далі проведено тест Харке-Бера для визначення нормальності розподілу часових рядів курсів криптовалют, який обґрунтовує доцільність використання фрактального аналізу, оскільки тест довів, що їх розподіл не є нормальним.

Також часові ряди були перевірені на стаціонарність за допомогою розширеного тесту Дікі-Фуллера та тесту КПСС, які визначили їх нестаціонарність. Тому далі в дослідженні використовуються моделі ARIMA та LSTM, які зможуть давати кращі результати прогнозування при таких умовах.

Наступним етапом було узагальнення інформації про модель ARIMA та рекурентну нейронну мережу LSTM, а також пояснено принцип їхньої роботи та визначення параметрів. В заключному підрозділі розглянуто метрики для оцінки точності зазначених моделей та наведено формули для їхнього розрахунку.

РОЗДІЛ 3. МОДЕЛЮВАННЯ ТА АНАЛІЗ РЕЗУЛЬТАТІВ

3.1. Збір та обробка даних

Дослідження проводилось на основі історичних щоденних даних у зведеному форматі OHLCV (Open, High, Low, Close, Volume), відкриття і закриття представляють перший і останній рівень ціни протягом дня, high і low – найвищий і найнижчий відповідно. Дані були імпортовані з Yahoo Finance за допомогою бібліотеки для Python «yfinance». Загалом сформовано п'ять наборів даних для таких криптовалют як: Bitcoin, Ethereum, BNB, Solana та XRP. Часовий проміжок для чотирьох наборів даних склав п'ять років з 5 травня 2019 року по 5 травня 2024. Лише набір даних Solana починається з 11 квітня 2020 року. Показники усіх криптовалют подані у доларах США.

На рис. 3.1 до 2021 року можемо спостерігати слабшу волатильність цін закриття та в цілому низькі ціни зумовлені пандемією COVID-19, далі бачимо різке підвищення курсів, що характерно для усіх досліджуваних криптовалют.

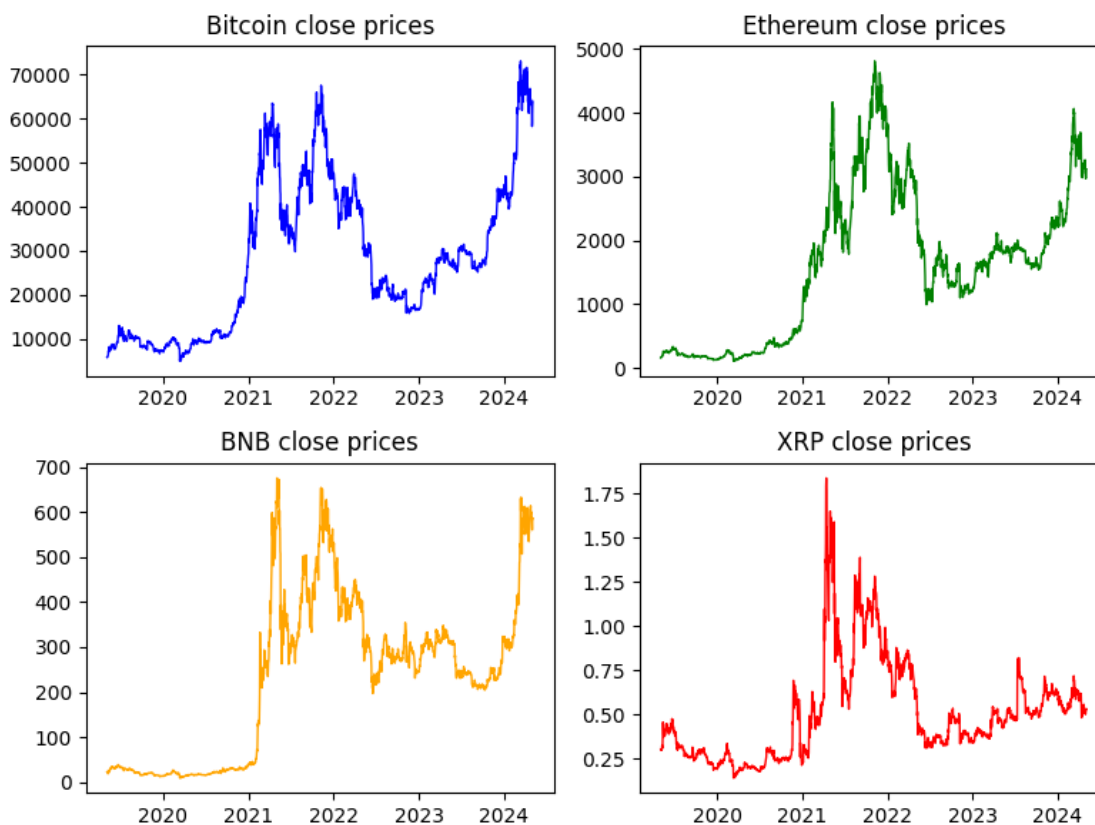


Рис. 3.1. Ціни закриття криптовалют Bitcoin, Ethereum, BNB, XRP

Джерело: розрахунки автора

Після досягнення максимумів у середині квітня 2021 року біткоїн та інші альткоїни швидко втратили близько половини своєї вартості через регулятивний тиск Китаю на цю галузь. Весною 2024 року Bitcoin поновив свій історичний максимум, який склав 73750 дол. США, що позитивно вплинуло на весь ринок в цілому.

Після процесу збору даних необроблені дані були очищені та попередньо оброблені для подальшого додавання технічних індикаторів. Крім того, було проведено ретельну перевірку, щоб переконатися, що набір даних повний і не містить відсутніх або нульових значень. Рис. 3.2-3.6 демонструють загальні характеристики наборів даних:

	Open	High	Low	Close	Adj Close	Volume
count	1827.0	1827.0	1827.0	1827.0	1827.0	1827.0
mean	28150.36	28792.61	27463.76	28179.92	28179.92	30706693617.98
std	17191.87	17624.52	16693.99	17200.92	17200.92	17872514476.91
min	5002.58	5331.83	4106.98	4970.79	4970.79	5331172801.0
max	73079.38	73750.07	71334.09	73083.5	73083.5	350967941479.0

Рис. 3.2. Характеристики набору даних Bitcoin

Джерело: розрахунки автора

	Open	High	Low	Close	Adj Close	Volume
count	1827.0	1827.0	1827.0	1827.0	1827.0	1827.0
mean	1603.16	1647.41	1554.69	1604.57	1604.57	15067885952.39
std	1185.11	1219.04	1146.0	1184.73	1184.73	9799991561.63
min	110.41	116.02	95.18	110.61	110.61	2081625742.0
max	4810.07	4891.7	4718.04	4812.09	4812.09	84482912776.0

Рис. 3.3. Характеристики набору даних Ethereum

Джерело: розрахунки автора

	Open	High	Low	Close	Adj Close	Volume
count	1827.0	1827.0	1827.0	1827.0	1827.0	1827.0
mean	231.3	237.84	224.37	231.58	231.58	1203221502.19
std	179.18	184.62	173.16	179.24	179.24	1410929525.44
min	9.37	10.24	6.96	9.39	9.39	106103588.0
max	676.32	690.93	634.55	675.68	675.68	17982945189.0

Рис. 3.4. Характеристики набору даних BNB

Джерело: розрахунки автора

	Open	High	Low	Close	Adj Close	Volume
count	1486.0	1486.0	1486.0	1486.0	1486.0	1486.0
mean	52.44	54.81	50.09	52.52	52.52	1279951430.27
std	57.88	60.3	55.21	57.87	57.87	1669641010.42
min	0.51	0.56	0.51	0.52	0.52	652020.0
max	258.78	260.06	246.12	258.93	258.93	17068643416.0

Рис. 3.5. Характеристики набору даних Solana

Джерело: розрахунки автора

	Open	High	Low	Close	Adj Close	Volume
count	1827.0	1827.0	1827.0	1827.0	1827.0	1827.0
mean	0.51	0.53	0.49	0.51	0.51	2793538405.67
std	0.28	0.3	0.27	0.28	0.28	3594748663.85
min	0.14	0.15	0.12	0.14	0.14	225391032.0
max	1.84	1.96	1.66	1.84	1.84	36955175105.0

Рис. 3.6. Характеристики набору даних XRP

Джерело: розрахунки автора

3.2. Характеристика та розробка параметрів для наборів даних

Технічні індикатори були додані та побудовані на основі історичних даних про курси криптовалют з метою підвищення якості вибірки. Також вони дають ширше розуміння динаміки ринку та значно покращують результати моделювання. Технічні індикатори наведено в табл. 3.1.

Використаймо експоненційне згладжування для стабілізації часових рядів, оскільки воно корисне для видалення шуму та згладжування екстремально великих значень з метою зменшення їх впливу на прогнозування. Також це допомагає виділити тренд, та в цілому покращити модель. Додамо в набір даних два нових поля: експоненційне згладжування на основі 20 та 100 попередніх днів, яке розраховується за формулою:

$$EMA_t = \alpha \cdot Y_t + (1 - \alpha) \cdot EMA_{t-1},$$

де EMA_t – значення згладжених даних в момент часу t ,

Y_t – поточна ціна,

α – коефіцієнт згладжування, $0 < \alpha < 1$.

Далі розрахуємо індекс відносної сили (англ. Relative Strength Index) розроблений Дж. Веллесом Вайлдером [32].

Показник відображається як осцилятор за шкалою від 0 до 100. Він використовується для виявлення ступеня перекупності та перепроданості при показнику вище 70 та нижче 30 відповідно. Також RSI дозволяє визначити тренд та дивергенцію, що може давати сигнал про покупку чи продаж, тому важливо враховувати цей показник в наборі даних. Його розрахунок проводиться за формулою:

$$RSI = 100 - \left[\frac{100}{1 + \frac{n_{up}}{n_{down}}} \right],$$

де n_{up} – середня зростаюча ціна за n днів,

n_{down} – середня спадна ціна за n днів.

В дослідженні використаємо часовий інтервал для розрахунку RSI 14 днів.

Наступним доданим параметром до набору буде показник Херста, який визначається у підрозділі 2.1. Цей показник є статистичним індикатором, який використовується для визначення ступеня самоподібності та ефекту пам'яті в часових рядах. Перші 300 записів будуть мати однакове значення показника, а усі наступні будуть розраховані на основі трьохсот попередніх цін закриття. Загалом показник Херста в часових рядах дозволяє виявити персистентність чи антиперсистентність від яких залежить тренд, тому це має покращити результати моделювання.

Далі при підготовці даних необхідно визначити цільове поле, яке буде використовуватись безпосередньо для прогнозування. Цим полем буде скоректована ціна закриття зі зсувом на одне значення назад для того, щоб модель тренувалась прогнозувати на основі попередніх.

Таблиця 3.1.

Характеристика полів наборів даних після додавання параметрів

Поле набору даних	Характеристика
Open	Ціна відкриття на початку дня
High	Найвища досягнута ціна протягом дня
Low	Найнижча досягнута ціна протягом дня
Adj Close	Скоригована ціна закриття в кінці дня
Volume	Загальна кількість криптовалюти проданої за день
hurst_value	Показник Херста
RSI	Індекс відносної сили, осцилятор імпульсу, який вимірює швидкість і зміну руху ціни.
EMA20	Експоненційне ковзне середнє з 20-денним коефіцієнтом згладжування
EMA100	Експоненційне ковзне середнє з 100-денним коефіцієнтом згладжування
TargetNextClose	Цільове поле на основі скоригованої ціни закриття

Теплова карта кореляційної матриці на рис. 3.7 була створена для ілюстрації зв'язків між цими технічними індикаторами. Теплова карта наочно представляє, наскільки ці показники корелюють один з одним. Це дозволяє нам визначити потенційні закономірності та залежності між індикаторами.




Рис. 3.7. Кореляційна матриця показників Bitcoin

Джерело: розрахунки автора

Після усіх маніпуляцій з даними та очищення пустих значень у наборах залишилось 1727 записів та 10 полів. Далі необхідно провести розбиття набору даних на тренувальну та тестову вибірки, які необхідні для навчання та оцінки точності прогнозу моделей. Таким чином, тренувальна вибірка склала 1447 записів, а тестувальна – 280.

3.3. Імплементация та налаштування LSTM моделі

Спершу для моделі LSTM варто масштабувати дані від нуля до одиниці, використавши MinMaxScaler. Нейронні мережі, зокрема LSTM, можуть гірше

працювати з немасштабованими вхідними даними. Наприклад, коли деякі ознаки мають значення у великих діапазонах, це може призводити до надмірного впливу цих ознак на ваги моделі під час навчання. Масштабування даних допомагає уникнути такої проблеми та забезпечити більш стабільне навчання. Також на значеннях від 0 до 1 модель буде набагато швидше здійснювати обчислення та тренуватись. Після завершення моделювання дані необхідно буде трансформувати в оригінальні значення для інтерпретації результатів.

Наступним кроком необхідно сформувати масив вхідних даних для моделі. Прогноз для кожного наступного дня буде проводитись на основі 50 попередніх значень. Таким чином модель приймає 50 часових інтервалів з дев'ятьма вхідними ознаками 1397 разів. Далі визначимо шар моделі LSTM, який є типом рекурентного шару нейронної мережі, призначений для обробки послідовних даних, враховуючи довготривалі залежності між ними. Значення параметра «units=150» означає кількість «пам'яті», яку має модель для використання при здійсненні наступного прогнозу.

Наступним визначимо щільний шар, він пов'язує кожен вхідний нейрон з кожним вихідним нейроном, що дозволяє шару виконувати лінійне перетворення вхідних даних, тобто обробляти кожен елемент попереднього шару, виконуючи матричне перемноження цих елементів зі своїми вагами та додаванням зміщення за такою формулою:

$$f(x) = W_x + b,$$

де W – матриця ваг для кожного з'єднання між вхідними та вихідними нейронами,

x – вхідні дані,

b – вектор зміщення,

$f(x)$ – вихідні дані.

Далі виконаємо процес компіляції моделі, використавши оптимізатор та функцію втрат. Оптимізатор відповідає за налаштування ваг моделі з метою мінімізації функції втрати під час навчання. В моделі використано оптимізатор «Adam», який є методом методом стохастичної оптимізації, який використовує

адаптивну оцінку моментів першого та другого порядку. Функція втрат визначає, як ефективно модель виконує свою задачу під час навчання. Вона порівнює прогнозовані значення моделі з фактичними значеннями та обчислює помилку. В моделі використано функцію для обчислення середньоквадратичної помилки між прогнозованими та фактичними значеннями.

Далі визначимо лінійну активаційну функцію у моделі, вона просто повертає вихідні значення без змін. Використання лінійної активаційної функції в останньому шарі обґрунтовується тим, що модель вирішує регресійну задачу, де вихідне значення є неперервною змінною.

Далі проведемо навчання моделі на основі набору вхідних даних та цільової змінної «TargetNextClose». Визначимо параметр «batch_size=64», який визначає кількість зразків даних, яка буде оброблятися моделлю перед оновленням ваг моделі. Модель буде навчатися за допомогою оновлення градієнтного спуску, де градієнт обчислюється на основі підмножини даних розміру цього параметра. Модель навчається протягом 25 епох, тобто скільки разів весь набір даних буде пройдено моделлю під час навчання. Кожна епоха складається з одного проходу через весь набір даних. Зазвичай більша кількість епох призводить до більш точних прогнозів. Однак надмірно висока їх кількість може призвести до проблем із перенавчанням, при якому модель відповідає шуму в навчальних даних, а не основним шаблонам. Таким чином, беручи до уваги результати функції втрат, було обрано оптимальну кількість епох для забезпечення найкращої точності моделі. Також використаємо перемішування даних, воно допомагає моделі уникнути залежностей від порядку даних і покращує здатність моделі генералізувати. Встановимо розділення тренувальних даних для валідації із значення 0.2, це означає, що 20% вхідних даних будуть використовуватись для оцінки ефективності моделі під час навчання.

У дослідженні використаємо дві LSTM моделі. В першій моделі застосуємо усі вищезгадані вхідні дані, окрім показника Херста, у другій – застосуємо його. Усі інші параметри моделі залишаться без змін. Такий підхід допоможе визначити вплив фрактального аналізу і персистентності часового ряду на

результати прогнозування та обґрунтувати його використання при моделюванні. На даному етапі навчання моделі завершено і вона готова до прогнозування та перевірки її точності на тестових даних.

Важливим етапом у виборі вхідних параметрів для моделі LSTM є оцінка впливу показника Херста, на загальний прогноз моделі. Гіпотеза полягає в тому, що така складова фрактального аналізу як показник Херста використовується в якості вхідних даних моделі LSTM з метою підвищення точності її прогнозу. Для цього необхідно розробити дві моделі LSTM з показником Херста та без і порівняти їх за метриками точності.

Таблиця 3.2

Результати моделей LSTM з показником Херста і без показника Херста

Криптовалюта	Модель	MAE	MSE	RMSE	R-squared	MAPE
Bitcoin	LSTM	2223.5598	8896695.9481	2982.7329	0.9594	4,68%
	LSTM + Hurst	1670.8446	5422235.4767	2328.5694	0.9752	3,56%

Джерело: розрахунки автора

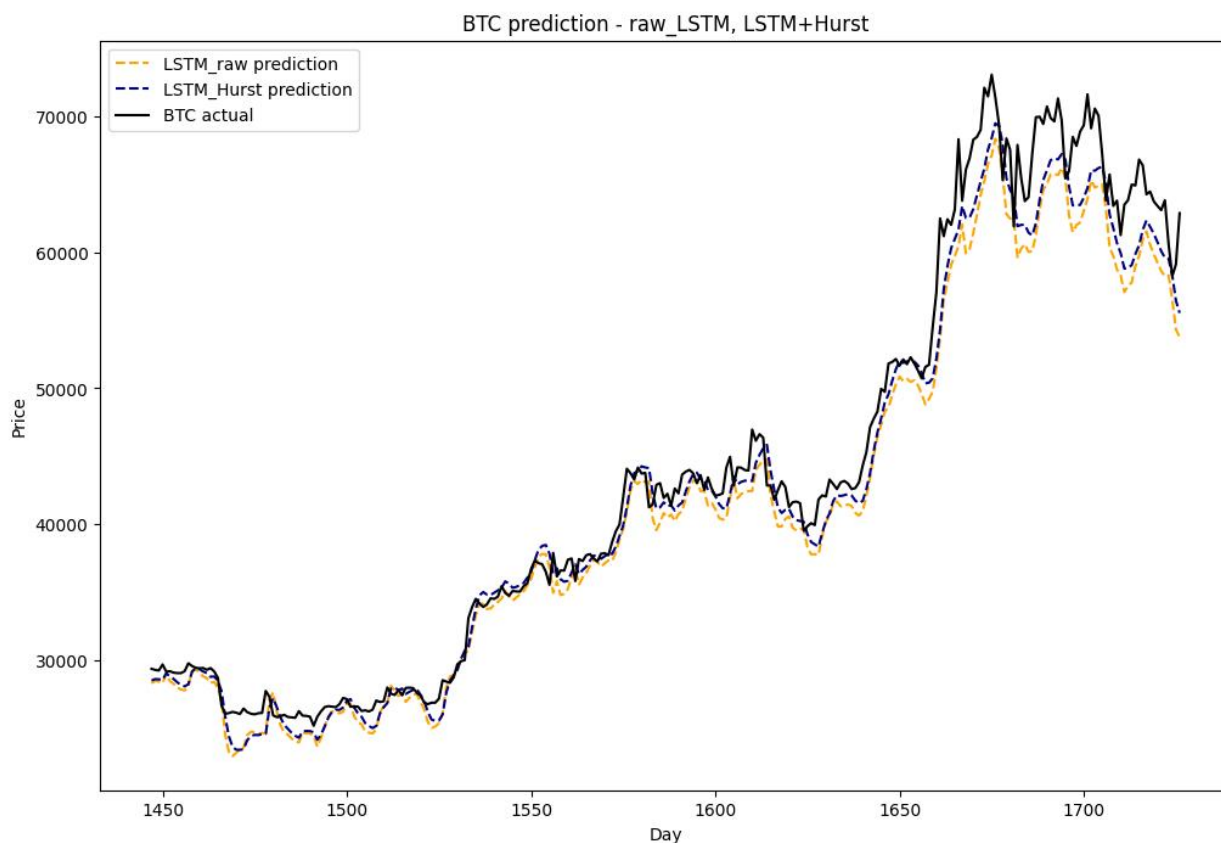


Рис. 3.8. Результати моделей LSTM з показником Херста і без нього

Джерело: розрахунки автора

Аналізуючи результати з табл. 3.2 та діаграму на рис. 3.8, можемо дійти висновку, що LSTM з показником Херста є точнішою для криптовалюти Bitcoin, про що свідчать усі метрики для визначення точності. Виходячи з цього, було прийняте рішення далі у дослідженні використовувати LSTM модель лише з показником Херста.

3.4. Імплементация та налаштування ARIMA моделі

У якості вхідних даних для моделі ARIMA використано одне поле «Adj Close» для криптовалюти з кожного набору даних. Наступним кроком буде визначення параметрів ARIMA моделі. Параметри p , d і q відповідають порядку авторегресії, ступеню різниці та порядку компонентів ковзного середнього відповідно. Параметр p вказує на кількість попередніх значень часового ряду, які

використовуються для прогнозування майбутнього значення. Параметр d вказує на кількість застосування диференціювання до часового ряду для досягнення стаціонарності. Параметр q вказує на кількість попередніх помилок моделі, тобто залишків, які використовуються для прогнозування майбутнього значення. Використаємо бібліотеку «`rpmardarima`» та функцію «`auto_arima`», для пошуку найкращих параметрів моделі з найменшим показником AIC для кожного набору даних, результат представлено у табл. 3.3.

Таблиця 3.3

Параметри для моделі ARIMA

Криптовалюта	Параметри моделі (p, d, q)	AIC
Bitcoin	(3, 1, 2)	30900.410
Ethereum	(1, 1, 0)	21408.660
BNB	(4, 1, 3)	14712.778
Solana	(1, 1, 5)	8589.414
XRP	(1, 1, 0)	-6740.984

Джерело: розрахунки автора

Показник AIC (Akaike Information Criterion) – це метрика, яка використовується для порівняння статистичних моделей. Його ідея полягає в тому, щоб збалансувати якість та складність моделі. Модель з найменшим значенням AIC вважається кращою, оскільки вона найкраще адаптується до даних, забезпечуючи мінімальною складністю.

Моделювання проводилося покроково, його принцип роботи полягає в тому, що модель ARIMA будується для кожного кроку прогнозування на основі наявних даних і зразу ж використовується для прогнозування наступного значення.

При кожній ітерації довжиною в тестовий набір даних, модель ARIMA будується знову на навчальному наборі даних, з використанням підібраних параметрів авторегресії, диференціювання та ковзного середнього. Після побудови модель адаптується до навчальних після чого використовується для

прогнозування значення на наступний часовий інтервал, тобто один день. Отримане прогнозоване значення зберігається, після цього реальне значення з тестового набору даних додається до навчального набору даних, і цикл повторюється для наступного часового кроку.

Отже, модель ARIMA перебудовується та оновлюється з кожним новим навчальним набором даних, що включає останнє спостереження, що дозволяє використовувати актуальну інформацію для прогнозування.

3.5. Результати моделей ARIMA та LSTM

У табл. 3.4 наведено порівняння моделей ARIMA та LSTM для усіх криптовалют за такими метриками точності: середня абсолютна похибка, середнє квадратичне відхилення, квадратичне кореневе середнє відхилення, коефіцієнт детермінації та середня абсолютна відсоткова похибка.

Таблиця 3.4

Метрики точності для моделей ARIMA та LSTM для криптовалют Bitcoin, Ethereum, BNB, Solana та XRP

Криптовалюта	Модель	MAE	MSE	RMSE	R-squared	MAPE
Bitcoin	ARIMA	1922,730	12342838,441	3513,238	0,944	4,84%
	LSTM	2309,359	9401466,352	3066,181	0,957	4,91%
Ethereum	ARIMA	80,265	15075,271	122,781	0,969	3,13%
	LSTM	88,758	12917,539	113,655	0,973	3,85%
BNB	ARIMA	12,619	497,284	22,300	0,973	3,34%
	LSTM	11,252	279,210	16,710	0,985	3,16%
Solana	ARIMA	7,222	194,992	13,964	0,934	15,31%
	LSTM	5,840	57,559	7,587	0,981	9,92%
XRP	ARIMA	0,019	0,001	0,028	0,778	3,30%
	LSTM	0,037	0,002	0,042	0,500	6,52%

Джерело: розрахунки автора

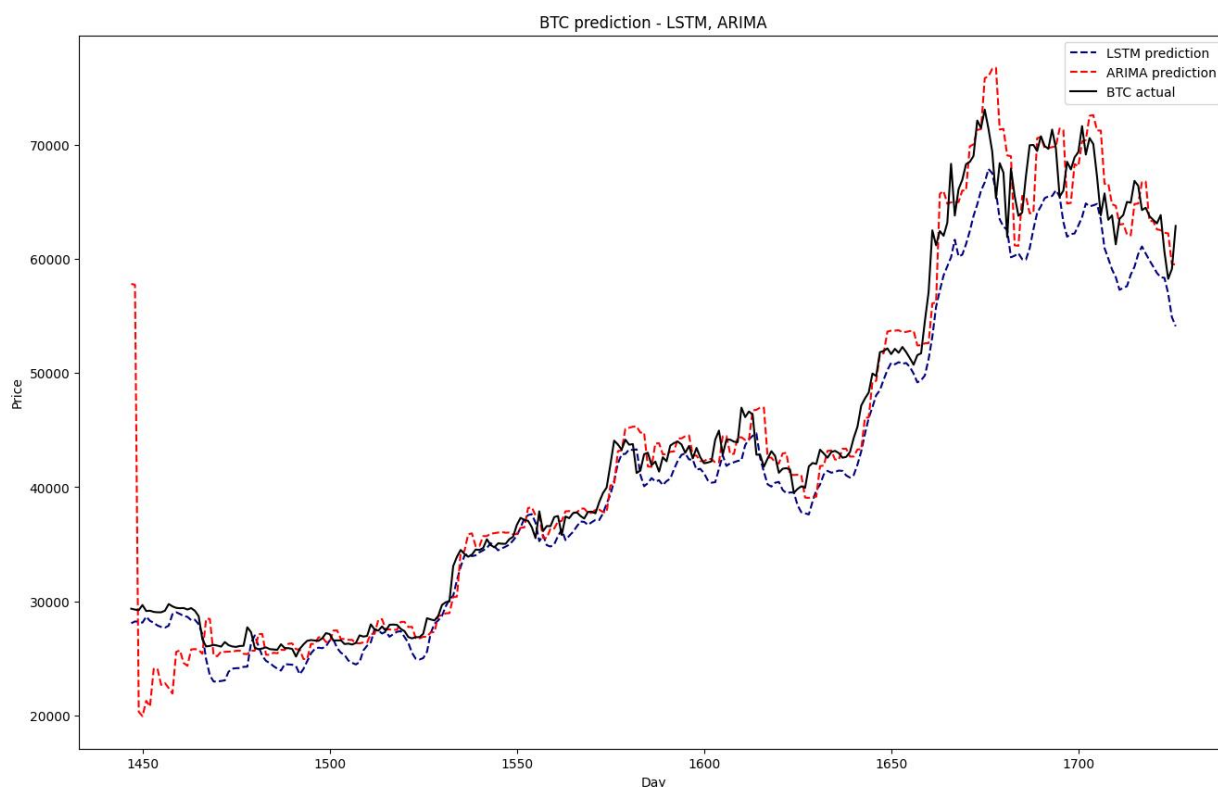


Рис. 3.9. Результати моделей LSTM та ARIMA для Bitcoin

Джерело: розрахунки автора

Обидві моделі, ARIMA та LSTM, мають низькі значення MAE, MSE та RMSE, що вказує на те, що обидві моделі добре прогнозують ціну закриття Bitcoin. Однак в LSTM ці значення дещо вищі, що може вказувати на меншу точність прогнозів. Коефіцієнт детермінації для обох моделей є високим, але для LSTM він трохи вищий, що може свідчити про кращу здатність цієї моделі пояснювати варіацію між попереднім та наступним днем в ціні закриття Bitcoin. Також ARIMA та LSTM мають низькі відсоткові похибки 4,84% та 4,91% відповідно, що свідчить про високу точність прогнозу. Загалом лінія трену LSTM переважно проходить нижче реальної ціни закриття Bitcoin, а ARIMA – вище протягом усього досліджуваного періоду. Також з діаграми можемо бачити значну невідповідність прогнозу ARIMA на початку періоду, проте потім прогноз стає набагато точнішим.




Рис. 3.10. Результати моделей LSTM та ARIMA для Ethereum

Джерело: розрахунки автора

Аналізуючи діаграму на рис. 3.10 та точність моделей з табл. 3.4, бачимо, що модель ARIMA дещо точніша в порівнянні з LSTM за метриками MAE та MAPE, хоча за іншими метриками прогноз LSTM кращий. Проте обидві моделі показали кращий результат для Ethereum, ніж для Bitcoin, що зумовлено меншим курсом Ethereum та меншою волатильністю.




Рис. 3.11. Результати моделей LSTM та ARIMA для BNB

Джерело: розрахунки автора

З діаграми на рис. 3.11. бачимо, що лінія передбачення LSTM знаходиться ближче до справжньої ціни, та не має значних відхилень, як ARIMA на піку ціни. Це ж твердження підтверджують нижчі значення метрик MAE, MSE, RMSE, MAPE для моделі LSTM та вище значення R^2 в порівнянні з ARIMA. Таким чином в прогнозуванні ціни закриття BNB LSTM показала кращі результати.




Рис. 3.12. Результати моделей LSTM та ARIMA для Solana

Джерело: розрахунки автора

Аналізуючи метрики точності для криптовалюти Solana, бачимо що результати двох моделей значно гірші, ніж для усіх інших криптовалют. Це може характеризуватись значно меншою вибіркою тренувальних даних для цієї криптовалюти, оскільки дата створення Solana – 16 березня 2020 року. Тому період, на основі якого можуть навчатись моделі є коротшим в порівнянні з іншими криптовалютами із дослідження. Модель ARIMA показує середню абсолютну помилку MAE: 7,222, що вказує на середнє відхилення прогнозованих значень від реальних. MSE: 194,992 та RMSE: 13,964 свідчать про наявність значних відхилень між прогнозованими та фактичними цінами. Коефіцієнт детермінації із значенням 0,934 вказує на високу, але не ідеальну здатність моделі пояснювати варіативність цін Solana. Високий MAPE 15,31% свідчить про значні відсоткові відхилення у прогнозах. В свою чергу модель LSTM демонструє значно кращі результати, ніж ARIMA, з MAE 5,84, MSE 57,559 та RMSE 7,587, що вказує на зменшення середніх відхилень та покращену точність

прогнозів. Високий коефіцієнт детермінації 0,981 свідчить про те, що модель LSTM краще пояснює варіативність даних. MAPE 9,92% показує значне зменшення відсоткових відхилень порівняно з моделлю ARIMA.




Рис. 3.13. Результати моделей LSTM та ARIMA для XRP

Джерело: розрахунки автора

З діаграми на рис. 3.13. бачимо, наскільки прогноз LSTM відхиляється від реальних даних, також це підтверджують метрики точності. В свою чергу модель ARIMA показали досить непогану точність навіть у порівнянні з іншими криптовалютами. Та поведінка може характеризуватись досить низьким курсом XRP, який коливається в межах 0,45-0,75 доларів США, у зв'язку з чим LSTM має значно гірші результати прогнозування.

3.6. Розробка гібридної моделі на основі LSTM та ARIMA та оцінка результатів

Наступним етапом дослідження буде розробка власної гібридної моделі на основі авторегресійної інтегрованої моделі ковзного середнього ARIMA та рекурентної нейронної мережі LSTM в комбінації з показником Херста, який визначає персистентність часового ряду. Суть гібридної моделі базується на комбінуванні прогнозів, що надаються моделями ARIMA та LSTM за допомогою лінійної регресії. Основна ідея полягає в тому, що кожна з цих моделей може мати свої сильні та слабкі сторони у прогнозуванні часових рядів, і комбінування їх прогнозів може допомогти зменшити помилки та покращити точність прогнозу. Її формула матиме такий вигляд:

$$Y_{hybrid} = \beta_0 + \beta_{ARIMA} \cdot Y_{ARIMA} + \beta_{LSTM} \cdot Y_{LSTM}$$

де Y_{hybrid} – підсумковий прогноз, отриманий за допомогою гібридної моделі,

β_0 – перехоплення (intercept),

β_{ARIMA} – коефіцієнт моделі ARIMA,

Y_{ARIMA} – прогноз моделі ARIMA,

β_{LSTM} – коефіцієнт моделі LSTM,

Y_{LSTM} – прогноз моделі LSTM.

На основі прогнозів ARIMA та LSTM необхідно побудувати матрицю ознак, де кожен рядок представляє один часовий крок, а стовпці відповідають прогнозам. Далі створюємо вектор відгуку, який містить фактичні значення ціни закриття криптовалюти для кожного часового кроку. Використовуючи матрицю ознак та вектор відгуку, проводимо навчання моделі лінійної регресії для апроксимації залежності між прогнозами моделей ARIMA і LSTM та фактичними значеннями. Після навчання моделі лінійної регресії отримуємо коефіцієнти β_0 , β_{ARIMA} та β_{LSTM} , які відображають перехоплення, тобто яким буде прогноз, коли всі інші змінні у моделі регресії дорівнюватимуть нулю, а також вплив кожної моделі у загальний прогноз.

Таблиця 3.5

Коефіцієнти для гібридної моделі для криптовалют Bitcoin, Ethereum, BNB, Solana та XRP

Криптовалюта	β_0	β_{ARIMA}	β_{LSTM}
Bitcoin	-1332,1884	0,3523	0,6742
Ethereum	38,8983	0,2258	0,7669
BNB	-7,7046	0,1531	0,8959
Solana	-1.1066	-0.1058	1.1251
XRP	0,1140	0,5824	0,2017

Джерело: розрахунки автора

Застосувавши відповідні коефіцієнти до гібридної моделі, отримуємо наступні результати, які представлені в табл. 3.5.

Таблиця 3.6

Метрики точності гібридної моделі для криптовалют Bitcoin, Ethereum, BNB, Solana та XRP

Криптовалюта	MAE	MSE	RMSE	R-squared	MAPE
Bitcoin	1710,181	6425614,651	2534,880	0,971	4,07%
Ethereum	71,078	11113,835	105,422	0,977	2,83%
BNB	10,555	293,490	17,132	0,984	2,88%
Solana	5,458	55,937	7,479	0,981	9,00%
XRP	0,019	0,001	0,027	0,793	3,25%

Джерело: розрахунки автора




Рис. 3.14. Результати гібридної, LSTM та ARIMA моделей для Bitcoin
Джерело: розрахунки автора

З рис. 3.14. бачимо, що гібридна модель, яка поєднує методи ARIMA та LSTM, продемонструвала найкращі результати: MAE у 1710,181; MSE у 6425614,651; RMSE у 2534,880; R-squared на рівні 0,971 та MAPE у 4.07%. Гібридна модель використовує переваги обох підходів: ARIMA для короткострокового прогнозування, а LSTM для врахування довготривалих залежностей і нелінійних взаємодій. Завдяки такому поєднанню, модель значно покращує точність прогнозування, знижуючи помилки і підвищуючи надійність прогнозів.

На графіку видно, що гібридна модель найближче прилягає до реальної ціни криптовалюти Bitcoin протягом усього періоду прогнозування. Вона краще враховує як короткострокові коливання, так і довготривалі тенденції, що дозволяє зменшити загальні помилки прогнозування. ARIMA та LSTM моделі, хоча і демонструють прийнятні результати, все ж мають більші відхилення, особливо в періоди різких змін цін.

Таким чином, гібридна модель є більш ефективною для прогнозування цін на криптовалюту завдяки своїй здатності комбінувати переваги ARIMA та LSTM моделей. Вона забезпечує більш точні прогнози, що є критично важливим для інвесторів та аналітиків, які працюють на ринку криптовалют.

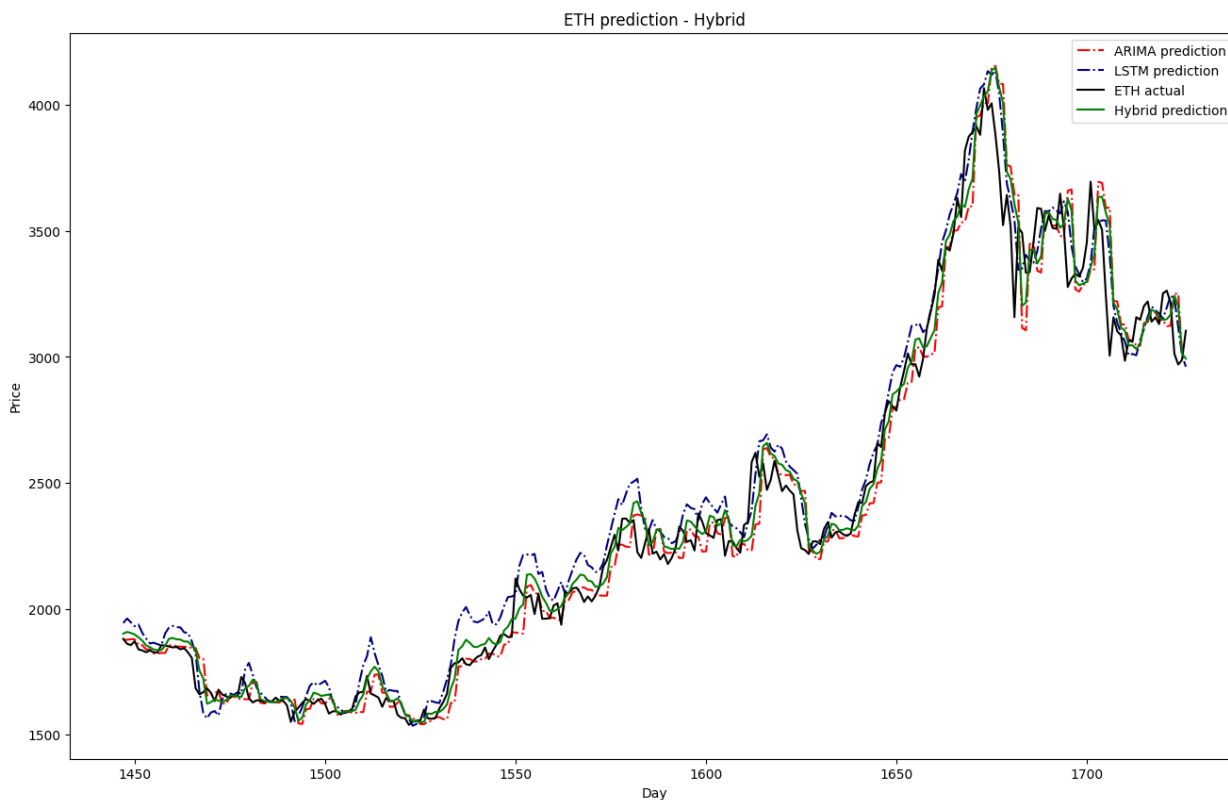


Рис. 3.15. Результати гібридної, LSTM та ARIMA моделей для Ethereum

Джерело: розрахунки автора

Аналізуючи середню абсолютну відсоткову помилку, можна побачити, що для моделей ARIMA та LSTM вона складає 3,13% та 3,85% відповідно, однак для гібридної моделі показник MAPE склав 2,84%. Це також доводить, що комбінація двох моделей за допомогою лінійної регресії показує кращі результати прогнозування.

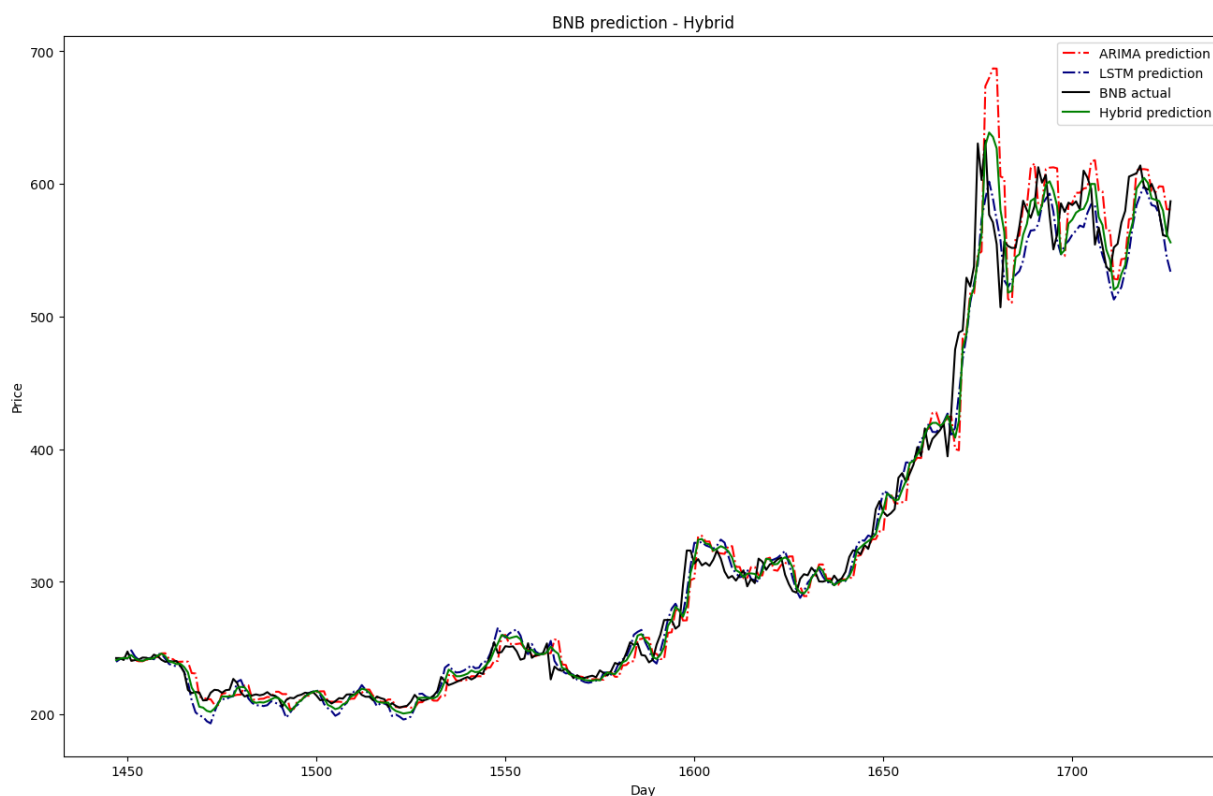


Рис. 3.16. Результати гібридної, LSTM та ARIMA моделей для BNB

Джерело: розрахунки автора

Гібридна модель, враховуючи всі переваги двох методів, показала найкращі результати за всіма метриками точності. У порівнянні з моделями ARIMA та LSTM гібридна модель значно знижує середнє абсолютне відхилення (MAE) та середньоквадратичну помилку (MSE), що свідчить про її високу точність. Корінь середньоквадратичної помилки (RMSE) також є найнижчим серед усіх моделей, що вказує на менші відхилення прогнозів від реальних значень. Коефіцієнт детермінації (R-squared) близький до 1, що свідчить про високу відповідність моделі до реальних даних. Середня абсолютна процентна помилка (MAPE) також є найнижчою, що підтверджує високу точність прогнозів гібридної моделі.

Таким чином, гібридна модель є найбільш ефективною для прогнозування цін на криптовалюти завдяки своїй здатності комбінувати переваги ARIMA та LSTM моделей.




Рис. 3.17. Результати гібридної, LSTM та ARIMA моделей для Solana

Джерело: розрахунки автора

Гібридна модель поєднує переваги моделей ARIMA та LSTM, що відображається в її метриках точності. MAE: 5,458, MSE: 55,937 та RMSE: 7,479 є найнижчими серед усіх моделей для криптовалюти Solana, що вказує на найменші середні відхилення прогнозів від фактичних значень. Коефіцієнт детермінації 0,9811 свідчить про найвищу здатність пояснювати варіативність цін. MAPE 9,00% є найнижчим, що вказує на найменші середні відсоткові відхилення.

На основі аналізу метрик точності можна зробити висновок, що гібридна модель є найефективнішою для прогнозування цін криптовалюти Solana. Вона перевершує як модель ARIMA, так і модель LSTM за всіма основними показниками. Модель LSTM також демонструє значні покращення порівняно з ARIMA, особливо у здатності уловлювати складні тимчасові залежності та короткострокові коливання цін.

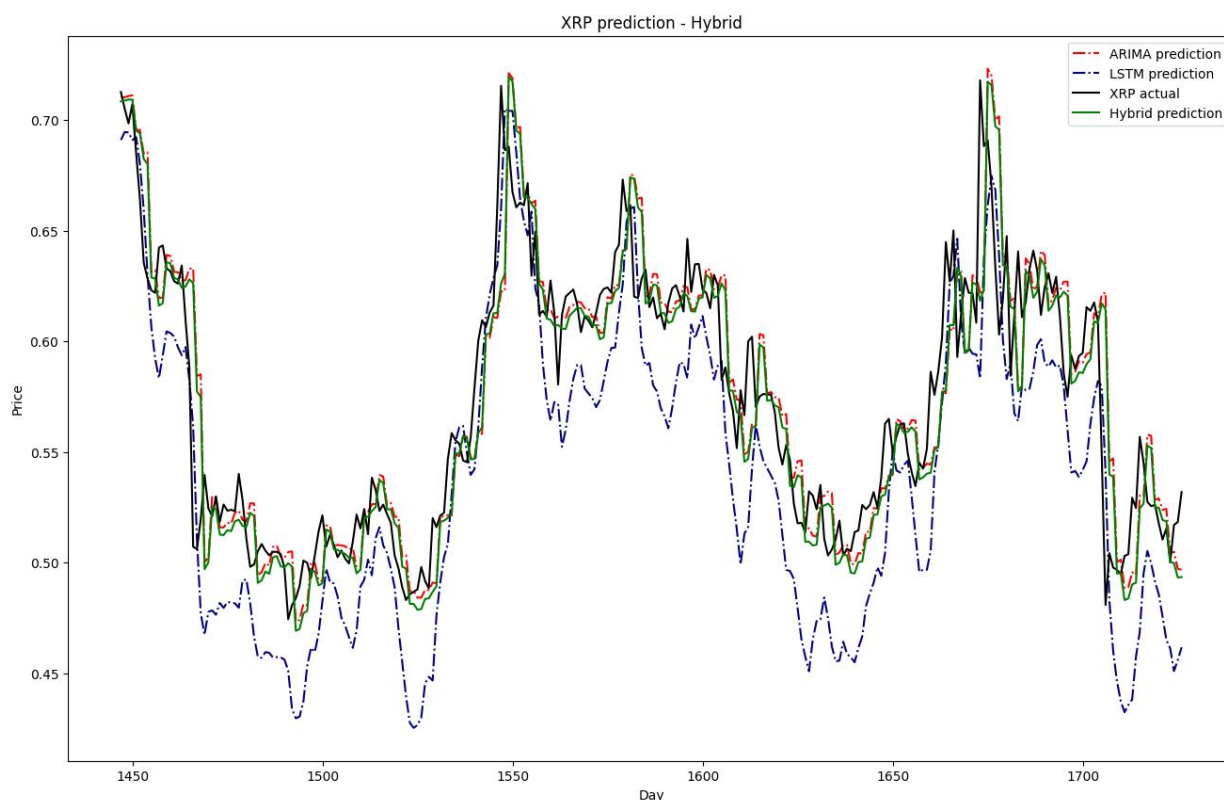


Рис. 3.18. Результати гібридної, LSTM та ARIMA моделей для XRP

Джерело: розрахунки автора

Аналізуючи графік прогнозу та реальної ціни криптовалюти XRP, видно, що модель ARIMA (червона пунктирна лінія) здатна добре відстежувати загальні тенденції, але може відставати в прогнозуванні швидких змін у ціні. Модель LSTM (синя пунктирна лінія) краще справляється з уловлюванням короткострокових коливань, але має тенденцію до більшої варіативності прогнозів і як наслідок значно гіршої точності ніж ARIMA для даної криптовалюти. Гібридна модель (зелена лінія) поєднує переваги обох підходів, що дозволяє їй забезпечувати більш точні прогнози, які ближче відповідають реальним значенням (чорна лінія). І як наслідок коефіцієнти гібридної моделі β_{ARIMA} та β_{LSTM} були розподілені як 0,5824 та 0,2017, оскільки метрики точності ARIMA були кращими.

Гібридна модель краще прогнозує ціну завдяки комбінуванню сильних сторін моделей ARIMA та LSTM. ARIMA ефективно вловлює довгострокові тренди завдяки своїм авторегресійним та ковзним середнім компонентам. LSTM

здатна розпізнавати складні тимчасові залежності та короткострокові коливання завдяки своїм керованим коміркам пам'яті. Комбінація цих двох підходів дозволяє гібридній моделі використовувати переваги обох методів, що призводить до більш точної й надійної системи прогнозування цін на криптовалюту.

3.7. Опис програмного забезпечення для дослідження

Для проведення дослідження було обрано мову програмування Python, оскільки вона є однією з найпопулярніших мов програмування у світі машинного навчання та аналізу даних, має велику кількість корисних бібліотек як для візуалізації даних, так і для тренування моделей. В якості середовища розробки було обрано Google Colab, який працює на базі Jupyter Notebook не вимагає налаштувань для використання та надає безкоштовний доступ до обчислювальних ресурсів, включаючи GPU та TPU, що дозволяє швидко тренувати складні моделі. Характеристики бібліотек, які використані в дослідженні наведені в табл. 3.7.

Таблиця 3.7

Бібліотеки Python та їхні характеристики

Бібліотека Python	Характеристика
pandas [33]	Бібліотека для аналізу даних, яка надає зручний інтерфейс для роботи з даними у вигляді таблиць, дозволяє легко зчитувати, обробляти та аналізувати дані. Використовувалася на етапі збору та підготовки даних.
yfinance [34]	API для Yahoo Finance. Використовувалася для отримання історичних даних про ціни курси досліджуваних криптовалют.

pandas_ta [35]	Бібліотека для аналізу технічних показників на фінансових ринках. Вона розширює можливості бібліотеки Pandas, дозволяючи легко створювати, обчислювати та використовувати технічні індикатори. Використовувалася на етапі розробки параметрів наборів даних, а саме EMA20, EMA100, RSI.
hurst [36]	Бібліотека для обчислення показника Херста для часових рядів.
statsmodels.stats. stattools [37]	Бібліотека використовувалась для проведення тесту Харке-Бера, який перевіряє нульову гіпотезу про те, що дані мають нормальний розподіл. А також для проведення тесту на стаціонарність даних за допомогою розширеного тесту Дікі-Фуллера та KPSS тесту.
numpy [38]	Бібліотека є основною інструментальною бібліотекою для наукових обчислень та роботи з масивами даних. Використовувалась для векторизованих обчислень, що дозволяють виконувати ефективні операції з числовими даними, а також для підготовки масивів для моделей.
sklearn.preprocessing. MinMaxScaler [39]	Функція, яка використовується для масштабування даних, щоб забезпечити їхню нормалізацію до певного діапазону значень, щоб уникнути перекоосу ваги під час навчання LSTM моделі.
keras [40]	Бібліотека для побудови моделей глибинного навчання. Використовувалися: клас Sequential, який дозволяє створювати послідовно шари LSTM, Dense, Activation для створення моделей.

sklearn.metrics [39]	Модуль з бібліотеки sklearn, який містить різноманітні метрики для оцінки якості моделей машинного навчання. У дослідженні використані: mean_squared_error, mean_absolute_error, r2_score.
statsmodels.tsa.arima.mode ARIMA [37]	Клас ARIMA дозволяє побудовувати та аналізувати моделі авторегресії, інтегрованого ковзного середнього (ARIMA).
pmdarima.auto_arima [41]	Функція використовувалась для автоматичного підбору оптимальних гіперпараметрів моделі ARIMA на основі оптимальної стратегії пошуку.
matplotlib [42]	Бібліотека, яка використовувалася для побудови діаграм та візуалізації результатів моделей.
seaborn [43]	Бібліотека для візуалізації даних, яка базується на matplotlib, використовувалась для побудови кореляційної матриці.

Висновки до розділу 3

У завершальному розділі дослідження було обрано для аналізу 5 таких криптовалют: Bitcoin, Ethereum, BNB, Solana та XRP, часовий проміжок для яких склав п'ять років. Далі було проведене очищення даних від пустих значень. Наступним важливим етапом був обрахунок технічних індикаторів та додавання їх у набори даних для забезпечення вищої точності моделі LSTM.

До цих індикаторів увійшов показник Херста, який визначає фрактальність рядів, експоненційне згладжування на основі 20 та 100 попередніх днів та індекс відносної сили RSI. А також було визначено цільове поле для моделей ARIMA та LSTM та створено теплову карту кореляційної матриці для візуалізації зв'язків між цими технічними індикаторами. Далі набір даних був розбитий на вибірки для тренування та тестування моделей.

Наступним етапом стала розробка та налаштування моделі LSTM, які склалися з масштабування даних, формування вхідних масивів даних для моделі, визначення оптимальної кількості клітин пам'яті, кількості епох, вибір оптимізатора, що відповідає за налаштування ваг, вибір функції втрат, визначення кількості зразків даних, які будуть оброблятися моделлю перед оновленням ваг моделі, визначення рівня валідації для оцінки ефективності моделі під час навчання. І найголовніше – запуск процесу тренування моделі.

Налаштування моделі ARIMA розпочалося із підбору найоптимальніших гіперпараметрів для кожного часового ряду ціни закриття криптовалют на основі показника AIC, які відповідають порядку авторегресії, ступеню різниці та порядку компонентів ковзного середнього, на основі яких і було проведено тренування моделі ARIMA.

Наступним етапом стала оцінка точності за обраними метриками та порівняння моделей ARIMA та LSTM, а також візуалізація їх прогнозів на діаграмах. В цілому моделі показали високу точність прогнозування, проте для ARIMA має кращі результати прогнозування ціни закриття криптовалюти XRP, що зумовлено низьким діапазоном цін для цього токена.

Ключовим аспектом даного дослідження стала розробка власної гібридної моделі на основі авторегресійної інтегрованої моделі ковзного середнього ARIMA та рекурентної нейронної мережі LSTM в комбінації з показником Херста. Суть гібридної моделі базується на комбінуванні прогнозів, що надаються моделями ARIMA та LSTM за допомогою лінійної регресії, з метою поєднання сильних сторін даних моделей. Оцінюючи результати гібридної моделі, встановлено, що її точність для кожної криптовалюти вища ніж у моделей ARIMA та LSTM по окремоті.

ВИСНОВКИ

Написання кваліфікаційної роботи магістра на тему «Економіко-математичне моделювання динаміки ринку криптовалют» дозволило зробити наступні висновки. Криптовалютні ринки характеризуються складною динамікою, екстремальними спостереженнями та високим ступенем волатильності. Вони також є нестационарними, фрактальними та мають негаусівський розподіл. Проте технологія блокчейн представляє собою надійну та стабільну фінансову систему з великими перспективами розвитку, тому задача моделювання та прогнозування її динаміки постає особливо актуальною проблемою в наші дні. Виходячи з цієї інформації, було сформовано постановку задачі дослідження, яка пояснює важливість прогнозування динаміки ринку криптовалют саме за допомогою моделей ARIMA та LSTM з додаванням показників фрактального аналізу.

У даному дослідженні було проведено аналіз криптовалютних часових рядів з використанням методології фрактального аналізу, яка дозволяє виявити їхню складність та фрактальну природу. Використання показника Херста підтвердило наявність довгострокової пам'яті ринку. Тест Харке-Бера підкреслив не нормальний розподіл цих рядів. Тести на стаціонарність, а саме розширений тест Дікі-Фуллера та тест KPSS довели нестационарність часових рядів, що обґрунтовує використання у дослідженні моделей ARIMA та LSTM для прогнозування. А також детально розглянуто принцип роботи моделей ARIMA та рекурентної нейронної мережі LSTM.

Дослідження включало аналіз п'яти основних криптовалют протягом п'яти років, очищення даних, визначення технічних індикаторів, у тому числі показника Херста, і побудову моделей. Моделі ARIMA та LSTM були налаштовані та використовувались для прогнозування цін закриття. Загалом результати обох моделей показали високу точність прогнозування за усіма застосованими метриками точності.

Однак ключовим внеском є розробка гібридної моделі, що поєднує модель ARIMA та модель LSTM з показником Херста на основі лінійної регресії. Ця

гібридна модель продемонструвала ще вищу точність прогнозування, порівняно зі стандартними моделями по окремоті. Таким чином, це дослідження підкреслює значення поєднання різних методів для отримання більш точних прогнозів на фоні нелінійності та нестационарності криптовалютних ринків.

У дослідженні було досягнуто мети, яка полягала в аналізі теоретико-методологічної бази, використанні ARIMA та LSTM моделей в поєднанні з фрактальним аналізом часових рядів для прогнозування курсів криптовалют, а також в розробці гібридної моделі на їх основі та порівняльному аналізі.

Для досягнення цієї мети було повністю виконано усі поставлені завдання, а саме:

- визначено сутність ринку криптовалют та технології блокчейн;
- проаналізовано стан наукової думки про методи прогнозування динаміки ринку криптовалют;
- описано моделі ARIMA та LSTM для прогнозування динаміки ринку криптовалют;
- визначено місце фрактального аналізу часових та його поєднання з LSTM моделлю;
- налаштовано та проведено тренування розроблених моделей;
- розроблено гібридну модель, скомбінувавши моделі ARIMA та LSTM;
- здійснено прогнозування криптовалют за допомогою розроблених моделей;
- проаналізовано та оцінено результати прогнозування.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Soloviev, V. N., & Belinskiy, A. (2019). Complex systems theory and crashes of cryptocurrency market. In Information and Communication Technologies in Education, Research, and Industrial Applications: 14th International Conference, ICTERI 2018, Kyiv, Ukraine, May 14-17, 2018, Revised Selected Papers 14 (pp. 276-297). Springer International Publishing.
2. V. Derbentsev, N. Datsenko, O. Stepanenko, and V. Bezkorovainyi, "Forecasting cryptocurrency prices time series using machine learning approach," vol. 02001, pp. 1–7, 2019
3. Gibert, Daniel, Carles Mateu, and Jordi Planes. "The rise of machine learning for detection and classification of malware: Research developments, trends and challenges." *Journal of Network and Computer Applications* 153 (2020): 102526.
4. S. Xiaolei, L. Mingxi, and S. Zeqian, "A novel cryptocurrency price trend forecasting model based on LightGBM," no. November, 2018, doi: 10.1016/j.frl.2018.12.032.
5. Gurdgiev, Constantin, and Daniel O'Loughlin. "Herding and anchoring in cryptocurrency markets: Investor reaction to fear and uncertainty." *Journal of Behavioral and Experimental Finance* 25 (2020): 100271.
6. Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. Retrieved from URL: <https://bitcoin.org/bitcoin.pdf>
7. Ahmad, F. A., Kumar, P., Shrivastava, G., & Bouhlel, M. S. (2018). Bitcoin: Digital decentralized cryptocurrency. In *Handbook of Research on Network Forensics and Analysis Techniques* (pp. 395-415). IGI Global.
8. DeVries, P. D. (2016). An analysis of cryptocurrency, bitcoin, and the future. *International Journal of Business Management and Commerce*, 1(2), 1-9.
9. Tasatanattakool, P., & Techapanupreeda, C. (2018, January). Blockchain: Challenges and applications. In *2018 International Conference on Information Networking (ICOIN)* (pp. 473-475). IEEE.

10. Tromp, John (2015). "Cuckoo Cycle: A Memory Bound Graph-Theoretic Proof-of-Work" (PDF). *Financial Cryptography and Data Security. Lecture Notes in Computer Science*. Vol. 8976. Springer.
11. Zhao, Wenbing; Yang, Shunkun; Luo, Xiong; Zhou, Jiong (26 March 2021). "On PeerCoin Proof of Stake for Blockchain Consensus". *ICBCT'21: The 3rd International Conference on Blockchain Technology*. ACM. pp. 129–134. doi:10.1145/3460537.3460547.
12. Queiroz, M. M., Telles, R., & Bonilla, S. H. (2019). Blockchain and supply chain management integration: A systematic review of the literature. *Supply Chain Management: An International Journal*.
13. Frizzo-Barker, J., Chow-White, P. A., Adams, P. R., Mentanko, J., Ha, D., & Green, S. (2020). Blockchain as a disruptive technology for business: A systematic review. *International Journal of Information Management*, 51, 10202
14. Guo, Y., & Liang, C. (2016). Blockchain application and outlook in the banking industry. *Financial Innovation*, 2(1), 24.
15. Girchenko, T., Semeniuk, I., & Girchenko, L. (2020). BLOCKCHAIN TECHNOLOGY: FEATURES, PROSPECTS. *European Cooperation*, 3(47), 17-32.
16. M. Mudassir, S. Bennbaia, D. Unal, and M. Hammoudeh, "Time-series forecasting of Bitcoin prices using high-dimensional features: a machine learning approach," *Neural Comput. Appl.*, Jul. 2020, doi: 10.1007/s00521-020-05129-6.
17. Yao, Y., Yi, J., & Zhai, S. (2018). Predictive analysis of cryptocurrency price using deep learning. *International Journal of Engineering & Technology*, 7(3.27), 258–264.
18. N. Latif, J. Selvam, M. Kapse, V. Sharma, and V. Mahajan, "Comparative Performance of LSTM and ARIMA for the Short-Term Prediction of Bitcoin Prices," *Australas. Account. Bus. Finance J.*, vol. 17, no. 1, pp. 256–276, Jan. 2023, doi: 10.14453/aabfj.v17i1.15.
19. S. M. Raju and A. M. Tarif, "Real-Time Prediction of BITCOIN Price using Machine Learning Techniques and Public Sentiment Analysis." URL: <https://doi.org/10.48550/arXiv.2006.14473>

20. Isaac, M., Saluja, S. and Zhao. A. (2015) Automated Bitcoin Trading via Machine Learning Algorithms. URL: <http://cs229.stanford.edu/proj2014/Isaac%20Madan,%20Shaurya%20Saluja,%20Aojia%20Zhao,Automated%20Bitcoin%20Trading%20via%20Machine%20Learning%20Algorithms.pdf>
21. Jiang, X. (2020) Bitcoin Price Prediction Based on Deep Learning Methods. Journal of Mathematical Finance, 10, 132-139. doi: 10.4236/jmf.2020.101009.
22. Дрогомерецький А.В. Шевченківська весна 2024. Стратегії економічного зростання: погляд у майбутнє для України, матеріали Міжнародної науковопрактичної конференції студентів, аспірантів та молодих вчених / За заг. ред. Л.А. Анісімової: - К., Інтерсервіс, 2024. – Вип. XXII. – 345 с. URL: https://econom.knu.ua/wp-content/uploads/2024/04/%D0%97%D0%B1%D1%96%D1%80%D0%BD%D0%B8%D0%BA-%D0%A8%D0%92_2024.pdf
23. The (Mis)Behaviour of Markets: A Fractal View of Risk, Ruin and Reward by Benoit B. Mandelbrot Richard L. Hudson, 2004. – p. 202.
24. Дербенцев В. Д. Синергетичні та еконофізичні методи дослідження динамічних та структурних характеристик економічних систем : монографія / В. Д. Дербенцев, О. А. Сердюк, В. М. Соловійов, О. Д. Шарапов. – Черкаси : Брама-Україна, 2010. – 205 с.
25. Найман, Э. Расчёт показателя Херста с целью выявления трендовости (персистентности) финансовых рынков и макроэкономических индикаторов. 2009. – 2 с.
26. Кравець Т. В., Гапоненко Т. О. Фрактальний аналіз валютного ринку за допомогою моніторингу показника Херста. БІЗНЕСІНФОРМ. 2015. № 11. с. 127.
27. R. H. Shumway and D. S. Stoffer, Time Series Analysis and Its Applications. in Springer Texts in Statistics. New York, NY: Springer New York, 2011. doi: 10.1007/978-1-4419-7865-3.

28. Hyndman, R. J., & Khandakar, Y. (2008). Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, 27(3), 1–22. URL: <https://doi.org/10.18637/jss.v027.i03>
29. L. Felizardo, R. Oliveira, E. Del-Moral-Hernandez and F. Cozman, "Comparative study of Bitcoin price prediction using WaveNets, Recurrent Neural Networks and other Machine Learning Methods," 2019 6th International Conference on Behavioral, Economic and Socio-Cultural Computing (BESC), Beijing, China, 2019, pp. 1-6, doi: 10.1109/BESC48373.2019.8963009.
30. C. -H. Wu, C. -C. Lu, Y. -F. Ma and R. -S. Lu, "A New Forecasting Framework for Bitcoin Price with LSTM," 2018 IEEE International Conference on Data Mining Workshops (ICDMW), Singapore, 2018, pp. 168-175, doi: 10.1109/ICDMW.2018.00032.
31. Hardesty, Larry (2017). Explained: Neural networks. MIT News Office. URL: <https://news.mit.edu/2017/explained-neural-networks-deep-learning-0414>
32. Wilder, J. Welles. *New concepts in technical trading systems*. Greensboro, NC, 1978. – p. 65.
33. McKinney, W., et al. (2024). *pandas: Powerful data structures for data analysis in Python*. URL: <https://pandas.pydata.org/>
34. Ran, A., et al. (2024). *yfinance: Yahoo! Finance market data downloader*. URL: <https://github.com/ranaroussi/yfinance>
35. Duran, K. (2024). *pandas-ta: A Technical Analysis Library in Python 3*. URL: <https://github.com/twopirllc/pandas-ta>
36. Lendl, M. (2024). *hurst: Library to compute the Hurst exponent of time series*. URL: <https://github.com/Mottl/hurst>
37. Seabold, S., & Perktold, J. (2010). *Statsmodels: Econometric and statistical modeling with Python*. Proceedings of the 9th Python in Science Conference. URL: <https://www.statsmodels.org/>
38. Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., ... & Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585(7825), 357-362. URL: <https://numpy.org/>

39. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830. URL: <https://scikit-learn.org/>
40. Chollet, F., & others. (2015). Keras. Retrieved from <https://keras.io/>
41. Taylor, R. A., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37-45. URL: <https://alkaline-ml.com/pmdarima/>
42. Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90-95. URL: <https://matplotlib.org/>
43. Waskom, M., & the seaborn development team. (2021). seaborn: Statistical data visualization. *Journal of Open Source Software*, 6(60), 3021. URL: <https://seaborn.pydata.org/>
44. Bruce, Peter, Andrew Bruce, and Peter Gedeck. *Practical statistics for data scientists: 50+ essential concepts using R and Python*. O'Reilly Media, 2020.

Календарний план виконання кваліфікаційної роботи магістра

№	Етапи роботи	Терміни виконання	Відмітка керівника про виконання
1	Вибір теми кваліфікаційної роботи магістра	27.10.2023	
2	Розробка та затвердження завдання кваліфікаційної роботи магістра	17.11.2023	
3	Збір та опрацювання теоретичної бази для кваліфікаційної роботи	15.01.2024	
4	Підготовка теоретичного розділу 1	29.01.2024	
5	Підготовка розділу 2 про методологічні аспекти дослідження	19.02.2024	
6	Збір даних для проведення обрахунків	04.03.2024	
7	Побудова моделей	18.03.2024	
8	Проведення обрахунків	01.04.2024	
9	Оформлення результатів у розділі 3	15.04.2024	
10	Написання висновків	22.04.2024	
11	Остаточне оформлення результатів	29.04.2024	
12	Перевірка на плагіат	06.05.2024	
13	Попередній захист роботи	10.05.2024	
14	Рецензування	20.05.2024	
15	Подача роботи на кафедрі	20.05.2024	
16	Захист роботи	27.05.2024	

Науковий керівник: Олена ЛЯШЕНКО _____

(підпис)

Студент: Артур ДРОГОМЕРЕЦЬКИЙ _____


(підпис)


Київський національний університет імені Тараса Шевченка
Економічний факультет
Кафедра економічної кібернетики

ЗАВДАННЯ
на кваліфікаційну роботу магістра
студента 2 курсу спеціальності 051 «Економіка»
ОНП «Економічна кібернетика»
Дрогомерецького Артура Володимировича

1. Тема роботи: «Економіко-математичне моделювання динаміки ринку криптовалют».
2. Термін завершення роботи: 29.04.2024 р.
3. Попередній захист роботи: 10.05.2024 р.
4. Об'єкт дослідження: процес прогнозування динаміки ринку криптовалют.
5. Предмет дослідження: моделі прогнозування курсів криптовалют на основі ARIMA, рекурентних нейронних мереж LSTM та фрактального аналізу.
6. Мета дослідження: використання ARIMA та LSTM моделей в поєднанні з фрактальним аналізом часових рядів для прогнозування курсів криптовалют, а також розробка гібридної моделі на їх основі, порівняльний аналіз застосованих моделей та оцінка результатів прогнозування.
7. Завдання дослідження:
 - 7.1 ознайомитися з теоретичними аспектами діяльності криптовалютних ринків;
 - 7.2 проаналізувати використання фрактального аналізу у моделюванні динаміки ринку криптовалют;
 - 7.3 здійснити прогнозування за допомогою ARIMA, LSTM та гібридної моделі та проаналізувати результати їхньої роботи.

Науковий керівник: докторка економічних наук, професорка Ляшенко Олена Ігорівна

Олена ЛЯШЕНКО _____

Студент:  _____
(підпис)

Затверджено на засіданні кафедри економічної кібернетики
протокол № 3 від 25 жовтня 2023 р.