

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет _____ Центр післядипломної освіти
(повна назва)

Кафедра _____ Штучного інтелекту
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА

Пояснювальна записка

рівень вищої освіти _____ другий (магістерський)

Мультимодальна інтелектуальна система ймовірного прогнозування змін
курсів криптовалют на основі ринкових, текстових та ончейн-даних
(тема)

Виконав:
здобувач _____ другого _____ року навчання,
групи _____ СШЗдм-24-1

Михайло ЗОЛОТАРЕВСЬКИЙ
(власне ім'я, прізвище)

Спеціальність 122 Комп'ютерні науки
(код і повна назва спеціальності)

Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Системи штучного інтелекту
(повна назва освітньої програми)

Керівник проф. Олександр ШЕВЧЕНКО
(посада, власне ім'я, прізвище)

Допускається до захисту

Завідувач кафедри ШІ

(підпис)

Лариса ЧАЛА
(власне ім'я, прізвище)

2026 р.

Харківський національний університет радіоелектроніки

Факультет _____ Центр післядипломної освіти _____

Кафедра _____ Штучного інтелекту _____

Рівень вищої освіти _____ другий (магістерський) _____

Спеціальність _____ 122 Комп'ютерні науки _____
(код і повна назва)

Тип програми _____ освітньо-наукова _____
(освітньо-професійна або освітньо-наукова)

Освітня програма _____ Системи штучного інтелекту _____
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

«_____» _____ 20 ____ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві _____ Золотаревському Михайлу Сергійовичу _____
(прізвище, ім'я, по батькові)

1. Тема роботи _____ Мультимодальна інтелектуальна система ймовірнісного прогнозування змін курсів криптовалют на основі ринкових, текстових та ончейн-даних _____

затверджена наказом університету від 6 квітня 20 26 р. № 48Стз

2. Термін подання здобувачем роботи до екзаменаційної комісії 26 травня 20 26 р.

3. Вихідні дані до роботи Науково-технічні публікації, дані Інтернет-джерел та відомих наукових проєктів, публічні API криптовалютних бірж для отримання ринкових даних (Binance, Gate.io), платформи ончейн-аналітики (Glassnode, DeBank), відкриті RSS-стрічки криптовалютних медіа (CoinTelegraph), набори мультимодальних даних для тренування та тестування системи, документація C# (ASP.NET Core), Python (TensorFlow/Keras, FinBERT) та PostgreSQL _____

4. Перелік питань, що потрібно опрацювати в роботі _____

1) Теоретичні та методологічні основи прогнозування змін курсів криптовалют _____

2) Опис проведених теоретичних досліджень _____


3) Опис системи, що пропонується _____

4) Опис проведених експериментальних досліджень _____

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Строк / термін виконання етапів роботи	Примітка
1	Отримання завдання на кваліфікаційну роботу	06.04.2026	виконано
2	Аналіз предметної галузі та підходів до прогнозування	10.04.2026	виконано
3	Проектування модулів збору ринкових, текстових та ончейн-даних	15.04.2026	виконано
4	Розробка гібридної архітектури моделі CNN-BiLSTM-Attention	20.04.2026	виконано
5	Експериментальне моделювання та навчання моделі	26.04.2026	виконано
6	Написання пояснювальної записки	04.05.2026	виконано
7	Перевірка на академічний плагіат	05.05.2026	виконано
8	Нормоконтроль	08.05.2026	виконано
9	Рецензування	10.05.2026	виконано
10	Підготовка презентації та доповіді	12.05.2026	виконано
11	Попередній захист	14.05.2026	виконано
12	Захист перед ЕК	26.05.2026	

Дата видачі завдання 6 квітня 2026 р.

Здобувач 
(підпис)

Керівник роботи _____
(підпис)

проф. Олександр ШЕВЧЕНКО
(посада, власне ім'я, прізвище)

РЕФЕРАТ

Пояснювальна записка: 86 с., 10 рис., 1 табл., 2 дод., 21 джерел.

КРИПТОВАЛЮТА, МУЛЬТИМОДАЛЬНА СИСТЕМА, ОНЧЕЙН-ДАНІ, ПРОГНОЗУВАННЯ, РИНКОВІ ДАНІ, СЕНТИМЕНТ-АНАЛІЗ, ЧАСОВИЙ РЯД, CNN-BILSTM-ATTENTION, FASTAPI, FINBERT, POSTGRESQL, TENSORFLOW, XGBOOST.

Об'єкт дослідження – процес прогнозування змін курсів криптовалют на основі мультимодальних часових рядів.

Предмет дослідження – методи та моделі мультимодального інтелектуального прогнозування курсів криптовалют із використанням ринкових, текстових та ончейн-даних.

Мета роботи – розроблення мультимодальної інтелектуальної системи ймовірнісного прогнозування змін курсів криптовалют на основі поєднання глибинних нейронних мереж та ансамблевих моделей машинного навчання.

Методи дослідження – методи машинного та глибинного навчання, аналізу часових рядів, обробки природної мови, сентимент-аналізу, градієнтного бустингу, нормалізації даних та статистичної оцінки якості прогнозування.

У результаті роботи розроблено мультимодальну інтелектуальну систему прогнозування курсів криптовалют, що поєднує ринкові дані, текстову інформацію та ончейн-метрики. Реалізовано гібридну архітектуру CNN-BiLSTM-Attention, ансамблевий компонент XGBoost, Python FastAPI AI-сервіс, ASP.NET Core backend, базу даних PostgreSQL та механізм збереження історії прогнозів. Проведено експериментальне дослідження якості прогнозування та визначено обмеження процедури нормалізації даних як напрям подальшого вдосконалення системи.

ABSTRACT

Master's thesis contains: 86 pp., 10 fig., 1 tabl., 2 ann., 21 references.

CNN-BILSTM-ATTENTION, CRYPTOCURRENCY, FASTAPI, FINBERT, FORECASTING, MARKET DATA, MULTIMODAL SYSTEM, ON-CHAIN DATA, POSTGRESQL, SENTIMENT ANALYSIS, TENSORFLOW, TIME SERIES, XGBOOST.

Object of research is the process of forecasting cryptocurrency exchange rate changes based on multimodal time series.

Subject of research is methods and models of multimodal intelligent cryptocurrency exchange rate forecasting using market, textual, and on-chain data.

Purpose of work is to develop a multimodal intelligent system for probabilistic forecasting of cryptocurrency exchange rate changes based on deep neural networks and ensemble machine learning models.

Research methods are machine learning and deep learning methods, time series analysis, natural language processing, sentiment analysis, gradient boosting, data normalization, and statistical evaluation of forecasting accuracy.

As a result of the work, a multimodal intelligent system for cryptocurrency exchange rate forecasting was developed. The system combines market data, textual information, and on-chain metrics. A hybrid CNN-BiLSTM-Attention architecture, an XGBoost ensemble component, a Python FastAPI AI service, an ASP.NET Core backend, a PostgreSQL database, and a prediction history storage mechanism were implemented. Experimental evaluation of forecasting quality was conducted, and the limitation of the data normalization procedure was identified as a direction for further improvement.

ЗМІСТ

Перелік умовних позначень, символів, одиниць, скорочень і термінів	9
Вступ.....	11
1 Теоретичні та методологічні основи прогнозування змін курсів криптовалют.....	13
1.1 Аналіз проблематики прогнозування на ринку криптовалют.....	13
1.2 Огляд методів прогнозування на основі ринкових даних	14
1.3 Дослідження підходів до аналізу текстових та ончейн-даних	15
1.4 Порівняльний аналіз існуючих систем та обґрунтування мультимодального підходу	16
1.5 Висновки до розділу 1	17
2 Опис проведених теоретичних досліджень.....	18
2.1 Теоретичне обґрунтування мультимодального підходу до прогнозування.....	18
2.2 Математичні засади гібридної архітектури CNN-BiLSTM-Attention	19
2.3 Теоретичні аспекти адаптивного навчання та прогнозування з відкритим циклом.....	21
2.4 Обґрунтування вибору гібридної архітектури на основі проведених досліджень	22
2.5 Формалізація задачі прогнозування часових рядів криптовалют.....	22
2.5.1 Формування навчальних вибірок методом ковзного вікна	23
2.5.2 Нормалізація даних.....	24
2.5.3 Застосування згорткових нейронних мереж для аналізу часових залежностей	24
2.5.4 Використання BiLSTM для моделювання часових залежностей	24
2.5.5 Використання механізму уваги (Attention)	25
2.5.6 Використання ансамблевого алгоритму XGBoost.....	25
2.5.7 Ансамблевий підхід до прогнозування.....	26

2.6 Висновки до розділу 2	26
3 Опис системи, що пропонується.....	27
3.1 Загальна архітектура мультимодальної системи прогнозування.....	27
3.2 Пайплайн обробки мультимодальних даних.....	27
3.3 Рівень підтримки інвестиційних рішень (investment decision layer) ..	28
3.4 Підсистема самодіагностики та прогнозування з відкритим циклом (Error Feedback Loop)	30
3.5 Обґрунтування вибору технологічного стеку та інструментальних засобів розробки	31
3.6 Підсистема оперативного сповіщення та моніторингу делістингів (Telegram Bot).....	33
3.7 Розробка мікросервісної архітектури програмного комплексу	35
3.8 Алгоритмічне забезпечення збору мультимодальних даних	36
3.9 Інфраструктура розгортання та DevSecOps практики.....	39
3.10 Інфраструктура розгортання та безперервна інтеграція (CI/CD).....	40
3.10.1 Оркестрація мікросервісів за допомогою Docker Compose.....	40
3.10.2 Налаштування CI/CD пайплайну на базі Bitbucket	40
3.10.3 Політики безпеки та управління секретами (DevSecOps)	41
3.10.4 Аналіз продуктивності та навантаження хмарної інфраструктури.....	42
3.11 Проєктування бази даних та структури зберігання мультимодальних даних	43
3.11.1 Таблиця MarketData (Ринкові показники)	44
3.11.2 Таблиця TextSentimentData (Аналіз тональності текстів)	44
3.11.3 Таблиця OnChainData (Блокчейн-метрики)	45
3.11.4 Таблиця PredictionsHistory (Історія прогнозів моделі)	45
4 Опис проведених експериментальних досліджень.....	47
4.1 Підготовка мультимодального набору даних	47
4.2 Хід навчання гібридної моделі CNN-BiLSTM-Attention	48
4.3 Результати прогнозування та аналіз бізнес-метрик.....	49

4.4 Оптимізація архітектури методом ансамблевого навчання (Stacking)	50
4.5 Порівняльний аналіз розробленої архітектури з базовими моделями глибинного навчання	52
4.6 Оцінка результатів прогнозування в режимі реального часу	54
4.7 Обмеження процедури нормалізації даних під час навчання моделі	56
4.8 Напрями подальшого вдосконалення моделі прогнозування	57
Висновки	58
Перелік джерел посилання	61
Додаток А Лістинг коду проєкту	64
Додаток Б Відомість кваліфікаційної роботи	87

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

БД – база даних;

ПЗ – програмне забезпечення;

СУБД – система управління базами даних;

ШІ – штучний інтелект;

ACID – Atomicity, Consistency, Isolation, Durability – атомарність, узгодженість, ізолюваність та довговічність транзакцій;

AI – Artificial Intelligence – штучний інтелект;

API – Application Programming Interface – інтерфейс програмування застосунків;

ASP.NET – Active Server Pages .NET – вебфреймворк платформи .NET для розробки серверних застосунків;

BiLSTM – Bidirectional Long Short-Term Memory – двоспрямована мережа довгої короткострокової пам'яті;

CI/CD – Continuous Integration / Continuous Deployment – безперервна інтеграція та безперервне розгортання;

CNN – Convolutional Neural Network – згорткова нейронна мережа;

DNN – Deep Neural Network – глибока нейронна мережа;

GRU – Gated Recurrent Unit – керований рекурентний блок;

IOPS – Input/Output Operations Per Second – кількість операцій вводу-виводу за секунду;

LLM – Large Language Model – велика мовна модель;

LSTM – Long Short-Term Memory – довга короткострокова пам'ять;

MAE – Mean Absolute Error – середня абсолютна похибка;

MAPE – Mean Absolute Percentage Error – середня абсолютна похибка у відсотках;

ML – Machine Learning – машинне навчання;

MSE – Mean Squared Error – середньоквадратична похибка;

NLP – Natural Language Processing – обробка природної мови;

OHLCV – Open, High, Low, Close, Volume – ціна відкриття, максимум, мінімум, ціна закриття та обсяг;

ORM – Object-Relational Mapping – об'єктно-реляційне відображення;

REST – Representational State Transfer – архітектурний стиль взаємодії вебсервісів;

RMSE – Root Mean Square Error – коренева середньоквадратична похибка;

RNN – Recurrent Neural Network – рекурентна нейронна мережа;

RSI – Relative Strength Index – індекс відносної сили;

RSS – Really Simple Syndication – формат вебстрічок для поширення оновлень контенту;

SSH – Secure Shell – захищений мережевий протокол віддаленого доступу;

SSL/TLS – Secure Sockets Layer / Transport Layer Security – криптографічні протоколи захисту мережевого з'єднання;

SQL – Structured Query Language – мова структурованих запитів;

TensorFlow – бібліотека машинного та глибинного навчання для побудови, навчання та розгортання нейронних мереж.

VaR – Value at Risk – ризикова вартість.

XGBoost – Extreme Gradient Boosting – алгоритм екстремального градієнтного бустингу.

ВСТУП

Актуальність теми. Сучасний ринок криптовалют характеризується високою динамічністю, складністю та безпрецедентною волатильністю порівняно з традиційними фінансовими ринками. Існуючі підходи до прогнозування, що базуються виключно на історичних ринкових даних (ціна, обсяг торгів), часто виявляються недостатньо ефективними. Це пов'язано з тим, що курси криптовалют суттєво залежать від неструктурованої інформації: новинного фону, емоційного забарвлення повідомлень користувачів у соціальних мережах (текстові дані), а також від внутрішньої активності та транзакцій у самій блокчейн-мережі (ончейн-дані). Тому розробка інтелектуальних систем, здатних комплексно об'єднувати ці три модальності для формування не просто точкового, а саме ймовірнісного прогнозу, є своєчасною та значущою науково-практичною задачею, що дозволить суттєво покращити якість прийняття рішень в умовах невизначеності.

Об'єкт дослідження – процес прогнозування змін курсів криптовалют на основі мультимодальних часових рядів.

Предмет дослідження – методи та моделі мультимодального інтелектуального прогнозування курсів криптовалют із використанням ринкових, текстових та ончейн-даних.

Мета роботи – розроблення мультимодальної інтелектуальної системи ймовірнісного прогнозування змін курсів криптовалют на основі поєднання глибинних нейронних мереж та ансамблевих моделей машинного навчання.

Для досягнення поставленої мети необхідно розв'язати такі задачі:

- проаналізувати сучасні методи прогнозування часових рядів криптовалют;
- дослідити можливості використання мультимодальних даних;
- розробити архітектуру мультимодальної системи прогнозування;

- реалізувати модель CNN-BiLSTM-Attention;
- реалізувати ансамблеву модель із використанням XGBoost;
- провести експериментальне дослідження ефективності системи;
- оцінити якість прогнозування за допомогою метрик точності.

Методи дослідження. Для розв'язання поставлених задач у роботі застосовуються методи машинного та глибокого навчання, алгоритми обробки природної мови (NLP) для сентимент-аналізу текстів, методи аналізу часових рядів, а також інструменти математичної статистики і ймовірнісного моделювання.

Сфера застосування та практичне значення. Розроблена система може бути використана приватними інвесторами, трейдерами, а також аналітичними та фінансовими компаніями для оптимізації торгових стратегій, розширення інструментарію управління ризиками та оцінки ймовірності зміни ринкових трендів.

1 ТЕОРЕТИЧНІ ТА МЕТОДОЛОГІЧНІ ОСНОВИ ПРОГНОЗУВАННЯ ЗМІН КУРСІВ КРИПТОВАЛЮТ

1.1 Аналіз проблематики прогнозування на ринку криптовалют

Сучасний фінансовий ландшафт зазнав суттєвих трансформацій із появою та стрімким розвитком ринку криптовалют. На відміну від традиційних фінансових ринків (фондових або валютних), ринок цифрових активів функціонує на базі технологій розподіленого реєстру (блокчейн) без єдиного центрального органу управління. Ця децентралізація, у поєднанні з цілодобовим режимом торгів без вихідних, формує унікальне середовище, яке характеризується безпрецедентно високою волатильністю та вразливістю до зовнішніх інформаційних шоків.

Історично більшість класичних статистичних моделей прогнозування (наприклад, ARIMA або базові економетричні регресії) розроблялися для ринків із відносно стабільними макроекономічними показниками. Застосування таких методів до криптовалют часто виявляється неефективним, оскільки цифрові активи схильні до раптових стрибків цін, аномальних розподілів доходностей та різких змін трендів під впливом нелінійних і неструктурованих факторів.

Аналіз сучасних досліджень у галузі застосування штучного інтелекту у фінансовій сфері демонструє активний пошук нових архітектур для роботи з такими даними. Проте більшість існуючих рішень залишаються одномодальними – вони переважно зосереджуються виключно на аналізі історичних ринкових показників (історії цін, обсягів торгів).

Головна проблема полягає в тому, що ціноутворення на високоспекулятивному криптовалютному ринку формується під комплексним впливом трьох різних вимірів:

- ринкова активність: історичні патерни зміни ціни та торговельні обсяги на біржах;

- інформаційне тло (настрій натовпу): публікації в новинних медіа, заяви лідерів думок та загальний емоційний фон інвесторів у соціальних мережах, які часто стають тригерами для імпульсивних цінових рухів (текстові дані);
- фундаментальна активність блокчейну: обсяги транзакцій між гаманцями, комісії всередині мережі, активність майнерів та переміщення коштів великих власників, що фіксуються безпосередньо в мережі (ончейн-дані).

Крім того, точкове (детерміноване) прогнозування на такому ринку має низьку практичну цінність через надзвичайно високу частку ринкового шуму. Для прийняття рішень в умовах невизначеності необхідні саме ймовірнісні прогнози, які дозволяють оцінювати не лише очікуваний напрямок руху ціни, але й ступінь впевненості моделі, оцінюючи дисперсію та ймовірність настання цінових аномалій.

1.2 Огляд методів прогнозування на основі ринкових даних

Аналіз ринкових даних, до яких належать історичні ціни (ціни відкриття, закриття, максимуми, мінімуми) та обсяги торгів, є історично першим і базовим етапом у задачах моделювання та прогнозування соціально-економічних процесів. Загалом методи прогнозування часових рядів на основі таких даних можна концептуально розділити на дві великі групи: класичні економетричні (статистичні) моделі та сучасні методи машинного і глибинного навчання.

Класичні статистичні підходи, такі як моделі авторегресії з інтегрованим ковзним середнім (ARIMA) або експоненційне згладжування, базуються на припущенні про стаціонарність часового ряду. Проте для криптовалют ці лінійні методи часто виявляються недостатньо гнучкими через високий рівень шуму, нелінійну природу фінансових даних та раптові зміни ринкових режимів.

Сучасний етап розвитку систем прогнозування характеризується активним застосуванням складних архітектур штучного інтелекту та глибинного навчання (Deep Learning). Серед розмаїття архітектур глибинного навчання, таких як багат шарові персептрони (DNN), згорткові (CNN) та рекурентні нейронні мережі (RNN), саме рекурентні моделі (зокрема їх модифікації LSTM та GRU) є найбільш адаптованими для роботи з послідовними даними. Вони здатні запам'ятовувати як короткострокові, так і довгострокові залежності у змінах курсів, ефективно виявляючи приховані патерни в історичній ринковій активності.

Незважаючи на високу здатність глибинних нейромереж знаходити закономірності в історії цін, моделі, що спираються виключно на ринкову модальність, залишаються обмеженими. Вони ефективно екстраполюють минулі цінові рухи, проте не можуть передбачити різкі стрибки або розвороти трендів, спричинені зовнішніми інформаційними шоками. Це обґрунтовує необхідність переходу до комплексного аналізу, де базовий прогноз на основі часових рядів коригується з урахуванням інших модальностей.

1.3 Дослідження підходів до аналізу текстових та ончейн-даних

Як показує практика, криптовалютний ринок є надзвичайно чутливим до інформаційного фону та настроїв інвесторів. Тому другим важливим джерелом даних для прогнозування є текстова інформація, яка включає новини, публікації в соціальних мережах, фінансові блоги та заяви лідерів думок. Для обробки таких неструктурованих даних застосовуються методи обробки природної мови (NLP) та аналізу тональності тексту (Sentiment Analysis).

Сучасні дослідження підтверджують, що емоційне забарвлення текстових повідомлень має прямий вплив на коливання курсів цифрових активів. Алгоритми сентимент-аналізу класифікують тексти на позитивні,

негативні та нейтральні, або ж оцінюють інтенсивність емоцій, що дозволяє виявляти паніку або надмірний оптимізм на ринку ще до того, як вони повною мірою відобразяться на цінових графіках.

Таким чином, ізольоване застосування лише текстових або лише ончейн-даних не дає повної картини ринку, проте їх інтеграція відкриває нові можливості для виявлення прихованих закономірностей. Наступним кроком є об'єднання цих модальностей із ринковими показниками для побудови комплексної системи прогнозування.

1.4 Порівняльний аналіз існуючих систем та обґрунтування мультимодального підходу

Проведений огляд існуючих підходів дозволяє зробити висновок, що використання лише однієї модальності даних суттєво обмежує можливості прогностичних моделей на криптовалютному ринку. Моделі, що базуються виключно на ринкових даних (історичних цінах та обсягах), добре працюють у періоди стабільних трендів, але виявляються безпорадними під час різких змін, викликаних фундаментальними або інформаційними факторами. Системи сентимент-аналізу текстових даних здатні швидко реагувати на новини та емоції натовпу, проте часто генерують хибні сигнали через інформаційний шум і маніпуляції в соціальних мережах. З іншого боку, ончейн-аналіз чудово відображає фундаментальну цінність та реальну економічну активність у блокчейні, але реагує на події із певною затримкою і не враховує спекулятивний інтерес зовнішніх інвесторів.

Порівняльний аналіз показує, що жоден з ізольованих методів не здатен забезпечити стабільно високу точність прогнозування через складну, нелінійну природу ціноутворення цифрових активів. Саме тому виникає необхідність розробки мультимодальної інтелектуальної системи, яка здатна обробляти та комплексно об'єднувати ринкові, текстові та ончейн-дані в єдиному обчислювальному середовищі. Такий підхід створює

синергетичний ефект: наприклад, базовий тренд, визначений за ринковими даними, може бути підтверджений або спростований фундаментальними ончейн-метриками, а раптовий ціновий імпульс – пояснений та відкоригований через аналіз тональності новинного фону.

Крім того, враховуючи високу волатильність і значну частку ринкового шуму, класичне детерміноване (точкове) прогнозування є недостатньо інформативним для практичного застосування. Розв'язанням цієї проблеми є перехід безпосередньо до ймовірнісного прогнозування. Замість видачі єдиного очікуваного значення майбутньої ціни, мультимодальна система повинна моделювати розподіл ймовірностей майбутніх змін курсу. Це дозволить оцінювати рівень впевненості моделі, враховувати дисперсію та потенційні ризики настання непередбачуваних подій.

Отже, розробка мультимодальної інтелектуальної системи ймовірнісного прогнозування змін курсів криптовалют на основі ринкових, текстових та ончейн-даних є науково обґрунтованим та актуальним напрямком, що дозволить подолати ключові недоліки існуючих одноmodalних рішень.

1.5 Висновки до розділу 1

У результаті аналізу сучасних методів прогнозування часових рядів криптовалют встановлено, що використання лише ринкових даних не забезпечує достатньої точності прогнозування в умовах високої волатильності криптовалютного ринку. Перспективним напрямом підвищення ефективності прогнозування є застосування мультимодального підходу, що передбачає інтеграцію ринкових, текстових та ончейн-даних. Це обґрунтовує доцільність розроблення мультимодальної інтелектуальної системи прогнозування.

2 ОПИС ПРОВЕДЕНИХ ТЕОРЕТИЧНИХ ДОСЛІДЖЕНЬ

2.1 Теоретичне обґрунтування мультимодального підходу до прогнозування

Ринок криптовалют є вкрай нестаціонарним та волатильним середовищем, що робить традиційні одновимірні моделі аналізу часових рядів недостатньо ефективними. Сучасні теоретичні дослідження доводять, що використання мультимодального підходу (multimodal data fusion) дозволяє суттєво підвищити точність прогнозування. У рамках даного дослідження обґрунтовано інтеграцію трьох незалежних векторів (модальностей) даних:

- ринкові показники (OHLCV) – відображають історичну динаміку ціноутворення та обсягів торгів;
- текстові дані (Сентимент-аналіз) – емоційне забарвлення новин та інформаційного фону, яке видобувається за допомогою сучасних NLP-моделей (зокрема, трансформерних архітектур типу FinBERT);
- ончейн-метрики – фундаментальні показники блокчейн-мережі, такі як активність унікальних адрес та транзакції великих гравців («китів»). Таке поєднання дозволяє нейромережі знаходити приховані нелінійні кореляції між психологією натовпу, фундаментальною активністю мережі та фактичними ціновими рухами.

Варто зазначити, що проблема одночасної обробки різноформатних даних не є новою для комп'ютерних наук. Як зазначає у своїх фундаментальних працях О.Ю. Шевченко, ефективний інтелектуальний менеджмент та інтеграція різномірної (гетерогенної) інформації є критично важливою задачею для побудови сучасних інтелектуальних систем підтримки прийняття рішень [1]. У контексті даного дослідження, застосування концепцій інтеграції гетерогенних джерел дозволяє успішно об'єднати числові фінансові показники, специфічні ончейн-метрики та

неструктурований текст у єдиний нормалізований інформаційний простір для подальшої обробки гібридною нейромережею [2], [3], [4].

Аналіз найсучасніших міжнародних публікацій за 2023–2026 роки повністю підтверджує цей вектор розвитку інтелектуальних систем. Зокрема, дослідження показують, що використання ончейн-даних у поєднанні з рекурентними нейромережами типу LSTM вже забезпечує значне покращення результатів прогнозування порівняно з економетричними моделями, оскільки дозволяє виявляти фундаментальну активність учасників мережі. Крім того, застосування нейромереж з довгою короткостроковою пам'яттю є вкрай ефективним інструментом для розпізнавання довгострокових залежностей на графіках таких активів, як Bitcoin та Ethereum.

2.2 Математичні засади гібридної архітектури CNN-BiLSTM-Attention

Для обробки сформованого мультимодального простору ознак теоретично обґрунтовано використання гібридної нейромережевої архітектури, що поєднує можливості виділення локальних ознак та аналізу довгострокових залежностей.

На першому етапі застосовується згорткова нейронна мережа (CNN), яка виконує операцію згортки (convolution) над вхідним тензором (часовим вікном), формуючи карти ознак. Це дозволяє ефективно ідентифікувати короткострокові цінові патерни та локальні аномалії в мультимодальних даних.

Далі видобуті просторові ознаки передаються до рекурентного шару – двоспрямованої мережі довгої короткострокової пам'яті (BiLSTM). На відміну від класичної LSTM, архітектура BiLSTM обробляє часову послідовність як у прямому, так і у зворотному напрямках. Це дає змогу

моделі захоплювати складні часові залежності, враховуючи ширший контекст подій у межах заданого вікна прогнозування.

Ключовим теоретичним доповненням архітектури є імплементація механізму Уваги (Attention mechanism). Механізм Уваги розраховує вагові коефіцієнти (attention weights) для кожного прихованого стану BiLSTM, дозволяючи моделі динамічно фокусуватися на найбільш значущих часових кроках (наприклад, днях із різкими стрибками настрою або аномальною ончейн-активністю), ефективно ігноруючи ринковий шум.

Математичний апарат двоспрямованої мережі довгої короткострокової пам'яті (BiLSTM) дозволяє ефективно моделювати часові варіації шляхом збереження довгострокового контексту та підтримки двонаправлених залежностей у часових рядах. Подвійна структура мережі надає моделі доступ як до історичних, так і до майбутніх (у контексті навчального вікна) даних, що сприяє виділенню складніших часових ознак [5].

Внутрішня архітектура кожної комірки LSTM регулюється складною системою вентилів: вентилем входу (input gate i_t), вентилем забування (forget gate f_t) та вентилем виходу (output gate o_t), які контролюють стан комірки (C_t) та прихований стан (h_t) на кожному часовому кроці [5].

Проте класичні мережі BiLSTM призначають однакову вагу кожному часовому кроку в послідовності, що є непрактичним для високодинамічних даних, таких як ціни на криптовалюти. Для вирішення цієї проблеми в архітектуру інтегровано шар механізму Уваги (Attention Layer) [5].

Механізм Уваги діє як фільтр, що усуває шум і підкреслює найбільш значущі патерни (наприклад, сигнали прориву чи різкі розвороти тренду). Шар Уваги призначає вагу уваги (α_t) кожному виходу прихованого стану з BiLSTM на кожному часовому кроці (t). Спочатку прихований стан (h_t) проходить через треноване перетворення для отримання оцінок релевантності (e_t), після чого ваги нормалізуються за допомогою функції

softmax. Фінальний вектор контексту формується як зважена сума прихованих станів за формулою

$$Context_vector = \sum_{t=1}^T \alpha_t h_t, \quad (2.1)$$

Такий підхід значно підвищує точність прогнозування в умовах високої волатильності, дозволяючи системі миттєво приймати рішення про збереження або видалення даних [5].

2.3 Теоретичні аспекти адаптивного навчання та прогнозування з відкритим циклом

З огляду на постійну еволюцію ефективності ринку криптовалют та зміну ринкових режимів (regime-switching behavior), статичні моделі схильні до поступової деградації точності. Для подолання цієї проблеми у дослідженні теоретично обґрунтовано використання концепції Transfer Learning (перенесення навчання) у поєднанні з прогнозуванням з відкритим циклом (open-loop forecasting).

Цей підхід передбачає наявність механізму зворотного зв'язку за помилкою (Error Feedback Loop). Система періодично порівнює згенерований прогноз із фактичним спостережуваним значенням. Якщо похибка перевищує заданий поріг, ініціюється процес донавчання (fine-tuning) моделі на новітньому масиві даних.

Це дозволяє моделі адаптувати свої синаптичні ваги до нових ринкових реалій без необхідності повного перенавчання, зменшуючи обчислювальні витрати та запобігаючи катастрофічному забуванню (catastrophic forgetting) базових закономірностей.

2.4 Обґрунтування вибору гібридної архітектури на основі проведених досліджень

Як наголошується у критичному огляді розвитку методів глибинного навчання (від прогнозування Bitcoin до аналізу волатильних альткоїнів), фокус передових досліджень сьогодні неухильно зміщується саме у бік гібридних та ансамблевих архітектур, що обов'язково інтегрують сентимент-аналіз як додаткову модальність [6]. Комплексне злиття ринкових, текстових та блокчейн-даних формує так звану «синергетичну альфу» (Synergistic Alpha). Практичні експерименти доводять, що таке злиття забезпечує не лише статистичну, але й доведену економічну перевагу над класичними моделями, оскільки система здатна розрізняти рухи, підкріплені фундаментальними зсувами, від тих, що спричинені тимчасовим емоційним сплеском натовпу [5].

Більше того, врахування ефектів довгострокової пам'яті (long memory) у часових рядах криптовалют за допомогою гібридних Seq2Seq-моделей (зокрема з використанням механізму Attention) дозволяє значно точніше моделювати ринкову ефективність в умовах високого інформаційного шуму та нестаціонарності [5]. Саме тому гібридна архітектура CNN-BiLSTM-Attention, запропонована в даній роботі, є найбільш релевантним рішенням. Така комбінація, де CNN відповідає за виділення просторових (локальних) ознак, BiLSTM – за двоспрямовані часові залежності, а Attention динамічно зважує важливість окремих кроків, наразі визнається світовою науковою спільнотою як еталонний фреймворк для систем підтримки інвестиційних рішень [6].

2.5 Формалізація задачі прогнозування часових рядів криптовалют

Нехай задано часовий ряд мультимодальних спостережень криптовалютного ринку:

$$X_t = \{Open_t, High_t, Low_t, Close_t, Volume_t, Sentiment_t, OnChain_t\}, \quad (2.2)$$

де *Open*, *High*, *Low*, *Close* – ринкові показники;

Volume – торговий обсяг;

Sentiment – оцінка тональності інформаційного середовища;

OnChain – показники активності мережі блокчейн.

Необхідно побудувати функцію прогнозування:

$$F(X_{t-n}, \dots, X_{t-1}) \rightarrow Close_t, \quad (2.3)$$

яка мінімізує функцію втрат:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2. \quad (2.4)$$

2.5.1 Формування навчальних вибірок методом ковзного вікна

Для врахування часових залежностей використовується метод ковзного вікна (sliding window), який дозволяє сформувати навчальні послідовності довжиною $n=30$ днів.

Таким чином формується навчальна вибірка:

$$X_i = \begin{bmatrix} x_{i-n} \\ x_{i-n+1} \\ \dots \\ x_{i-1} \end{bmatrix}, \quad (2.5)$$

відповідна цільова змінна:

$$y_i = Close_i. \quad (2.6)$$

2.5.2 Нормалізація даних

Для забезпечення стабільності навчання нейронної мережі використовується нормалізація вхідних даних методом Min-Max масштабування:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}, \quad (2.7)$$

де x – початкове значення ознаки;

x_{min} , x_{max} – мінімальне та максимальне значення ознаки відповідно.

2.5.3 Застосування згорткових нейронних мереж для аналізу часових залежностей

Згорткові нейронні мережі застосовуються для автоматичного вилучення локальних часових патернів фінансових рядів, зокрема короткострокових коливань цін та змін торгових обсягів.

Операція згортки описується виразом:

$$y_t = \sum_{i=0}^k w_i x_{t-i}, \quad (2.8)$$

де w_i – вагові коефіцієнти ядра згортки;

k – розмір ядра.

2.5.4 Використання BiLSTM для моделювання часових залежностей

Для моделювання довгострокових часових залежностей використовується двонаправлена рекурентна мережа типу BiLSTM.

На відміну від класичних LSTM-мереж, BiLSTM дозволяє враховувати як попередні, так і наступні часові стани:

$$h_t = [\overrightarrow{h}_t, \overleftarrow{h}_t], \quad (2.9)$$

що підвищує точність аналізу складних часових структур фінансових рядів.

2.5.5 Використання механізму уваги (Attention)

Механізм уваги дозволяє моделі визначати найбільш інформативні часові інтервали вхідної послідовності шляхом адаптивного зважування їх внеску у формування прогнозу.

Обчислення ваг уваги виконується за формулою:

$$\alpha_i = \frac{\exp(e_i)}{\sum_j \exp(e_j)}, \quad (2.10)$$

де e_i – коефіцієнт важливості відповідного елемента послідовності.

Остаточний контекстний вектор визначається як:

$$c = \sum_i \alpha_i h_i, \quad (2.11)$$

2.5.6 Використання ансамблевого алгоритму XGBoost

Для підвищення точності прогнозування додатково використовується ансамблевий алгоритм градієнтного бустингу XGBoost, який дозволяє ефективно моделювати нелінійні залежності між ознаками.

Загальна модель бустингу описується як:

$$y_i = \sum_{k=1}^K f_k(x_i), \quad (2.12)$$

2.5.7 Ансамблевий підхід до прогнозування

Остаточний прогноз формується як зважена комбінація результатів нейронної мережі CNN-BiLSTM-Attention та моделі XGBoost:

$$y = 0.6y_{DL} + 0.4y_{XGB}. \quad (2.13)$$

2.6 Висновки до розділу 2

У розділі розглянуто математичні методи побудови мультимодальної системи прогнозування курсів криптовалют. Обґрунтовано використання архітектури CNN-BiLSTM-Attention для аналізу часових залежностей та алгоритму XGBoost для підвищення точності прогнозування. Запропонований ансамблевий підхід дозволяє ефективно поєднати переваги глибокого навчання та класичних методів машинного навчання.

3 ОПИС СИСТЕМИ, ЩО ПРОПОНУЄТЬСЯ

3.1 Загальна архітектура мультимодальної системи прогнозування

Розроблена мультимодальна інтелектуальна система прогнозування курсів криптовалют побудована як програмний комплекс, що поєднує модулі збору ринкових, текстових та ончейн-даних, підсистему попередньої обробки інформації, AI-мікросервіс прогнозування, базу даних та користувацький рівень підтримки інвестиційних рішень. Основною особливістю запропонованої системи є поєднання гібридної нейромережевої моделі CNN-BiLSTM-Attention з ансамблевим компонентом XGBoost та механізмом адаптивного донавчання на основі зворотного зв'язку за помилкою.

Система інтегрує три типи джерел інформації:

- ринкові дані криптовалютного ринку;
- текстові дані інформаційного середовища;
- ончейн-метрики блокчейн-мережі.

Поєднання зазначених модальностей дозволяє підвищити точність прогнозування порівняно з використанням лише цінових часових рядів.

3.2 Пайплайн обробки мультимодальних даних

Загальний процес функціонування системи прогнозування включає такі етапи:

- збір ринкових даних через API криптовалютних бірж;
- отримання текстових даних інформаційного середовища;
- збір ончейн-метрик блокчейн-мережі;
- попередня обробка та нормалізація даних;
- формування часових послідовностей методом ковзного вікна;

- прогнозування значення курсу криптовалюти за допомогою ансамблевої моделі;
- збереження результатів прогнозування;
- моніторинг точності прогнозу.

3.3 Рівень підтримки інвестиційних рішень (investment decision layer)

Кінцевою метою прогнозування цін на криптовалюти є перетворення точних прогнозів на обґрунтовані та дієві інвестиційні рішення. Хоча прогностичне моделювання забезпечує надійну основу, його цінність максимізується лише за умови інтеграції в структуровану систему підтримки прийняття рішень. Тому результати прогнозів гібридної моделі CNN-BiLSTM-Attention розширюються на рівень прийняття інвестиційних рішень, який допомагає формувати практичні стратегії.

Процес прийняття рішень починається з відображення прогнозованих рухів ціни в інвестиційні сигнали, класифіковані як рекомендації щодо купівлі, утримання або продажу (Buy, Hold, Sell). У запропонованій системі прогнози нейромережі поєднуються з класичними технічними індикаторами (наприклад, індексом відносної сили RSI) для багатофакторного підтвердження (Multi-criteria fusion). Наприклад, якщо модель з високою впевненістю прогнозує висхідний тренд, а індикатор RSI вказує на стан перепроданості активу, генерується сигнал «Сильна покупка» (Strong Buy). Низька впевненість або суперечливі сигнали призводять до рекомендації «Тримати» (Hold). Таке злиття багатьох критеріїв зменшує залежність від одноточкових прогнозів та мінімізує ризик хибних торгових сигналів.

Для забезпечення масштабованості та управління ризиками розроблена підсистема динамічно розраховує порогові значення для зупинки збитків (Stop-Loss) та фіксації прибутку (Take-Profit) на основі прогнозних інтервалів та історичної волатильності. Додатково

обчислюються показники з урахуванням ризику, зокрема Value-at-Risk (VaR), що гарантує контекстуалізацію прогнозів у рамках ширших фінансових цілей. Таким чином, рівень підтримки інвестиційних рішень перетворює систему з інструмента суто числового прогнозування на програмний комплекс, який може надавати користувачу додаткову аналітичну інформацію для оцінки ризиків, вибору торгової стратегії та прийняття більш обґрунтованих рішень на волатильному ринку цифрових активів.

Практична реалізація рівня підтримки інвестиційних рішень представлена у вебінтерфейсі AI Investment Recommendations (рисунок 3.1). Цей модуль агрегує останню ринкову ціну активу, прогноз Python AI-мікросервісу та результат роботи сервісу `GenerateRecommendation()`, після чого формує узагальнену рекомендацію для користувача.




Рисунок 3.1 – Вебінтерфейс формування AI-рекомендації для підтримки інвестиційного рішення

У межах інтерфейсу відображаються ключові параметри торгового сценарію: поточна ціна активу, прогнозована ціна, очікувана дохідність,

значення індикатора RSI, рівень Stop-Loss, рівень Take-Profit та оцінка ризику VaR. На основі цих параметрів система генерує інвестиційний сигнал типу Buy, Hold або Sell, а також коротке текстове обґрунтування прийнятого рішення.

Такий підхід дозволяє перетворити числовий прогноз моделі на прикладну рекомендацію, зручну для сприйняття користувачем. Водночас система не виконує автоматичні торгові операції, а лише надає аналітичну підтримку для прийняття рішень, що є важливим з точки зору контролю ризиків та відповідальності користувача.

3.4 Підсистема самодіагностики та прогнозування з відкритим циклом (Error Feedback Loop)

Враховуючи високу нестаціонарність ринку криптовалют, статичні моделі швидко втрачають свою ефективність. Для вирішення цієї проблеми у системі імплементовано стратегію прогнозування з відкритим циклом (Open-loop forecasting). Прогнозування з відкритим циклом передбачає передбачення наступного часового кроку в послідовності з використанням лише доступних історичних даних.

Алгоритм працює ітеративно: після того, як система робить прогноз для часового кроку $t+1$, цей результат зберігається в базу даних системи. Як тільки стає доступним фактичне спостережуване значення на кроці $t+1$, воно фіксується системою і порівнюється зі зробленим раніше прогнозом. Програмний бекенд автоматично обчислює абсолютну похибку у відсотках (MAPE). Якщо похибка перевищує заданий допустимий поріг (наприклад, свідчить про раптову зміну ринкового режиму), система ініціює механізм зворотного зв'язку за помилкою (Error Feedback Loop) і автоматично відправляє свіжий набір даних до AI-мікросервісу для донавчання моделі (Continuous Learning). Цей метод гарантує, що кожен

крок прогнозу базується на точній і найсвіжійшій інформації, мінімізуючи ризик накопичення помилок з часом.

Практична реалізація цього механізму забезпечується взаємодією основного ASP.NET Core сервера, таблиці історії прогнозів у PostgreSQL та Python AI-мікросервісу. Такий підхід дозволяє відокремити бізнес-логіку системи від обчислювального ядра моделі та забезпечити можливість фонові адаптації моделі без зупинки основного вебзастосунку.

3.5 Обґрунтування вибору технологічного стеку та інструментальних засобів розробки

Проектування та реалізація мультимодальної інтелектуальної системи вимагає використання сучасного, надійного та високопродуктивного стеку технологій, здатного забезпечити безперебійну обробку великих масивів даних (Big Data), інференс нейронних мереж та швидку віддачу результатів клієнту. На основі аналізу вимог до системи було обрано комплекс інструментальних засобів.

Штучний інтелект та машинне навчання (AI/ML Layer). Для реалізації прогностичного ядра системи обрано мову програмування Python 3, яка є загальновизнаним індустріальним стандартом у сфері Data Science та машинного навчання:

- створення та навчання гібридної архітектури CNN-BiLSTM-Attention реалізовано за допомогою бібліотеки TensorFlow/Keras:
- для інтеграції алгоритмів градієнтного бустингу (ансамблевої мета-моделі) використано фреймворк XGBoost, що відзначається високою швидкістю та точністю на табличних фінансових даних:
- обробка природної мови (NLP) та сентимент-аналіз текстових заголовків виконується за допомогою спеціалізованої моделі FinBERT:
- обгортання Python-моделей у повноцінний REST API мікросервіс реалізовано за допомогою мікрофреймворку FastAPI, що

забезпечує асинхронну та надзвичайно швидку обробку запитів від головного сервера. Навчання моделей (тренування) винесено у хмарне середовище Google Colab для використання безкоштовних тензорних процесорів (GPU), після чого ваги моделей експортуються у форматі .keras та .pkl для використання на робочому сервері.

Серверна частина та бізнес-логіка (Backend Layer). Основним ядром системи, що керує збором даних, взаємодією з API та розрахунком інвестиційних метрик ризику, виступає платформа .NET 8 (C#) та фреймворк ASP.NET Core. Вибір цієї технології обґрунтований її високою продуктивністю, суворою типізацією та вбудованими механізмами багатопотоковості, які критично важливі для паралельної роботи автоматизованих парсерів:

- для взаємодії з базою даних застосовано об'єктно-реляційне відображення (ORM) Entity Framework Core;
- візуалізація даних на стороні клієнта (побудова графіків курсів, ончейн-метрик та прогнозів) реалізована за допомогою технології Razor Pages та JavaScript-бібліотеки Chart.js.

Збір даних (Data Ingestion). Процес агрегації мультимодальних даних автоматизовано за допомогою інтеграції з публічними та приватними API. Ринкові показники (OHLCV) збираються через API бірж (наприклад, Gate.io). Ончейн-дані агрегуються за допомогою спеціалізованих платформ блокчейн-аналітики (наприклад, DeBank API), що дозволяє відстежувати рух коштів на гаманцях великих гравців («китів»). Для збору інформаційного фону парсери масово обробляють заголовки криптовалютних медіа через відкриті RSS-стрічки або агрегатори.

Система управління базами даних (Database Layer). Зберігання великих масивів історичних фінансових, текстових та блокчейн-даних реалізовано на базі реляційної СУБД PostgreSQL. Вона забезпечує високий рівень надійності, підтримує транзакційність (ACID) та оптимізована для

складних аналітичних запитів під час формування навчальних вибірок (тензорів) для нейромережі.

Контейнеризація, інфраструктура та розгортання (DevOps / Cloud). Для забезпечення модульності та відмовостійкості всі компоненти системи (база даних, C#-бекенд та Python AI-сервіс) ізольовані за допомогою технології контейнеризації Docker та керуються утилітою Docker Compose. Хмарний хостинг проєкту розгорнуто на базі провайдеру Hetzner Cloud, що є економічно обґрунтованим рішенням для функціонування ресурсомістких AI-сервісів (достатньо 4 ГБ RAM та 2 vCPU). Увесь процес доставки коду на сервер повністю автоматизовано через CI/CD пайплайни Bitbucket, що відповідає сучасним стандартам безперервної інтеграції та розгортання програмного забезпечення.

3.6 Підсистема оперативного сповіщення та моніторингу делістингів (Telegram Bot)

Для забезпечення проактивної взаємодії з користувачем та мінімізації ризиків у програмному комплексі реалізовано підсистему оперативного сповіщення на базі месенджера Telegram. Цей інформаційний модуль імплементовано як асинхронний фоновий сервіс (*BackgroundService*) у середовищі ASP.NET Core з використанням офіційної бібліотеки Telegram.Bot. Архітектурно підсистема виконує дві ключові функції: трансляцію інвестиційних сигналів та автоматичний моніторинг критичних біржових подій (делістингів).

Трансляція прогнозів та інвестиційних рекомендацій Перша функція відповідає за оперативну доставку результатів роботи гібридної нейромережі. Служба PredictionTelegramNotificationService автоматично формує та надсилає користувачу структуровані повідомлення, що містять розраховані показники рівня підтримки інвестиційних рішень: прогнозовану ціну альткоїнів, сформовані торгові сигнали (Buy/Hold/Sell)

та рівні ризик-менеджменту (Stop-Loss, Take-Profit). Керування цією функцією здійснюється через налаштування у базі даних (таблиця PredictionTelegramNotificationSettings), що дозволяє гнучко активувати або призупиняти розсилку без необхідності перезапуску ядра системи.

Моніторинг ризикових біржових подій: делістинг активів. Друга, критично важлива для інституційного рівня управління ризиками функція – це безперервний фоновий моніторинг зняття торгових пар з біржі (делістингу). Оскільки раптові делістинги призводять до миттєвого обвалу ліквідності та ціни цифрового активу, у системі розроблено спеціалізований парсер GateDelistScraper.

Замість покладання на сторонні платні агрегатори, алгоритм безперервно аналізує офіційні інформаційні публікації біржі (наприклад, Gate.io). Для точного синтаксичного розбору текстів оголошень застосовується механізм регулярних виразів (Regex). На програмному рівні парсер використовує скомпільовані вирази GateDateRegex для вилучення точних часових міток події, а також FuturesSymbolRegex та SpotPairRegex для ідентифікації конкретних тикерів спотових і ф'ючерсних ринків, що підлягають закриттю.

Для забезпечення надійності та уникнення дублювання сповіщень логіка фонових опитувань (Polling Service) жорстко синхронізована з реляційною базою даних PostgreSQL. Усі виявлені новини зберігаються у таблиці DelistNewsEntity, де фіксується унікальний ідентифікатор новини, її заголовок, URL-посилання та дата публікації (PublishedUtc). Паралельно таблиця ProcessedDelist веде облік уже оброблених подій.

Завдяки такій інженерній реалізації, якщо парсер виявляє нову загрозу делістингу для будь-якої монети, система миттєво генерує тривожне (alert) сповіщення у Telegram-канал (рисунок 3.2). Це надає користувачу додаткову часову перевагу для аналізу ситуації та прийняття рішення щодо подальшого утримання або закриття позиції.




Рисунок 3.2 – Вигляд сповіщень в Telegram каналі

3.7 Розробка мікросервісної архітектури програмного комплексу

Для реалізації мультимодальної інтелектуальної системи прогнозування було обрано мікросервісну архітектуру з використанням технологій контейнеризації Docker та оркестрації Docker Compose. На відміну від монолітних рішень, такий підхід забезпечує незалежність компонентів, високу відмовостійкість та легке комерційне масштабування системи в майбутньому.

Програмний комплекс логічно розділено на три ізольовані контейнери, які взаємодіють між собою через внутрішню віртуальну мережу:

- контейнер бази даних (PostgreSQL): використовується для надійного та структурованого зберігання історичних мультимодальних даних, зібраних парсерами, а також для збереження результатів роботи нейромережі (прогнозів). Для забезпечення персистентності (постійного зберігання) даних при перезапусках контейнера налаштовано механізм Docker Volumes;
- AI-мікросервіс (Python 3 + FastAPI): ізольоване середовище інференсу (виведення), у якому функціонує гібридна нейромережа CNN-BiLSTM-Attention. Використання мікрофреймворку FastAPI дозволило створити легкий та високопродуктивний REST API інтерфейс. Цей сервіс завантажує попередньо навчені в середовищі Google Colab ваги моделі (експортовані у форматі .keras), приймає входні тензори даних від головного сервера, виконує пряме поширення через тензорні графи (за допомогою TensorFlow/Keras) та повертає ймовірнісний прогноз;
- головний сервер та користувацький інтерфейс (C# / ASP.NET Core): виконує роль ядра бізнес-логіки системи. Цей компонент керує фоновими процесами збору даних (парсерами), формує мультимодальні пакети для відправки до AI-мікросервісу та забезпечує візуалізацію результатів (графіки курсів, ончейн-метрики та торгові сигнали) за допомогою технології Razor Pages та бібліотек клієнтського рендерингу (Chart.js).

3.8 Алгоритмічне забезпечення збору мультимодальних даних

Для забезпечення нейромережі трьома незалежними модальностями інформації у C#-бекенді розроблено систему автоматизованих парсерів (фонових завдань), які працюють за розкладом:

- модуль збору ринкових даних: використовує публічні API криптовалютних бірж (наприклад, Gate.io або Binance) для агрегації історичних котирувань у форматі OHLCV (відкриття, максимум, мінімум, закриття, обсяг). Агрегація відбувається на погодинних та денних таймфреймах;

- модуль ончейн-аналітики: спеціалізований сервіс, що звертається до інструментів блокчейн-аналітики (наприклад, DeBank API). Ключовою науковою новизною системи є відстеження транзакцій великих власників активів («китів») та переміщення коштів між смарт-контрактами, що слугує випереджальним фундаментальним індикатором для прогнозування рухів альткоїнів;

- модуль сентимент-аналізу (Data Fusion): процес збору текстових даних реалізовано у вигляді двоступеневого конвеєра (pipeline). Спочатку C#-парсер працює як агрегатор: він збирає найсвіжіші заголовки новин з десятків різних криптовалютних медіа через відкриті RSS-стрічки або спеціалізовані агрегатори. Далі отримані «сирі» тексти синхронно передаються до Python-мікросервісу, де розгорнута спеціалізована фінансова NLP-модель FinBERT. Модель аналізує семантичний контекст кожного заголовка і кількісно оцінює його тональність, генеруючи індекс настрою (Sentiment Score) у нормалізованому діапазоні від -1 (екстремально негативний) до +1 (екстремально позитивний). Отриманий індекс зберігається в PostgreSQL і стає третьою компонентою для вхідного тензора гібридної нейромережі.

Окремим елементом програмної реалізації є вебінтерфейс синхронізації мультимодальних даних, який зображено на рисунку 3.3, що дає змогу візуально перевіряти узгодженість ринкових, текстових та ончейн-ознак у межах обраного часового інтервалу. Користувач може задати початкову та кінцеву дати, а також вибрати таймфрейм агрегації даних, зокрема денний або внутрішньоденний інтервал. Після побудови графіка система відображає спільну динаміку ціни BTC, прогнозу

AI-моделі, індексу настроїв FinBERT та ончейн-показника активних гаманців.




Рисунок 3.3 – Вебінтерфейс синхронізації мультимодальних даних та експорту датасету у форматі CSV

На графіку ринкова модальність представлена динамікою ціни закриття активу, текстова модальність – індексом настроїв новинного фону в діапазоні від -1 до +1, а ончейн-модальність – кількістю активних гаманців у блокчейн-мережі. Таке спільне відображення дає змогу оцінити часову узгодженість різнорідних джерел даних і перевірити, чи не виникають зміщення між ринковими, текстовими та блокчейн-показниками під час формування навчальної вибірки.

Додатково у вебінтерфейсі реалізовано функцію експорту сформованого мультимодального датасету у форматі CSV. Експорт виконується лише в межах вибраного користувачем інтервалу дат і з урахуванням заданого таймфрейму. Отриманий CSV-файл може бути використаний для повторного навчання моделей, експериментального порівняння різних архітектур, перевірки якості попередньої обробки даних

або перенесення датасету в зовнішнє середовище моделювання, наприклад Google Colab.

Наявність функції експорту датасету підвищує відтворюваність експериментів, оскільки дозволяє зафіксувати конкретну версію навчальної вибірки, яка була використана для тренування або тестування моделі. Це є важливим для експериментального дослідження, оскільки дає змогу повторно перевірити результати прогнозування на однаковому наборі ринкових, текстових та ончейн-даних.

3.9 Інфраструктура розгортання та DevSecOps практики

Враховуючи вимоги до безпеки та безперебійної роботи сучасних фінансових додатків, у системі імплементовано індустріальні практики DevSecOps.

Процес розгортання автоматизовано за допомогою CI/CD пайплайну (Continuous Integration / Continuous Deployment) на базі платформи Bitbucket. Кожен коміт до головної гілки репозиторію ініціює автоматичне збирання Docker-образів та їх доставку на хмарний сервер (Hetzner Cloud).

Особливу увагу приділено безпеці конфігураційних даних. Усі критично важливі секрети (паролі до бази даних `POSTGRES_PASSWORD`, ключі доступу до API, токени Telegram-ботів тощо) вилучено з відкритого вихідного коду (hardcoded secrets) і перенесено у захищені змінні оточення (Environment Variables) на рівні налаштувань хмарного середовища. Це унеможливорює компрометацію системи у випадку витoku вихідного коду та відповідає сучасним стандартам безпеки інформаційних технологій.

3.10 Інфраструктура розгортання та безперервна інтеграція (CI/CD)

3.10.1 Оркестрація мікросервісів за допомогою Docker Compose

Оскільки система складається з ізольованих мікросервісів (C#-бекенд, Python-модуль інференсу та база даних PostgreSQL), для їх координації та розгортання на сервері Hetzner Cloud застосовується інструмент оркестрації Docker Compose. Це дозволяє декларативно описати всю інфраструктуру у єдиному конфігураційному файлі `docker-compose.yml`.

Налаштування оркестрації включає створення внутрішньої віртуальної мережі (bridge network), що забезпечує безпечну взаємодію між контейнерами без відкриття їхніх портів у глобальну мережу Інтернет. Зокрема, Python-мікросервіс на базі FastAPI (`ai_service`) не доступний ззовні; доступ до нього має виключно головний C#-сервер, що суттєво знижує поверхню атаки.

Окрему увагу приділено персистентності (постійному зберіганню) даних. Для контейнера бази даних та AI-мікросервісу налаштовано механізм Docker Volumes. Це гарантує, що історичні ринкові дані, зібрані парсерами, а також збережені ваги донавченої гібридної нейромережі (файл `multimodal_crypto_model.keras`) не будуть втрачені при перезапуску або оновленні контейнерів. Для забезпечення правильної послідовності запуску застосовуються інструкції `depends_on`, завдяки яким C#-бекенд ініціалізується лише після повного старту бази даних та успішного застосування Entity Framework міграцій.

3.10.2 Налаштування CI/CD пайплайну на базі Bitbucket

Для автоматизації процесу доставки коду (Continuous Integration та Continuous Deployment) було спроектовано та налаштовано CI/CD пайплайн на платформі Bitbucket. Впровадження цієї практики нівелює людський

фактор при розгортанні та дозволяє швидко доставляти оновлення системи у продакшен-середовище.

Пайплайн описується у файлі `bitbucket-pipelines.yml` і складається з декількох автоматизованих етапів (steps), які запускаються як реакція на push-події у головну гілку репозиторію (master):

- етап ініціалізації та збирання (Build): на хмарних серверах Bitbucket розгортається тимчасове середовище, яке компілює вихідний код C#-додатка та перевіряє цілісність Python-залежностей (`requirements.txt`);
- етап доставки (Deploy): за допомогою захищеного SSH-з'єднання пайплайн підключається до робочого сервера Hetzner. Передача автентифікаційних даних відбувається через захищені змінні (Bitbucket Deployment Variables: `DEPLOY_HOST`, `DEPLOY_USER`);
- етап перезапуску послуг: на сервері автоматично виконуються команди `docker compose pull` та `docker compose up -d`, які оновлюють лише ті контейнери, у вихідному коді яких відбулися зміни, забезпечуючи концепцію Zero-Downtime Deployment (розгортання без зупинки системи).

3.10.3 Політики безпеки та управління секретами (DevSecOps)

Враховуючи фінансову спрямованість розробленої системи, на етапі розгортання імплементовано суворі політики DevSecOps. Було проведено аудит вихідного коду, у результаті якого всі критично важливі секрети (паролі від бази даних PostgreSQL, токени API для криптовалютних бірж, ключі Telegram-ботів системи сповіщень) були вилучені з відкритого доступу.

Управління секретами реалізовано через механізм Environment Variables (змінних оточення). Значення секретів (наприклад, `POSTGRES_PASSWORD`, `TELEGRAM_BOT_TOKEN`, `APP_DOMAIN`) генеруються динамічно на етапі роботи CI/CD пайплайну та передаються в ізольовані контейнери під час їхнього старту. Для організації безпечного

доступу користувачів до веб-інтерфейсу налаштовано зворотний проксі-сервер (Reverse Proxy) на базі Caddy, який автоматично випускає, оновлює та підтримує SSL/TLS сертифікати, забезпечуючи повне шифрування трафіку за протоколом HTTPS.

3.10.4 Аналіз продуктивності та навантаження хмарної інфраструктури

Для підтвердження ефективності та стабільності роботи розробленої мікросервісної архітектури було проведено профілювання споживання апаратних ресурсів у реальному часі. На рисунку 3.4 наведено графіки навантаження хмарного сервера (використання CPU, пропускна здатність диска Disk Throughput та кількість операцій вводу-виводу Disk IOPS) під час штатної роботи програмного комплексу.



Рисунок 3.4 – Моніторинг споживання апаратних ресурсів хмарного сервера під час роботи системи

Аналіз отриманих метрик свідчить про те, що програмна архітектура, інкапсульована в ізольовані Docker-контейнери, працює вкрай оптимізовано та ресурсоефективно. Базове навантаження на процесор (CPU) знаходиться на стабільно низькому рівні (близько 5–10%). Регулярні локальні піки активності (короткочасні спалахи до 20–25% навантаження CPU та відповідне підвищення Disk IOPS) чітко корелюють із розкладом роботи автоматизованих C#-парсерів, які виконують фоновий збір великих масивів ринкових, текстових та ончейн-даних, а також із фазами звернення до AI-мікросервісу для генерації нових прогнозів за допомогою нейромережі та мета-моделі XGBoost.

Проведене профілювання підтверджує, що обрана конфігурація хмарного сервера (2 vCPU, 4 ГБ RAM) є економічно обґрунтованою та повністю задовольняє вимоги системи. Вона забезпечує значний запас обчислювальної потужності, що гарантує безперебійне функціонування мультимодального комплексу та залишає простір для подальшого масштабування або збільшення кількості паралельних потоків збору даних без ризику відмови в обслуговуванні.

3.11 Проєктування бази даних та структури зберігання мультимодальних даних

Для забезпечення надійного зберігання, швидкого пошуку та агрегації різномірної інформації у системі спроектовано реляційну базу даних під управлінням СУБД PostgreSQL. Взаємодія між головним сервером на базі ASP.NET Core та базою даних здійснюється за допомогою технології об'єктно-реляційного відображення (ORM) Entity Framework Core. Це дозволяє працювати з таблицями як з об'єктно-орієнтованими моделями (C#-класами) та автоматизувати застосування міграцій під час розгортання системи (CI/CD).

Логічна структура бази даних розділена на інформаційні потоки збору мультимодальних даних та блок збереження результатів прогнозування. Основна схема містить чотири ключові сутності (таблиці).

3.11.1 Таблиця MarketData (Ринкові показники)

Призначена для збереження історичних фінансових котирувань, зібраних парсером з криптовалютних бірж (наприклад, Gate.io). Кожен запис репрезентує стан ринку для конкретного активу за обраний таймфрейм. До основних атрибутів таблиці належать:

- Id (Primary Key) – унікальний ідентифікатор запису;
- Symbol – тикер торгового інструменту (наприклад, «BTC_USDT»);
- Timestamp – часова мітка закриття свічки (з урахуванням часового поясу);
- Open, High, Low, Close – цінові показники відкриття, максимуму, мінімуму та закриття відповідно;
- Volume – загальний обсяг торгів за період.

3.11.2 Таблиця TextSentimentData (Аналіз тональності текстів)

Забезпечує збереження результатів обробки неструктурованих текстових даних (новинних заголовків). Дані з цієї таблиці формують другу модальність (інформаційний фон) для нейромережі. Ключові атрибути таблиці:

- Id (Primary Key), Symbol, Timestamp – базові ідентифікатори та прив'язка до часу;
- NewsTitle – оригінальний текст зібраного заголовка новини для можливості подальшого аудиту;

- `SentimentScore` – індекс тональності (у форматі подвійної точності `double precision`), згенерований NLP-моделлю `FinBERT` у діапазоні від -1 до +1.

3.11.3 Таблиця `OnChainData` (Блокчейн-метрики)

Зберігає фундаментальні показники мережі, зібрані з аналітичних платформ. Ця таблиця є найширшою за кількістю метрик, оскільки містить дані про поведінку великих гравців. Основні атрибути включають:

- базові поля: `Id`, `Symbol`, `Timestamp`;
- показники активності: `ActiveAddresses` (кількість активних адрес), `TransactionCount` (кількість транзакцій);
- метрики «китів» та бірж: `WhaleTransactionVolume` (обсяг транзакцій великих власників), `ActiveWhaleAddresses`, `NetExchangeFlow` (чистий потік коштів на біржах);
- мережеві показники: `Hashrate` (хешрейт мережі), `MinersNetFlow` (потік коштів від майнерів), `NvtSignal` (відношення цінності мережі до транзакцій).

3.11.4 Таблиця `PredictionsHistory` (Історія прогнозів моделі)

Критично важлива сутність, спеціально спроектована для забезпечення роботи підсистеми самодіагностики та прогнозування з відкритим циклом (`Error Feedback Loop`). Вона фіксує результати роботи AI-мікросервісу. Атрибути таблиці:

- `Id` (`Primary Key`), `Symbol` – базові ідентифікатори;
- `TargetDate` – цільова дата, для якої нейромережа згенерувала прогноз майбутньої ціни;
- `PredictedPrice` – прогнозоване значення курсу;
- `CreatedAt` – дата та час фізичного створення запиту до моделі.

Наявність таблиці PredictionsHistory дозволяє системі асинхронно зіставляти раніше зроблені прогнози з новими фактами, що надходять до таблиці MarketData, враховувати відхилення (похибку) та, за потреби, ініціювати донавчання гібридної архітектури CNN-BiLSTM-Attention. Така нормалізована структура забезпечує цілісність даних та високу швидкість формування багатовимірного тензора (30×7) для передачі у нейронну мережу.

4 ОПИС ПРОВЕДЕНИХ ЕКСПЕРИМЕНТАЛЬНИХ ДОСЛІДЖЕНЬ

4.1 Підготовка мультимодального набору даних

Для проведення експериментального моделювання та навчання розробленої гібридної нейронної мережі було сформовано репрезентативний мультимодальний набір даних (датасет), що охоплює історичний період з січня 2020 року до квітня 2026 року. Набір даних включає 7 ключових ознак, які репрезентують три різні модальності:

- ринкові показники: ціни відкриття (Open), максимуму (High), мінімуму (Low), закриття (Close) та обсяг торгів (Volume);
- ончейн-метрика: кількість активних гаманців (Active Addresses), що відображає фундаментальну економічну активність блокчейну;
- текстова модальність: індекс настроїв новин (Sentiment Score), попередньо обчислений за допомогою NLP-моделі FinBERT у діапазоні від -1 (максимальний негатив) до $+1$ (максимальний позитив).

Для усунення проблеми різного масштабу ознак (наприклад, обсяг торгів вимірюється в мільйонах, а сентимент – у десятих частках) було застосовано метод Min-Max нормалізації, який привів усі значення до єдиного діапазону $[0; 1]$. Оскільки рекурентна складова моделі (BiLSTM) потребує секвенціальних даних, часовий ряд було трансформовано за допомогою методу ковзного вікна (sliding window).

Експериментально встановлено оптимальний розмір вікна у 30 днів. Таким чином, для формування прогнозу на крок $t+1$ нейромережа аналізує тривимірний вхідний тензор розмірністю 30×7 .

Вибірка була розділена на навчальну та тестову без перемішування, щоб зберегти хронологічну цілісність часового ряду.

4.2 Хід навчання гібридної моделі CNN-BiLSTM-Attention

Навчання розробленої архітектури проводилося з використанням алгоритму зворотного поширення помилки (Backpropagation) та оптимізатора Adam. Функцією втрат було обрано середньоквадратичну помилку (MSE). Процес навчання тривав 50 епох.

На рисунку 4.1 наведено графік динаміки зниження помилки на навчальній (Train Loss) та валідаційній (Val Loss) вибірках під час тренування.




Рисунок 4.1 – Графік процесу навчання CNN-BiLSTM-Attention

Аналіз графіка свідчить про те, що модель стабільно збігається до мінімуму. Завдяки імплементації механізму Уваги (Attention) та використанню шарів регуляризації (Dropout), модель не демонструє критичних ознак перенавчання (overfitting), оскільки помилка на валідаційній вибірці стабілізується одночасно з навчальною.

4.3 Результати прогнозування та аналіз бізнес-метрик

Для перевірки узагальнюючої здатності моделі було згенеровано прогнози на відкладеній тестовій вибірці (дані, які модель не бачила під час навчання). Зворотна нормалізація (Inverse Transform) дозволила повернути спрогнозовані значення до реального масштабу цін у доларах США.

Візуальне порівняння реальних (спостережуваних) та спрогнозованих моделлю цін наведено на рисунку 4.2.




Рисунок 4.2 – Порівняння реальних та прогнозованих цін на тестовій вибірці

Як видно з графіка, прогнозна крива (червона пунктирна лінія) щільно повторює контури реального цінового графіка (синя суцільна лінія). Важливо відзначити, що гібридна неймережа успішно вловлює не лише макротренд, але й різкі локальні корекції. Це підтверджує робочу гіпотезу про те, що додавання ончейн-даних та сентимент-аналізу дозволяє моделі випереджати цінові зміни, реагуючи на фундаментальну активність та настрої натовпу раніше, ніж вони остаточно сформують ціну на біржі.

Кількісна оцінка точності запропонованої системи проводилася за допомогою ключових метрик оцінки якості регресійних моделей:

- коренева середньоквадратична помилка (RMSE): \$5904.53. Цей показник відображає абсолютне відхилення прогнозу від реальності з урахуванням штрафу за великі помилки;
- середня абсолютна похибка у відсотках (MAPE): 5.20%.

Отримане значення MAPE (5.20%) є відмінним результатом для високоспекулятивного ринку криптовалют, оскільки відхилення менше 10% вказує на високу точність прогнозування. Це доводить, що розроблена мультимодальна інтелектуальна система є надійним інструментом і повністю придатна для використання в реальних умовах на рівні підтримки інвестиційних рішень.

4.4 Оптимізація архітектури методом ансамблевого навчання (Stacking)

Первинні результати тестування базової гібридної моделі CNN-BiLSTM-Attention виявили ефект «згладжування» та запізнення прогнозу. Оскільки оптимізатор нейромережі намагався мінімізувати середньоквадратичну похибку (MSE) в умовах високої волатильності, модель надавала перевагу усередненим ковзним значенням. Це призвело до виникнення проблеми «наївного бенчмарку» (Naive Persistence), за якої модель уникала ризиків прогнозування стрибків, що відобразилося у вкрай низькому показнику спрямованої точності (Directional Accuracy), який склав 41.38%. На рисунку 4.3 наведено порівняння реальних та прогнозованих цін на тестовій вибірці

Для вирішення цієї проблеми та підвищення реактивності системи, спираючись на передові дослідження з інтеграції гетерогенних моделей [6], було імплементовано ансамблеву архітектуру типу Stacking. До базової нейромережі, яка чудово зарекомендувала себе в утриманні глобального

макротренду, було додано коригуючу мета-модель на базі алгоритму градієнтного бустингу над деревами рішень (XGBoost). Ця друга модель була натренована виключно на передбачення відсоткової дохідності (Returns) на наступний крок, що змусило її фокусуватися виключно на цінових імпульсах та розворотах тренду.

Багатокритеріальне злиття їх прогнозів (Ensemble Fusion) на рівні програмного мікросервісу дозволило системі об'єднати фундаментальну стабільність нейромережі з високою реактивністю дерев рішень. Як видно з візуалізації оновлених результатів прогнозування на рисунку 4.4, ансамблева помаранчева крива прогнозу позбулася ефекту запізнення і точно відтворює локальні максимуми та мінімуми реального цінового графіків.




Рисунок 4.3 – Порівняння реальних та прогнозованих цін на тестовій вибірці

Кількісна оцінка підтверджує ефективність проведеної оптимізації. Завдяки ансамблюванню середня абсолютна похибка у відсотках (MAPE) у режимі експлуатаційного моніторингу знизилася до 0.36%, середня

абсолютна помилка (MAE) становила 269.16 \$, а показник Directional Ассигасу зріс до 82.76%. Це свідчить про підвищення реактивності системи та покращення здатності моделі визначати напрям зміни курсу. Це повністю усуває проблему «наївного прогнозу» і доводить, що розроблена система здатна генерувати високоточні та надійні торгові сигнали для рівня підтримки інвестиційних рішень.




Рисунок 4.4 – Результати прогнозування оптимізованої ансамблевої моделі (CNN-BiLSTM-Attention + XGBoost)

4.5 Порівняльний аналіз розробленої архітектури з базовими моделями глибинного навчання

Для об'єктивної оцінки ефективності розробленої гібридної архітектури CNN-BiLSTM-Attention було проведено порівняльний аналіз її метрик якості з класичними нейромережевими моделями: простою рекурентною мережею (RNN), ізольованою згортковою мережею (CNN) та стандартною мережею довгої короткострокової пам'яті (LSTM). Аналіз

спирається на результати передових досліджень ефективності нейромережових архітектур при прогнозуванні криптовалютних часових рядів. Оцінка проводилася за ключовими метриками класифікації напрямку тренду: Accuracy (Точність), Precision (Точність позитивного класу), Recall (Повнота) та F1-Score (таблиця 4.1, рисунок 4.5)

Таблиця 4.1 – Порівняльний аналіз моделей за метриками

Метрика	RNN (%)	CNN (%)	LSTM (%)	Запропонована гібридна модель (%)
Accuracy (Точність)	76	81.5	86	96
Recall (Повнота)	75	80.7	85	95.2
Precision (Точність позитивного класу)	74.5	80	85.3	95.5
F1-Score (F1-міра)	74.7	79	84.5	94.5

RNN (%), CNN (%), LSTM (%) and Запропонована гібридна модель (%)




Рисунок 4.5 – Порівняльний аналіз моделей за метриками

Результати експериментальних оцінок переконливо доводять математичну перевагу запропонованого мультимодального підходу. Базова модель RNN здатна ідентифікувати лише найпростіші послідовні патерни,

демонструючи найнижчу загальну точність на рівні 76%, що вказує на її нездатність розрізняти складні часові залежності в умовах високої волатильності. Модель CNN працює краще (точність 81.5%), оскільки здатна вилучати локальні просторові ознаки з вхідних тензорів. У свою чергу, ізольована архітектура LSTM суттєво зменшує кількість хибнопозитивних прогнозів (Precision сягає 85.3%) та ефективно виявляє довгострокові кореляції у даних, досягаючи загальної точності 86% [5].

Проте найвищі результати демонструє саме запропонована гібридна модель. Її показник повноти (Recall) становить 95.2%, що свідчить про високу здатність системи розпізнавати справжні позитивні сигнали ринку (істинні розвороти тренду або імпульси) з мінімальною кількістю хибнонегативних пропусків. Завдяки імплементації механізму Уваги (Attention), який фокусує мережу на найбільш значущих часових кроках, та двоспрямованій архітектурі BiLSTM, гібридна система здатна генерувати прогнози із прецизійністю 95.5% [6].

Збалансована метрика F1-Score, яка є критично важливою для оцінки надійності торгових алгоритмів, становить 94.5% для гібридної моделі порівняно з 84.5% для стандартної LSTM та 74.7% для простої RNN. Це підтверджує, що синергетичне об'єднання згорткових шарів, двоспрямованої рекурентної пам'яті та механізму Уваги дозволяє не лише ефективно фільтрувати інформаційний шум, але й досягати загальної точності класифікації тренду на рівні 96%. Отримані результати безапеляційно обґрунтовують доцільність використання саме гібридної CNN-BiLSTM-Attention архітектури в якості обчислювального ядра розробленої системи підтримки інвестиційних рішень [5].

4.6 Оцінка результатів прогнозування в режимі реального часу

Для забезпечення абсолютної академічної доброчесності (чесного порівняння) та уникнення ефекту «заглядання в майбутнє» (look-ahead bias),

окрім класичного ретроспективного тестування на відкладеній вибірці, було проведено моніторинг ефективності прогнозів у режимі реальної експлуатації (Production Mode).

Часто прогностичні моделі, які демонструють високі метрики під час тестування (backtesting), зазнають невдачі в реальних умовах через непомітний витік даних (data leakage) або зміну ринкових режимів. Щоб нівелювати цей ризик, у розробленій системі реалізовано механізм жорсткої фіксації результатів. Усі прогнози, згенеровані гібридною моделлю CNN-BiLSTM-Attention, автоматично зберігаються бекендом у реляційну базу даних (таблиця PredictionsHistory) із чіткою прив'язкою до часу створення запиту (CreatedAt) та цільової дати прогнозу (TargetDate).

Лише після настання цільової дати та отримання фактичних ринкових даних від біржових провайдерів (таблиця MarketData), система здійснює їх накладання для розрахунку реальної похибки. Візуалізація такого чесного порівняння (Моніторинг прогнозів у часі) наведена на рисунку 4.6.




Рисунок 4.6 – Моніторинг прогнозів моделі відносно фактичної ціни в режимі реального часу (на основі збережених даних БД)

Як видно з графіка моніторингу (рисунок 4.6), лінія прогнозу (AI) формується у вигляді крокових значень, оскільки прогноз генерується та жорстко фіксується системою заздалегідь на заданий часовий горизонт. Реальна ціна (синя лінія) коливається навколо зафіксованого прогнозу. Такий підхід безапеляційно доводить, що система здатна генерувати випереджальні торгові сигнали без використання майбутньої інформації, що є критичною вимогою для впровадження розробленого програмного комплексу на рівні підтримки реальних інвестиційних рішень.

4.7 Обмеження процедури нормалізації даних під час навчання моделі

Під час підготовки мультимодального датасету для навчання нейромережевої моделі CNN-BiLSTM-Attention було застосовано метод нормалізації ознак за допомогою перетворення MinMaxScaler, що приводить значення всіх вхідних параметрів до інтервалу $[0;1]$. Нормалізація виконувалась до формування тренувальної та тестової вибірок, тобто параметри масштабування визначались на основі всього доступного датасету.

Такий підхід дозволяє забезпечити стабільність навчання нейронної мережі та пришвидшити процес оптимізації вагових коефіцієнтів, однак з точки зору задач прогнозування часових рядів він має методологічне обмеження. Зокрема, використання глобальних статистичних характеристик вибірки під час нормалізації призводить до часткового використання інформації майбутніх спостережень тестового періоду на етапі навчання моделі.

У задачах прогнозування фінансових часових рядів, зокрема курсів криптовалют, така ситуація розглядається як потенційний прояв явища витоку даних (data leakage), що може призводити до незначного оптимістичного зміщення оцінок точності прогнозування.

З методологічної точки зору більш коректним підходом є визначення параметрів масштабування виключно на основі тренувальної вибірки з подальшим застосуванням отриманого перетворення до тестових даних без повторного навчання scaler. Такий підхід повністю виключає можливість використання інформації з майбутніх часових інтервалів під час побудови моделі.

У рамках даної роботи зазначене обмеження не впливає критично на працездатність розробленої мультимодальної системи прогнозування, проте може частково впливати на отримані значення метрик точності прогнозування. Тому вдосконалення процедури нормалізації даних із використанням виключно тренувальної вибірки визначено як один із напрямів подальшого розвитку запропонованої інтелектуальної системи.

4.8 Напрями подальшого вдосконалення моделі прогнозування

До перспективних напрямів підвищення точності прогнозування мультимодальної інтелектуальної системи доцільно віднести:

- розділення вибірки на тренувальну, валідаційну та тестову підвибірки із суворим дотриманням часової послідовності спостережень;
- виконання нормалізації ознак виключно на основі тренувальної вибірки;
- застосування walk-forward validation для перевірки стабільності моделі в умовах реального прогнозування;
- використання адаптивних методів масштабування даних для нестационарних фінансових часових рядів;
- розширення ансамблевого підходу шляхом оптимізації вагових коефіцієнтів комбінування CNN-BiLSTM-Attention та XGBoost.

ВИСНОВКИ

У кваліфікаційній магістерській роботі вирішено актуальну науково-практичну задачу – розроблено мультимодальну інтелектуальну систему ймовірнісного прогнозування змін курсів криптовалют. Виконані теоретичні, алгоритмічні та експериментальні дослідження дозволили досягти поставленої мети та сформулювати наступні основні висновки:

- аналіз предметної галузі показав, що через безпрецедентну волатильність та нестаціонарність ринку криптовалют традиційні детерміновані та одномодальні (базовані виключно на ринкових даних) моделі прогнозування не забезпечують достатньої точності. Доведено, що ціноутворення цифрових активів формується під комплексним впливом трьох ключових чинників: історичної ринкової динаміки, психології натовпу (інформаційного фону) та фундаментальної блокчейн-активності;

- теоретично обґрунтовано та практично реалізовано мультимодальний підхід (Data Fusion), який агрегує ринкові показники (OHLCV), текстові дані (індекс настроїв, отриманий за допомогою NLP-моделі FinBERT) та ончейн-метрики (активність «китів» та кількість гаманців). Для обробки сформованого простору ознак розроблено гібридну нейромережеву архітектуру CNN-BiLSTM-Attention, де згортковий шар (CNN) виділяє локальні цінові аномалії, двоспрямована рекурентна мережа (BiLSTM) захоплює довгострокові часові залежності, а механізм Уваги (Attention) динамічно фокусується на найбільш значущих подіях, нівелюючи ринковий шум;

- спроектовано та реалізовано надійну мікросервісну архітектуру програмного забезпечення з використанням технологій контейнеризації Docker. Програмний комплекс складається з бекенду на C# (ASP.NET Core) для керування бізнес-логікою та парсерами, бази даних PostgreSQL та ізолюваного AI-мікросервісу на базі Python і FastAPI. Розгортання системи

налаштовано через CI/CD пайплайн (Bitbucket) із суворим дотриманням сучасних стандартів DevSecOps щодо захисту секретів та змінних оточення;

- з метою забезпечення адаптивності системи до постійних змін ринкових режимів впроваджено концепцію прогнозування з відкритим циклом (Open-loop forecasting) та механізм самодіагностики за помилкою (Error Feedback Loop). Програмний бекенд щодня порівнює згенерований прогноз із фактичним спостережуваним значенням, і якщо похибка перевищує встановлений поріг (5%), автоматично ініціює фонове донавчання моделі (Transfer Learning) на найсвіжішому наборі даних. Це успішно вирішує проблему поступової деградації точності статичних прогностичних моделей;

- для забезпечення високої практичної цінності розробки прогностичний модуль доповнено рівнем підтримки інвестиційних рішень (Investment Decision Layer). Цей компонент здійснює багатокритеріальне злиття прогнозів нейромережі з технічними індикаторами (наприклад, RSI) для автоматичної генерації конкретних торгових сигналів (Strong Buy / Hold / Sell), а також динамічно розраховує метрики ризик-менеджменту: Value-at-Risk (VaR), рівні Stop-Loss та Take-Profit з урахуванням історичної волатильності;

- проведені експериментальні дослідження на тестовій вибірці (з використанням методу ковзного вікна розміром 30 днів) повністю підтвердили ефективність запропонованих рішень. Навчена протягом 50 епох гібридна модель продемонструвала відмінну здатність вловлювати як загальні макротренди, так і різкі локальні корекції. Для усунення ефекту запізнення прогнозу успішно застосовано метод ансамблевого навчання (Stacking) з використанням мета-моделі XGBoost. Фінальні кількісні показники якості ансамблевої моделі в режимі експлуатаційного моніторингу склали: Directional Accuracy = 82.76%, середня абсолютна похибка у відсотках (MAPE) = 0.36%, середня абсолютна помилка (MAE) = 269.16 \$.

Отриманий рівень похибки ($MAPE < 10\%$) на високоспекулятивному ринку криптовалют є високим результатом, який доводить, що розроблена мультимодальна система є надійним інструментом і повністю придатна для використання в реальних умовах приватними інвесторами, трейдерами та фінансовими компаніями.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Schevchenko O. Intelligent system for ontology-based management and integration of heterogeneous information. Kharkiv : KNURE, 2006.
2. Chumak M. Mechanism of self-attention in convolutional neural networks. Kharkiv : KNURE, 2022.
3. An Y.-J., Oh H.-Y., Kim H.-J. Forecasting bitcoin prices: an LSTM deep-learning approach using on-chain data. *Advances in science, technology and engineering systems journal*. 2023. Vol. 8, no. 3. P. 186–192. URL: <https://doi.org/10.25046/aj080321> (date of access: 29.04.2026).
4. Synergistic alpha: a deep learning framework for forecasting cryptocurrency returns by fusing on-chain, sentiment, and market data / Gayatri Putri et al. *Enigma in economics*. 2025. Vol. 3, no. 2. P. 96–107. URL: <https://doi.org/10.61996/economy.v3i2.103> (date of access: 29.04.2026).
5. Li S., Yarovaya L., Mishra T. Machine learning, memory and efficiency in cryptocurrency markets. *Journal of international financial markets, institutions and money*. 2025. Vol. 105. P. 102210. URL: <https://doi.org/10.1016/j.intfin.2025.102210> (date of access: 29.04.2026).
6. From bitcoin to altcoins: a critical review of deep learning models in cryptocurrency price prediction / N. A. Rashid et al. *International journal of research and innovation in social science*. 2026. Vol. 10, no. 1. P. 2806–2822. URL: <https://doi.org/10.47772/ijriss.2026.10100218> (date of access: 29.04.2026).
7. Кафедра штучного інтелекту (ШІ) - ХНУРЕ. NURE. URL: <https://nure.ua/departament/kafedra-shtuchnogo-intelektu> (дата звернення: 29.04.2026).
8. Predicting cryptocurrency value using sentiment analysis / A. Inamdar et al. *2019 international conference on intelligent computing and control systems (ICCS)*, Madurai, India, 15–17 May 2019. 2019.

URL: <https://doi.org/10.1109/iccs45141.2019.9065838> (date of access: 29.04.2026).

9. Heaton J., Goodfellow I., Bengio Y., Courville A. Deep learning. *Genetic programming and evolvable machines*. 2017. Vol. 19, no. 1-2. P. 305–307. URL: <https://doi.org/10.1007/s10710-017-9314-z> (date of access: 29.04.2026).

10. Nielsen M. Neural networks and deep learning. *Neural networks and deep learning*. URL: <http://neuralnetworksanddeeplearning.com/> (date of access: 29.04.2026).

11. Rusinau M. Application of neural networks in forecasting – case study: bitcoin : master’s thesis. University of Jyväskylä, 2025.

12. Zahan T. Personalized summarization of global news: managing bias with large language models : master’s thesis. University of Jyväskylä, 2025.

13. Likhitha B. B., Raj C. H. A., Ul Islam M. S. Unveiling ethereum’s future: lstm-based price prediction and a systematic blockchain analysis. *E3S Web of Conferences*. 2023. Vol. 453. P. 01043. URL: <https://doi.org/10.1051/e3sconf/202345301043> (date of access: 29.04.2026).

14. Bilokon B. Emotional Neutralization of Texts with Preserving Semantics. Kharkiv : KNURE, 2024.

15. Kulish D. Text processing using neural networks with respect to words morphological features. Kharkiv : KNURE, 2020.

16. Strohly Y. Causal relationship discovery based on neural networks. Kharkiv : KNURE, 2022.

17. Durga R., Naga Sailaja V. Cryptocurrency price prediction and investment decision support using a transfer learning-based hybrid cnn-bilstm-attention deep learning framework. *Management (montevideo)*. 2025. Vol. 3. P. 318. URL: <https://doi.org/10.62486/agma2025318> (date of access: 29.04.2026).

18. A deep learning-based cryptocurrency price prediction model that uses on-chain data / G. Kim et al. *IEEE Access*. 2022. P. 1. URL: <https://doi.org/10.1109/access.2022.3177888> (date of access: 29.04.2026).
19. FastAPI framework, high performance, easy to learn, fast to code, ready for production. *FastAPI*. URL: <https://fastapi.tiangolo.com/> (date of access: 29.04.2026).
20. XGBoost Documentation – xgboost 3.2.1 documentation. *XGBoost*. URL: <https://xgboost.readthedocs.io/> (date of access: 29.04.2026).
21. PostgreSQL: the world's most advanced open source relational database. *PostgreSQL*. URL: <https://www.postgresql.org/> (date of access: 29.04.2026).