

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ**  
**Чорноморський національний університет**  
**імені Петра Могили**  
**Факультет комп'ютерних наук**  
**Кафедра інтелектуальних інформаційних систем**

ДОПУЩЕНО ДО ЗАХИСТУ

Завідувач кафедри інтелектуальних  
інформаційних систем

\_\_\_\_\_ Євген СІДЕНКО

«\_\_\_» \_\_\_\_\_ 2026 р.

**КВАЛІФІКАЦІЙНА РОБОТА**  
**НА ЗДОБУТТЯ ОСВІТНЬОГО СТУПЕННЯ БАКАЛАВРА**  
**РЕКОМЕНДАЦІЙНА СИСТЕМА ПРИЙНЯТТЯ**  
**ІНВЕСТИЦІЙНИХ РІШЕНЬ НА ОСНОВІ**  
**ПРОГНОЗУВАННЯ ПОВЕДІНКИ АКЦІЙ S&P 500**

Спеціальність 122 Комп'ютерні науки

Освітня програма «Комп'ютерні науки»

*Здобувач*

\_\_\_\_\_ Андрій Удич  
«\_\_\_» \_\_\_\_\_ 2026 р.

*Керівник* канд. пед. наук, доцент

\_\_\_\_\_ Надія БОЛЮБАШ  
«\_\_\_» \_\_\_\_\_ 2026 р.

Чорноморський національний університет імені Петра Могили  
(повне найменування закладу вищої освіти)

Факультет	Комп'ютерних наук
Кафедра	Інтелектуальних інформаційних систем
Рівень вищої освіти	Перший (бакалаврський)
Освітній ступень	Бакалавр
Спеціальність	122 Комп'ютерні науки
Освітня програма	Комп'ютерні науки

**ЗАТВЕРДЖУЮ**

Завідувач кафедри інтелектуальних  
інформаційних систем  
\_\_\_\_\_ Євген СІДЕНКО  
«\_\_\_\_» \_\_\_\_\_ 2025 р.

**З А В Д А Н Н Я**

**на кваліфікаційну роботу здобувача**

**Удїча Андрїя Олександровича**

(прїзвище, їм'я, по батьковї здобувача)

1. Тема кваліфікаційної роботи «Рекомендаційна система прийняття інвестиційних рішень на основї прогнозування поведїнки акцій S&P 500».

Керївник роботи: Болюбаш Надїя Миколаївна, доцент кафедри інтелектуальних інформаційних систем, канд. пед. наук, доцент.

Затв. наказом Ректора ЧНУ їм. Петра Могили від «25» грудня 2025 р. № 353

2. Строк представлення кваліфікаційної роботи студентом «17» червня 2026 р.

3. Очікуваний результат роботи та початковї данї, якщо такї потрібні: рекомендаційна система для підтримки прийняття інвестиційних рішень на основї нейромережевих моделей аналізу й прогнозування поведїнки акцій їндексу S&P 500 ї фїнансових новин та методїв багатокритерїальної оцїнки їнвестиційних

активів; історичні OHLCV-дані акцій компаній індексу S&P 500 та фінансові новини стосовно їх активів.

4. Перелік питань, що підлягають розробці: проведення аналізу теоретичних засад прийняття інвестиційних рішень, дослідження сучасних підходів та програмних рішень у сфері прогнозування поведінки акцій на фондовому ринку; обґрунтування вибору нейромережових моделей аналізу й прогнозування поведінки акцій індексу S&P 500 і фінансових новин та методів багатокритеріальної оцінки інвестиційних рішень; проведення навчання моделей LSTM і TFT на історичних OHLCV-даних і технічних індикаторах та дослідження їх прогностичної якості; здійснення проектування, програмної реалізації і тестування рекомендаційної системи прийняття інвестиційних рішень на основі прогнозування поведінки акцій компаній індексу S&P 500 та оцінка її якості.

5. Перелік графічного матеріалу: презентація, рисунки, таблиці.

**Керівник роботи**

\_\_\_\_\_  
(Особистий підпис)

Надія БОЛЮБАШ  
(Власне ім'я ПРІЗВИЩЕ)

**Здобувач**

\_\_\_\_\_  
(Особистий підпис)

Андрій Удід  
(Власне ім'я ПРІЗВИЩЕ)

Дата видачі завдання « 24 » грудня 2025 р.

## КАЛЕНДАРНИЙ ПЛАН кваліфікаційної роботи

Тема: Рекомендаційна система прийняття інвестиційних рішень на основі прогнозування поведінки акцій S&P 500

№	Найменування роботи	Початок	Закінчення	Примітки
1	Визначення керівника і теми КР. Подання заяви на затвердження теми	25.09.2025	17.12.2025	Виконано
2	Отримання завдання на виконання КР	26.12.2025	27.12.2025	Виконано
3	Аналіз предметної сфери аналізу й прогнозування фінансових часових рядів і новин та надання інвестиційних рекомендацій, постановка задачі	28.12.2025	30.01.2026	Виконано
4	Огляд літературних джерел та програмних рішень у сфері прогнозування поведінки акцій на фондовому ринку	31.01.2026	17.02.2026	Виконано
5	Вибір технологій та інструментальних засобів розробки для вирішення поставленої задачі	18.02.2026	28.02.2026	Виконано
6	Навчання нейромережових моделей, проектування, програмна реалізація та тестування рекомендаційної системи	01.03.2026	15.04.2026	Виконано
7	Робота над розділами КР	16.04.2026	24.05.2026	Виконано
8	Перший попередній захист КР на засіданні комісії кафедри	25.05.2026	25.05.2026	Виконано
9	Корегування КР за результатами попереднього захисту	26.05.2026	04.06.2026	Виконано
10	Другий попередній захист КР	05.06.2026	05.06.2026	Виконано
11	Остаточне оформлення КР, підготовка доповіді та слайдів до захисту	06.06.2026	14.06.2026	Виконано
12	Подання КР, її електронної копії та інших документів (відгуку, рецензії) до захисту	15.06.2026	19.06.2026	Виконано

Керівник роботи

\_\_\_\_\_

(Особистий підпис)

Надія БОЛЮБАШ  
(Власне ім'я ПРІЗВИЩЕ)

Здобувач

\_\_\_\_\_

(Особистий підпис)

Андрій Удич  
(Власне ім'я ПРІЗВИЩЕ)

Дата складання календарного плану  
« 30 » січня 2026 р.

## АНОТАЦІЯ

до кваліфікаційної роботи здобувача групи 401 ЧНУ ім. П. Могили

**Удїча Андрїя Олександровича**

на тему: **«Рекомендаційна система прийняття інвестиційних рішень на основі прогнозування поведінки акцій S&P 500»**

Дана кваліфікаційна робота присвячена розробці рекомендаційної системи підтримки прийняття інвестиційних рішень із урахуванням історичних даних щодо цін активів, поточного контексту ринку, ризиків та тональності фінансових новин стосовно цих активів. Що є актуальним в умовах високої динамічності фінансових ринків, їх значної волатильності та залежності від великої кількості взаємопов'язаних факторів.

**Об'єкт дослідження** – процес прийняття інвестиційних рішень на фондовому ринку.

**Предмет дослідження** – методи та нейромережеві моделі аналізу й прогнозування поведінки фінансових часових рядів і новин та формування багатокритеріальних інвестиційних рекомендацій.

**Мета дослідження** – підвищення ефективності прийняття інвестиційних рішень шляхом розробки рекомендаційної системи на основі нейромережевих моделей аналізу й прогнозування поведінки акцій індексу S&P 500 і фінансових новин та методів багатокритеріальної оцінки інвестиційних активів.

Структура кваліфікаційної роботи включає вступ, чотири розділи, висновки та додатки. У першому розділі розкрито теоретичні аспекти аналізу фондового ринку та прийняття інвестиційних рішень, досліджено сучасні підходи та програмні рішення у цій сфері. У другому розділі обґрунтовано вибір моделей та методів надання рекомендацій на основі аналізу й прогнозування поведінки акцій компаній індексу S&P 500 та фінансових новин. У третьому розділі описано навчання та обґрунтовано вибір нейромережевих моделей для прогнозування поведінки акцій. У четвертому розділі описано проектування, програмну

реалізацію і тестування рекомендаційної системи прийняття інвестиційних рішень на основі прогнозування поведінки акцій індексу S&P 500 та оцінено її якість.

Кваліфікаційна робота містить 97 сторінок (без додатків), 33 рисунка, 15 таблиць, 40 джерел та 3 додатки.

**Ключові слова:** *рекомендаційна система, інвестиційні рішення, трансформерні моделі, фільтрація на основі знань, аналіз настроїв.*

## ABSTRACT

to the qualification work by the student of the group 401 of Petro Mohyla Black Sea  
National University

**Udicha Andriia Oleksandrovycha**

on the subject: «**Recommendation System for Investment Decision-Making Based  
on Forecasting S&P 500 Stock Behavior**»

This bachelor's qualification work is devoted to the development of a recommendation system to support investment decisions taking into account historical data on asset prices, the current market context, risks and the tone of financial news regarding these assets. What is relevant in the conditions of high dynamism of financial markets, their significant volatility and dependence on a large number of interrelated factors.

**Object of the study** – the process of investment decision-making in the stock market.

**Subject of the study** – methods and neural network models for the analysis and forecasting of financial time series and news, as well as the generation of multi-criteria investment recommendations.

**The purpose of the work** is to increase the efficiency of investment decision-making by developing a recommender system based on neural network models for the analysis and forecasting of S&P 500 stock behavior and financial news, as well as multi-criteria methods for evaluating investment assets.

The structure of the bachelor's work includes an introduction, four sections, conclusions and appendices. The first section presents the theoretical aspects of stock market analysis and investment decision-making, as well as examines modern approaches and software solutions in this field. The second section substantiates the choice of models and methods of providing recommendations based on the analysis and forecasting of the behavior of S&P 500 index shares and financial news. The third section describes the training and justifies the choice of neural network models for forecasting stock behavior. The fourth section describes the design, software implementation and testing of the

recommender system for making investment decisions based on forecasting the behavior of shares of the S&P 500 index and assesses its quality.

The qualification work contains 97 pages (without appendices), 33 figures, 15 tables, 40 sources, and 3 appendices.

**Keywords:** *recommendation system, investment decisions, transformer models, knowledge-based filtering, sentiment analysis.*

## ЗМІСТ

СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАКИ .....	4
ВСТУП.....	5
1 ТЕОРЕТИЧНІ ЗАСАДИ АНАЛІЗУ ФОНДОВОГО РИНКУ ТА ПРИЙНЯТТЯ ІНВЕСТИЦІЙНИХ РІШЕНЬ.....	8
1.1 Індекс S&P 500 – ключовий індикатор стану фондового ринку .....	8
1.2 Основні підходи до аналізу фінансових ринків .....	10
1.3 Роль інформаційного фону та новин у формуванні ринкових настроїв ...	14
1.4 Огляд програмних рішень у сфері фінансової аналітики та інвестування	17
1.5 Аналіз останніх досліджень і публікацій .....	21
1.6 Постановка задачі.....	24
Висновки до розділу 1 .....	26
2 МОДЕЛІ ТА МЕТОДИ НАДАННЯ РЕКОМЕНДАЦІЙ НА ОСНОВІ ПРОГНОЗУВАННЯ ПОВЕДІНКИ АКЦІЙ S&P 500 .....	28
2.1 Knowledge-based підхід надання рекомендацій для прийняття інвестиційних рішень.....	28
2.2 Формування та оцінка портфеля інвестора .....	31
2.3 Нейромережеві моделі прогнозування часових рядів: LSTM, TFT.....	33
2.4 Моделі аналізу текстових даних та фінансових новин .....	38
2.5 Оцінювання якості прогнозних моделей та ефективності рекомендаційної системи .....	40
Висновки до розділу 2 .....	45
3 ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ТА НАВЧАННЯ НЕЙРОМЕРЕЖЕВИХ МОДЕЛЕЙ.....	47
3.1 Попередня обробка та формування набору даних.....	47
3.2 Навчання моделі LSTM .....	49
3.3 Навчання моделі Temporal Fusion Transformer .....	52
3.4 Аналіз прогностичної якості навчених нейромережевих моделей.....	55

Висновки до розділу 3 .....	59
<b>4 МОДЕЛЮВАННЯ, ПРОЄКТУВАННЯ ТА ПРОГРАМНА РЕАЛІЗАЦІЯ РЕКОМЕНДАЦІЙНОЇ СИСТЕМИ .....</b>	<b>61</b>
4.1 Моделювання та проєктування рекомендаційної системи .....	61
4.2 Інструментальні засоби розробки.....	66
4.3 Реалізація архітектури та модульної структури системи .....	68
4.4 Програмна реалізація функціональних модулів .....	72
4.5 Користувацький інтерфейс застосунку (UI/UX).....	77
4.6 Тестування та оцінка якості рекомендаційної системи .....	93
Висновки до розділу 4 .....	99
<b>ВИСНОВКИ.....</b>	<b>102</b>
<b>ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ.....</b>	<b>104</b>
<b>ДОДАТОК А Технічні індикатори та формули їх розрахунку .....</b>	<b>109</b>
<b>ДОДАТОК Б Python-реалізація технічних індикаторів .....</b>	<b>110</b>
<b>ДОДАТОК В Робастне масштабування ознак .....</b>	<b>114</b>

## **СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАКИ**

ІС – інформаційна система

ШІ – штучний інтелект

AI – Artificial Intelligence

BERT – Bidirectional Encoder Representations from Transformers

EAI – Explainable Artificial Intelligence

FinBERT – Financial Bidirectional Encoder Representations from Transformers

LSTM – Long Short-Term Memory

ML – Machine Learning

NLP – Natural Language Processing

OHLCV – Open High Low Close Volume

SSR – Server-Side Rendering

TFT – Temporal Fusion Transformer

## ВСТУП

**Актуальність.** Стрімкий розвиток цифрової економіки супроводжується впровадженням рекомендаційних механізмів до інформаційних систем у фінансовому секторі, що дозволяє інвесторам оперативно отримувати персоналізовані поради стосовно оптимізації інвестицій та управління ризиками. Важливим напрямом, спрямованим на підвищення ефективності бізнес-процесів у цій сфері, є інтеграція до онлайн сервісів рекомендаційних механізмів, які поєднують нейромережеві моделі аналізу й прогнозування багатовимірних часових рядів ринкових даних і фінансових новин, та методи багатокритеріального прийняття рішень.

Ключовою характеристикою сучасних фондових ринків є їх висока динамічність, значна волатильність та залежність від великої кількості взаємопов'язаних факторів: макроекономічні показники, ринкові очікування, інформаційний фон. Тому прийняття інвестиційних рішень є складною багатокритеріальною задачею, яка потребує врахування не лише історичних даних з цінами акцій компаній, але й поточного контексту ринку, ризиків та тональності фінансових новин стосовно цих активів.

Сучасні програмні рішення у сфері фінансової аналітики та інвестування – Wealthfront, Betterment, Kavout, Estimote, TradingView, Alpha Vantage та інші, надають можливість для отримання прогнозів цін акцій на ринку. Однак вони є комерційними і зазвичай спеціалізуються на окремих аспектах: технічному аналізі, соціальному трейдингу або базовій алгоритмічній торгівлі. Переважна більшість із них не містить вбудованих рекомендаційних механізмів із врахуванням аналізу фінансових новин, ризиків та багатокритеріальної оцінки дохідності (дохідність, ризик, інформаційний вплив). Еталонні і професійні AI-прогнозні сервіси найвищого рівня, такі як Bloomberg Terminal, мають високу вартість, є закритими та не надають відкритої архітектури для інтеграції власних моделей.

Це обумовило **мету дослідження**, яка полягає у підвищенні ефективності прийняття інвестиційних рішень шляхом розробки рекомендаційної системи на основі нейромережових моделей аналізу й прогнозування поведінки акцій індексу S&P 500 і фінансових новин та методів багатокритеріальної оцінки інвестиційних активів.

Відповідно до поставленої мети було сформульовано **завдання**:

– провести аналіз теоретичних засад прийняття інвестиційних рішень, дослідити сучасні підходи та програмні рішення у сфері прогнозування поведінки акцій на фондовому ринку;

– обґрунтувати вибір нейромережових моделей аналізу й прогнозування поведінки акцій індексу S&P 500 і фінансових новин та методів багатокритеріальної оцінки інвестиційних рішень;

– провести навчання моделей LSTM і TFT на історичних OHLCV-даних і технічних індикаторах та дослідити їх прогностичну якість;

– здійснити проєктування, програмну реалізацію і тестування рекомендаційної системи прийняття інвестиційних рішень на основі прогнозування поведінки акцій компаній індексу S&P 500 та оцінити її якість.

**Об’єкт дослідження** – процес прийняття інвестиційних рішень на фондовому ринку.

**Предмет дослідження** – методи та нейромережові моделі аналізу й прогнозування поведінки фінансових часових рядів і новин та формування багатокритеріальних інвестиційних рекомендацій.

**Методологічною основою** дослідження є загальнонаукові методи, методи прогнозування фінансових часових рядів, методи аналізу фінансових новин, методи багатокритеріальної оцінки інвестиційних рішень, які дозволили комплексно вивчити предмет і об’єкт роботи, дослідити підходи до підтримки прийняття інвестиційних рішень та надання багатокритеріальних інвестиційних рекомендацій.

**Практичне значення** отриманих результатів полягає в тому, що розроблена рекомендаційна система дозволяє підвищити обґрунтованість прийняття інвестиційних рішень і може бути використана інвесторами на фондовому ринку.

**Структура кваліфікаційної роботи.** Відповідно до мети, завдань і предмета роботи, кваліфікаційна робота складається із вступу, чотирьох розділів, висновку, списку використаних джерел та 3-х додатків. Загальний обсяг роботи – 97 сторінок. Кількість використаних джерел – 40.

# 1 ТЕОРЕТИЧНІ ЗАСАДИ АНАЛІЗУ ФОНДОВОГО РИНКУ ТА ПРИЙНЯТТЯ ІНВЕСТИЦІЙНИХ РІШЕНЬ

## 1.1 Індекс S&P 500 – ключовий індикатор стану фондового ринку

Фондовий ринок є складною динамічною системою, в межах якої відбувається обіг цінних паперів. Його головне призначення полягає в перерозподілі капіталу між інвесторами та емітентами. Сучасний стан розвитку фондових ринків характеризується високою швидкістю виконання угод, значною кількістю учасників та появою альтернативних торговельних майданчиків. Ці чинники ускладнюють можливість отримання стабільного прибутку без використання формалізованих методів аналізу.

Одним із ключових індикаторів стану фондового ринку США та світової економіки в цілому є індекс S&P 500. Він включає 500 найбільших публічних компаній США з різних секторів економіки, які котируються на біржах NYSE та NASDAQ, що забезпечує високу диверсифікацію та репрезентативність ринкових процесів. Важливою властивістю індексу S&P 500 є його збалансованість за галузями. До нього входять підприємства зі сфер технологій, фінансів, охорони здоров'я, промисловості та споживчих товарів (рис.1.1).

Завдяки своїй структурі S&P 500 вважається одним із найкращих індикаторів стану всієї американської економіки, а через її глобальний вплив – і світової економіки загалом. Поведінка акцій компаній, які входять до складу індексу, не є хаотичною і характеризується складною динамікою, що формується під впливом як макроекономічних факторів, так і корпоративних та інформаційних подій. У ній простежуються циклічні коливання, довготривалі тренди та періоди підвищеної волатильності (рис.1.2).

Водночас передбачити точну траєкторію руху індексу на коротких проміжках часу надзвичайно складно через велику кількість впливових факторів. Історично динаміка S&P 500 демонструє стійку висхідну тенденцію, незважаючи



кваліфікаційній роботі не виконується, оскільки він є зовнішньо визначеним фінансовим показником, що відображає середньозважену динаміку ринку акцій компаній США.

## 1.2 Основні підходи до аналізу фінансових ринків

Аналіз фінансових ринків традиційно поділяють на два фундаментальних напрями: фундаментальний аналіз та технічний аналіз (табл. 1.1). Кожен із цих підходів має власну логіку, інструментарій та обмеження.

Фундаментальний аналіз базується на вивченні внутрішньої вартості активу. Дослідник розраховує мультиплікатори, такі як відношення ціни до прибутку, ціни до балансової вартості, дивідендну дохідність та інші [3]. Крім того, аналізуються звіти про прибутки та збитки, баланси компаній, галузеві тенденції. Метою є визначення того, чи є акція недооціненою або переоціненою відносно її реальної вартості.

На практиці фундаментальний аналіз добре працює на довгих часових горизонтах, тобто від одного року і більше. Однак для короткострокових інвестиційних рішень, які часто потребують швидкої реакції на зміну ринкової ситуації, він виявляється недостатньо гнучким. Причина полягає в тому, що ринкова ціна може відхилятися від фундаментальної вартості протягом тривалого часу через дію психологічних факторів та спекулятивних настроїв.

Технічний аналіз, навпаки, не цікавиться внутрішньою вартістю компанії [4, 5]. Він передбачає, що вся доступна інформація вже врахована в ціні, а рух цін підпорядковується певним закономірностям. Основними інструментами технічного аналізу є статистичні методи та моделі аналізу й прогнозування часових рядів: ковзні середні (Simple Moving Average, SMA), індекс відносної сили (Relative Strength Index, RSI), смуги Боллінджера (Bollinger Bands), фігури розвороту та продовження тренду, адитивна та мультиплікативна моделі, авторегресійні моделі AR та їх модифікації ARMA, ARIMA, SARIMA [6, 7].

Таблиця 1.1 – Порівняльна характеристика фундаментального та технічного аналізу

<b>Критерій</b>	<b>Фундаментальний аналіз</b>	<b>Технічний аналіз</b>
Об'єкт дослідження	Внутрішня вартість компанії	Ціна та обсяги торгів
Часовий горизонт	Довгостроковий (роки)	Коротко- та середньостроковий
Вихідні дані	Фінансова звітність, макроекономіка	Історичні ціни, обсяги, графіки
Математичний апарат	Оцінка мультиплікаторів, DCF-моделі	Статистика, індикатори, патерни
Ступінь суб'єктивності	Високий	Середній

За останні десятиліття обидва підходи зазнали критики з боку прихильників гіпотези ефективного ринку. Вони стверджують, що неможливо систематично перевершувати ринок без використання інсайдерської інформації. Однак практика показує, що деякі інвестори та хедж-фонди демонструють стабільно вищі результати. Це спонукає науковців шукати нові методи аналізу.

З математичної точки зору, ціни акцій компаній, що входять до індексу S&P 500, можна розглядати як нелінійні, стохастичні часові ряди з високим рівнем шуму та змінною волатильністю. Такі ряди характеризуються наявністю трендів, сезонних компонент та випадкових коливань, що ускладнює їх точне прогнозування класичними статистичними методами.

Однією з ключових особливостей поведінки акцій є кластеризація волатильності, коли періоди високих коливань цін змінюються відносно стабільними періодами. Це означає, що ризик ринку є динамічним і залежить від поточного стану економічного середовища. Додатково спостерігається ефект автокореляції дохідностей на коротких інтервалах часу, що дозволяє використовувати історичні дані для побудови прогнозних моделей.

Важливу роль у формуванні цін акцій відіграють макроекономічні фактори, такі як процентні ставки, рівень інфляції, монетарна політика Федеральної резервної системи США, а також глобальні економічні події. Наприклад, зміни ключової ставки можуть суттєво впливати на вартість акцій через зміну вартості капіталу та інвестиційної привабливості ринку.

Крім економічних факторів, значний вплив мають інформаційні та поведінкові чинники. Новинний фон, корпоративні звіти, геополітичні події та очікування інвесторів формують короткострокові коливання ринку. У сучасних умовах інформаційного перенасичення реакція ринку на новини відбувається майже миттєво, що підсилює роль автоматизованого аналізу текстових даних.

Саме тому сучасні підходи до моделювання поведінки акцій S&P 500 базуються на інтеграції декількох типів даних: історичні цінові ряди (OHLCV); технічні індикатори (RSI, MACD, ковзні середні); макроекономічні показники; текстові дані новин і фінансових повідомлень [8, 9, 10].

У даній роботі передбачається об'єднання фундаментального та технічного аналізу з використанням сучасних нейромережевих моделей аналізу фінансових часових рядів. Основою для моделей прогнозування часових рядів є історичні ціни акцій та технічні індикатори, які будуть використані як додаткові ознаки.

З точки зору машинного навчання, поведінка акцій розглядається як задача прогнозування багатовимірних часових рядів, де необхідно враховувати як внутрішню структуру даних, так і зовнішні фактори впливу. У цьому контексті ефективними є нейромережеві моделі, зокрема LSTM та Transformer-архітектури, які здатні виявляти приховані залежності у даних без явного задання статистичної моделі.

Окремо слід відзначити, що ринок акцій індексу S&P 500 є нестационарним середовищем, тобто його статистичні властивості змінюються з часом. Це означає, що моделі повинні бути адаптивними та здатними до перенавчання на нових даних. Крім того, на ринку присутній високий рівень шуму, що ускладнює відокремлення корисного сигналу від випадкових коливань.

Формування інвестиційної рекомендації не може ґрунтуватися лише на одному показнику (наприклад, очікуваній дохідності). Інвестора цікавить компроміс між дохідністю, ризиком, ліквідністю, чутливістю до ринку та багатьма іншими факторами. Багатокритеріальна оцінка дозволяє врахувати всі ці аспекти та прийняти обґрунтоване рішення. Проведений аналіз дозволив виявити чотири найбільш поширені методи багатокритеріальної оцінки інвестиційних рішень.

Метод АНР (Analytic Hierarchy Process) розроблений Томасом Сааті, заснований на попарних порівняннях критеріїв за шкалою від 1 до 9. На основі цих порівнянь будуються матриці, обчислюються власні вектори та вагові коефіцієнти. Переваги: зрозумілість, врахування думки експерта. Недоліки: залежність від суб'єктивних думок, обмеженість кількості альтернатив.

Метод TOPSIS (Technique for Order Preference by Similarity to Ideal Solution) порівнює кожен альтернативу з ідеальним та антиідеальним рішеннями. Переваги: відсутність потреби в попарних порівняннях, зрозуміла геометрична інтерпретація. Недоліки: чутливість до додавання/видалення альтернатив.

Метод MOORA (Multi-Objective Optimization on the basis of Ratio Analysis) нормалізує значення критеріїв діленням на корінь із суми квадратів, потім обчислює суму нормалізованих значень для критеріїв максимізації мінус суму для критеріїв мінімізації. Переваги: простота реалізації. Недоліки: відсутність ваг критеріїв (якщо не задані додатково).

Метод NSGA-II (Nondominated Sorting Genetic Algorithm II) належить до еволюційних алгоритмів. Він не знаходить єдине рішення, а будує множину Парето-оптимальних рішень, де жодне рішення не домінує інше за всіма критеріями одночасно. Переваги: відсутність потреби в заданні ваг, можливість бачити весь фронт компромісів. Недоліки: обчислювальна складність та стохастичність результату.

Використання нейромережових моделей прогнозування поведінки акцій дозволяє інтегрувати різні типи даних, зокрема історичні часові ряди цін (OHLCV), технічні індикатори, фундаментальні показники та текстові фінансові

новини (sentiment), що формує більш повний опис стану ринку. На відміну від класичних методів багатокритеріального прийняття рішень (АНР, TOPSIS, MOORA, NSGA-II), які, як правило, працюють із заздалегідь заданими або статичними оцінками критеріїв, запропонований підхід дозволяє отримувати динамічні, прогнозно-орієнтовані оцінки та застосувати спрощений метод багатокритеріальної оцінки для прийняття інвестиційних рішень на основі лінійної згортки критеріїв (дохідність, ризик, інформаційний фон).

Таким чином, поведінка акцій індексу S&P 500 є результатом взаємодії економічних, фінансових та інформаційних факторів, що формує складну багатовимірну систему. Це обґрунтовує доцільність використання сучасних методів штучного інтелекту, які дозволяють інтегрувати різноманітні джерела даних та підвищувати якість прогнозування і прийняття інвестиційних рішень.

### **1.3 Роль інформаційного фону та новин у формуванні ринкових настроїв**

Фондовий ринок є не лише економічним, але й інформаційним простором. Кожна новина про компанію, галузь чи макроекономічну ситуацію здатна спричинити миттєву зміну цін. При цьому важливий не лише зміст новини, але й її сенсаційність, джерело, час появи в публічному доступі.

Ринкові настрої – це сукупна емоційна реакція учасників ринку на поточну інформацію. Вони можуть бути оптимістичними або песимістичними. В екстремальних випадках формуються «бульбашки» та «панічні розпродажі». Виміряти ці настрої безпосередньо неможливо. Однак непрямими індикаторами виступають обсяги торгів, індекс страху, а також аналіз текстів новин та постів у соціальних мережах.

Сучасні дослідження підтверджують, що новинний фон має передбачувальну здатність щодо короткострокових рухів ринку. Наприклад, серія негативних новин про конкретну компанію часто передують падінню її акцій, навіть якщо фінансові

показники залишаються стабільними. Аналогічно, позитивні новини про галузь можуть підвищити ціни всіх гравців ринку.

Показовим прикладом впливу інформаційного фону на фондовий ринок є події, пов'язані з введенням нових мит адміністрацією президента США Дональда Трампа навесні 2025 року. 2 квітня 2025 року, який отримав назву «День визволення» (Liberation Day) [11]. Білий дім оголосив про запровадження масштабних імпорتنих мит проти більшості торговельних партнерів США. Зокрема, було встановлено 34% мито на китайські товари, 20% на продукцію з країн Європейського Союзу та 46% на імпорт з В'єтнаму. Ця новина стала потужним негативним сигналом для глобальних ринків. Реакція інвесторів була миттєвою та різкою. Протягом чотирьох днів після оголошення індекс S&P 500 впав приблизно на 12% (рис. 1.3), а промисловий індекс Dow Jones втратив майже 4600 пунктів або близько 11%. Дослідження, проведене на вибірці з 67 країн, зафіксувало сукупне падіння фондових індексів у середньому на 7,16% у місцевій валюті протягом триденного вікна після анонсу мит.

Драматичним підтвердженням чутливості ринку до інформаційного фону стала подальша динаміка. Всього через тиждень після панічного розпродажу, 9 квітня 2025 року, Трамп оголосив у соціальних мережах про «90-денну паузу» для більшості запроваджених мит (за винятком китайських). Ця новина спричинила протилежний ефект: S&P 500 злетів на 9,5%, що стало одним із найкращих денних показників в історії індексу. Така волатильність демонструє, як зміна інформаційного сигналу (навіть у формі короткого повідомлення в соціальних мережах) може кардинально змінити ринкові настрої та вартість активів.

Цей приклад ілюструє кілька ключових аспектів, важливих для розуміння ролі новин у прийнятті інвестиційних рішень. По-перше, ринок реагує не лише на сам факт політичного рішення, але й на сигнали про його ймовірну тривалість та масштаб. По-друге, швидкість поширення інформації (особливо через соціальні медіа) потребує автоматизованих систем моніторингу та аналізу новинного потоку в реальному часі. По-третє, навіть тимчасові коливання, спричинені

інформаційним шумом, створюють як ризики, так і можливості для інвесторів, які здатні швидко оцінювати тональність новин та приймати обґрунтовані рішення.



Рисунок 1.3 – Динаміка індексу S&P 500 за період введення тарифів у 2025 році [11]

Проте аналіз новин ускладнюється низкою проблем. По-перше, новинний потік є надзвичайно великим. Щодня виходять тисячі статей, звітів, інтерв'ю аналітиків. По-друге, одна й та сама новина може інтерпретуватися по-різному. По-третє, існує проблема фальшивих новин та маніпулятивних матеріалів, що поширюються задля впливу на ціни. Крім того, досвід 2025-2026 років показує, що ринок поступово адаптується до нових інформаційних реалій. Як зазначають аналітики, до 2026 року митна тематика значною мірою втратила свою руйнівну силу для ринку, оскільки інвестори навчилися сприймати такі новини крізь призму довгострокових фундаментальних факторів, зокрема зростання корпоративних прибутків у

технологічному секторі. Тому доцільно використовувати автоматизовані методи аналізу текстів, зокрема моделі глибокого навчання, навчені на фінансових текстах. Це дозволить кількісно оцінити тональність новин та перетворити її на числові ознаки для подальшого прогнозування.

У зв'язку з великим обсягом текстової інформації, що генерується щоденно, актуальним є застосування автоматизованих методів обробки природної мови для аналізу фінансових новин. Сучасні підходи базуються на використанні попередньо навчених мовних моделей, зокрема архітектури BERT, адаптованої до фінансової предметної області, що дозволяє враховувати контекст та специфіку термінології. Такі моделі здатні визначати тональність новинних повідомлень та перетворювати текстову інформацію у числові показники, які можуть бути інтегровані у моделі прогнозування.

У практичній реалізації систем підтримки прийняття інвестиційних рішень результати аналізу тональності новин агрегуються за певний часовий інтервал, як правило, за торговий день. Це дозволяє сформувати часовий ряд індикатора ринкових настроїв для окремих компаній або секторів економіки. Отриманий показник використовується як додаткова ознака при прогнозуванні динаміки цін акцій та оцінці інвестиційної привабливості активів.

Таким чином, інформаційний фон виступає важливим фактором, що доповнює традиційні фінансові показники та підвищує точність прогнозування ринкової поведінки. Інтеграція аналізу новин у рекомендаційні системи дозволяє більш повно враховувати як кількісні, так і якісні аспекти функціонування фондового ринку, що сприяє підвищенню обґрунтованості інвестиційних рішень.

#### **1.4 Огляд програмних рішень у сфері фінансової аналітики та інвестування**

Існуючі програмні рішення у сфері фінансової аналітики та інвестування можна умовно поділити на три основні категорії: платформи технічного аналізу, системи алгоритмічної торгівлі та професійні аналітичні комплекси.

Серед комерційних продуктів можна назвати платформи Wealthfront та Betterment, які використовують пасивні інвестиційні стратегії на основі біржових інвестиційних фондів. Більш просунутими є системи, що використовують методи машинного навчання, такі як Kavout (прогнозування на основі AI) та Estimize (краудсорсингові прогнози). У таблиці 1.2 наведено порівняльну характеристику відомих фінансових систем.

Таблиця 1.2 – Порівняння існуючих комерційних фінансових систем

Назва	Тип	Методи	Переваги	Недоліки
Wealthfront	Robo-advisor	Пасивне інвестування в ETF	Низька вартість, автоматизація	Відсутність індивідуального підходу
Betterment	Robo-advisor	Пасивне інвестування в ETF	Зручний інтерфейс, соціальна відповідальність	Обмежена гнучкість
Kavout	Рекомендація акцій	AI, машинне навчання	Висока точність прогнозів	Закрита модель, висока вартість
Estimize	Краудсорсинг	Kavout	Унікальна модель даних	Специфічність платформи

Попри різноманіття наявних рішень, більшість із них мають суттєві недоліки: орієнтацію лише на прогнозування без урахування рекомендаційного аспекту, ігнорування інформаційного фону та новин, відсутність багатокритеріальної оцінки (дохідність, ризик, інформаційний вплив).

Рекомендаційні системи вже давно використовуються в електронній комерції, стрімінгових сервісах та соціальних мережах (рис. 1.4). Їхнє завдання запропонувати користувачеві об'єкти, які з високою ймовірністю виявляться для нього цікавими. У фінансовій сфері такі системи набули поширення порівняно

недавно. Вони зазвичай використовують регресійні моделі, нейронні мережі або ансамблеві методи.

До програмних рішень, за допомогою яких інвестори можуть отримувати поради стосовно інвестицій, відносять також системи для формування портфеля, які розраховують оптимальні частки активів згідно з теорією Г. Марковіца (сучасна портфельна теорія) або іншими моделями. Є також роботи-радники (англ. robo-advisors), які повністю автоматизують управління капіталом на основі заданих інвестором параметрів ризику та горизонту інвестування.

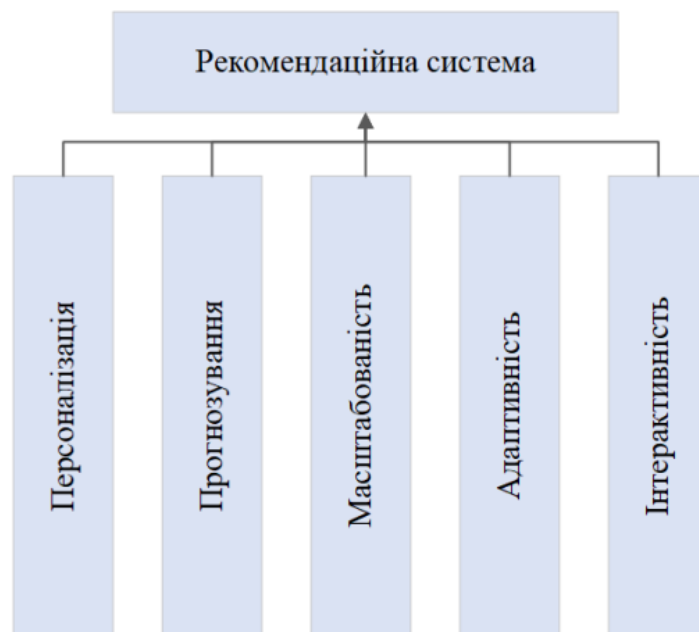


Рисунок 1.4 – Основні характеристики рекомендаційних систем [12]

Для розроблюваного проєкту у рамках даної кваліфікаційної роботи доцільно зробити аналіз існуючих програмних рішень основних 4-х типів фінансових систем, характеристика яких надана нижче.

1. *Торгові платформи з аналітикою.* Одним із найпоширеніших інструментів є TradingView, який забезпечує користувачів широким набором графічних інструментів та технічних індикаторів. Однак дана платформа не реалізує повноцінних моделей машинного навчання для прогнозування та не враховує

новинний фон у формуванні інвестиційних рішень. Іншим популярним рішенням є MetaTrader 5, що використовується для автоматизованої торгівлі за допомогою експертних радників (Expert Advisors). Незважаючи на можливість алгоритмічної торгівлі, система переважно базується на класичних індикаторах і не підтримує інтеграцію сучасних нейромережових моделей та NLP-аналізу.

2. *Інвестиційні платформи зі смарт рекомендаціями.* Платформа eToro реалізує концепцію соціального трейдингу, де користувачі можуть копіювати стратегії інших інвесторів. Такий підхід не передбачає глибокого аналізу ринку або прогнозних моделей, а базується на поведінкових даних користувачів. Robinhood реалізує базову аналітику та надає прості рекомендації, однак NLP та Deep Learning моделі відсутні.

3. *AI/quant платформи.* До них відносять Alpacas, яка надає API для алгоритмічної торгівлі, дозволяє підключати ML-моделі, однак не має власної комплексної AI-системи. Більш просунутим рішенням є QuantConnect, що дозволяє створювати та тестувати алгоритмічні торгові стратегії з використанням Python та C#. Тут є ML інтеграція. Проте дана платформа орієнтована переважно на розробку користувацьких моделей і не містить вбудованих комплексних рекомендаційних механізмів із врахуванням новинного аналізу.

4. *AI-прогнозні сервіси.* Представником такого типу сервісів є Alpha Vantage: тут є фінансові дані та індикатори та обмежено AI features, однак відсутня повноцінна рекомендаційна система. Еталоном і професійною системою найвищого рівня є Bloomberg Terminal, яка забезпечує доступ до великого обсягу фінансових даних, новин та аналітики. Однак ця система є закритою, має високу вартість та не надає відкритої архітектури для інтеграції власних моделей машинного навчання.

Проведений аналіз показав, що існуючі програмні рішення у сфері інвестування зазвичай спеціалізуються на окремих аспектах: технічному аналізі, соціальному трейдингу або базовій алгоритмічній торгівлі. Більшість платформ не інтегрують одночасно прогнозування часових рядів, аналіз новин із використанням

NLP та багатокритеріальну оптимізацію портфеля в єдину систему прийняття рішень.

Таким чином, доцільною є розробка рекомендаційної системи для підтримки прийняття інвестиційних рішень, яка інтегрує в єдину архітектуру нейромережеві моделі аналізу й прогнозування фінансових часових рядів і новин (LSTM/Transformer, BERT) та методи багатокритеріальної оцінки інвестиційних рішень і має практичну цінність як універсальний інструмент підтримки прийняття інвестиційних рішень.

### **1.5 Аналіз останніх досліджень і публікацій**

Сучасні дослідження у сфері прогнозування фінансових часових рядів та побудови інтелектуальних рекомендаційних систем демонструють поступовий перехід від класичних статистичних методів до нейромережевих моделей глибокого навчання, які дозволяють враховувати складні нелінійні залежності та багатofакторний характер фінансових ринків.

Традиційно для прогнозування фінансових часових рядів використовувалися статистичні моделі ARIMA (AutoRegressive Integrated Moving Average) та VAR (Vector Autoregression), які й сьогодні часто застосовуються як базові моделі порівняння. Однак результати дослідження [13] показали, що під час прогнозування індексу S&P 500 статистичні підходи поступаються сучасним нейромережевим моделям за точністю прогнозування та здатністю враховувати складні закономірності ринку.

Одним із перших успішних напрямів використання глибокого навчання для аналізу фінансових даних стали рекурентні нейронні мережі, зокрема LSTM. Завдяки механізму пам'яті такі моделі здатні враховувати часові залежності та широко застосовуються для прогнозування цін акцій і фінансових показників. Результати сучасних досліджень свідчать, що LSTM забезпечують високу якість коротко- та середньострокового прогнозування, однак їх ефективність знижується

під час моделювання довгострокових залежностей і складних взаємозв'язків між великою кількістю факторів.

Подальший розвиток методів прогнозування пов'язаний із появою Transformer-архітектур, які базуються на механізмі уваги (Attention). На відміну від рекурентних мереж, Transformer-моделі здатні ефективно аналізувати довгі часові послідовності та виявляти залежності між віддаленими у часі подіями. У роботі [13] Transformer продемонстрував найкращі результати серед порівнюваних моделей прогнозування фондового ринку. Висновки дослідження [14] також підтверджують перевагу Transformer-архітектур над ARIMA та LSTM у більшості експериментальних сценаріїв. Аналогічні результати наведено у роботі [15], де Transformer перевершив ARIMA, LSTM та Random Forest на даних фондового ринку. Водночас аналіз досліджень показує, що LSTM і Transformer мають різні сильні сторони [15]: LSTM характеризуються меншою обчислювальною складністю та добре працюють із короткими послідовностями, тоді як Transformer є ефективнішими для моделювання довгострокових залежностей.

Особливу увагу останнім часом приділено спеціалізованим Transformer-моделям для часових рядів, серед яких можна виділити моделі TFT, Informer, Autoformer та PatchTST. Дослідження [16] показало, що модель PatchTST перевершує низку інших підходів для горизонтів прогнозування один та п'ять торгових днів. Такі моделі, як TFT, Informer та Autoformer продемонстрували суттєве покращення якості прогнозування порівняно з рекурентними мережами. Їх основною перевагою є здатність ефективно обробляти довгі часові залежності та працювати з багатовимірними часовими рядами та великою кількістю вхідних ознак, включаючи технічні індикатори та зовнішні фактори. Моделі Informer та Autoformer розглядаються як перспективні сучасні підходи, однак їх використання у межах бакалаврської роботи є менш доцільним через високу складність реалізації та налаштування.

Важливою перевагою TFT є поєднання механізмів самоуваги, рекурентних компонентів та модулів автоматичного відбору ознак, що дозволяє не лише

підвищити точність прогнозування, але й отримувати інтерпретовані результати щодо впливу окремих факторів на прогноз [17]. З огляду на високу якість прогнозування, підтримку багатовимірних часових рядів та наявність механізмів інтерпретації, саме TFT було обрано як основну прогнозну модель у даній роботі, тоді як LSTM використовується як базова модель для порівняння. Поєднання LSTM як базової моделі та Temporal Fusion Transformer як більш сучасного підходу дозволяє забезпечити баланс між складністю, точністю та можливістю експериментального дослідження ефективності прогнозування часових рядів фінансових даних.

Окремий напрям сучасних досліджень пов'язаний із використанням методів обробки природної мови для аналізу фінансових новин та оцінювання ринкових настроїв. Одним із найпоширеніших рішень є модель FinBERT – спеціалізована модифікація BERT, адаптована до фінансової предметної області. FinBERT дозволяє визначати тональність фінансових новин, аналітичних матеріалів та корпоративних повідомлень, формуючи кількісні оцінки інформаційного фону. Як показано в роботах [18, 19, 20], використання sentiment-аналізу разом із нейромережевими моделями прогнозування дозволяє підвищити точність прогнозів, особливо в умовах підвищеної ринкової волатильності. Модель FinBERT, попередньо навчена на великих об'ємах фінансових текстів [21], забезпечує ефективне врахування поведінкових та інформаційних факторів, що впливають на рух фінансових активів.

Перспективним напрямом є інтеграція аналізу фінансових новин із прогнозними моделями часових рядів [22, 23, 24]. Так, у роботі [1] комбінована модель FinBERT-LSTM перевершила базові LSTM та DNN під час прогнозування даних індексу NASDAQ-100. Аналогічно, у дослідженні [19] поєднання FinBERT і LSTM забезпечило кращі результати порівняно з окремим використанням BERT, LSTM та ARIMA. Останнім трендом є побудова моделей, які поєднують прогнозування часових рядів, аналіз текстових даних та методи багатокритеріального прийняття рішень. Такі системи інтегрують нейромережеві

моделі з фінансовими індикаторами ризику та дохідності, що дозволяє формувати більш збалансовані інвестиційні рекомендації.

Таким чином, аналіз сучасних досліджень свідчить про тенденцію переходу від окремих моделей прогнозування до комплексних інтелектуальних систем, які поєднують нейромережеві моделі аналізу часових рядів, методи обробки природної мови та механізми підтримки прийняття рішень. Найбільш перспективним підходом для розробки рекомендаційних систем у фінансовій сфері є інтеграція Transformer-моделей прогнозування, зокрема TFT, із засобами sentiment-аналізу фінансових новин на основі моделі FinBERT та методами багатокритеріального оцінювання інвестиційних активів.

## 1.6 Постановка задачі

Провівши аналіз особливостей функціонування фондового ринку та індексу S&P 500, а також методів, моделей та програмних рішень, які застосовують для проведення їх аналізу, було зроблено висновок про необхідність розробки рекомендаційної системи прийняття інвестиційних рішень на основі прогнозування поведінки акцій компаній, що входять до індексу S&P 500, яка комплексно поєднує нейромережеві моделі прогнозування (LSTM/Transformer), аналіз фінансових новин на основі FinBERT та методи багатокритеріальної оцінки інвестиційних рішень.

**Об'єкт дослідження** – процес прийняття інвестиційних рішень на фондовому ринку.

**Предмет дослідження** – методи та нейромережеві моделі аналізу й прогнозування поведінки фінансових часових рядів і новин та формування багатокритеріальних інвестиційних рекомендацій.

**Мета роботи** полягає у підвищенні ефективності прийняття інвестиційних рішень шляхом розробки рекомендаційної системи на основі нейромережевих моделей аналізу й прогнозування поведінки акцій індексу S&P 500 і фінансових новин та методів багатокритеріальної оцінки інвестиційних активів.

Для розробки інформаційної системи необхідно вирішити такі завдання:

- провести аналіз теоретичних засад прийняття інвестиційних рішень, дослідити сучасні підходи та програмні рішення у сфері прогнозування поведінки акцій на фондовому ринку;
- обґрунтувати вибір нейромережових моделей аналізу й прогнозування поведінки акцій індексу S&P 500 і фінансових новин та методів багатокритеріальної оцінки інвестиційних рішень;
- провести навчання моделей LSTM і TFT на історичних OHLCV-даних і технічних індикаторах та дослідити їх прогностичну якість;
- здійснити проєктування, програмну реалізацію і тестування рекомендаційної системи прийняття інвестиційних рішень на основі прогнозування поведінки акцій S&P 500 та оцінити її якість.

Робота з рекомендаційною системою базується на розробленому вебзастосунку, до якого інтегровано нейромережову модель прогнозування поведінки акцій (LSTM/TFT), модель аналізу фінансових новин на основі FinBERT та впроваджено багатокритеріальну оцінку інвестиційної привабливості активів. Вебзастосунок повинен мати наступну функціональність:

- мати зрозумілий інтерфейс, що дозволить інвестору легко аналізувати поведінку обраних акцій стосовно їх дохідності та формувати ефективну інвестиційну стратегію;
- мати два основних сценарії для роботи: оцінка однієї акції та робота з портфелем інвестора;
- надавати можливість для введення початкового капіталу, задання періоду аналізу, порогів для купівлі та продажу, горизонту прогнозу, вибору активів та регулювання ваг для врахування дохідності, ризику та тональності новин;
- підключатися до джерела свіжих історичних OHLCV-даних відібраних активів, автоматично аналізувати їх, розраховувати технічні індикатори та давати прогностичні інвестиційні рекомендації;

- формувати часовий ряд тональності новин для вказаного користувачем періоду аналізу та визначати тональність новин стосовно обраних активів;
- забезпечити інтеграцію модулів прогнозування, аналізу новин та формування рекомендацій;
- реалізувати модуль оцінки інвестиційних рішень, що враховує прогнозовану дохідність, ризик та інформаційний (sentiment) фактор;
- здійснювати порівняння обраної інвестором інвестиційної стратегії з базовою інвестиційною стратегією Buy & Hold та ринковим бенчмарком S&P 500 і робити висновок про її ефективність чи неефективність;
- виводити графік реальних цін, реальної та прогнозованої дохідності, криву капіталу, текстову інтерпретацію рекомендацій з оцінкою стратегії поведінки стосовно активу, який оцінюється.

В результаті буде створено комплексний інструмент, який дозволить оперативно та ефективно проводити аналіз інвестиційної стратегії інвестора та надавати рекомендації стосовно її покращення.

## **Висновки до розділу 1**

У першому розділі роботи було розглянуто теоретичні основи функціонування фондового ринку. Показано, що висока динамічність, нестационарність та велика кількість впливових факторів роблять задачу прогнозування та надання рекомендацій складною. Установлено, що індекс S&P 500 може бути використаним для як джерело даних та бенчмарк для оцінки ефективності інвестиційної стратегії, запропонованої рекомендаційною системою. Проведено порівняльний аналіз фундаментального та технічного підходів до аналізу ринку. Зроблено висновок, що жоден з них окремо не є достатнім. Однак їхнє поєднання з використанням методів машинного навчання може дати кращі результати. Обґрунтовано важливість врахування інформаційного фону та новинних даних. Ринкові настрої, які не відображаються безпосередньо в цінах та

обсягах, є важливим чинником короткострокової волатильності. Сучасні моделі обробки природної мови здатні виділяти тональність та сенс новин автоматично.

Проаналізовано існуючі програмні рішення у сфері фінансової аналітики та інвестування. Виявлено, що більшість із них мають суттєві недоліки: орієнтацію лише на прогнозування без урахування рекомендаційного аспекту, ігнорування інформаційного фону та новин, відсутність багатокритеріальної оцінки (дохідність, ризик, інформаційний вплив). Рекомендаційні системи у фінансовій сфері набули поширення порівняно недавно. Еталонні і професійні AI-прогнозні сервіси найвищого рівня, такі як Bloomberg Terminal, мають високу вартість є закритими та не надають відкритої архітектури для інтеграції власних моделей і не містять вбудованих рекомендаційних механізмів із врахуванням новинного аналізу.

Проведений аналіз досліджень у сфері прогнозування фінансових часових рядів та побудови інтелектуальних рекомендаційних систем показав перехід від класичних статистичних методів до глибоких нейромережових архітектур, що дозволяють враховувати складні нелінійні залежності у ринкових даних. Виявлено, що базовий підхід із використанням рекурентних нейронних мереж LSTM ефективно працює на коротко- та середньострокових прогнозах фінансових часових рядів, однак має обмеження у моделюванні довгострокових залежностей та складних багатofакторних впливів.

Більш прогресивними є трансформерні моделі TFT, Informer та Autoformer, здатні ефективно обробляти довгі часові залежності та працювати з багатовимірними ознаками. Найбільш поширеним рішенням використанням моделей обробки природної мови для аналізу фінансових новин є уже навчена модель FinBERT. В цілому сучасний стан досліджень свідчить про перехід до комплексних багатofакторних систем, які поєднують LSTM/Transformer моделі, NLP-аналіз фінансових новин та методи оптимізації інвестиційних рішень.

## **2 МОДЕЛІ ТА МЕТОДИ НАДАННЯ РЕКОМЕНДАЦІЙ НА ОСНОВІ ПРОГНОЗУВАННЯ ПОВЕДІНКИ АКЦІЙ S&P 500**

### **2.1 Knowledge-based підхід надання рекомендацій для прийняття інвестиційних рішень**

Класичними підходами до формування рекомендацій у рекомендаційних системах є методи колаборативної, контентно-орієнтованої та гібридної фільтрації [25, 26]. Контентна фільтрація будує рекомендації на основі характеристик об'єктів та історії взаємодій користувача з ними. Колаборативна фільтрація здійснює прогнозування релевантності об'єктів для користувача на основі поведінки користувачів зі схожими вподобаннями. Окремо виділяють також knowledge-based підходи, які ґрунтуються на використанні колективних патернів взаємодії між користувачами та об'єктами [27, 28]. Гібридні рекомендаційні системи поєднують сильні сторони кількох підходів (наприклад, контентно-орієнтовані + колаборативні), що дозволяє усунути окремі недоліки кожного з них і забезпечити кращу якість рекомендацій.

Сучасний стан у підходах до надання рекомендацій можна охарактеризувати переходом від класичних методів фільтрації інформації до складних гібридних, контекстно-орієнтованих, адаптивних та пояснювальних інтелектуальних рекомендаційних систем, які базуються на новітніх технологіях Artificial Intelligence (AI) [29-33].

У задачах підтримки прийняття інвестиційних рішень застосування класичних підходів є обмеженим. Це обумовлено тим, що: відсутня достатня кількість відкритих даних про поведінку інвесторів; інвестиційні рішення є індивідуальними та залежать від ринкової ситуації; фінансові дані мають високу динамічність і залежать від зовнішніх факторів.

У зв'язку з цим у даній роботі використовується knowledge-based підхід, який базується на використанні структурованих знань про фінансові активи та ринкові

умови. На відміну від колаборативної фільтрації, рекомендації формуються не на основі історії користувачів, а шляхом аналітичної оцінки характеристик активів, таких як прогнозована дохідність, ризик та інформаційний фон. Такий підхід дозволяє: уникнути проблеми холодного старту; забезпечити пояснюваність рекомендацій; інтегрувати результати прогнозних моделей та аналізу новин; адаптувати рекомендації до індивідуальних параметрів інвестора.

Формування рекомендацій щодо інвестиційних рішень здійснюється шляхом апроксимації функції корисності:

$$f(i, t, c) : I \times T \times C \rightarrow \mathcal{R}, \quad (2.1)$$

де:

$I = \{i_k \mid k = 1, \dots, n\}$  – множина фінансових активів (акцій компаній, що входять до складу індексу S&P 500);

$T = \{t_s \mid s = 1, \dots, \tau\}$  – множина моментів часу (торгові дні);

$C$  – множина контекстів, що включає параметри інвестора (схильність до ризику, інвестиційний горизонт) та поточні ринкові умови;

$\mathcal{R}$  – впорядкований числовий простір значень корисності, заданий на множині дійсних чисел ( $\mathcal{R} \subseteq \mathbb{R}$ ).

Значення функції корисності  $f(i_k, t_s, c)$  інтерпретується як інтегральна оцінка інвестиційної привабливості активу  $i_k$  у момент часу  $t_s$  із урахуванням контексту  $c$ .

Функція корисності визначається як агрегована оцінка ключових факторів:

$$f(i, t, c) = w_1 \cdot \hat{r}_i - w_2 \cdot \sigma_{i,t} + w_3 \cdot s_{i,t}, \quad (2.2)$$

де:

$\hat{r}_i$  – прогнозована дохідність активу, отримана за допомогою моделей прогнозування часових рядів (LSTM, TFT);

$\sigma_{i,t}$  – оцінка ризику активу (стандартне відхилення дохідності);

$s_{i,t}$  – показник ринкових настроїв (sentiment), отриманий шляхом аналізу фінансових новин за допомогою моделей обробки природної мови (англ. Natural Language Processing, NLP),  $s_{i,t} \in [-1; 1]$ ;

$w_1, w_2, w_3$  – вагові коефіцієнти ( $w_1 + w_2 + w_3 = 1$ ), що відображають відносну важливість відповідних факторів:  $w_1$  – дохідності,  $w_2$  – ризику та  $w_3$  – новинного фону. Контекст  $c$  дозволяє адаптувати рекомендації до індивідуальних вимог інвестора, зокрема шляхом зміни вагових коефіцієнтів (наприклад, більша вага ризику для консервативних стратегій).

Перед обчисленням функції корисності всі складові нормалізуються до числового діапазону  $[0, 1]$ , для забезпечення їх коректної інтеграції.

Прогнозовану дохідність акції  $i$ -го активу ( $i$ -ї компанії) рахують за формулою:

$$\hat{r}_i = \frac{\hat{p}_{i,t+1} - p_{i,t}}{p_{i,t}}, \quad (2.3)$$

де:

$p_{i,t}$  – поточна ціна акції;

$\hat{p}_{i,t+1}$  – прогнозна ціна акції, отримана з допомогою нейромережових моделей LSTM / TFT по часовому ряду історичних даних курсу акцій.

Ризик є мірою нестабільності, яку розраховують за даними часового ряду з цінами акцій  $i$ -го активу як стандартне відхилення дохідностей:

$$\sigma_{i,t} = \sigma(r_i). \quad (2.4)$$

Новинний фон  $s_{i,t}$  є оцінкою настрою новин стосовно  $i$ -го активу із використанням NLP-моделі, яка для кожної акції (компанії, акціонерів тощо) видає усереднене за день значення оцінок тональності новин, формуючи daily sentiment time series.

Описаний підхід реалізує багатокритеріальну оцінку інвестиційної привабливості активів на основі лінійної згортки критеріїв (дохідність, ризик,

інформаційний фон), що дозволяє отримати інтегральний показник для подальшого ранжування. Отримані значення функції корисності активів ранжують у порядку спадання та використовують для формування портфеля інвестора.

## 2.2 Формування та оцінка портфеля інвестора

Формування інвестиційного портфеля здійснюється шляхом відбору активів з найвищими значеннями функції корисності, з урахуванням ресурсних обмежень інвестора, які включають доступний капітал, мінімальний обсяг інвестицій та диверсифікацію. Для оцінки ефективності портфеля (portfolio performance evaluation) використовується інтегральна функція корисності, після чого здійснюється відбір активів та обчислення показників ефективності портфеля.

Основні методи оцінки уже сформованого портфеля є наступними:

- кількісний аналіз: простий підрахунок вартості активів, розрахунок прибутковості, дивідендів та ризиків (стандартне відхилення, коефіцієнт);
- якісний аналіз: оцінка диверсифікації, відповідність активів стратегії інвестора;
- порівняльний аналіз (бенчмаркінг): порівняння прибутковості портфеля з ринковими індексами S&P 500 та Buy & Hold.

У даній роботі для оцінки ефективності сформованого інвестиційного портфеля використовуються показники дохідності, ризику, коефіцієнт Шарпа та проводиться порівняння з ринковим бенчмарком S&P 500 і базовою інвестиційною стратегією Buy & Hold.

Дохідність портфеля розраховують як зважене значення дохідності акцій усіх активів:

$$R_p = \sum w_i \cdot \hat{r}_i, \quad (2.5)$$

де:  $\hat{r}_i$  – прогнозована дохідність  $i$ -го активу;

$w_i$  – вага  $i$ -го активу у портфелі ( $\sum w_i = 1$ ).

Вагові коефіцієнти активів у портфелі визначають частку інвестицій, що припадає на кожну акцію, та можуть задаватися рівномірно або пропорційно інтегральній оцінці привабливості активів. Ваги акцій активів у портфелі можуть бути рівними:  $w_i = \frac{1}{m}$  ( $m$  – кількість активів у портфелі), або пропорційними дохідності:  $w_i = \frac{\hat{r}_i}{\sum \hat{r}_i}$ .

Ризик портфеля розраховують за формулою:

$$\sigma_p = \sqrt{w^T \Sigma w}, \quad (2.6)$$

де:  $w = (w_1, w_2, \dots, w_m)$  – вектор ваг акцій усіх активів у портфелі,  $w^T$  – транспонований вектор;

$\Sigma$  – коваріаційна матриця дохідностей.

Коваріаційна матриця дохідностей формується на основі історичних значень дохідностей активів та відображає не лише індивідуальну варіативність кожного активу, але й взаємозв'язки між ними. Елементи матриці визначаються як коваріації між дохідностями відповідних активів, що дозволяє врахувати ефект диверсифікації при оцінці ризику портфеля.

Коефіцієнт Шарпа (спрощений варіант) розраховується на основі вже визначених показників дохідності та ризику портфеля як відношення надлишкової дохідності до стандартного відхилення дохідності портфеля:

$$S = \frac{R_p}{\sigma_p}. \quad (2.7)$$

Значення  $S$  інтерпретують наступним чином:  $< 1$ : погано,  $0-1$ : слабо,  $1-2$ : добре (прийнятний рівень),  $2-3$ : дуже добре,  $> 3$ : відмінно (рідко, висока ефективність).

Ранжовані значення функції корисності, розбиті на три групи – високі, середні та низькі, можуть бути використані для отримання рекомендацій стосовно

активів портфеля: високі значення – купити (buy), середні значення – тримати (hold), низькі значення – продати (sell). Це допомагає інвестору здійснювати:

– щоквартальне ребалансування: якщо оцінка акцій певного сектору зросла та займає, наприклад, 60% замість запланованих 40%, можна продати частину для купівлі облігацій;

– порівняння з індексом: якщо портфель інвестора зріс на 10%, а ринок (індекс) – на 15%, це є сигналом переглянути стратегію;

– аналіз ризику: зрозуміти, наскільки сильно портфель впаде при обвалі ринку. Оцінка портфеля дозволяє інвестору зрозуміти, чи досягаються фінансові цілі, порівняти результати з ринком і ухвалити рішення про купівлю/продаж активів.

Таким чином, knowledge-based підхід дозволяє отримувати значення функції корисності, які реалізують багатокритеріальну оцінку інвестиційної привабливості активів (дохідність, ризик, інформаційний фон) і використовуються для ранжування акцій за рівнем інвестиційної привабливості, відбору множини активів для формування інвестиційного портфеля та формування рекомендацій типу купити / утримувати / продати.

На відміну від класичних рекомендаційних систем, де корисність базується переважно на історії взаємодій користувачів, у даній роботі функція корисності інтегрує: прогнозні оцінки фінансових часових рядів, кількісні показники ризику, якісні характеристики інформаційного фону. Це забезпечує більш повне врахування факторів, що впливають на поведінку ринку, та підвищує обґрунтованість інвестиційних рішень.

### **2.3 Нейромережеві моделі прогнозування часових рядів: LSTM, TFT**

Модель LSTM (Long Short-Term Memory) є однією з базових моделей для прогнозування часових рядів як різновид рекурентної нейронної мережі RNN, спеціально розробленої для роботи з послідовностями даних, де важливі як

короткострокові, так і довгострокові залежності. Вона розроблена для ефективної обробки послідовних даних (текст, часові ряди, мова).

Основна проблема звичайних рекурентних мереж, які містять обернені зв'язки, полягає у затухаючому (англ. vanishing) або вибухаючому (англ. exploding) градієнті під час зворотного поширення помилки через багато часових кроків. LSTM вирішує цю проблему завдяки наявності у її архітектурі спеціальних комірок пам'яті (англ. cell state) та трьох механізмів контролю – гейтів (англ. gates), які регулюють потік інформації (рис. 2.1): *вхідний гейт* (input gate) – визначає, яку частину нової інформації слід зберегти в пам'яті; *гейт забування* (forget gate) – вирішує, яку інформацію з попереднього стану слід видалити; *вихідний гейт* (output gate) – контролює, яка частина інформації з поточної пам'яті потрапить у вихідний сигнал і буде використана для прогнозу.

У контексті прогнозування цін акцій LSTM навчається на історичних даних про ціни відкриття (Open), закриття (Close), мінімальні (Low) та максимальні (High) значення, а також обсяги торгів (Volume). Вхідна послідовність охоплює певне ретроспективне вікно. На виході модель прогнозує одне або кілька значень.

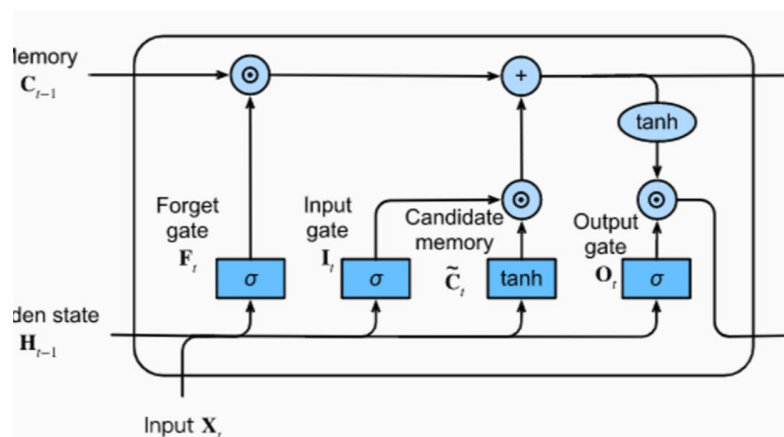


Рисунок 2.1 – Архітектура комірки LSTM із трьома вентилями [34]

Сучасні підходи до прогнозування базуються на архітектурі Transformer, яка використовує механізм самоуваги (self-attention) для виявлення залежностей між елементами послідовності незалежно від їх позиції (рис. 2.2).

Модель Transformer, запропонована у 2017 році науковцями компанії Google, створювалася для завдань обробки природної мови. Згодом вона показала високі результати й у прогнозуванні часових рядів. В основі Transformer лежить механізм самоуваги (self-attention), який дозволяє моделі безпосередньо зіставляти будь-які два елементи вхідної послідовності незалежно від відстані між ними. Моделі Transformer-архітектури здатні виявляти приховані залежності у даних без явного задання статистичної моделі, що є актуальним для прогнозування поведінки акцій як задачі прогнозування багатовимірних часових рядів, де необхідно враховувати як внутрішню структуру даних, так і зовнішні фактори впливу [17].

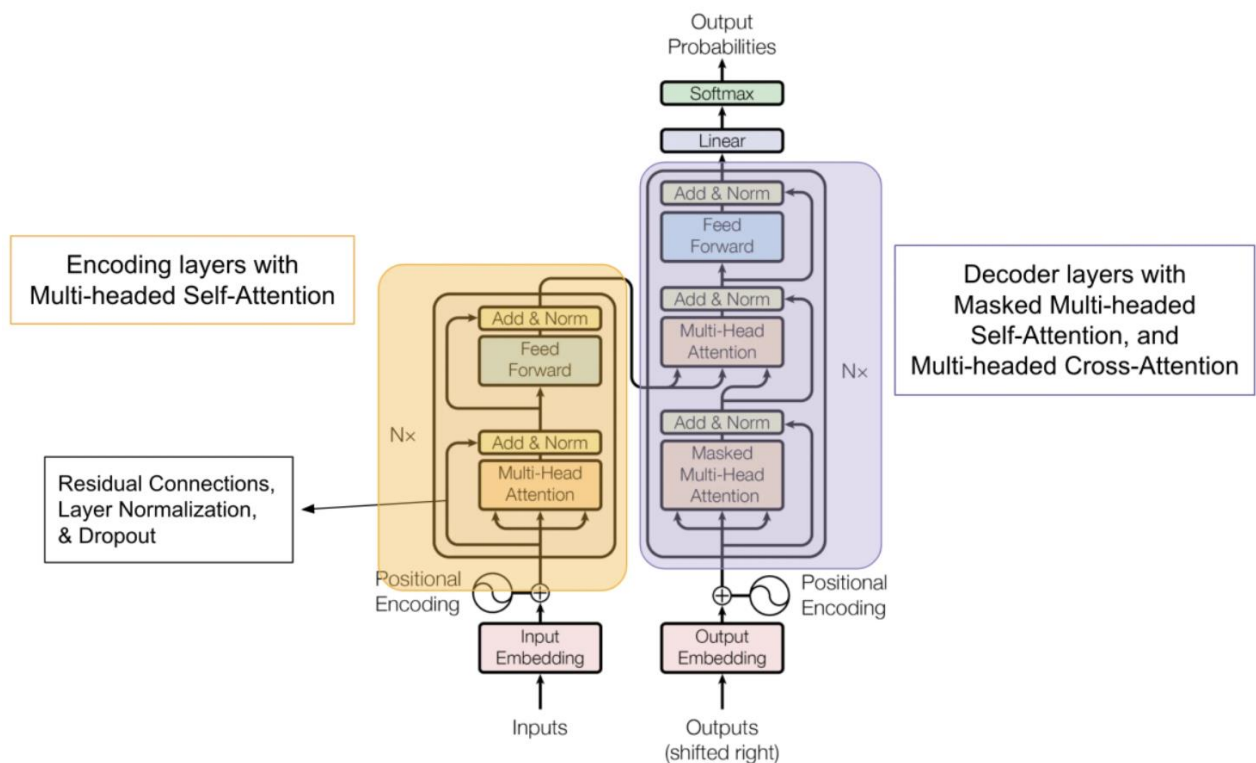


Рисунок 2.2 – Механізм самоуваги в архітектурі Transformer [35]

У традиційних рекурентних мережах, зокрема LSTM, зв'язок між віддаленими у часі спостереженнями передається через проміжні стани крок за кроком, що може призводити до втрати інформації. Transformer обчислює для кожної позиції послідовності вагові коефіцієнти відносно всіх інших позицій, що дає змогу враховувати довгострокові залежності без затухання сигналу. Архітектура Transformer складається з енкодера та декодера. Для прогнозування

часових рядів часто використовують лише енкодер, доповнений лінійним шаром для регресії. Позиційне кодування (positional encoding) дозволяє моделі розрізняти порядок елементів послідовності, оскільки механізм уваги не враховує позицію за замовчуванням.

У таблиці 2.1 наведено порівняльний аналіз моделей LSTM та Transformer для прогнозування цін на акції з метою підтримки прийняття інвестиційних рішень.

Таблиця 2.1 – Порівняння моделей LSTM та Transformer

<b>Критерій</b>	<b>LSTM</b>	<b>Transformer</b>
Об'єм необхідних даних	Помірний (сотні зразків)	Великий (десятки тисяч зразків)
Час навчання	Відносно швидкий	Повільніший через механізм самоуваги
Здатність до паралелізації	Низька (послідовна обробка)	Висока (паралельна обробка)
Облік довгострокових залежностей	Добра (завдяки вентилям)	Дуже висока (завдяки механізму самоуваги)
Стійкість до зашумлених даних	Добра	Середня (потребує великих обсягів)

Перевагою LSTM моделей є відносно невелика кількість параметрів порівняно з Transformer моделями, що зменшує ризик перенавчання (overfitting) на фінансових даних, які часто містять шум та викиди. Навчання моделі Transformer потребує дуже великих обсягів даних (сотні тисяч зразків) та значних обчислювальних ресурсів. Використання уже навчених для прогнозування часових рядів нейромережевих моделей шляхом їх донавчання на фінансових даних прискорює процес їх створення. Для моделі LSTM навчених моделей немає, тому її потрібно створювати та навчати з нуля. У той час як для трансформенні моделей є готові уже навчені моделі для прогнозування часових рядів Temporal Fusion

Transformer (TFT), які об'єднують рекурентні мережі та механізм уваги. Їх можна використати для навчання на реальних ринкових даних з урахуванням специфічних закономірностей фондового ринку, зберігаючи загальну здатність до узагальнення.

Temporal Fusion Transformer є спеціалізованою моделлю для прогнозування часових рядів, яка поєднує механізми рекурентних мереж та attention. Вона підтримує роботу з багатьма типами ознак: статичні (наприклад, сектор компанії), відомі наперед (календарні ознаки), динамічні (ціни, обсяги, sentiment). TFT використовує: LSTM для локальних залежностей; attention для глобальних зв'язків; gating-механізми для відбору релевантних ознак. Це робить модель особливо ефективною для фінансових даних, де важливими є як часові, так і контекстні залежності.

До трансформерних моделей, архітектура яких налаштована для прогнозування часових рядів, відносять також Informer та Autoformer. Informer є оптимізованою версією Transformer для довгих часових рядів. Його ключовою особливістю є механізм ProbSparse attention, який зменшує обчислювальну складність. Це дозволяє працювати з великими історичними даними, однак модель є більш складною для налаштування та інтерпретації. Autoformer розширює Transformer, вводячи механізм декомпозиції часового ряду на тренд і сезонну компоненту. Модель автоматично виділяє ці компоненти та використовує autocorrelation attention для виявлення періодичних залежностей.

Для розв'язання поставленої задачі доцільно дослідити моделі LSTM та TFT для побудови прогнозних моделей цін акцій. Модель LSTM є більш простою у реалізації й ефективною для базового прогнозування. Її можна використати як базову модель для порівняння під час навчання прогнозних моделей. Вибір TFT обумовлений: здатністю працювати з багатовимірними даними, інтеграцією різних типів ознак (ціни, індикатори, sentiment), використанням механізму attention для виявлення складних залежностей. Моделі Informer та Autoformer розглядаються як перспективні сучасні підходи, однак їх використання є менш доцільним через високу складність реалізації та налаштування.

Таким чином використання LSTM як базової моделі та TFT як більш сучасного підходу дозволяє забезпечити баланс між складністю, точністю та можливістю експериментального дослідження ефективності прогнозування часових рядів фінансових даних.

## 2.4 Моделі аналізу текстових даних та фінансових новин

Аналіз текстових даних є важливим компонентом рекомендаційних систем підтримки прийняття інвестиційних рішень, оскільки фінансові новини, аналітичні звіти та публічні заяви компаній безпосередньо впливають на ринкові настрої та динаміку цін активів. Обробляти тисячі новинних повідомлень вручну неможливо. Тому виникає необхідність в автоматизованих методах, заснованих на обробці природної мови.

Для обробки таких даних застосовуються сучасні трансформерні NLP моделі, зокрема BERT-подібні архітектури, які здатні враховувати контекст слів у тексті та забезпечувати високу точність класифікації тональності [18]. Модель BERT стала важливим кроком у розвитку NLP завдяки використанню двонаправленого контексту [20]. На відміну від попередніх моделей, які читали текст зліва направо або справа наліво, BERT одночасно враховує слова, що стоять як праворуч, так і ліворуч від поточного. Це дозволяє глибше розуміти зміст речення [19].

Серед найбільш поширених підходів до аналізу фінансових текстів можна виділити моделі DistilBERT, FinBERT та GPT-based моделі (табл. 2.2) [21]. DistilBERT є спрощеною версією BERT, яка забезпечує швидшу обробку тексту та менші обчислювальні витрати, однак може поступатися у точності при роботі зі спеціалізованими фінансовими термінами. DistilBERT, створена за допомогою процесу дистиляції знань, зберігає близько 95% точності повного BERT. При цьому DistilBERT працює в півтора-два рази швидше та потребує вдвічі менше пам'яті. Для фінансових застосунків, де швидкість обробки великого потоку новин є критичною, DistilBERT може бути добрим компромісом. Однак спеціалізованої

фінансової версії DistilBERT не існує в загальному доступі. Її використання вимагало б донавчання на фінансових текстах, що збільшує обчислювальну складність.

Таблиця 2.2 – Порівняння моделей аналізу фінансових текстів

Модель	Точність	Швидкість	Спеціалізація	Використання
GPT-based	Дуже висока	Низька	Загальна	Великі ресурси
DistilBERT	Висока	Висока	Загальна	Можливий компроміс
FinBERT	Висока	Середня	Фінансова	Основна модель у роботі

GPT подібні моделі представляють інший підхід, заснований на генерації тексту. На відміну від BERT family, які переважно використовуються для класифікації, GPT моделі можна використовувати для генерації аналітичних звітів, відповідей на запитання про компанію, виокремлення ключових фактів. GPT-based моделі характеризуються високою гнучкістю та здатністю до генерації тексту і глибокого семантичного аналізу, проте їх використання для задач класифікації тональності часто є надлишковим і потребує значних обчислювальних ресурсів. До того ж вони вимагають значних обчислювальних ресурсів і часто недоступні для запуску на локальних серверах. Крім того, для фінансових завдань їх потрібно додатково налаштовувати, щоб уникнути галюцинацій, тобто генерації вигаданих фактів.

У даній роботі передбачається використання вже готової спеціалізованої попередньо навченої трансформерної моделі FinBERT, яка не потребує донавчання, базується на архітектурі BERT і призначена для аналізу текстів у фінансовій сфері з метою оцінки настрою новин [36]. Це уже навчена на великих обсягах фінансової інформації модель, яка розуміє професійну термінологію та

контекст, характерний для біржових новин, фінансових звітів та аналітики. Що дозволяє моделі більш точно інтерпретувати фінансову термінологію, враховувати контекст ринкових подій та коректно визначати тональність повідомлень (позитивна, нейтральна, негативна). Використання FinBERT забезпечує отримання релевантних оцінок інформаційного фону для кожного активу, які агрегуються у часовому розрізі та інтегруються до функції корисності разом із прогнозованою дохідністю та ризиком.

Таким чином, застосування FinBERT у поєднанні з нейромережевими моделями прогнозування часових рядів дозволяє враховувати не лише кількісні фінансові показники, але й якісні інформаційні фактори, що підвищує обґрунтованість багатокритеріальної оцінки інвестиційної привабливості активів у рамках knowledge-based рекомендаційної системи.

## **2.5 Оцінювання якості прогнозних моделей та ефективності рекомендаційної системи**

Оцінювання якості прогнозних моделей та ефективності рекомендаційної системи здійснюється з використанням сукупності статистичних, фінансових і ризик-орієнтованих метрик, що дозволяють комплексно оцінити не лише точність прогнозування, але й практичну доцільність використання моделей у задачах підтримки прийняття інвестиційних рішень. Ці метрики та методи можна структурувати наступним чином:

- метрики точності прогнозу: MAE (Mean Absolute Error), RMSE (Root Mean Squared Error) – оцінюють точність прогнозування ціни акції та дохідності;
- метрика торгової релевантності прогнозу: DA (Directional Accuracy): оцінює точність напрямку руху ціни й має практичну користь для інвестора, для якого важливіше не точне значення ціни, а напрям зміни – упаде чи підніметься;
- метрика впевненості прогнозу (невизначеності): Confidence;

- метрики ризику: стандартне відхилення дохідностей, коефіцієнт Шарпа та MDD (Max Drawdown);
- фінансові метрики: Cumulative Return (CR), крива капіталу (Equity Curve) застосовують для оцінювання ефективності інвестиційної стратегії;
- порівняння з бенчмарком: базовою інвестиційною стратегією Buy & Hold та ринковим S&P 500.

Формули для розрахунку метрик ризику наведено у попередніх параграфах: стандартне відхилення дохідностей  $\sigma_t$  (параграф 4.1, формула 2.4), коефіцієнт Шарпа (параграф 4.1, формула 2.6). Далі наведено формули для розрахунку інших метрик оцінки якості рекомендаційної системи.

Метрика MAE характеризує середню абсолютну похибку прогнозу та дозволяє оцінити середнє відхилення прогнозованих значень від фактичних:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (2.8)$$

де:  $y_i$  – фактичне значення;

$\hat{y}$  – прогнозоване значення;

$n$  – кількість спостережень.

Метрика RMSE враховує квадратичне зростання похибки, що підвищує чутливість до значних відхилень і дозволяє краще оцінити стабільність прогнозовної моделі:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (2.9)$$

Метрика DA визначає частку випадків, у яких модель правильно прогнозує напрям зміни ціни активу (зростання або зниження), що є критично важливим для формування торгових сигналів та прийняття інвестиційних рішень:

$$DA = \frac{1}{n} \sum_{i=1}^n I((y_i - y_{i-1})(\hat{y}_i - \hat{y}_{i-1}) > 0), \quad (2.10)$$

де:  $I()$  – індикаторна функція, яка дорівнює 1 у разі правильного прогнозу напрямку руху ціни та 0 – в іншому випадку.

Для фінансових ринків значення DA рівне та менше за 50% – випадковий прогноз, 52-54% – слабка, але корисна модель, 55–58% – добра модель, 58% і більше – дуже сильний результат. Прийнятні для фінансів значення метрик точності наведено у таблиці 2.3.

Таблиця 2.3 – Інтерпретація MAE / RMSE (у %)

Якість моделі	MAE	RMSE	Інтерпретація
Неприйнятна	> 3–4%	> 5–6%	модель нестабільна
Прийнятна	1.5–3%	2–4%	базово працездатна
Добра	0.8–1.5%	1–2.5%	хороший прогноз
Якісна	< 0.8%	< 1.5%	дуже висока точність

Метрика Confidence – впевненості прогнозу, характеризує рівень невизначеності моделі TFT та обчислюється на основі Monte Carlo Dropout, який дозволяє оцінити надійність результатів прогнозування шляхом формування ансамблю прогнозів із активованим Dropout. Стандартне відхилення отриманих прогнозів  $\sigma_{MC}$  є показником невизначеності прогнозу:

$$\sigma_{MC} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (y_i - \bar{y})^2}, \quad (2.12)$$

де:  $N$  – кількість прогнозів, отриманих методом MC Dropout ( $N=32$ );

$y_i$  – прогноз під час  $i$ -го проходу моделі;

$\bar{y}$  – середнє значення ансамблю прогнозів.

Значення Confidence обчислювалося як нормалізована величина, обернено пропорційна стандартному відхиленню ансамблю прогнозів:

$$Confidence = \left(1 - \frac{\sigma_{MC}}{\sigma_{max}}\right) \cdot 100\%, \quad (2.13)$$

де:  $\sigma_{max}$  – максимально допустиме значення невизначеності: 95-й перцентиль значень  $\sigma_{MC}$ .

Чим меншим є значення  $\sigma_{MC}$ , тим вищою є впевненість моделі у сформованому прогнозі.

Метрика CR характеризує сумарну накопичену дохідність інвестиційної стратегії за визначений період часу:

$$CR = \prod_{t=1}^T (1 + r_t) - 1, \quad (2.14)$$

де:  $r_t$  – дохідність у момент часу  $t$ ;

$T$  – кількість часових періодів.

Динаміка зміни накопиченої вартості портфеля інвестора візуалізується за допомогою *кривої капіталу* Equity Curve, яка відображає зміну вартості інвестиційного капіталу у часі та дозволяє оцінити стабільність роботи рекомендаційної системи. Фактично це є вартість інвестиційного портфеля інвестора після застосування інвестиційної стратегії:

$$EC_t = EC_{t-1}(1 + r_t), \quad (2.15)$$

де:  $r_t$  – дохідність активу або стратегії у період  $t$ ;

$EC_t$  – значення капіталу (вартість інвестиційного портфеля) у момент часу  $t$ ;

$EC_{t-1}$  – значення капіталу у попередній момент часу.

Наприклад, якщо стартовий капітал був рівним  $EC_0 = 1000\$$ , а дохідність за перший день становила  $r_t = 0,05$  (+5%), тоді  $EC_1 = EC_0(1 + 0,05) = 1050$ . За розрахованими таким чином значеннями будують криву капіталу.

Метрика MDD характеризує максимальне відносне падіння вартості портфеля від локального максимуму до наступного мінімуму та дозволяє оцінити ризик – потенційний рівень фінансових втрат інвестора:

$$MDD = \max_{t \in [1, T]} \left( \frac{Peak_t - EC_t}{Peak_t} \right), \quad (2.16)$$

де:  $EC_t$  – поточна вартість інвестиційного портфеля у момент часу  $t$ ;

$Peak_t = \max (EC_1, EC_2, \dots, EC_t)$  – максимальна досягнута вартість портфеля у момент часу  $t$ .

Інтерпретація отриманих значень є наступною:  $MDD = 5\%$  – дуже добре,  $MDD = 5-15\%$  – нормально,  $MDD = 15-30\%$  – ризиковано,  $MDD > 30\%$  – неприйнятно для більшості стратегій.

Для оцінки ефективності інвестиційної стратегії з урахуванням ризику використовується також коефіцієнт Шарпа, який характеризує співвідношення між дохідністю портфеля та рівнем прийнятого ризику, що дозволяє оцінити ефективність отриманого прибутку відносно волатильності активів.

Для підтвердження практичної доцільності рекомендаційної системи результати її роботи порівнюють з базовими інвестиційними підходами, зокрема стратегією Buy & Hold, яка передбачає пасивну інвестиційну стратегію – купівлю активу та його утримання протягом усього інвестиційного періоду. А також із ринковим індексом S&P 500, що використовується як benchmark (еталонний показник ринкової дохідності). Таке порівняння дозволяє оцінити, чи забезпечує розроблена система додаткову ефективність відносно пасивного інвестування та загальної ринкової динаміки.

Визначення якості інвестиційної стратегії здійснюють, аналізуючи перераховані вище метрики у комплексі. Прогнозна модель вважається прийнятною, якщо  $MAE \leq 1\%$ ,  $RMSE \leq 1.5\%$ ,  $DA \geq 55\%$ . Модель вважається якісною, якщо  $MAE \leq 1\%$ ,  $RMSE \leq 1.5\%$ ,  $DA \geq 60\%$ . Але навіть якщо  $DA = 51\%$  прогнозна модель може бути прибутковою, якщо є контроль ризику та обрана правильна стратегія. А при значеннях  $DA = 60\%$  стратегія може бути збитковою, якщо прибутки малі, а збитки високі.

Для інвестора важливо правильно вгадати напрямок руху ціни, отримати прибуток та не отримати велику просадку – зниження вартості інвестиційного портфеля, MDD. Тому у фінансах для інвестиційної стратегії найбільш важливими практично є DA, CR, MD та порівняння з Buy & Hold. Стратегія є ефективною, якщо її кумулятивна дохідність є вищою CR за benchmark, а метрики ризику – нижчими.

Таким чином, використання сукупності статистичних, фінансових та ризик-орієнтованих метрик забезпечує комплексне оцінювання якості прогнозних моделей і рекомендаційної системи, дозволяючи враховувати не лише точність прогнозу, але й ефективність, стабільність та ризиковість інвестиційної стратегії.

## **Висновки до розділу 2**

У другому розділі роботи було розглянуто нейромережеві моделі та методи надання рекомендацій на основі прогнозування поведінки акцій S&P 500.

Виявлено, що у задачах підтримки прийняття інвестиційних рішень застосування класичних підходів фільтрації інформації, до яких відносять колаборативну та контентно-орієнтовану фільтрацію, є обмеженим. Обґрунтовано використання knowledge-based підходу, який базується на використанні структурованих знань про фінансові активи та ринкові умови.

У межах даного підходу описано модель фільтрації інформації, у якій функція корисності інтегрує прогнозні оцінки фінансових часових рядів, кількісні показники ризику та якісні характеристики інформаційного фону. Це дозволяє

реалізувати багатокритеріальну оцінку інвестиційної привабливості активів на основі лінійної згортки критеріїв (дохідність, ризик, інформаційний фон), що забезпечує більш повне врахування факторів, які впливають на поведінку ринку, та підвищує обґрунтованість інвестиційних рішень. Формування інвестиційного портфеля здійснюється шляхом відбору активів із найвищими значеннями функції корисності, з урахуванням ресурсних обмежень інвестора. Для оцінки ефективності сформованого інвестиційного портфеля використовуються показники дохідності, ризику, коефіцієнт Шарпа та проводиться порівняння з ринковим бенчмарком S&P 500.

Розглянуто сучасні нейромережеві моделі для прогнозування часових рядів та обґрунтовано для розв'язання поставлених задач вибір моделей LSTM та Temporal Fusion Transformer. Поєднання LSTM як базової моделі та Temporal Fusion Transformer як більш сучасного підходу дозволяє забезпечити баланс між складністю, точністю та можливістю експериментального дослідження ефективності прогнозування часових рядів фінансових даних. Описано ключові метрики для оцінювання якості прогнозних моделей та ефективності рекомендаційної системи.

Проаналізовано методи аналізу текстових даних, зокрема FinBERT, DistilBERT та GPT-подібні моделі. Обґрунтовано вибір FinBERT як основної моделі для визначення тональності фінансових новин завдяки її спеціалізації на фінансовій термінології та оптимальному балансу між точністю та обчислювальними витратами. Проведений теоретичний аналіз створює підґрунтя для практичної реалізації рекомендаційної системи.

## 3 ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ТА НАВЧАННЯ НЕЙРОМЕРЕЖЕВИХ МОДЕЛЕЙ

### 3.1 Попередня обробка та формування набору даних

Для навчання прогнозних нейромережових моделей LSTM та TFT використано набір даних S&P 500 OHLCV Stock Data (<https://www.kaggle.com/datasets/jacksaleeby/s-and-p500-historical-data>), який містить історичні OHLCV-дані стосовно 472 акцій компаній, що входять до індексу S&P 500 (або входили історично), охоплює період даних: 2000-2026 роки, має обсяг понад 2,7 мільйона рядків. Дані є якісними, очищеними і не мають пропусків. Він забезпечує достатню глибину історії для вивчення довгострокових трендів, ринкових циклів та сезонних патернів.

З метою зменшення обчислювального навантаження та забезпечення репрезентативності ринкової динаміки з 472 доступних активів для навчання моделей було відібрано 24 компанії з різних секторів економіки (табл. 3.1). Такий підхід дозволяє охопити різні типи ринкової поведінки при збереженні обчислювальної ефективності моделювання.

Для розширення простору вхідних ознак і підвищення здатності моделей виявляти закономірності фінансового ринку на основі історичних OHLCV-даних було розраховано набір технічних індикаторів, що формують додаткові часові ряди ознак для кожного активу. Зокрема використано:

- *трендові індикатори*: SMA 20/50/200, EMA 12/26, MACD, смуги Боллінджера – для оцінки напряму та сили тренду;
- *осцилятори*: RSI (14, 20), стохастичний осцилятор, Williams %R, ROC – для виявлення зон перекупленості, перепроданості та швидкості зміни ціни;
- *індикатори волатильності*: ATR та історична волатильність за 30 днів – для оцінки інтенсивності цінових коливань;

– *індикатори обсягу*: OBV і MFI. – для аналізу взаємозв’язку між рухом ціни та торговим обсягом.

Таблиця 3.1 – Відібрані для навчання моделей акції індексу S&P 500

<b>Сектор</b>	<b>Тікери фінансових активів</b>
Технології	AAPL, MSFT, GOOGL, NVDA, AMD, INTC, ADBE, META
Споживчий сектор	WMT, HD, KO, PEP
Енергетика	XOM
Промисловість	GE
Фінанси	JPM, BAC, V, MA, GS
Охорона здоров’я	JNJ, PFE, UNH, ABBV

Усі технічні індикатори обчислювалися окремо для кожного активу з урахуванням хронологічного порядку та формували часові ряди ознак із щоденним кроком. Формули для розрахунку цих індикаторів наведено у додатку А. Розрахунок виконувався з використанням бібліотеки *ta* (technical analysis) та власних реалізацій на мові програмування Python у середовищі PyCharm (додаток Б). Загальна кількість вхідних ознак після розрахунку індикаторів склала 33.

Перед поданням даних на вхід нейромережевих моделей виконувалося робастне масштабування ознак на основі медіани та інтерквартильного розмаху (Interquartile Range, IQR), що забезпечує стійкість до викидів у фінансових часових рядах (додаток В). Масштабування здійснювалося з використанням класу *RobustScaler* бібліотеки *scikit-learn* за формулою:

$$X_{sc} = \frac{x - \text{median}(X)}{Q_3(X) - Q_1(X)}, \quad (3.1)$$

де:  $Q_1(X)$  та  $Q_3(X)$  – перший і третій квантілі відповідно.

Робастне масштабування не обмежує значення ознак фіксованим інтервалом, але приводить усі ознаки до порівнянного масштабу та виконується однаково для train/validation/test вибірок. Для уникнення витоку даних параметри масштабування обчислювалися виключно на навчальній вибірці та застосовувалися до валідаційної і тестової вибірок без повторного перенавчання.

Для уникнення витоку даних розподіл на навчальну (train), валідаційну (validation) та тестову (test) вибірки здійснювався з урахуванням хронологічного порядку без перемішування даних, що відповідає природі фінансових часових рядів. Для зменшення обчислювальної складності та часу навчання було використано історичні дані за період 2010-2026 років. Обраний період охоплює кілька ринкових циклів, кризових подій та фаз зростання і спаду ринку, що забезпечує достатню репрезентативність даних для навчання моделі. Співвідношення вибірок становило: train – 80%, validation – 10%, test – 10%. Навчальна вибірка використовувалася для оптимізації параметрів моделей, валідаційна – для налаштування гіперпараметрів та контролю перенавчання, а тестова – для фінальної оцінки прогностичної якості моделей.

Для вирішення задачі прогнозування поведінки акцій S&P 500 було реалізовано та порівняно дві нейромережеві архітектури: базову модель LSTM та трансформерну TFT-модель. Оцінювання якості прогнозування обох моделей виконувалося на однаковій тестовій вибірці, що дозволяє здійснювати порівняльний аналіз їх практичної ефективності.

### 3.2 Навчання моделі LSTM

Навчання моделі LSTM виконувалося у середовищі PyCharm на мові програмування Python із використанням Python-бібліотек numpy, pandas, matplotlib, torch, yfinance, та (Technical Analysis Library), scikit-learn [37].

Архітектура реалізованої LSTM-моделі включає згортковий шар TCN (Temporal Convolutional Network), який виконує попереднє вилучення локальних

часових патернів, після чого дані обробляються LSTM-шарами для моделювання довгострокових залежностей. Для підвищення здатності моделі фокусуватися на найбільш інформативних часових інтервалах після LSTM використано шар Multihead Attention. Модель має дві вихідні голови (dual-head): регресійну для прогнозування числового значення дохідності та класифікаційну для прогнозування напрямку руху ціни. Такий підхід реалізує багатозадачне навчання і дозволяє одночасно оптимізувати модель щодо точності прогнозу та правильності визначення ринкового тренду. Для зменшення ризику перенавчання застосовано шари Dropout.

Гіперпараметри, визначені шляхом підбору під час навчання моделі LSTM, наведено в таблиці 3.3. Для оптимізації моделі використано комбіновану функцію втрат, яка враховує одночасно якість прогнозування дохідності та точність визначення напрямку руху ціни. Загальна функція втрат визначається як зважена сума регресійної та класифікаційної складових:

$$L = \alpha L_{MSE} + (1 - \alpha) L_{BCE}, \quad (3.2)$$

де:  $\alpha$  – коефіцієнт балансування задач;

$L_{MSE}$  – середньоквадратична похибка регресійної голови моделі;

$L_{BCE}$  – функція бінарної крос-ентропії класифікаційної голови.

$L_{MSE}$  розраховують за формулою:

$$L_{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (3.3)$$

де:  $y_i$  – фактичне значення;

$\hat{y}_i$  – прогнозоване значення;

$n$  – кількість спостережень.

Для оцінювання якості класифікації напрямку руху використовується функція бінарної крос-ентропії:

$$L_{BCE} = -\frac{1}{n} \sum_{i=1}^n (y_i \log(\hat{y}_i) + (1 - \hat{y}_i) \log(1 - \hat{y}_i)), \quad (3.4)$$

де:  $y_i \in \{0,1\}$  – фактичний клас напрямку руху ціни;

$\hat{y}_i$  – прогнозована ймовірність належності до класу зростання.

У роботі використано значення  $\alpha = 0.4$ , що забезпечує співвідношення 40% ваги для регресійної складової та 60% для класифікаційної. Такий вибір обумовлений тим, що для практичного використання рекомендаційної системи правильне визначення напрямку руху активу є не менш важливим, ніж точність прогнозування числового значення дохідності.

Навчання моделі виконувалося на наборі даних S&P 500 OHLCV Stock Data (2010-2026 роки) із використанням оптимізатора Adam із початковою швидкістю навчання 0.001 та L2-регуляризацією (weight decay)  $1 \cdot 10^{-4}$ . Розмір батчу становив 64. Для підвищення стабільності навчання застосовувався кліппінг градієнтів на рівні 1.0, що дозволяє запобігати проблемі вибуху градієнтів.

Навчання виконувалося протягом максимум 100 епох із використанням механізму ранньої зупинки. Критерієм зупинки було покращення метрики Directional Accuracy (DA) на валідаційній вибірці. Значення параметра patience становило 20 епох, тобто навчання припинялося у разі відсутності покращення валідаційної метрики протягом двадцяти послідовних епох. Такий підхід дозволяє зменшити ризик перенавчання та забезпечити кращу узагальнюючу здатність моделі на нових даних.

На рисунку 3.1 наведено динаміку функції втрат на навчальній та валідаційній вибірках протягом навчання. Отриманий результат продемонстрував, що після 30-ї епохи спостерігаються ознаки перенавчання, які проявляються у зростанні Validation Loss при одночасному зменшенні Training Loss. З огляду на це

для подальшого дослідження використано модель, отриману на етапі до початку суттєвого розходження кривих, оскільки вона забезпечує найкращий баланс між якістю апроксимації навчальних даних та здатністю до узагальнення.

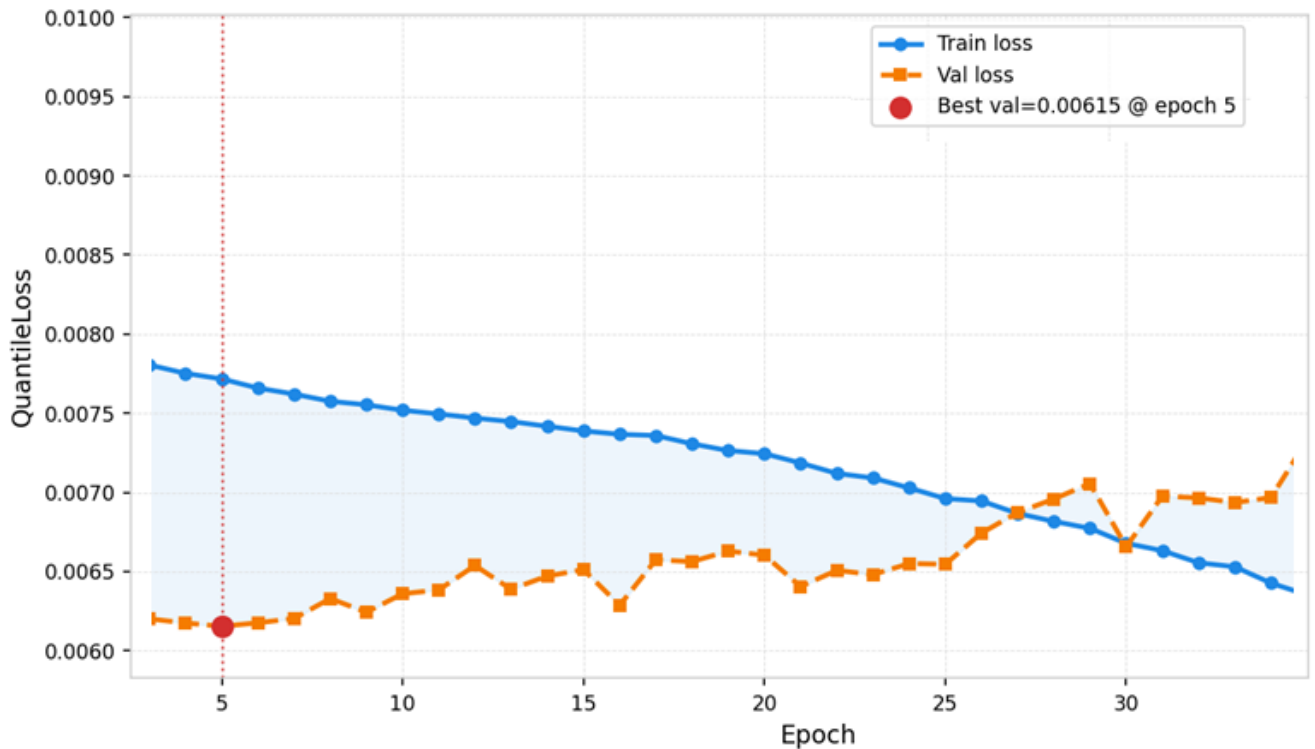


Рисунок 3.1 – Функція втрат для LSTM моделі на навчальній та валідаційній вибірках

### 3.3 Навчання моделі Temporal Fusion Transformer

Реалізацію TFT-моделі виконано з використанням бібліотеки PyTorch Forecasting та фреймворку PyTorch Lightning, що забезпечує ефективну організацію процесу навчання та експериментів. Вхідними даними для моделі є мультисерійний часовий ряд, де кожна серія відповідає окремому тікеру компанії з індексу S&P 500.

Прогнозування виконується для цільової змінної  $target_t$  – одноденної логарифмічної дохідності, що розраховується за формулою:

$$target_t = \ln \left( \frac{Close_{t+1}}{Close_t} \right), \quad (3.5)$$

де:  $Close_t$  та  $Close_{t+1}$  – ціни закриття активу у поточний та наступний торговий день відповідно.

Архітектура моделі TFT включає наступні основні компоненти:

- *Variable Selection Network (VSN)* – виконує адаптивне зважування вхідних ознак та визначає їхню важливість для прогнозування;
- *LSTM-енкодер і декодер* – моделюють коротко- та середньострокові часові залежності у фінансових рядах;
- *Gated Residual Networks (GRN)* – забезпечують нелінійне перетворення ознак із механізмом гейтінгу;
- *Multi-Head Attention (4 голови)* – дозволяє моделі виявляти довгострокові залежності між віддаленими у часі подіями;
- *Quantile Output Layer* – формує прогноз розподілу у вигляді набору квантилів;
- *інтерпретаційний модуль* – забезпечує оцінку важливості ознак та пояснюваність прогнозів.

Гіперпараметри TFT, визначені експериментально, наведено у таблиці 3.2.

TFT оптимізує квантильну функцію втрат, що дозволяє прогнозувати не лише очікуване значення, але й невизначеність прогнозу. Для кожного квантиля  $q \in Q$ , де  $Q = \{0.05, 0.1, 0.25, 0.5, 0.75, 0.9, 0.95\}$  втрата визначається за формулою:

$$L_q(y, \hat{y}_q) = \max(q(y - \hat{y}_q), (q - 1)(y - \hat{y}_q)), \quad (3.6)$$

де:  $y$  – фактичне значення дохідності;  $\hat{y}_q$  – прогноз для квантиля  $q$ .

Загальна функція втрат  $L$  є середнім арифметичним значенням втрат за всіма квантилями.

Таблиця 3.2 – Гіперпараметри моделі TFT

Параметр	Значення	Опис
max_encoder_length	60 днів	Довжина історичного вікна (lookback)
max_prediction_length	5 днів	Максимальний горизонт прогнозу
hidden_size	64	Розмір прихованого шару LSTM
attention_head_size	4	Кількість голів уваги
dropout	0.2	Ймовірність випадкового вимкнення нейронів (регуляризація)
hidden_continuous_size	32	Розмір шару для безперервних ознак
learning_rate	0.0005	Швидкість навчання
batch_size	128	Розмір батчу
gradient_clip	0.1	Кліппінг градієнтів для стабілізації навчання
patience	20	Кількість епох без покращення для early stopping

Модель використовує три групи вхідних ознак: *статичні категоріальні ознаки* – ідентифікатор компанії (ticker); *часозалежні відомі ознаки* – календарні змінні (день тижня, місяць, торгові календарні ефекти); *часозалежні невідомі ознаки* – історичні ціни, дохідності, технічні індикатори (RSI, MACD, ATR, Bollinger Bands position тощо), значення яких доступні лише до моменту прогнозу.

Для навчання використано оптимізатор AdamW, який поєднує адаптивну швидкість навчання з коректною L2-регуляризацією (weight decay), що є особливо ефективним для роботи з шумними фінансовими часовими рядами. Для запобігання перенавчанню та стабілізації процесу навчання використано наступні механізми: Dropout 0,2 у всіх основних шарах моделі; Early stopping з пацієнтністю 20 епох; кліппінг градієнтів на рівні 0,1; оптимізатор AdamW з початковою

швидкістю навчання 0,0005 та спадом ваги. Додаткове зменшення швидкості навчання при досягненні плато не застосовувалося.

Для моніторингу навчання моделі TFT на GPU було використано TensorBoard. На рисунку 3.2 наведено динаміку функції втрат на навчальній та валідаційній вибірках протягом навчання. Отриманий результат продемонстрував стабільну збіжність без ознак перенавчання, оскільки валідаційна втрата зменшується разом з тренувальною. Механізм early stopping зупинив навчання після досягнення плато.




Рисунок 3.2 – Функція втрат для TFT моделі на навчальній та валідаційній вибірках

### 3.4 Аналіз прогностичної якості навчених нейромережевих моделей

Результати порівняльного аналізу моделей LSTM та TFT на тестовій вибірці для горизонту прогнозу один торговий день наведено в таблиці 3.3.

Таблиця 3.3 – Порівняння якості прогнозування моделей LSTM та TFT

<b>Метрика</b>	<b>LSTM</b>	<b>TFT</b>	<b>Інтерпретація</b>
MAE (%)	0.97%	0.81%	TFT точніша на 0.66%
RMSE (%)	1.6%	1.34%	TFT стабільніша
DA (%)	53.52%	54.73%	TFT краще вгадує напрямок руху (вище випадкового 50%)
Cumulative Return	+18.6%	+40.5%	TFT приносить більший прибуток
MDD	21.8%	16.8%	TFT має меншу максимальну просадку (ризик)

Як видно з отриманих результатів, модель TFT перевершує LSTM за всіма основними показниками якості прогнозування. Зокрема, TFT демонструє менші значення MAE та RMSE, що свідчить про вищу точність прогнозування дохідності. Показник DA також є вищим, що вказує на кращу здатність моделі визначати напрямок зміни ціни активу. Окрім прогнозних метрик, TFT забезпечує кращі результати з точки зору практичного використання в інвестиційних стратегіях. На тестовій вибірці модель сформувала вищу кумулятивну дохідність Cumulative Return та меншу максимальну просадку MDD, що свідчить про більш сприятливе співвідношення прибутковості та ризику порівняно з моделлю LSTM.

На рисунку 3.3 представлено порівняння кривих капіталу та показника ризику MDD, сформованих на основі прогнозів моделі LSTM та базової інвестиційної стратегії Buy & Hold. На рисунках 3.4 та 3.5 представлено порівняння кривих капіталу та показника ризику MDD, сформованих на основі прогнозів моделі TFT та базової інвестиційної стратегії Buy & Hold. Отримані результати підтверджують доцільність використання архітектури Temporal Fusion Transformer для прогнозування фінансових часових рядів.

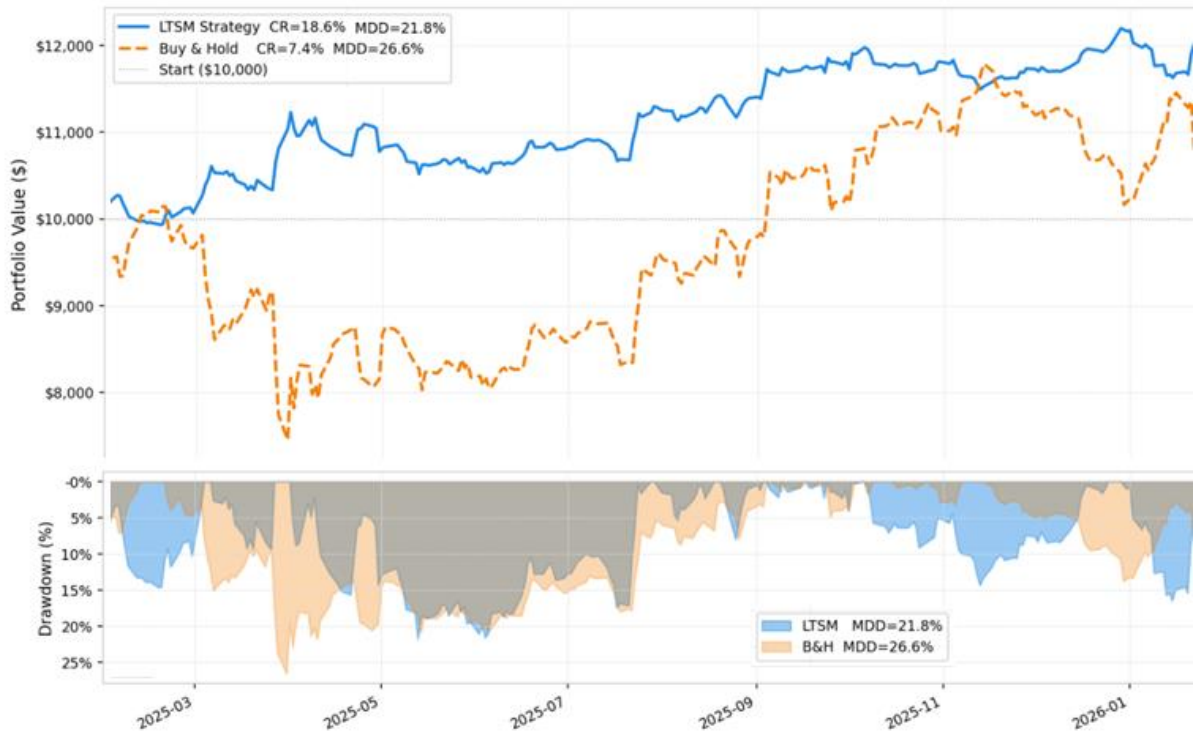


Рисунок 3.3 – Порівняння кривих капіталу та MDD для LSTM-стратегії і Buy & Hold на тестовій вибірці

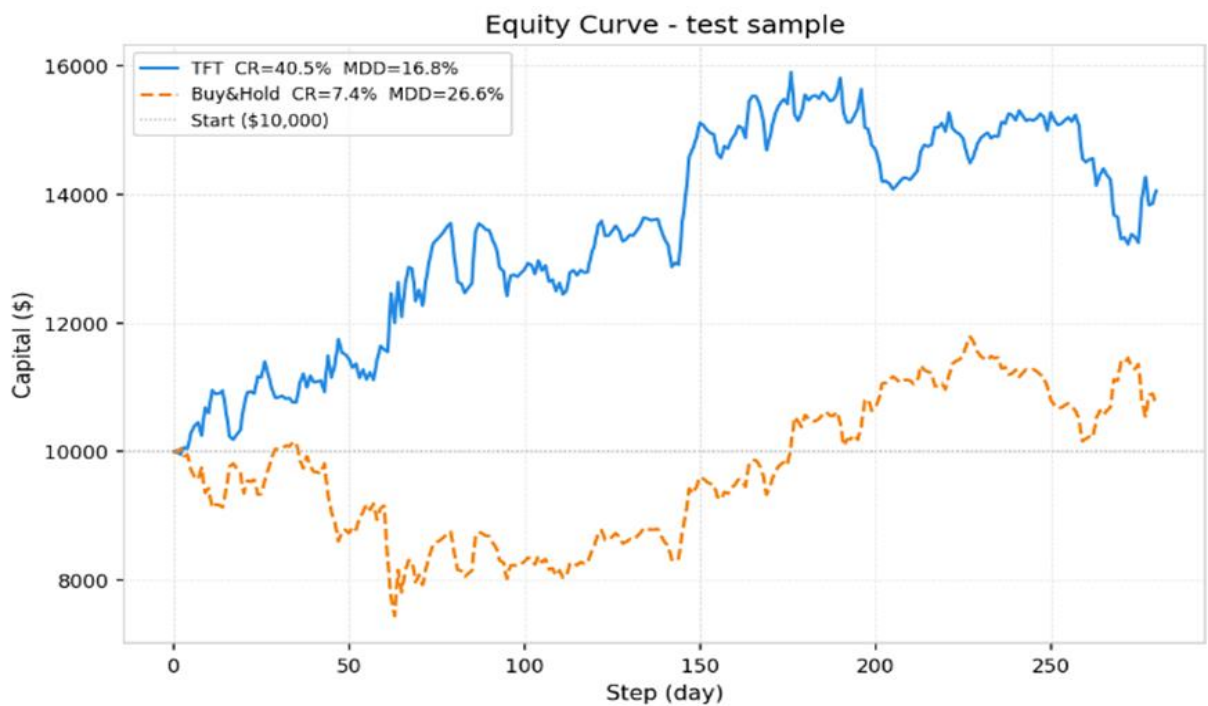


Рисунок 3.4 – Порівняння кривих капіталу для TFT-стратегії і Buy & Hold на тестовій вибірці




Рисунок 3.5 – Порівняння ризику за метрикою MDD для TFT-стратегії і Buy & Hold на тестовій вибірці

Модель TFT продемонструвала такі результати на тестовій вибірці: DA = 54,73%, MAE = 0,81%, MDD = 16,8% та Cumulative Return = +40,5%. Стратегія Buy & Hold забезпечила кумулятивну дохідність Cumulative Return=+7,4% при максимальній просадці MDD=26,6%. Це свідчить про здатність моделі TFT ефективно визначати напрямок руху ринку та формувати інвестиційні сигнали, які забезпечують вищу дохідність за нижчого рівня ризику порівняно з пасивною інвестиційною стратегією.

З огляду на перевагу моделі TFT над LSTM за прогнозними метриками, а також над стратегією Buy & Hold за показниками дохідності та ризику, саме модель TFT було інтегровано до вебзастосунку рекомендаційної системи як основний модуль прогнозування.

Для додаткової оцінки отриманих результатів проведено порівняння з дослідженнями, представленими у науковій літературі. Аналіз виконувався за показниками точності прогнозування та визначення напрямку руху ціни на даних

фондового ринку США. Результати порівняння підтверджують конкурентоспроможність розробленого підходу. Архітектура TFT, яка поєднує механізми уваги, рекурентні компоненти LSTM та адаптивний механізм відбору ознак, забезпечує ефективне виявлення довгострокових часових залежностей, що узгоджується з висновками робіт [13, 14, 38].

Отримане значення  $DA=54,73\%$  є прийнятним для періоду підвищеної волатильності фондового ринку у 2024-2025 роках та є порівняним із результатами сучасних моделей прогнозування, наведеними в роботі [13]. Це свідчить про здатність моделі зберігати якість прогнозування навіть в умовах нестабільної ринкової кон'юнктури. Отримані результати також узгоджуються з висновками робіт [13, 14, 15, 39], у яких показано перевагу Transformer-архітектур над класичними рекурентними нейронними мережами за показниками точності прогнозування фінансових часових рядів.

Таким чином, проведений аналіз показав, що модель TFT забезпечує найкращу якість прогнозування серед досліджених підходів та може ефективно використовуватися як складова рекомендаційної системи підтримки інвестиційних рішень.

### **Висновки до розділу 3**

У третьому розділі проведено експериментальне дослідження та навчання нейромережових моделей прогнозування фінансових часових рядів. Для навчання моделей сформовано набір даних на основі історичних OHLCV-даних акцій компаній індексу S&P 500 та розрахованих технічних індикаторів. Реалізовано та досліджено нейромережові моделі прогнозування: LSTM та TFT. Для кожної моделі визначено архітектуру, підібрано гіперпараметри та виконано навчання на історичних фінансових даних. Модель LSTM використовувала комбіновану функцію втрат для одночасного прогнозування дохідності та напрямку руху ціни,

модель TFT забезпечувала багатofакторне прогнозування часових рядів із використанням механізмів уваги та адаптивного відбору ознак.

Оцінювання якості моделей виконувалося за метриками MAE, RMSE, Directional Accuracy, Cumulative Return та Maximum Drawdown. Результати експериментів показали, що модель TFT перевершує LSTM за всіма основними показниками якості прогнозування, забезпечуючи вищу точність, кращу здатність визначати напрямок руху ринку та більш сприятливе співвідношення дохідності й ризику. Крім того, модель TFT продемонструвала перевагу над базовою інвестиційною стратегією Buy & Hold за показниками кумулятивної дохідності та максимальної просадки. Отримані результати підтвердили доцільність використання моделі TFT для прогнозування фінансових часових рядів. З огляду на її вищу прогностичну якість модель TFT була обрана як основний модуль прогнозування для подальшої інтеграції до рекомендаційної системи підтримки інвестиційних рішень.

## 4 МОДЕЛЮВАННЯ, ПРОЄКТУВАННЯ ТА ПРОГРАМНА РЕАЛІЗАЦІЯ РЕКОМЕНДАЦІЙНОЇ СИСТЕМИ

### 4.1 Моделювання та проєктування рекомендаційної системи

На етапі моделювання рекомендаційної системи підтримки прийняття інвестиційних рішень було сформовано основні сценарії використання та описано логіку взаємодії інвестора з системою. Це дозволило чітко визначити функціональні вимоги до неї та структурувати її внутрішні процеси.

Рекомендаційна система орієнтована на інвесторів, які прагнуть підвищити ефективність управління капіталом шляхом отримання обґрунтованих сигналів типу «купити» / «тримати» / «продати». Користувач взаємодіє із системою через графічний інтерфейс вебзастосунку: переглядає поточні котирування, аналізує прогнози нейромережових моделей, налаштовує власний профіль ризику та отримує підсумкові рекомендації щодо портфеля. Для формалізації взаємодії користувача з системою розроблено діаграму прецедентів (рис. 4.1).

Діаграма прецедентів містить одного основного актора – інвестора (Investor), який взаємодіє з вебзастосунком, та двох допоміжних акторів – Yahoo Finance API і Financial News Sources, що виступають зовнішніми джерелами ринкових даних і фінансових новин [40]. Отримана від них інформація використовується для аналізу активів, прогнозування їх дохідності, аналізу настрою та формування інвестиційних рекомендацій.

Усі прецеденти можна поділити на дві групи: ті, що ініціюються користувачем (інтерактивні), та ті, що виконуються системою автоматично (обчислювальні бекенд-процеси). Це підкреслює автономність аналітичного ядра та мінімальне навантаження на користувача щодо ручної обробки даних.

*Use case 1: завантаження ринкових даних.* Система автоматично отримує історичні та поточні біржові дані через Yahoo Finance API про фінансові активи, налаштовані по замовчуванню при початковому відкритті та обрані користувачем

при повторному користуванні системою. Завантажені дані відображає їх у вигляді watch-листа та використовуються для подальшого аналізу, прогнозування та оцінювання інвестиційної привабливості активів.

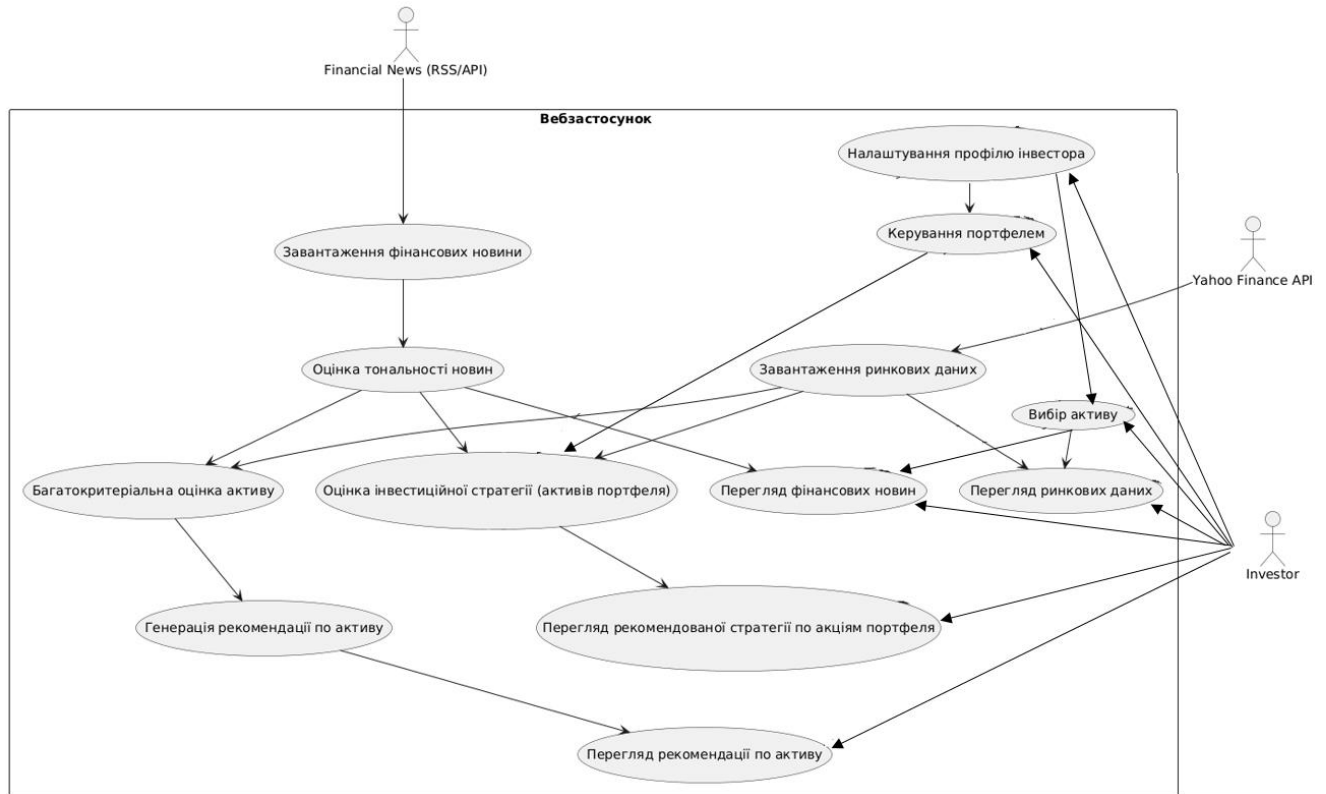


Рисунок 4.1 – Діаграма прецедентів рекомендаційної системи

*Use case 2: завантаження фінансових новин.* Система автоматично отримує фінансові новини із зовнішніх інформаційних джерел: RSS-стрілок Reuters, Bloomberg, Yahoo Finance для налаштованих активів. Отримані новини використовуються для визначення інформаційного фону та подальшого аналізу тональності.

*Use case 3: вибір активу.* Інвестор обирає фінансовий актив для аналізу. Після вибору система надає доступ до ринкових даних, фінансових новин та інвестиційних рекомендацій щодо обраного активу.

*Use case 4: перегляд ринкових даних.* Користувач переглядає актуальні та історичні дані щодо обраного активу (наприклад, AAPL, MSFT, NVDA), включаючи графіки цін, обсяги торгів та інші ринкові показники.

*Use case 5: оцінка тональності новин.* Паралельно з прогнозуванням цін система надсилає заголовки та анотації фінансових новин з RSS-стрілок Reuters, Bloomberg, Yahoo Finance до мікросервісу FinBERT. Модель NLP повертає ймовірності позитивної, негативної та нейтральної тональності, які агрегуються у денні показники настрою.

*Use case 6: перегляд фінансових новин.* Інвестор отримує доступ до актуальних фінансових новин та результатів аналізу їхньої тональності для обраного активу.

*Use case 7: багатокритеріальна оцінка активу.* Система ініціює виклик Python-скрипту з моделлю TFT, яка на основі історичних цін OHLCV-даних розраховує технічні індикатори та будує прогноз ціни на 1-5 днів вперед. Також система виконує інтегральне оцінювання інвестиційної привабливості активу на основі прогнозованої доходності, ризику та новинного настрою. Підсумкова оцінка визначається за допомогою функції корисності з ваговими коефіцієнтами, які враховують профіль інвестора.

*Use case 8: генерація рекомендації по активу.* На основі результатів багатокритеріальної оцінки система формує рекомендацію щодо активу типу BUY (рекомендовано купівлю), HOLD (утримувати актив) або SELL (рекомендовано продаж).

*Use case 9: перегляд рекомендації по активу.* Користувач переглядає сформовану рекомендацію та супровідну аналітичну інформацію, що пояснює причини її формування (Explainable AI).

*Use case 10: керування портфелем.* Інвестор формує та редагує власний інвестиційний портфель, визначаючи перелік активів для подальшого аналізу та моніторингу.

*Use case 11: оцінка інвестиційної стратегії (активів портфеля).* Система автоматично виконує оцінювання ефективності портфеля та інвестиційної стратегії з використанням показників доходності, ризику, коефіцієнта Шарпа, максимальної

просадки та інших фінансових метрик, а також відображає криву капіталу у порівнянні з бенчмарком S&P 500.

*Use case 12: перегляд рекомендованої стратегії по акціях портфеля.* Користувач переглядає результати оцінювання портфеля, рекомендації щодо окремих активів, узагальнену інформацію про ефективність інвестиційної стратегії та зведену таблицю всіх активів свого портфеля (ціна, зміна за день, TFT-прогноз, рівень довіри, підсумковий сигнал).

*Use case 13: налаштування профілю інвестора.* Інвестор налаштовує власний інвестиційний профіль, визначаючи співвідношення між очікуваною дохідністю, ризиком та впливом новинного фактору. Є можливість обрати один із п'яти попередньо визначених профілів ризику (агресивний, помірний, консервативний тощо) або плавно налаштувати власний профіль. Також у разі потреби змінює набір акцій у портфелі, стартовий капітал, джерела новин, горизонт прогнозу, налаштовує пороги спрацьовування сигналів (BUY/ HOLD/ SELL). Задані параметри використовуються системою під час формування персоналізованих рекомендацій та оцінювання активів

На етапі проєктування розроблено діаграму діяльності рекомендаційної системи (рис. 4.2). Діаграма діяльності відображає послідовність взаємодії інвестора з рекомендаційною системою та внутрішні процеси обробки даних, необхідні для формування інвестиційних рекомендацій. Процес починається з вибору користувачем фінансового активу або формування інвестиційного портфеля через вебінтерфейс системи.

Після надходження запиту система автоматично виконує завантаження актуальних ринкових даних із сервісу Yahoo Finance API та фінансових новин із зовнішніх інформаційних джерел. На основі отриманих даних здійснюється прогнозування майбутньої дохідності активу за допомогою моделі Temporal Fusion Transformer (TFT), а новинні повідомлення передаються до моделі FinBERT для визначення їх тональності та розрахунку показника ринкового настрою.

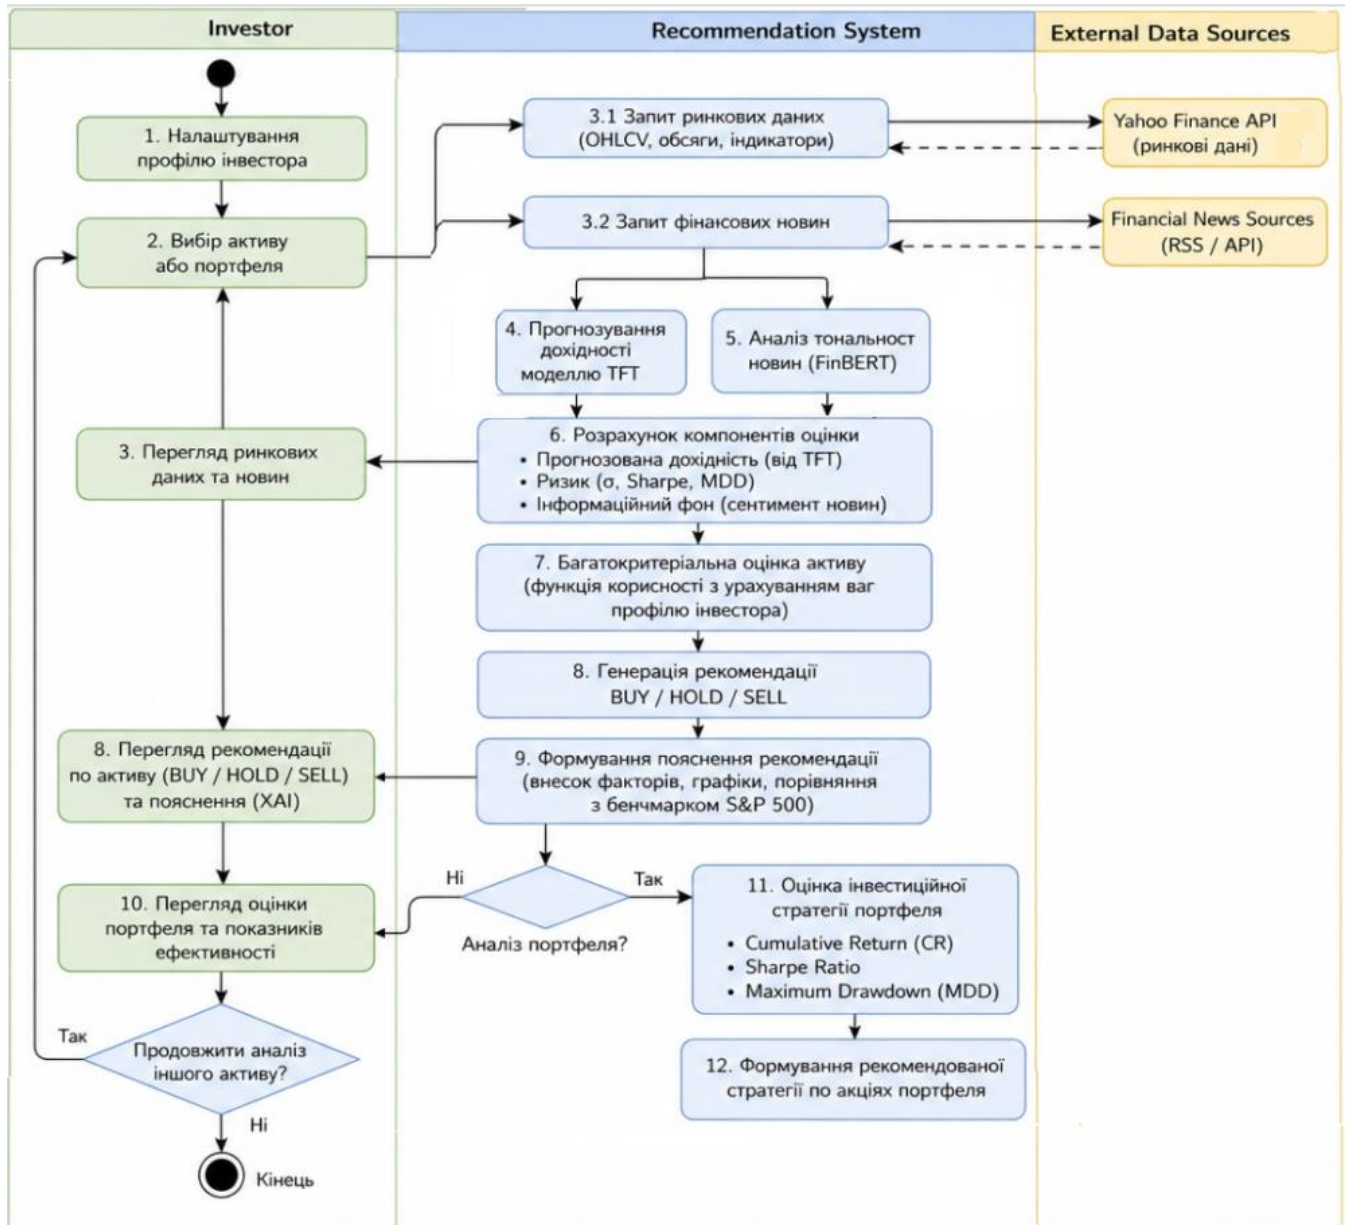


Рисунок 4.2 – Діаграма діяльності

Результати прогнозування та аналізу новин разом із показниками ризику використовуються в модулі багатокритеріальної оцінки активів. На цьому етапі система враховує індивідуальні параметри профілю інвестора, зокрема вагові коефіцієнти критеріїв дохідності, ризику та інформаційного фону. На основі розрахованої функції корисності виконується ранжування активів та формується інвестиційна рекомендація щодо купівлі, утримання або продажу активу. Сформовані рекомендації передаються користувачеві разом із поясненнями

результатів роботи моделі, прогнозними показниками, характеристиками ризику та візуалізацією ефективності інвестиційної стратегії. Для портфельного аналізу система додатково здійснює оцінювання ефективності портфеля за фінансовими метриками дохідності та ризику з порівнянням отриманих результатів із базовою стратегією Buy & Hold та ринковим індексом S&P 500.

Таким чином, діаграма діяльності відображає повний цикл функціонування рекомендаційної системи – від отримання зовнішніх даних та їх інтелектуальної обробки до формування персоналізованих інвестиційних рекомендацій і оцінювання ефективності прийнятих рішень.

Під час моделювання інформаційної системи також було розроблено високорівневу архітектуру системи, яка була деталізована на етапі проектування. Для роботи рекомендаційної системи передбачено використання трьох рівнів: рівень представлення (Frontend на Razor Pages + Chart.js), рівень бізнес-логіки та рівень даних і ML-моделей (Python-моделі TFT та FinBERT, зовнішні API Yahoo Finance та RSS). Взаємодія між рівнями організована через асинхронні HTTP-запити та виклик зовнішніх процесів.

Таким чином, визначено основні сценарії використання, послідовність взаємодії інвестора з рекомендаційною системою та внутрішні процеси обробки даних, а також ключові етапи обробки ринкових даних та формування інвестиційної рекомендації. Побудовані діаграма прецедентів і діаграма діяльності дозволяють наочно відобразити структуру і логіку роботи системи, що спрощує її подальшу реалізацію та тестування.

## 4.2 Інструментальні засоби розробки

Для реалізації *серверної частини* вебзастосунку рекомендаційної системи було використано мову програмування C# у складі кросплатформеного фреймворку ASP.NET Core MVC на платформі .NET 8. Цей вибір обумовлений перерахованими нижче факторами.

1. *Інтеграція з ML-моделями.* Незважаючи на те, що основні моделі глибокого навчання (LSTM, TFT) реалізовано на Python з використанням бібліотек PyTorch та PyTorch Forecasting, C# забезпечує ефективну взаємодію з Python-скриптами через виклик зовнішніх процесів System.Diagnostics.Process та обмін даними у форматі JSON. Це дозволяє використовувати переваги Python для наукових обчислень та C# для побудови надійної вебархітектури.

2. *Продуктивність та масштабованість.* ASP.NET Core є високопродуктивним фреймворком, який забезпечує обробку сотень паралельних запитів із низьким часом відповіді ( $\leq 100$  мс). Асинхронна модель програмування (async/await) дозволяє ефективно працювати з операціями введення-виведення (запити до Yahoo Finance, HTTP-виклики до FinBERT мікросервісу).

3. *Крос-платформеність.* Платформа .NET 8 працює на операційних системах Windows, Linux та macOS, що забезпечує гнучкість при розгортанні системи на сервері або в контейнерах Docker.

4. *Розвинена екосистема.* Наявність бібліотек для кешування – IMemoryCache, роботи з JSON – Newtonsoft.Json, System.Text.Json, HTTP-клієнта IHttpConnectionFactory та вбудованої системи логування ILogger суттєво прискорює розробку.

Альтернативні варіанти фреймворків FastAPI та Django на Python були розглянуті, але відхилені. FastAPI, хоч і забезпечує високу продуктивність, не має вбудованих механізмів для роботи з RSS-стрічками та HTML-сторінками (Server-Side Rendering). Django, навпаки, є надто важким фреймворком для задачі, яка потребує тісної інтеграції з ML-моделями та частими зовнішніми HTTP-викликами.

Для реалізації *клієнтської частини* вебзастосунку рекомендаційної системи було обрано підхід Server-Side Rendering (SSR) із використанням механізму Razor Pages у складі ASP.NET Core MVC, доповнений динамічними компонентами на чистому JavaScript (ES6+) та бібліотекою Chart.js для візуалізації даних.

Такий вибір обумовлений наступними чинниками:

- *спрощення архітектури*: відсутність необхідності розгортати окремий фронтенд-сервер (Node.js) та підтримувати два незалежних репозиторії зменшує складність розробки та розгортання;
- *SEO-оптимізація*: SSR забезпечує повне відображення контенту на стороні сервера, що важливо для індексації сторінок пошуковими системами;
- *інтерактивність*: для побудови графіків, динамічного оновлення даних та реалізації зум-функцій було використано бібліотеку Chart.js (версія 4.4.1) із плагіном chartjs-plugin-zoom (версія 2.0.1), що обумовлено простотою інтеграції, малою вагою та зручним API для створення лінійних графіків, стовпчикових діаграм та гістограм розподілу дохідностей;
- *стилізація*: виконана з використанням чистого CSS із підтримкою темної теми, основні класи стилів (.pf-card, metrics-g, .port-chip, .sig-table) розроблені вручну з урахуванням вимог до адаптивності.

Альтернативні фреймворки React, Vue.js та Angular були відхилені через надмірну складність для задачі, яка не потребує складного керування станом на клієнті Redux/Vuex та маршрутизації. Крім того, використання React значно збільшило б час початкового завантаження сторінки через необхідність завантаження великих JavaScript-бандлів.

### 4.3 Реалізація архітектури та модульної структури системи

Під час розробки рекомендаційної системи використано модульний підхід, який передбачає розділення функціональності на незалежні компоненти, кожен з яких відповідає за виконання окремого завдання. Такий підхід спрощує супровід програмного забезпечення, забезпечує можливість масштабування системи та дозволяє модернізувати окремі компоненти без впливу на інші частини застосунку.

*Архітектура системи* реалізована за трирівневою схемою та включає рівень представлення (Frontend), рівень бізнес-логіки (Backend) та рівень даних і моделей машинного навчання (Data & ML Layer).

У структурі системи виділено такі *функціональні модулі*:

- модуль збору ринкових даних;
- модуль збору та аналізу фінансових новин;
- модуль прогнозування дохідності активів;
- модуль формування інвестиційних рекомендацій;
- модуль керування налаштуваннями користувача;
- модуль візуалізації результатів.

*Рівень представлення.* Клієнтська частина реалізована у вигляді вебінтерфейсу на основі HTML та Razor Pages. Користувач має можливість переглядати ринкові дані, обирати акції для аналізу, налаштовувати вагові коефіцієнти критеріїв оцінювання та отримувати інвестиційні рекомендації. Динамічна взаємодія з сервером (наприклад, перемикання вкладок, зміна прогнозу при зміні горизонту) реалізована засобами JavaScript та асинхронних AJAX-запитів до серверних контролерів без повного перезавантаження сторінки.

*Рівень бізнес-логіки.* Серверна частина реалізована на платформі ASP.NET Core MVC та складається з набору сервісів, кожен з яких відповідає за окремий функціональний модуль системи (табл. 4.1).

*Рівень даних та ML-моделей* включає:

- *зовнішні джерела даних:* Yahoo Finance API, RSS-стрілки фінансових видань;
- *модель прогнозування TFT:* реалізована на Python із використанням бібліотек PyTorch та Pytorch Forecasting;
- *мікросервіс аналізу тональності FinBERT:* реалізований на Flask;
- *файл параметрів масштабування scaler\_params.npz,* який містить медіани та інтерквартильні розмахи IQR, використані під час масштабування вхідних ознак.

Модель TFT навчена на історичних даних 24 компаній індексу S&P 500 за період 2010-2026 років та збережена у файлі Forecast.pt. Взаємодія із моделлю здійснюється через сервіс TFTService, який запускає зовнішній Python-процес та отримує результати прогнозування у форматі JSON.

Таблиця 4.1 – Сервіси рівня бізнес-логіки системи

Назва сервісу	Призначення	Ключові методи
StockService	Отримання котирувань акцій з Yahoo Finance, побудова історичних рядів цін (OHLCV)	GetQuoteAsync(), GetMultipleQuotesAsync()
NewsScraperService	Парсинг RSS-стрічок фінансових видань (Reuters, Bloomberg, MarketWatch), фільтрація новин за символом	GetNewsAsync(), GetWeeklySentimentAsync()
FinBertService	Взаємодія з мікросервісом FinBERT для аналізу тональності текстів, fallback на ключовий аналіз при недоступності	AnalyzeAsync(), AnalyzeNewsAsync()
TFTService	Запуск Python-скрипту tft_predict.py з передачею цінкових рядів та sentiment-оцінок, парсинг JSON-відповіді	PredictAsync(), PredictMultipleAsync()
RecommendationService	Розрахунок функції корисності ( $w_1 \cdot \text{return} - w_2 \cdot \text{risk} + w_3 \cdot \text{sentiment}$ ), Генерація сигналів BUY/HOLD/SELL	GenerateAsync(), BuildRecommendation()
UserSettingsService	Збереження та завантаження налаштувань користувача (ваги, список символів, джерела новин) у файл user_settings.json	Get(), Save(), ResetToDefaults()

Модель FinBERT розгорнута як окремий мікросервіс на базі Flask. Сервіс отримує текст новини через HTTP POST-запит, виконує аналіз тональності та

повертає ймовірності класів *positive*, *neutral* та *negative*. У випадку недоступності сервісу система автоматично переходить у режим резервного аналізу тональності на основі ключових слів, що забезпечує безперервність роботи застосунку.

*Взаємодія модулів системи* під час обробки типового запиту користувача (наприклад, отримання прогнозу для портфеля) здійснюється таким чином. Після натискання користувачем кнопки «Оновити портфель» браузер надсилає GET-запит до контролера `PortfolioController.Index`. Далі модуль збору ринкових даних через сервіс `StockService`, викликаючи `StockService.GetMultipleQuotesAsync()`, отримує актуальні котирування акцій із Yahoo Finance та кешує їх на п'ять хвилин для зменшення навантаження на зовнішнє API.

Паралельно модуль збору та аналізу новин за допомогою сервісу `NewsScraperService`, викликаючи `NewsScraperService.GetNewsAsync()`, отримує актуальні публікації з RSS-стрічок фінансових видань і передає їх до `FinBertService` (викликаючи `FinBertService.AnalyzeNewsAsync()`) для визначення тональності. Результатом роботи модуля є числова оцінка інформаційного фону для кожного активу.

Після цього модуль прогнозування викликає сервіс `TFTService` (`TFTService.PredictAsync()`), який формує вхідні дані у форматі JSON, запускає Python-скрипт `tft_predict.py`, передає дані через `stdin` та зчитує результат з `stdout`, отримуючи прогноз майбутньої дохідності. Отримані результати кешуються на 15 хвилин.

На основі прогнозованої дохідності, оцінки ризику та показника тональності модуль формування рекомендацій через `RecommendationService` (контролер викликає `RecommendationService.GenerateAsync()`) обчислює для кожної акції значення функції корисності та генерує інвестиційний рекомендаційний сигнал типу BUY, HOLD або SELL.

Сформовані результати передаються до `PortfolioViewModel` та відображаються у вебінтерфейсі у вигляді HTML-сторінки, згенерованої Razor.

Модуль візуалізації на стороні клієнта JavaScript за допомогою бібліотеки Chart.js будує графіки динаміки цін, кривої капіталу та просадки портфеля.

Запропонована архітектура забезпечує високий рівень модульності, масштабованості та відмовостійкості. Наприклад, при недоступності FinBERT система продовжує працювати з використанням fallback-алгоритму. Розділення вебзастосунку (ASP.NET Core) і моделей машинного навчання (Python) дозволяє незалежно оновлювати, перенавчати та модифікувати нейромережеві моделі без внесення змін до основної логіки рекомендаційної системи.

#### **4.4 Програмна реалізація функціональних модулів**

Програмна реалізація рекомендаційної системи виконана відповідно до модульної архітектури, описаної у попередньому підрозділі. Основні функціональні можливості системи реалізовано у вигляді незалежних програмних модулів, кожен з яких відповідає за окремий етап обробки даних, прогнозування та формування інвестиційних рекомендацій. Такий підхід спрощує супровід системи, забезпечує можливість незалежного оновлення окремих компонентів та підвищує її масштабованість.

**1. Реалізація модуля збору ринкових даних.** Модуль збору ринкових даних реалізовано у вигляді сервісу StockService, який забезпечує отримання історичних та поточних котирувань акцій із сервісу Yahoo Finance. Для безкоштовного програмного доступу до котирувань з Yahoo Finance використано бібліотеку ufinance. Перевагами її використання є: отримання даних за будь-який період (1 день – 10+ років); автоматичне оновлення цін у реальному часі (з затримкою до 15 хв для безкоштовного доступу); підтримка широкого спектру тікерів, включаючи індекс S&P 500; відсутність необхідності зберігати та оновлювати власну базу даних.

Основними методами сервісу є GetQuoteAsync() та GetMultipleQuotesAsync(). Під час виконання запиту сервіс формує унікальний ключ кешування та перевіряє

наявність даних у IMemoryCache. За відсутності актуальних даних виконується HTTP-запит до Yahoo Finance з подальшою обробкою JSON-відповіді. Для десеріалізації використовується бібліотека `Newtonsoft.Json`, а необхідні значення цін, обсягів торгів та часових міток витягуються зі структури `chart.result[0]`.

Результатом роботи сервісу є об'єкт `StockQuote`, який містить поточну ціну активу, історичний ряд котирувань, торгові обсяги та додаткові ринкові показники. Для підвищення відмовостійкості системи реалізовано механізм `GenerateMockQuote()`, що дозволяє генерувати синтетичні дані у випадку тимчасової недоступності зовнішнього джерела.

**2. Реалізація модуля збору та обробки фінансових новин.** Отримання та попередня обробка фінансових новин реалізовані у сервісі `NewsScraperService`. Джерелами інформації виступають RSS-стрічки Yahoo Finance, Reuters, Bloomberg та MarketWatch. Фільтрація новин відбувається за назвами статей, біржовим символом акції (наприклад, AAPL), назвою компанії («Apple») тощо.

Основними методами сервісу є `GetNewsAsync()` та `GetWeeklySentimentAsync()`. Під час роботи модуль завантажує RSS-документи, виконує їх розбір за допомогою `XDocument.Parse()`, вилучає заголовки, анотації, посилання та дати публікації новин. Після цього здійснюється фільтрація повідомлень за біржовим символом компанії, видалення дублікатів та відбір новин за останні сім днів. Використання семиденного вікна збору новин обумовлене короткостроковим характером впливу інформаційного фону на поведінку фінансових активів. Новини більшого віку поступово втрачають актуальність і мають значно менший вплив на поточну ринкову динаміку.

Для забезпечення безперервності роботи системи реалізовано механізм `GenerateMockNews()`, який дозволяє формувати тестовий набір новин у випадку недоступності зовнішніх інформаційних ресурсів.

**3. Реалізація модуля аналізу тональності фінансових новин.** Для визначення тональності фінансових новин використано попередньо навчену модель `FinBERT`, спеціалізовану для аналізу текстів фінансової тематики. Оскільки

модель застосовується виключно в режимі інференсу, її додаткове навчання не проводилося. Модель FinBERT розгорнута у вигляді окремого мікросервісу на основі фреймворку Flask. Для реалізації використано бібліотеки transformers та torch. Такий підхід забезпечує незалежність NLP-компоненти від основного вебзастосунку та дозволяє оновлювати модель без модифікації серверної частини системи.

Мікросервіс виконує завантаження моделі FinBERT із бібліотеки Hugging Face, приймає HTTP POST-запити із текстом фінансової новини, виконує токенизацію та інференс моделі, після чого повертає JSON-відповідь із ймовірностями класів positive, negative та neutral, а також підсумковою оцінкою тональності.

Взаємодія між ASP.NET Core-застосунком та мікросервісом реалізована через клас FinBertService за допомогою HttpClient із таймаутом 3 секунди. У випадку тимчасової недоступності сервісу система автоматично переходить у fallback-режим, метод MockSentiment() виконує аналіз тональності на основі словників позитивних та негативних слів.

На основі результатів роботи FinBERT формується часовий ряд настроїв для кожної акції. Для кожної новини визначається індивідуальна оцінка тональності, після чого виконується її агрегація на денному рівні. Отримані щоденні значення використовуються для побудови показника інформаційного фону, який надалі враховується під час формування інвестиційних рекомендацій. Крім щоденних значень, система обчислює інтегральний показник середньої тональності за останній тиждень із урахуванням свіжості новин. Більша вага надається більш новим повідомленням, що дозволяє оперативніше реагувати на зміни інформаційного середовища.

**4. Реалізація модуля прогнозування на основі моделі TFT.** Прогнозування дохідності активів реалізовано за допомогою навченого екземпляра моделі Temporal Fusion Transformer, збереженого у файлі Forecast.pt. Виконання інференсу здійснюється окремим Python-скриптом tft\_predict.py.

Модуль прогнозування реалізовано у сервісі TFTService, основними методами якого є PredictAsync() та PredictMultipleAsync(). Під час роботи сервіс формує набір вхідних ознак, що включає історичні цінові дані, технічні індикатори, після чого запускає Python-процес через Process.Start().

Передача даних між .NET та Python виконується у форматі JSON через stdin/stdout. У процесі прогнозування модель завантажує параметри робастного масштабування із файлу scaler\_params.npz та виконує формування прогнозу для заданого горизонту часу. Для оцінювання невизначеності прогнозу використовується механізм MC Dropout.

Результатом роботи модуля є прогнозна ціна активу, очікувана дохідність, оцінка ймовірності напрямку руху та показники впевненості прогнозу. Для зменшення обчислювального навантаження результати прогнозування кешуються на визначений проміжок часу.

**5. Реалізація модуля формування інвестиційних рекомендацій.** Модуль формування рекомендацій реалізовано у класі RecommendationService. Його основним завданням є інтеграція результатів прогнозування TFT, оцінок ризику та показників тональності новин для формування підсумкових рекомендацій інвестору. Основними методами є GenerateAsync() та BuildRecommendation(). У процесі роботи модуль отримує прогнозовану дохідність активу, оцінює рівень ризику на основі історичних даних та враховує інформаційний фон, сформований модулем FinBERT. Після цього обчислюється інтегральна оцінка привабливості активу відповідно до математичної моделі, наведеної у другому розділі роботи.

На основі отриманих значень система виконує ранжування активів за рівнем інвестиційної привабливості та формує рекомендації типу BUY, HOLD або SELL. Рекомендації формується на основі двох факторів: напрямку прогнозу Position та значення функції корисності ConfidenceScore (додаток Г).

При визначенні Position пріоритет надається classification head моделі TFT (DirectionProbability), оскільки ця голова навчена безпосередньо на задачі бінарної класифікації (зростання/падіння) з використанням BCE-функції втрат. Якщо

$\text{DirectionProbability} > 0.55$  –  $\text{Position} = +1$  (прогноз зростання); якщо  $\text{DirectionProbability} < 0.45$  –  $\text{Position} = -1$  (прогноз падіння); інакше  $\text{Position} = 0$  (невпевненість). Fallback варіант – порівняння  $\text{PredictedPrice}$  з  $\text{CurrentPrice}$  з мертвою зоною  $\pm 0.1\%$ . Якщо  $\text{Position} = +1$  а значення функції корисності  $\text{ConfidenceScore} < 0.45$ , рекомендація знижується до HOLD (суперечливий сигнал). Якщо  $\text{Position} = -1$ , а  $\text{ConfidenceScore} > 0.55$ , рекомендація також знижується до HOLD. Додатково користувачу надається деталізація внеску окремих факторів, що підвищує прозорість і пояснюваність прийнятих рішень.

Ранжування активів здійснюється з використанням методу `GenerateAsync()`, який виконує паралельний розрахунок для всіх активів із портфеля, після чого сортує їх за спаданням  $\text{ConfidenceScore}$ . Це дозволяє інвестору бачити найбільш привабливі активи (з найвищою очікуваною корисністю) на початку списку. Результат включає детальну розбивку за компонентами:  $\text{ReturnScore}$ ,  $\text{RiskScore}$ ,  $\text{SentimentScore}$ , що забезпечує пояснюваність рекомендацій (Explainable AI).

Таким чином, модуль формування інвестиційних рекомендацій забезпечує повний цикл прийняття інвестиційного рішення: від отримання вхідних даних (ціни, новини, TFG-прогноз) до формування зрозумілої рекомендації з цільовою ціною та рівнем впевненості.

**6. Реалізація модуля керування налаштуваннями користувача.**  
Збереження параметрів роботи системи реалізовано у сервісі `UserSettingsService`. Модуль забезпечує зберігання вагових коефіцієнтів критеріїв оцінювання, списку вибраних акцій та налаштувань інформаційних джерел. Основними методами є `Get()`, `Save()` та `ResetToDefaults()`. Збереження налаштувань здійснюється у JSON-файлі `user_settings.json`, що дозволяє підтримувати персоналізовані параметри роботи рекомендаційної системи між сеансами використання.

Таким чином, програмна реалізація рекомендаційної системи базується на сукупності взаємопов'язаних функціональних модулів, які забезпечують повний цикл підтримки прийняття інвестиційних рішень: від збору ринкових даних та

аналізу фінансових новин до прогнозування поведінки активів і формування інвестиційних рекомендацій.

#### 4.5 Користувацький інтерфейс застосунку (UI/UX)

Користувацький інтерфейс вебзастосунку розроблено з метою забезпечення зручної взаємодії інвестора з рекомендаційною системою, візуалізації результатів прогнозування та підтримки процесу прийняття інвестиційних рішень. Інтерфейс реалізовано у вигляді набору взаємопов'язаних вебсторінок, які надають доступ до ринкових даних, прогнозів нейромережових моделей, результатів аналізу новин та сформованих інвестиційних рекомендацій.

Робота користувача із системою передбачає послідовне виконання таких дій: вибір фінансових активів для аналізу; отримання актуальних ринкових даних та фінансових новин; побудова прогнозу за допомогою моделі TFT; аналіз показників ризику, дохідності та новинного сентименту; отримання рекомендацій щодо купівлі, утримання або продажу активів.

Головною сторінкою застосунку є інформаційний дашборд, який дозволяє переглядати актуальні дані та рекомендації щодо *окремих активів*. У верхній частині головного вікна розміщена панель навігації із вкладками для переходу між вебсторінками застосунку: *Дашборд*, *Портфель* та *Налаштування* (рис. 4.3).

Нижче під ними розміщені кнопки з тікерами акцій (назвами активів) у ранжованому порядку відповідно до їх капіталізації. За замовчуванням це AAPL, MSFT, GOOGL, NVDA, META, TSLA, ^GSPC.

Якщо інвестор уже має сформований портфель, у цій області на кнопках будуть відображені тікери активів, ранжовані відповідно до їх капіталізації та частки у його портфелі. У нижній частині вікна головного дашбоду уже відображена поточна ринкова інформація активу з найбільшою капіталізацією. Для вибору іншого активу необхідно натиснути кнопку з його тікером, і у вікні нижче

система автоматично оновить сторінку з виведенням інформації, яка стосується цього активу.

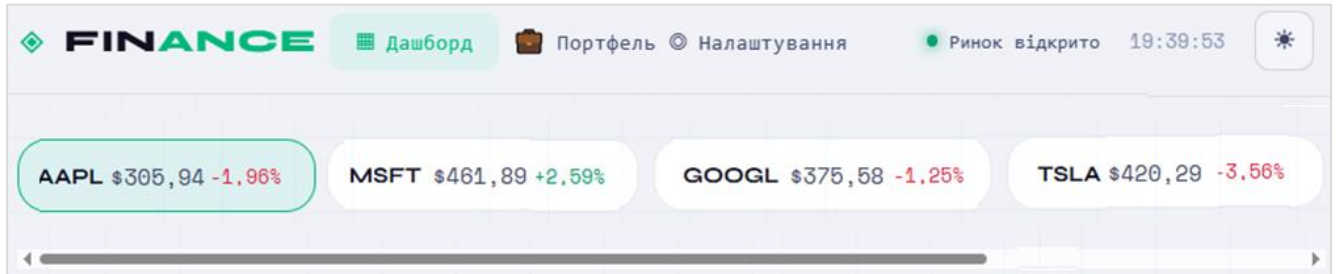


Рисунок 4.3 – Головне вікно вебзастосунку: панель навігації та кнопки вибору активів

Під панеллю спостережень інформаційного дашбода розміщена область з детальною інформацією про обраний актив (рис. 4.4). Тут користувач бачить назву компанії, поточну ціну акції, зміну за день у доларах та відсотках, а також додаткові показники: ціну відкриття, максимум, мінімум, ціну закриття попереднього дня, обсяг торгів, 52-тижневий максимум та мінімум. Нижче у вікні виводиться інтерактивний графік історичної динаміки ціни акції за останні 30 днів. Колір лінії зелений, якщо кінцева ціна вища за початкову, або червоний – якщо нижча. Користувач може навести курсор на будь-яку точку графіка, щоб побачити точне значення ціни на конкретну дату.

Праворуч на цій сторінці розташована стрічка фінансових новин стосовно обраного активу із результатами аналізу тональності, отриманими за допомогою моделі FinBERT (рис. 4.5). Це дозволяє одночасно бачити як ринкові показники, так і поточний інформаційний фон, який стосується акції. Кожна новина має заголовок, джерело, дату публікації та результат аналізу тональності від моделі FinBERT у вигляді агрегованого сентименту. Якщо новина позитивна – вона має зелений індикатор з позначкою «POSITIVE», якщо негативна – червоний з позначкою «NEGATIVE», якщо нейтральна – сірий з позначкою «NEUTRAL». При

натисканні на заголовок новина відкривається в новій вкладці браузера для її більш детального перегляду.



Рисунок 4.4 – Головне вікно вебзастосунку: ринкові дані обраної акції

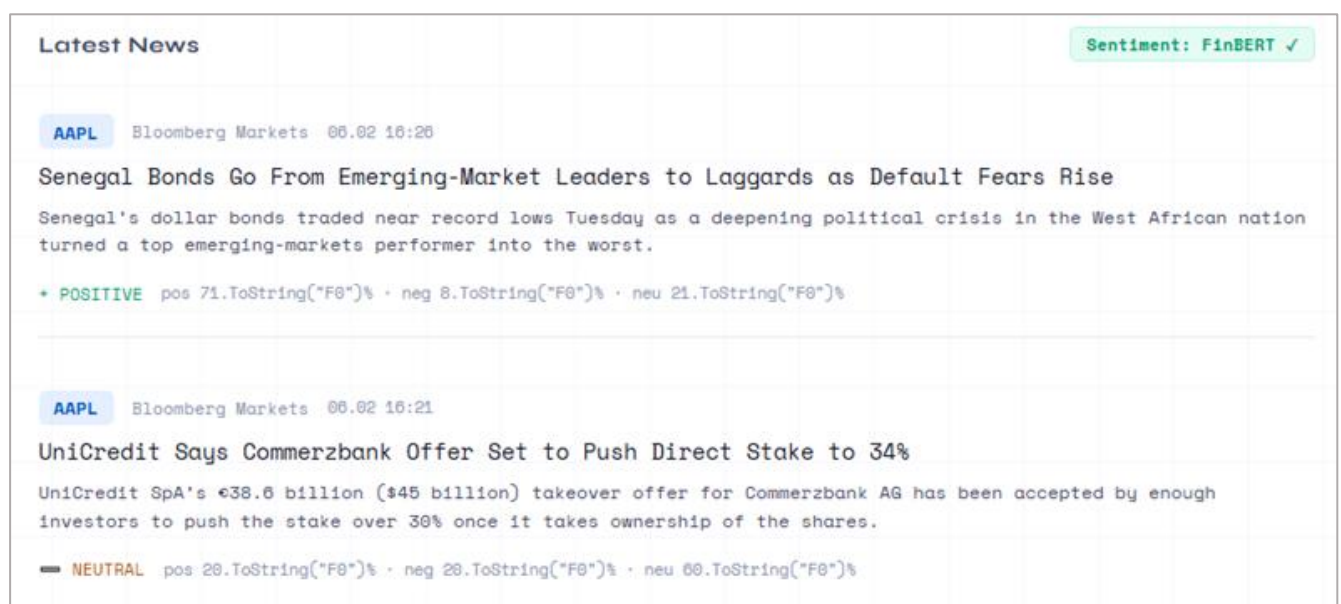


Рисунок 4.5 – Стрічка фінансових новин стосовно обраного активу

Особливу увагу приділено забезпеченню пояснюваності рекомендацій (Explainable AI). Для отримання AI-рекомендації у нижній частині вікна ліворуч під графіком ціни розміщена область, яка містить згенеровані системою на основі аналізу поточних ринкових даних та фінансових новин текстові рекомендації із зазначенням ключових факторів, що вплинули на рішення. Користувач бачить картки з рекомендаціями для акцій (рис. 4.6). Для кожного активу система відображає не лише підсумкову рекомендацію BUY – зелений, HOLD – сірий або SELL – червоний, а й інформацію про внесок окремих факторів у прийняте рішення. Користувач може переглянути вплив прогнозованої дохідності, ризику та новинного настрою на значення функції корисності, що забезпечує прозорість процесу формування рекомендацій. Додатково надається текстова інтерпретація отриманих результатів та рівня впевненості прогнозованої моделі.

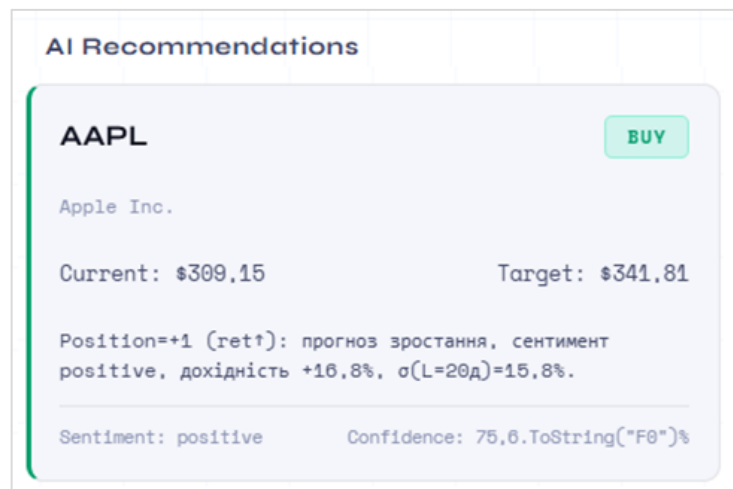


Рисунок 4.6 – AI-рекомендації з коротким поясненням

Для поглибленого аналізу прогнозів та отримання інвестиційних рекомендацій реалізовано окремий *портфельний дашборд*. Користувач переходить до нього, натиснувши на панелі анвігації у верхній частині сторінки вкладку *Портфель*. Буде відкрита сторінка, яка містить основний інвестиційний сценарій: від вибору активу до оцінки стратегії. У верхній частині цієї сторінки розташована панель із кнопками, що містять тікер акції, зміну за день у відсотках

та кольорову крапку, що відображає тижневий сентимент новин (зелена – позитивний, червона – негативний, сіра – нейтральний) (рис. 4.7). При натисканні на кнопку з активом інформація на сторінці оновлюється відповідно до обраного активу.

Для зміни горизонту прогнозу праворуч над кнопками з акціями розташовані випадаючі списки, де можна обрати акцію та горизонт прогнозу від 1 до 5 днів. Після вибору система перераховує прогноз TFT та оновлює інформацію на сторінці відповідно до обраних налаштувань. Під кнопками з тикерами активів розміщені вкладки сторінки *Портфель: Огляд, Сигнали, Порівняння, Ризик, Рекомендації AI*.

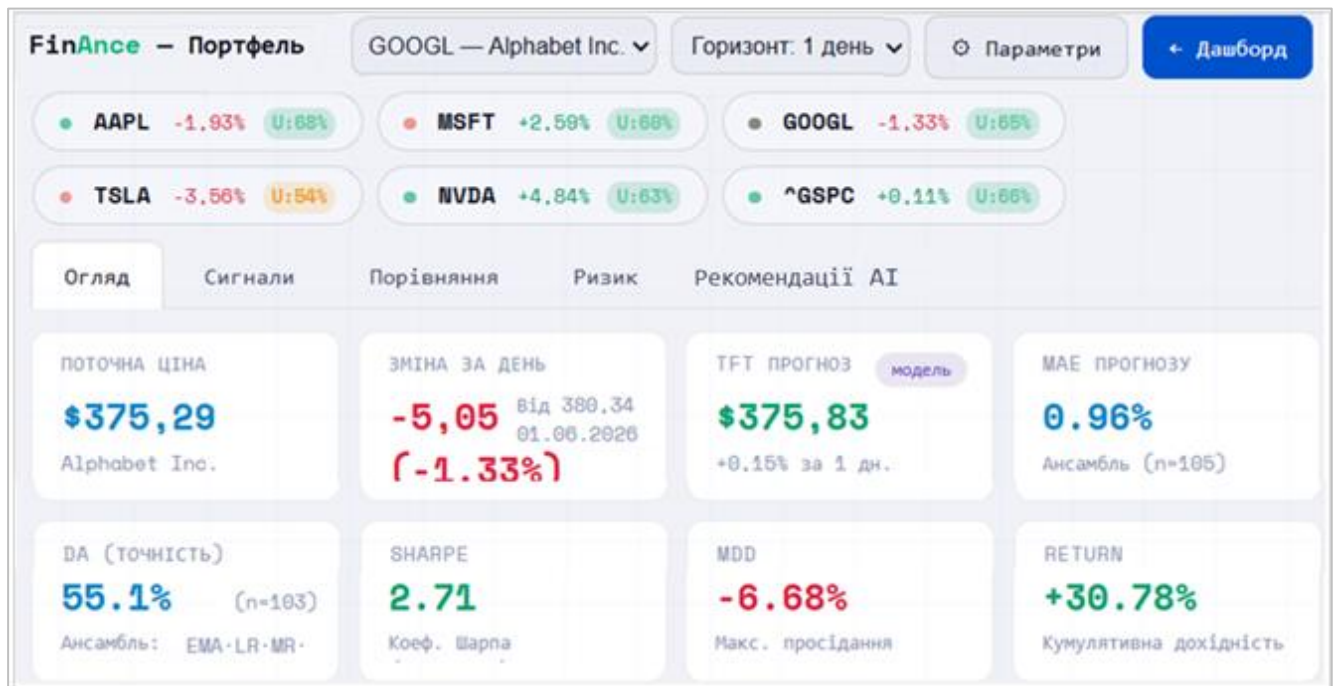


Рисунок 4.7 – Вкладка Огляд

При першому відкритті сторінки активною буде вкладка *Огляд*. Нижче під вкладками виведена інформація з метриками, які оцінюють якість отриманих рекомендацій стосовно прогнозу ціни, напряму руху, кумулятивної дохідності, ризику (рис. 4.7).

У центральній частині сторінки на вкладці *Огляд* відображаються результати прогнозування у вигляді графіків історичних цін та прогнозованої траєкторії руху

активу. На графіку цін суцільною синьою лінією відображається історична ціна акції, а пунктирною помаранчевою лінією – прогноз TFT (рис. 4.8). Якщо новинний фон суттєво впливає на прогноз, додатково відображається сіра пунктирна лінія – прогноз без урахування сентименту. Зеленими трикутниками позначені точки, де система рекомендувала BUY, червоними ромбами – точки продажу SELL. Під графіком розташована таблиця з детальним прогнозом на кожен день.



Рисунок 4.8 – Графіки історичних цін та прогнозованої траєкторії руху активу

Нижче під графіком цін відображено графік кривої капіталу (рис. 4.9). Користувач має можливість аналізувати криву капіталу інвестиційної стратегії, порівнювати її з базовою стратегією Buy & Hold та ринковим індексом S&P 500, а також оцінювати зміну ризику та інформаційного фону в часі. Для зручності роботи передбачено інтерактивні засоби масштабування та навігації по часових рядах.




Рисунок 4.9 – Графік кривої капіталу

Для перегляду текстової інтерпретації в кінці вкладки *Огляд* розташований блок Текстова інтерпретація стратегії (рис. 4.10). Тут система природною мовою пояснює: яку дохідність показала стратегія, який рівень ризику, яке співвідношення дохідності до ризику (коефіцієнт Шарпа), як стратегія порівнюється з Buy & Hold та S&P 500, яка точність прогнозу напрямку (DA) та який вплив новинного фону.

На окремій вкладці *Сигнали* користувач може побачити декомпозицію інтегральної оцінки привабливості активу. Візуалізуються три складові функції корисності: нормалізована дохідність дати (рис. 4.11), інвертований ризик (менший ризик – вища оцінка) та сентимент новин. Тут відображається графік, на якому показано чотири лінії: дохідність (синя), ризик (червона пунктирна), сентимент (зелена пунктирна) та інтегральний показник Utility (помаранчева). Нижче розташована таблиця з торговими сигналами для кожної компоненти. Це дозволяє зрозуміти, який фактор (очікуваний прибуток, волатильність або інформаційний фон) зробив найбільший внесок у рекомендацію.

**Текстова інтерпретація стратегії**

Потенційна прибутковість: стратегія показала дохідність **+17.18%**. Потенціал є.

Помірний ризик: **MDD = -10.5%** – контролюйте позицію.

Відмінний Sharpe: **1.79** – стратегія ефективно компенсує ризик.

Стратегія перевищує Buy&Hold та S&P 500 (**+17.18% vs B&H +10.53% vs S&P +10.16%**).

Активне управління виправдовує себе.

DA точність ансамблю: **53.6%** (n=101) – нестабільна. Ринок зараз важко передбачуваний.

Тижневий новинний фон (17 стат.): **сентимент positive** (помірний, score: **+0.199**).

FinBERT-корекція підвищила TFT прогноз на **~0.06%** (1 дн. \* вага сентименту).

**!! Інформаційний характер: Будь-які рішення потребують власного аналізу та консультації спеціаліста.**

Рисунок 4.10 – Текстова інтерпретація стратегії



Рисунок 4.11 – Вкладка Сигнали

Також на цій вкладці внизу розташована таблиця з рекомендаціями для всіх акцій портфеля (рис. 4.12). Для кожного активу вказано: символ, сигнал (BUY/SELL/HOLD), поточну ціну, цільову ціну, привабливість (U) у вигляді кольорової прогрес-панелі (зелена – висока, жовта – середня, червона – низька), компоненти оцінки (R – дохідність,  $\sigma$  – ризик, S – сентимент) та текстове пояснення.

Рекомендації (сервер)						
АКЦІЯ	СИГНАЛ	ПОТОЧНА	ЦІЛЬОВА	ПРИВАБЛИВІСТЬ (U)	КОМПОНЕНТИ U	ПРИЧИНА
<b>^GSPC</b> ^GSPC	HOLD	\$7590,04	\$7741,84		68% R:0,60 $\sigma$ :0,90 S:0,65	Position=0 (CLS≈(0,49)): нейтральний напрямок, сентимент positive, дохідність +5,8%, $\sigma(L=20d)=9,9\%$ . Утримувати та спостерігати.
<b>AAPL</b> Apple Inc.	HOLD	\$309,15	\$315,33		68% R:0,65 $\sigma$ :0,84 S:0,58	Position=0 (CLS≈(0,52)): нейтральний напрямок, сентимент positive, дохідність +8,7%, $\sigma(L=20d)=15,8\%$ . Утримувати та спостерігати.

Рисунок 4.12 – Рекомендації для всіх акцій портфеля

Обравши вкладку *Порівняння*, користувач отримує можливість порівняти стратегію, рекомендовану системою, з базовою стратегією Buy & Hold та ринковим індексом S&P 500 (рис. 4.13). У верхній частині розташовані три картки з кумулятивною дохідністю стратегії FinSight, стратегії Buy & Hold та індексу S&P 500 (рис. 4.14, верхня область). Під картками – графік порівняльної дохідності трьох стратегій у відсотках, а також таблиця з детальними метриками: кумулятивна дохідність, максимальна просадка (MDD), коефіцієнт Шарпа, річна волатильність, Win rate та кількість угод.

Для аналізу та перегляду детальної інформації стосовно ризику необхідно обрати вкладку *Ризик*. Тут відображаються шість карток з ключовими ризик-метриками рекомендованої стратегії: MDD, коефіцієнт Шарпа, річна волатильність, Win rate (частка прибуткових угод портфеля), кількість угод та середня дохідність угод у портфелі.

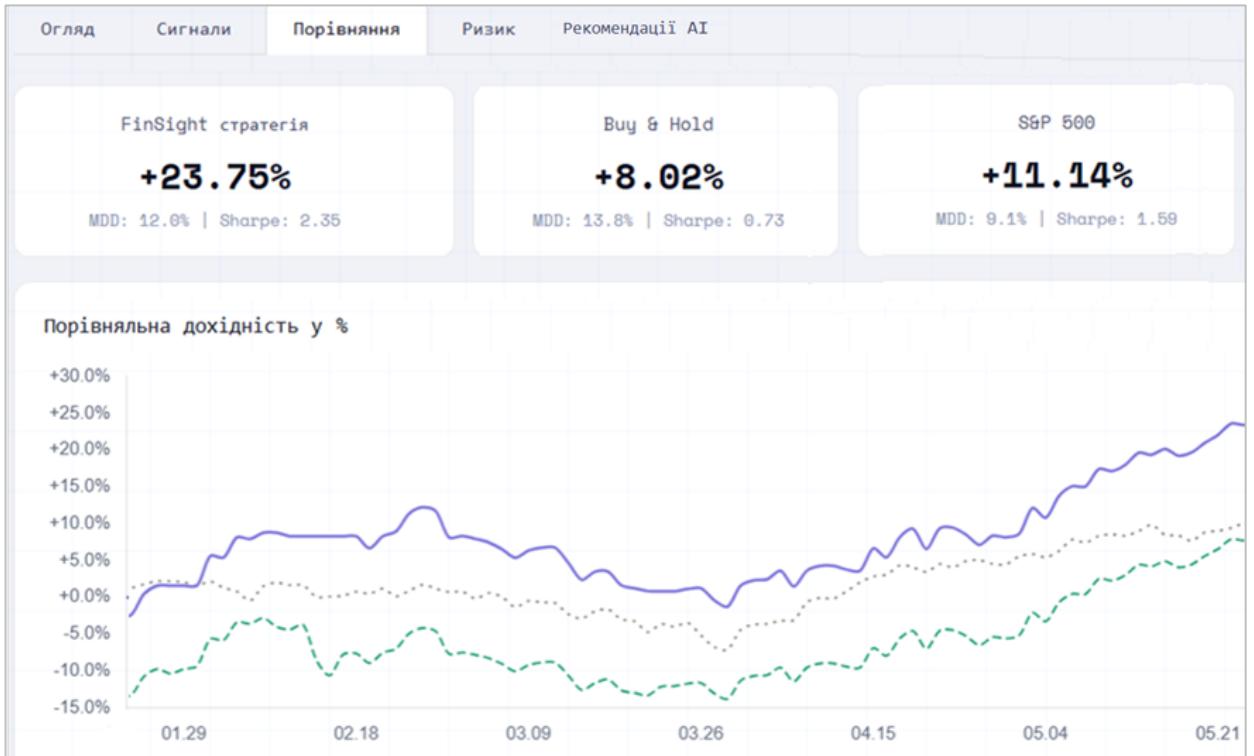


Рисунок 4.13 – Вкладка Порівняння

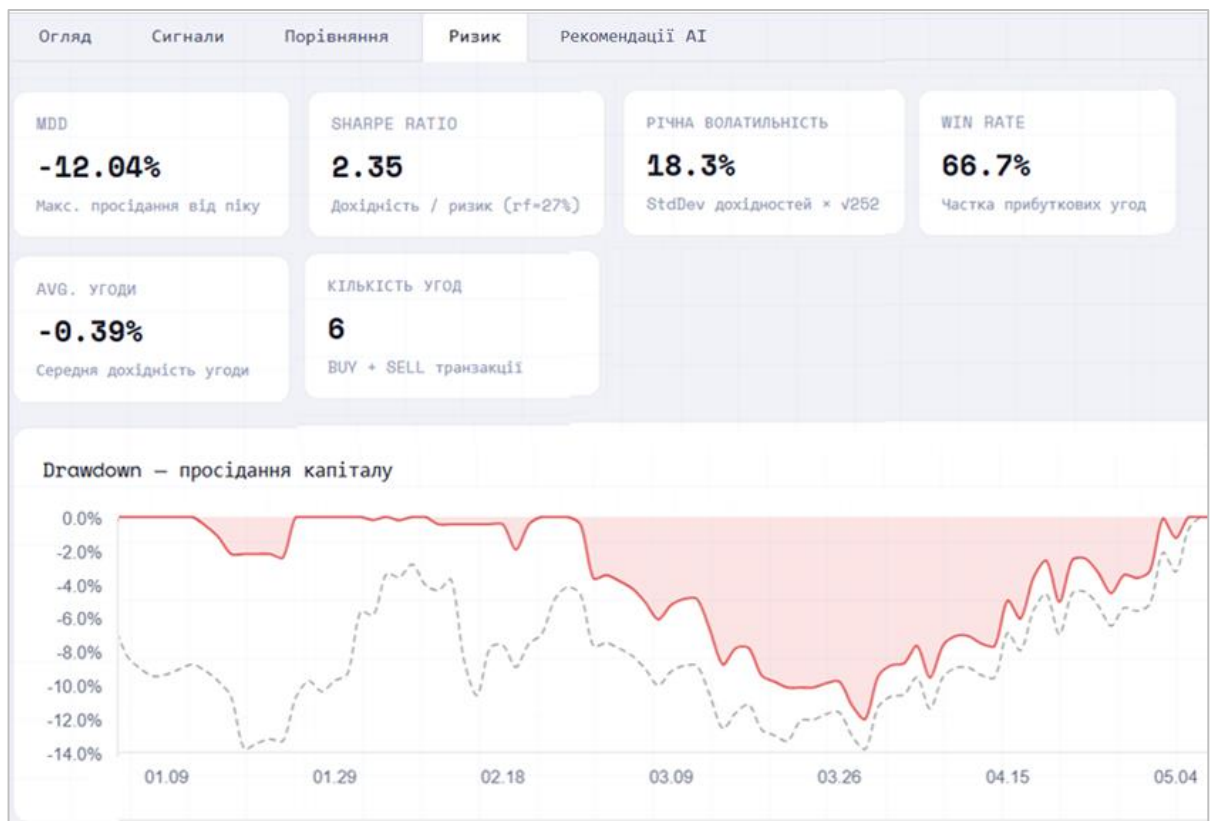


Рисунок 4.14 – Вкладка Ризик

Нижче – графік просідання капіталу (Drawdown) для стратегії FinSight та його порівняння з Buy & Hold, а також гістограма розподілу доходностей угод (рис. 4.15).




Рисунок 4.15 – Гістограма розподілу доходностей угод

Обравши вкладку портфельного дашборду *Рекомендації AI*, користувач отримує можливість комплексно переглянути всі активи портфеля з інтегральною оцінкою їх інвестиційної привабливості (рис. 4.16). Вона складається з двох основних блоків. У верхній частині розташовані шість карток із метриками портфеля: кількість унікальних активів, кількість акцій що зросли або впали за день, середня відсоткова зміна по портфелю, кількість прогнозів TFT, середня прогнозована зміна TFT та кількість сигналів BUY, SELL, HOLD. Позитивні значення виділяються зеленим кольором, негативні — червоним, нейтральні — синім.

У центральній частині сторінки розташована таблиця активів портфеля, яка містить для кожного активу назву компанії, поточну ціну, відсоткову зміну за день, прогнозовану ціну TFT, прогнозовану відсоткову зміну TFT, рівень впевненості моделі TFT, інтегральну оцінку привабливості Utility (кольорова прогрес-панель:

зелена 60-100% – висока, жовта 40-60% – середня, червона 0-40% – низька), під якою відображаються компоненти  $R$  (нормалізована дохідність),  $\sigma$  (інвертований ризик) та  $S$  (сентимент новин). Останній стовпець містить підсумкову рекомендацію BUY, SELL або HOLD у вигляді кольорового бейджа. Користувач може клацнути на будь-якому рядку таблиці, щоб переключити портфельний дашборд на відповідний актив для детального аналізу.

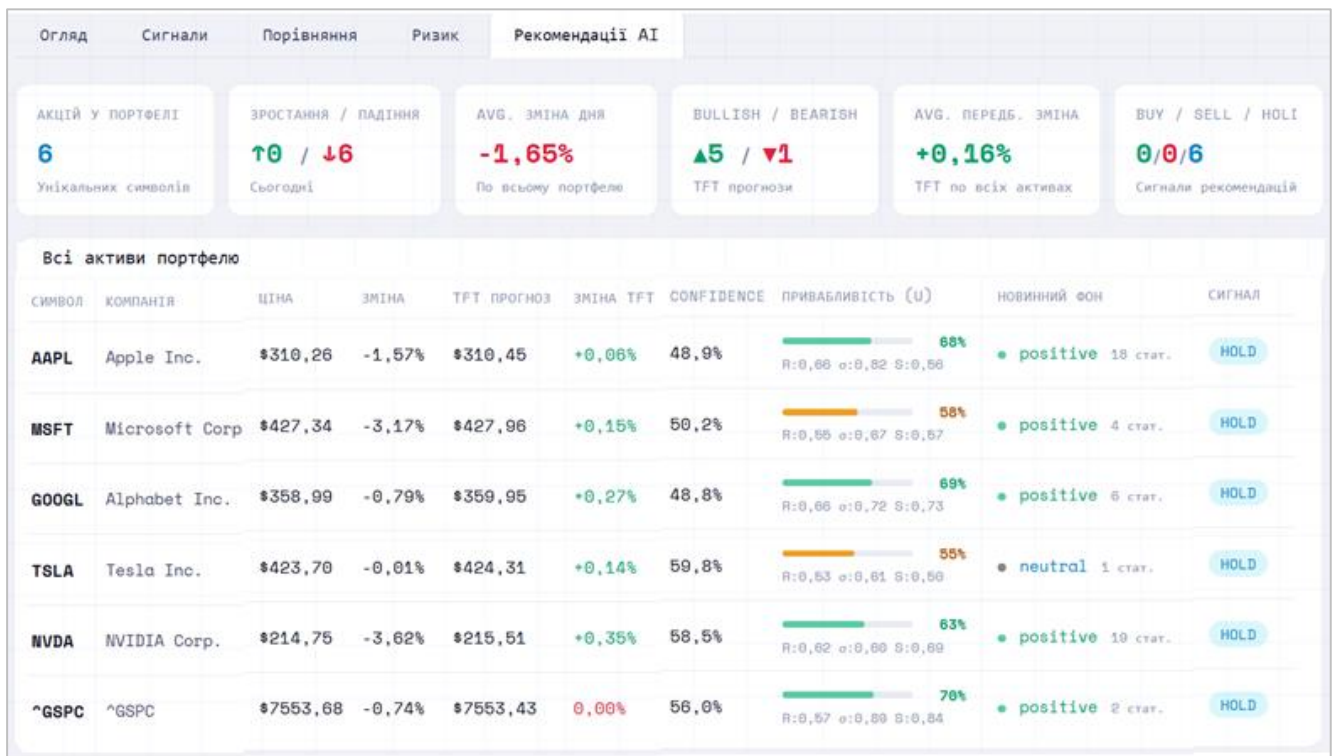


Рисунок 4.16 – Вкладка Рекомендації AI

Важливою складовою системи є сторінка налаштувань профілю інвестора. Для переходу до налаштувань користувач натискає вкладку *Налаштування* у верхньому меню навігації. У верхній частині вікна налаштувань, яке відкріється, розміщена область у якій користувач може задавати: період аналізу (від 1 місяця до 3-х років – обсяг історичних даних які буде завантажено з Yahoo Finance), початковий інвестиційний капітал (використовується для розрахунку кривої капіталу та метрик прибутковості) та параметри генерації рекомендацій (пороги сигналів: BUY – зелений) та SELL – червоний) (рис. 4.17).

У області *Загальні налаштування* сторінки налаштувань ліворуч відображаються кнопки з тікерами усіх акцій портфеля (рис. 4.18). У цій області користувач має можливість видалити актив, натиснувши хрестик на кнопці з активом. А також додати новий актив, ввівши у текстове поле символи тікера акції та натиснувши кнопку *+Додати* або клавішу *Enter*. Праворуч знаходиться область, у якій можна установити прапори для відображення інформації: сентименту новин, TFT прогнозу, рекомендацій та кількості новин (рис. 4.19).

Рисунок 4.17 – Сторінка Налаштування: задання періоду аналізу, початкового капіталу та порогів сигналів BUY/ SELL

Рисунок 4.18 – Загальні налаштування: список спостережень

Окремо реалізовано механізм налаштування вагових коефіцієнтів критеріїв багатокритеріального оцінювання активів, які визначають відносну важливість прогнозованої дохідності, рівня ризику та новинного настрою. Область для їх задання знаходиться у центральній частині сторінки налаштувань (рис. 4.20). Під повзунками розташована кольорова прогрес-панель, що візуалізує нормалізований розподіл ваг що дає змогу бачити реальне співвідношення факторів. Зміна ваг негайно зберігається та впливає на всі подальші рекомендації.

**Відображення**

Показувати настрою новин  Показувати TFT прогнози  
 Показувати рекомендації

Кількість новин для відображення

10

Рисунок 4.19 – Загальні налаштування: відображення

Для спрощення роботи передбачено набір готових профілів інвестора, які можна обрати лівою кнопкою миші: агресивний, помірний, консервативний, новинно-орієнтований та ризик-нейтральний (рис. 4.21). Пресети профілів інвестора наведено у таблиці 4.2.

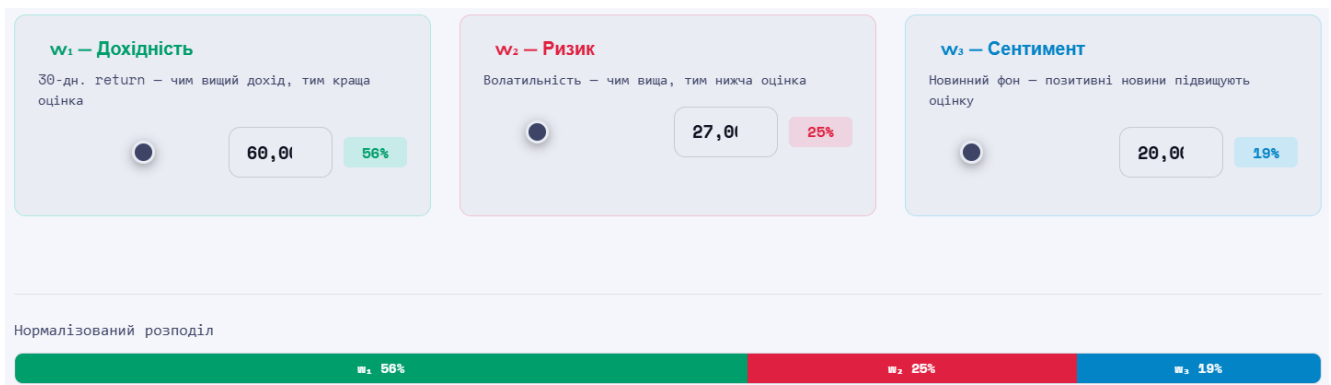


Рисунок 4.20 – Налаштування профілю інвестора




Рисунок 4.21 – Вибір профілю інвестора

Таблиця 4.2 – Пресети профілів інвестора

Профіль	$w_1$ (дохідність)	$w_2$ (ризик)	$w_3$ (сентимент)	Характеристика
Агресивний	60	20	20	Максимізація дохідності
Помірний	50	30	20	Баланс дохідності та ризику
Консервативний	30	50	20	Мінімізація ризику
Новинно-орієнтований	40	20	40	Висока чутливість до новин
Ризик-нейтральний	50	25	25	Збалансоване врахування

Для налаштування джерел новин у нижній частині сторінки налаштувань розташована область, у якій відображено всі джерела у вигляді списку з URL-адресами (рис. 4.22). Користувач може видалити джерело, натиснувши хрестик, або додати нове, ввівши URL у текстове поле та натиснувши кнопку *+ Додати сайт*.

Усі зміни на сторінці налаштувань зберігаються автоматично через 1,5 секунди після останньої дії. У верхній частині сторінки з'являється повідомлення *Налаштування збережено* зеленого кольору. Для повернення до дашборду користувач натискає кнопку *← До дашборду* внизу сторінки. Для скидання налаштувань користувач натискає кнопку *↺ Скинути до дефолтних* внизу сторінки, після чого підтверджує дію у спливаючому вікні.



Рисунок 4.22 – Налаштування джерел надходження фінансових новин

У розробленій системі реалізовано одну з ключових вимог до сучасних рекомендаційних систем – **пояснюваність прийнятих рішень** (Explainable AI, XAI). Цей принцип реалізовано на трьох рівнях: деталізація компонентів функції корисності, текстова інтерпретація метрик та візуалізація впливу факторів. Для кожної згенерованої рекомендації система надає:

- *текстову інтерпретацію*: коротке пояснення природною мовою, чому рекомендовано саме цю дію («Прогноз TFT вказує на зростання (+1.2%), настрої новин позитивний, ризик помірний – рекомендовано BUY»);

- *візуалізацію внеску факторів*: стовпчикова діаграма, що показує, який із трьох факторів (дохідність, ризик, настрої) зробив найбільший внесок у підсумкову оцінку;

- *рівень впевненості*: числове значення (у відсотках), що відображає впевненість моделі у прогнозі, низька впевненість (нижче 50%) автоматично знижує рекомендацію до HOLD, що запобігає хибним сигналам у невизначених ринкових умовах;

- *узгодженість голів TFT-моделі*: спеціальний індикатор, який показує, чи не суперечать одна одній регресійна (прогноз числового значення) та

класифікаційна (прогноз напрямку) голови моделі TFT, у разі суперечності система зменшує magnitude прогнозу та знижує рівень довіри, що підвищує надійність рекомендацій.

Такий підхід до пояснюваності ХАІ дозволяє інвестору не просто отримати сигнал «купити/продати», але й зрозуміти його логіку, що критично важливо для прийняття зважених фінансових рішень. Інтерфейс підтримує автоматичне оновлення відображуваних даних. Використання інтерактивних графіків, інформаційних панелей та засобів пояснюваності дозволяє підвищити зручність роботи користувача та сприяє прийняттю більш обґрунтованих інвестиційних рішень. Таким чином, розроблений користувацький інтерфейс забезпечує повний цикл взаємодії інвестора з рекомендаційною системою: від отримання актуальних ринкових даних і прогнозів до формування та інтерпретації інвестиційних рекомендацій.

#### **4.6 Тестування та оцінка якості рекомендаційної системи**

Для підтвердження працездатності та ефективності розробленої рекомендаційної системи проведено комплексне тестування, яке включало оцінку продуктивності програмної реалізації, валідацію на історичних даних (бектестинг), аналіз впливу новинного фактору на якість прогнозування та порівняльну оцінку ефективності knowledge-based моделі для різних профілів інвесторів.

1. *Тестування продуктивності системи.* Для оцінки придатності системи до використання в реальних умовах проведено тестування продуктивності на апаратній конфігурації: процесор Intel Core i7-10750H (2.60 ГГц), оперативна пам'ять 16 ГБ, твердотільний накопичувач NVMe.

*Час відповіді API.* Вимірювання часу виконання основних ендпоінтів виконувалося за допомогою вбудованого механізму логування. Кожен ендпоінт тестувався при 10 послідовних викликах (табл. 4.3). Найбільш витратними за часом є операції, пов'язані з викликом TFT-моделі (1,85 с для одного символу), що обумовлено необхідністю запуску процесу, завантаження ваг моделі та виконання

MC Dropout (32 семпли). Впровадження кешування (TTL = 15 хвилин) дозволяє суттєво знизити навантаження: повторні запити для тих самих символів виконуються за 5-10 мс.

*Продуктивність ML-моделей.* Для оцінки максимальної пропускної здатності системи проведено навантажувальне тестування FinBERT мікросервісу та TFT-скрипту. FinBERT мікросервіс Flask тестувався за допомогою утиліти wrk з параметрами: 10 потоків, 100 з'єднань, тривалість 30 секунд. Результати: середня пропускна здатність – 42 запити на секунду, 95-й перцентиль часу відповіді – 180 мс. TFT-скрипт при стандартній довжині вхідного вікна (60 днів) виконується за 1,2–1,5 секунди. Використання механізму MC Dropout (32 семпли) збільшує час виконання приблизно в 3 рази, однак це дозволяє отримувати оцінку невизначеності прогнозу, що підвищує надійність прогнозу.

Таблиця 4.3 – Час відповіді основних API-ендпоінтів

Ендпоінт	Опис	Середній t, мс	Кешування
/Home/GetQuote	Отримання котирування для одного символу	420	так (5 хв)
/Portfolio/GetForecast	TFT-прогноз для одного символу	1850	так (15 хв)
/Portfolio/GetForecastMultiple	TFT-прогноз для 5 символів	4250	так (15 хв)
/News/GetWeeklySentiment	Агрегація тижневого сентименту	320	так (30 хв)

*Тестування паралельних запитів.* Для перевірки роботи системи в умовах багатокористувацького доступу проведено тестування з емуляцією 10 одночасних сесій. Сервер ASP.NET Core успішно обробив усі запити без помилок, однак час виконання TFT-прогнозів зріс через конкуренцію за доступ до файлової системи.

Рекомендованим рішенням для промислової експлуатації є попереднє завантаження моделі в оперативну пам'ять (наприклад, через розгортання TFT як окремого мікросервісу на FastAPI).

У ході тестування було виявлено наступні обмеження: 1) затримка при першому виклику TFT-моделі (до 3 секунд) через необхідність завантаження ваг моделі з диска; 2) FinBERT мікросервіс має обмежену пропускну здатність (близько 40 запитів на секунду), що при великій кількості новин є вузьким місцем; 3) кешування прогнозів на 15 хвилин є компромісом між свіжістю даних та продуктивністю і при швидких ринкових змінах може призводити до застарілих рекомендацій; 4) система не підтримує реальний режим роботи – оновлення даних відбувається лише при перезавантаженні сторінки або вручну.

**2. Бектестинг рекомендаційної системи на історичних даних.** Для оцінки ефективності рекомендаційної системи в умовах, наближених до реальних, проведено бектестинг на історичних даних за період з 1 січня 2024 року по 31 грудня 2025 року. Методологія бектестингу передбачала: початковий капітал 10000 USD; сигнали BUY/HOLD/SELL на основі функції корисності з вагами за замовчуванням ( $w_1=0,50$ ,  $w_2=0,25$ ,  $w_3=0,25$ ) та порогами (BUY=0,55, SELL=0,45); комісія за угоду 0,1%; рівномірний розподіл ваг активів у портфелі; порівняння з двома бенчмарками: пасивною стратегією Buy & Hold та індексом S&P 500. Підсумкові результати бектестингу для портфеля з 5 акцій (AAPL, MSFT, GOOGL, TSLA, NVDA) наведено в таблиці 4.4.

Отримані результати дозволяють зробити наступні висновки:

– *перевищення ринку*: рекомендаційна система забезпечила кумулятивну дохідність +24,1%, вищу за Buy & Hold та S&P 500, це підтверджує, що активне управління на основі TFT-прогнозів та аналізу настрою є більш ефективним, ніж пасивне інвестування;

– *контроль ризику*: MDD системи становить 16,8%, що значно нижче за Buy & Hold та S&P 500, це свідчить про ефективність механізмів контролю ризику:

система вчасно генерувала сигнали SELL для виходу з позицій під час ринкових спадів;

– *коефіцієнт Шарпа*: значення 1,58 що вказує на більш ефективне співвідношення дохідності до ризику, ніж для S&P 500 та Buy & Hold;

– *Directional Accuracy*: досягнута точність прогнозу напрямку руху ціни 56,8% перевищує випадковий рівень (50%), що є прийнятним результатом для фінансових часових рядів з високим рівнем шуму.

Таблиця 4.4 – Результати бектестингу рекомендаційної системи

Метрика	Рекомендаційна система	Buy & Hold	S&P 500
Кумулятивна дохідність, %	+24,1	+17,0	+14,8
Максимальна просадка (MDD), %	16,8	26,6	19,2
Коефіцієнт Шарпа	1,58	0,92	1,21
Win rate (частка прибуткових угод), %	54,2	–	–
Кількість угод	42	–	–
Середня дохідність угоди, %	+0,57	–	–
Directional Accuracy (DA), %	56,8	–	–

**3. Дослідження впливу компонентного складу функції корисності на якість надання інвестиційних рекомендацій.** Для формування інвестиційних рекомендацій у даній роботі використано knowledge-based підхід, який базується на явно заданих знаннях про фінансові активи та ринкові умови. Центральним елементом цього підходу є функція корисності, що агрегує три ключові критерії: прогнозовану дохідність, ризик та новинний фон (sentiment).

Для оцінки впливу критеріїв, які відображують індивідуальні уподобання інвестора, на ефективність стратегії було протестовано п'ять профілів інвестора,

які відповідають різним стратегіям і відрізняються ваговими коефіцієнтами функції корисності (табл. 4.2). Для кожного профілю було проведено симуляцію торгівлі на валідаційній вибірці з однаковими початковими умовами (початковий капітал 10 000 USD, однакові пороги сигналів та інші налаштування. Результати порівняння наведено в таблиці 4.5.

Таблиця 4.5 – Порівняння ефективності профілів інвестора

Профіль	Cumulative Return	MDD	Sharpe Ratio	Win Rate
Агресивний	+27.4%	10.1%	2.25	51.2%
Помірний (базовий)	+20.7%	8.3%	1.90	53.5%
Консервативний	+15.2%	11.4%	1.61	56.1%
Новинно-орієнтований	+22.1%	19.6%	1.35	54.8%
Ризик-нейтральний	+23.5%	17.2%	1.65	54.2%

Агресивний профіль забезпечує найвищу дохідність (+27,4%) та найкращий коефіцієнт Шарпа (2,25), однак супроводжується підвищеною волатильністю та найнижчим Win rate (51,2%). Консервативний профіль демонструє найнижчу дохідність, але найвищу стабільність (Win rate 56,1%) та помірну просадку. Новинно-орієнтований профіль, незважаючи на високу чутливість до настроїв, показав найгірший коефіцієнт Шарпа (1,35) через значну просадку (19,6%), що пояснюється іноді надто пізньою реакцією на зміну настроїв. Ризик-нейтральний профіль забезпечує найкращий компроміс між дохідністю та ризиком, демонструючи другу за величиною кумулятивну дохідність (+23,5%) при прийнятному рівні просадки. Саме цей профіль обрано як базовий для

вебзастосунку, з можливістю для користувача змінювати ваги через інтерфейс налаштувань.

Для оцінки внеску новинного фактору в якість надання рекомендацій було проведено дослідження з формуванням рекомендацій із врахуванням компоненти sentiment та з її виключенням зі збереженням відношення дохідності до ризику у базовому профілі. Отримані результати показали, що включення компоненти тональності новин супроводжувалося покращенням ключових метрик. Зростання Directional Accuracy (DA) на 1,1%, свідчить про те, що інформація про ринкові настрої допомагає краще передбачати напрямок руху ціни. Крім того, використання сентименту дозволило знизити максимальну просадку (MDD) на 1,4%, що підтверджує роль аналізу новин у своєчасному виході з позицій під час негативного інформаційного фону.

**4. Порівняльний аналіз з бенчмарками.** Для оцінки ефективності запропонованої рекомендаційної моделі було проведено порівняння з двома бенчмарками: Buy & Hold (B&H) – пасивна стратегія «купив і тримай» та з індексом S&P 500 – ринковий бенчмарк, що відображає середньоринкову дохідність (дані отримано через Yahoo Finance за тикером ^GSPC). Тестування виконувалося на вибірці 2024-2025 років. Початковий капітал становив \$10 000. Результати порівняння наведено в таблиці 4.6. Інтерпретація результатів:

– *перевищення ринку*: запропонована рекомендаційна модель забезпечила кумулятивну дохідність +24.1%, що на 7.1% вище за Buy & Hold та на 9.3% вище за індекс S&P 500, це підтверджує, що активне управління на основі TFT-прогнозів та аналізу сентименту є більш ефективним, ніж пасивне інвестування;

– *контроль ризику*: модель продемонструвала значно нижчу максимальну просадку (MDD = 16.8%), ніж Buy & Hold (26.6%). Це означає, що рекомендаційна система вчасно генерувала сигнали SELL для виходу з позицій під час ринкових спадів, що дозволило зберегти капітал;

– *коефіцієнт Шарпа*: значення Sharpe Ratio = 1.58 свідчить про ефективне співвідношення дохідності до ризику, S&P 500 має Sharpe = 1.21, а Buy & Hold – 0.92;

– *Directional Accuracy (DA)*: досягнута точність прогнозу напрямку руху ціни 56.8% є достатньою для отримання прибутку, оскільки навіть невелике перевищення випадкового рівня (50%) у поєднанні з контролем ризику дає позитивний результат.

Таблиця 4.6 – Порівняння рекомендаційної моделі з бенчмарками

Метрика	Рекомендаційна система	Buy & Hold	S&P 500
Cumulative Return (%)	+22.05%	+11.0%	-3.66%
Max Drawdown (MDD, %)	10.7%	13.6%	5.7%
Sharpe Ratio	2.23	1.05	-1.78
Кількість угод	7	–	–
Середня дохідність угоди (%)	+0.57%	–	–

У порівнянні з існуючими програмними рішеннями запропонована система відрізняється комплексним підходом, який дозволяє формувати більш обґрунтовані рекомендації (табл. 4.7).

Отримані результати підтверджують, що запропонована архітектура та методи є ефективними для підтримки прийняття інвестиційних рішень на основі прогнозування поведінки акцій S&P 500 з урахуванням багатокритеріальної оцінки (дохідність, ризик, інформаційний фон).

#### Висновки до розділу 4

У четвертому розділі виконано моделювання, проєктування та програмну реалізацію рекомендаційної системи підтримки прийняття інвестиційних рішень. Розроблено архітектуру вебзастосунку, що забезпечує інтеграцію нейромережевих моделей аналізу та прогнозування ринкових даних і фінансових новин, а також

реалізовано функціональні модулі прогнозування, формування рекомендацій, оцінювання ризику та багатокритеріального ранжування активів.

Таблиця 4.7 – Порівняння існуючих програмних рішень і розробленої системи

Система	Прогноз (AI, ML)	Аналіз новин	Портфельна оптимізація	Персоналізація рішень	Комплексність
TradingView	–	–	–	частково	низька
MetaTrader 5	– (rule-based)	–	–	через алгоритми	низька
eToro	–	–	–	+ (соціальне копіювання)	середня
QuantConnect	+ (ч/з користувача)	–	+	+	середня
Bloomberg Terminal	+ (закриті моделі)	+	+	+	висока (закрита)
Розроблена система	+ TFT	+ FinBERT	+	+	висока (відкрита)

Для реалізації системи використано сучасний стек технологій, який забезпечує взаємодію між серверною частиною на платформі .NET та неймережевими моделями, реалізованими засобами Python. Розроблено користувацький інтерфейс, що підтримує повний цикл роботи інвестора із системою: від отримання ринкових даних і аналізу новин до формування прогнозів, налаштування інвестиційного профілю та отримання персоналізованих рекомендацій. Реалізовано механізми Explainable AI, які забезпечують прозорість прийняття рішень та інтерпретацію рекомендацій і внеску окремих факторів у підсумкову оцінку активів.

Проведене тестування підтвердило працездатність та ефективність розробленої системи. Результати бектестингу показали перевагу запропонованої системою стратегії над пасивним підходом Buy & Hold за показниками. Встановлено, що включення новинного фактору позитивно впливає на якість прогнозування та інвестиційні результати. Дослідження профілів інвестора підтвердило доцільність використання knowledge-based підходу, який забезпечує персоналізацію рекомендацій шляхом налаштування вагових коефіцієнтів функції корисності відповідно до індивідуальних пріоритетів користувача.

Отримані результати підтверджують ефективність запропонованих моделей, алгоритмів та архітектурних рішень, а також практичну придатність розробленої рекомендаційної системи для підтримки прийняття інвестиційних рішень.

## ВИСНОВКИ

У ході виконання роботи вирішено актуальне завдання розробки рекомендаційної системи підтримки прийняття інвестиційних рішень на основі прогнозування поведінки акцій індексу S&P 500 із використанням нейромережових моделей прогнозування та аналізу ринкових даних і фінансових новин.

У результаті проведеного дослідження встановлено, що традиційні підходи до аналізу фондового ринку мають обмежену ефективність при роботі з багатофакторними фінансовими даними. Аналіз існуючих програмних рішень виявив їхні недоліки: високу вартість, закритість архітектури та відсутність інтегрованих рекомендаційних механізмів з урахуванням новинного аналізу. Показано доцільність використання комплексного підходу, який поєднує прогнозування фінансових часових рядів, аналіз інформаційного фону та багатокритеріальне оцінювання інвестиційної привабливості активів.

Обґрунтовано використання knowledge-based підходу для побудови рекомендаційної системи та розроблено модель фільтрації інформації, що базується на функції корисності, яка інтегрує прогнозовану дохідність, ризик та новинний сентимент, що дозволяє реалізувати багатокритеріальну оцінку інвестиційної привабливості активів. Для аналізу тональності фінансових новин обґрунтовано використання моделі FinBERT. Запропонований підхід забезпечує формування персоналізованих інвестиційних рекомендацій з урахуванням індивідуальних пріоритетів інвестора.

Проведено експериментальне дослідження нейромережових моделей LSTM і Temporal Fusion Transformer для прогнозування фінансових часових рядів. За результатами оцінювання встановлено перевагу моделі TFT за показниками точності прогнозування, визначення напрямку руху ринку та співвідношення дохідності й ризику, що обумовило її вибір як прогнозного модуля системи.

Розроблено та реалізовано вебзастосунок рекомендаційної системи, який інтегрує модулі прогнозування, аналізу тональності фінансових новин, оцінювання

ризик, багатокритеріального ранжування активів та засоби пояснюваного штучного інтелекту. Проведене тестування підтвердило працездатність системи та ефективність запропонованих підходів. Результати бектестингу показали перевагу сформованої інвестиційної стратегії над пасивною стратегією Buy & Hold, а врахування новинного фактору забезпечило додаткове покращення якості прогнозування та інвестиційних результатів.

Отримані результати підтверджують досягнення поставленої мети дослідження та практичну придатність розробленої рекомендаційної системи для підтримки прийняття інвестиційних рішень на фондовому ринку. Поставлені завдання виконано у повному обсязі, однак система у подальшому може бути вдосконалена шляхом додавання автоматичного ребалансування портфеля, інтеграції з новими джерелами даних (Twitter/X API, Reddit, Telegram-каналами), розширення набору активів.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Finviz. Financial Visualizations : вебсайт. URL: <https://finviz.com/> (дата звернення: 20.04.2026).
2. TradingView. S&P 500 Index (SPX) : вебсайт. URL: <https://www.tradingview.com/symbols/SPX/> (дата звернення: 24.04.2026).
3. Моделювання і прогнозування по часових рядах : вебсайт. URL: [https://stud.com.ua/75017/statistika/modelyuvannya\\_prognozuvannya\\_chasovih\\_ryadah](https://stud.com.ua/75017/statistika/modelyuvannya_prognozuvannya_chasovih_ryadah) (дата звернення: 15.04.2026).
4. Стаціонарні та нестаціонарні часові ряди. Основні характеристики часових рядів : вебсайт. URL: <https://studfile.net/preview/2398204/page:22/> (дата звернення: 17.04.2026).
5. Фінансове моделювання : електронний посібник. Луцьк, 2018. URL: [https://elib.lntu.edu.ua/sites/default/files/elib\\_upload/Електронний%20посібник%20ФМ/index.html](https://elib.lntu.edu.ua/sites/default/files/elib_upload/Електронний%20посібник%20ФМ/index.html) (дата звернення: 09.02.2026).
6. The Complete Guide to Time Series Models. Built-in. Data Science : вебсайт. URL: <https://builtin.com/data-science/time-series-model> (дата звернення: 19.05.2024).
7. Introduction to the Fundamentals of Time Series Data and Analysis. APTECH : вебсайт. URL: <https://www.aptech.com/blog/introduction-to-the-fundamentals-of-time-series-data-and-analysis/> (дата звернення: 18.04.2026).
8. Woodward W. A., Sadler B. P., Robertson S. Time Series for Data Science: Analysis and Forecasting. Boca Raton : Chapman and Hall/CRC, 2022. 506 p.
9. Forecasting at Scale : препринт. URL: <https://peerj.com/preprints/3190.pdf> (дата звернення: 29.03.2026).
10. Prophet – Automatic Forecasting Procedure : вебсайт. URL: <https://pypi.org/project/fbprophet/> (дата звернення: 23.03.2026).
11. Kaczmarek T., Demir E., Rouatbi W., Zaremba A. Tariffs announcement as a global stress test: Early stock market reactions to U.S. protectionism. Finance Research Letters. 2025. Vol. 85. URL:

<https://www.sciencedirect.com/science/article/pii/S1544612325013376> (дата звернення: 24.04.2026).

12. Персоналізовані рекомендаційні системи для електронної комерції на основі гібридних AI-моделей. URL: <https://reposit.nupp.edu.ua/files/original/107/17950/20a4b73981e30a3fec04bfbb51fcafd1c130cc7b.pdf> (дата звернення: 25.04.2026).

13. Integrating deep learning and econometrics for stock price prediction. ScienceDirect. 2025. URL: <https://www.sciencedirect.com/science/article/pii/S2666827025001136> (дата звернення: 23.05.2026).

14. Prediction of Stock Price Time Series using Transformers. BWAIF 2023. URL: <https://www.semanticscholar.org/paper/b5122e0d32955d14bd0336afc28a7590ff90bdbb> (дата звернення: 22.05.2026).

15. A Critical Study on LSTM and Transformer Models for Financial Analysis. Springer. 2025. URL: [https://econpapers.repec.org/bookchap/sprisochnp/978-3-031-95099-5\\_5f9.htm](https://econpapers.repec.org/bookchap/sprisochnp/978-3-031-95099-5_5f9.htm) (дата звернення: 2.05.2026).

16. Comparing deep learning architectures for time series forecasting. Journal of Mathematics and Modeling in Finance. 2025. URL: [https://jmmf.atu.ac.ir/article\\_18671.html](https://jmmf.atu.ac.ir/article_18671.html) (дата звернення: 22.04.2026).

17. Lim B., Arik S., Loeff N., Pfister T. Temporal Fusion Transformers for interpretable multi-horizon time series forecasting. International Journal of Forecasting. 2021, vol. 37, pp. 1748-1764. URL: <https://doi.org/10.1016/j.ijforecast.2021.03.012> (дата звернення: 19.03.2026).

18. FinBERT-LSTM: Integrating News Sentiment Analysis. Scilit. 2024. URL: <https://www.scilit.net/publications/f500bbb89345c48d66c64a0f60a89388> (дата звернення: 2.04.2026).

19. Predicting Stock Prices with FinBERT-LSTM. ArxivLens. 2024. URL: <https://arxivlens.com/PaperView/Details/predicting-stock-prices-with-finbert-lstm-1320-2525459> (дата звернення: 17.03.2026).

20. Financial sentiment analysis using FinBERT with application in predicting stock movement. arXiv. 2025. URL: <http://arxiv.org/abs/2306.02136v2> (дата звернення: 7.04.2026).

21. FinBERT-DSA: Sentiment Analysis Model for Annual Reports. ACM Digital Library. 2024. URL: <https://dl.acm.org/doi/10.1145/3690407.3690460> (дата звернення: 12.05.2026).

22. Yang Y., Uy M. C. S., Huang A. FinBERT: A Pretrained Language Model for Financial Communications. Proceedings of the 29th ACM International Conference on Information and Knowledge Management. 2020. P. 1–4.

23. Kim W. та ін. DisSim-FinBERT: Text Simplification for Core Message Extraction in Complex Financial Texts. arXiv.org. 2025. URL: <https://arxiv.org/abs/2501.04959> (дата звернення: 29.04.2026).

24. Shobayo O., Adeyemi-Longe S., Popoola O., Ogunleye B. Innovative Sentiment Analysis and Prediction of Stock Price Using FinBERT, GPT-4 and Logistic Regression: A Data-Driven Approach. Big Data and Cognitive Computing. 2024. Vol. 8, № 11. P. 143.

25. Falk K. Practical recommender systems. Shelter Island, NY: Manning, 2019. 432 p.

26. Padti P.G., Hegde K., Kumar P. Hybrid Movie Recommender System. International Journal of Research in Engineering, Science and Management. 2021, vol. 4, no. 7, pp. 311–314.

27. Uta M, Felfernig A, Le V-M, Tran TNT, Garber D, Lubos S., Burgstaller T. Knowledge-based recommender systems: overview and research directions. Frontiers in Big Data. 2024, vol 7, P. 1304439. URL: <https://doi.org/10.3389/fdata.2024.1304439> (дата звернення: 15.04.2026).

28. Boliubash N., Khodzitskyi O. Dynamic updating of association rules in intelligent e-commerce recommendation systems. Actual Issues of Modern Science. European Scientific e-Journal. 2025, vol. 35, no 1, pp. 55-64. URL: <https://doi.org/10.47451/inn2025-01-02> (дата звернення: 6.03.2026).

29. Ko H., Lee S., Park Y., Choi A. A Survey of Recommendation Systems: Recommendation Models, Techniques, and Application Fields. *Electronics*. 2022, vol 11, no 1, 141. URL: <https://doi.org/10.3390/electronics11010141> (дата звернення: 3.05.2026).

30. Roy D., Dutta M. A systematic review and research perspective on recommender systems. *Journal of Big Data*. 2022, vol. 9, 59. URL: <https://doi.org/10.1186/s40537-022-00592-5> (дата звернення: 5.05.2026).

31. Болюбаш Н.М., Желтобрюхов О.І. Чат-бот для надання рекомендацій із перегляду відеофільмів на основі матричних факторизаційних моделей. *Інформаційні технології та суспільство*. 2024, № 1 (12), с. 20-30. URL: <https://doi.org/10.32689/maup.it.2024.1.3> (дата звернення: 12.04.2026).

32. Zhang Q., Lu J., Jin Y. Artificial intelligence in recommender systems. *Complex & Intelligent Systems*. 2021, vol. 7, pp. 439-457. URL: <https://doi.org/10.1007/s40747-020-00212-w> (дата звернення: 14.04.2026).

33. Boliubash N.M. Increasing the efficiency of psychological support in crisis situations using an information system based on generative artificial intelligence. *German International Journal of Modern Science*. 2026, № 124, pp. 84-92. URL: <https://doi.org/10.5281/zenodo.19195814> (дата звернення: 10.05.2026).

34. Tillari K. S. LSTM Architecture: Key to Understanding Sequential Data in AI. LinkedIn : вебсайт. URL: <https://www.linkedin.com/pulse/lstm-architecture-key-understanding-sequential-data-ai-tillari-opgrc/> (дата звернення: 29.04.2026).

35. Dokania R. Explain Transformer Architecture with Examples and Videos. LinkedIn : вебсайт. URL: <https://www.linkedin.com/pulse/explain-transformer-architecture-examples-videos-ritika-dokania-gxxbc/> (дата звернення: 29.04.2026).

36. Huang Y., Yang C. Enhancing stock price forecasting with a modular deep learning framework incorporating plug-and-play transformer variants. *Expert Systems with Applications*. 2026, vol. 315, P. 131572. URL: <https://doi.org/10.1016/j.eswa.2026.131572> (дата звернення: 4.04.2026).

37. Найпопулярніші бібліотеки Python : вебсайт. URL: <https://foxminded.ua/ru/biblioteki-python/> (дата звернення: 10.11.2025).
38. Evaluation of Stock Closing Prices using Transformer Learning. ETASR. 2023. URL: <https://www.etasr.com/index.php/ETASR/article/view/6173> (дата звернення: 22.05.2026).
39. Evaluation of Stock Closing Prices using Transformer Learning. Semantic Scholar. 2023. URL: <https://www.semanticscholar.org/paper/291e400786587f9925e01d5c1fb9b0aaa2a0ebd2> (дата звернення: 22.05.2026).
40. Yfinance Library – A Complete Guide : вебсайт. URL: <https://pypi.org/project/yfinance/> (дата звернення: 12.04.2026).

## ДОДАТОК А

### Технічні індикатори та формули їх розрахунку

Індикатор	Призначення	Формула
SMA	Згладжування тренду: середнє значення ціни за n періодів	$SMA_t = \frac{1}{n} \sum_{i=0}^{n-1} P_{t-i}$
EMA	Експоненціальне ковзне середнє, що надає більшу вагу новішим цінам	$EMA_t = \alpha P_t + (1 - \alpha) EMA_{(t-1)}$
MACD	Сила та напрям тренду	$MACD = EMA_{12} - EMA_{26}$
Bollinger Bands	Волатильність: смуги навколо ковзного середнього	$U = SMA + k\sigma$ $L = SMA - k\sigma$
RSI	Перекупленість/перепроданість, Індекс відносної сили	$RSI = 100 - \frac{100}{1 + RS}$
Stochastic	Імпульс руху: показує положення поточної ціни закриття відносно діапазону цін за останні n періодів	$\%K = 100 \cdot \frac{Close - Low_n}{High_n - Low_n}$
Williams %R	Сила імпульсу: рівень поточної ціни відносно максимуму та мінімуму за останні n періодів	$\%R = -100 \cdot \frac{High_n - Close}{High_n - Low_n}$
ROC	Швидкість зміни ціни	$ROC = \frac{Close_t - Close_{t-n}}{Close_{t-n}} \cdot 100$
ATR	Середня істинна волатильність	$ATR_t = \frac{1}{n} \sum_{i=1}^n TR_i$
OBV	Зв'язок ціни та обсягу: кумулятивний індикатор обсягу торгів	$OBV_t = BV_{t-1} + \begin{cases} Vol_t, Cl_t > Cl_{t-1} \\ 0, Cl_t = Cl_{t-1} \\ -Vol_t, Cl_t < Cl_{t-1} \end{cases}$

## ДОДАТОК Б

### Python-реалізація технічних індикаторів

```

import pandas as pd
import numpy as np

try:
    import ta
    TA_AVAILABLE = True
except ImportError:
    TA_AVAILABLE = False

def add_advanced_features(df: pd.DataFrame, dropna: bool = True,
                        use_technical: bool = True) -> pd.DataFrame:
    print(f" Обчислення ознак (технічні індикатори: {'ТАК' if use_technical else
'НІ'})...")
    groups = []

    for ticker, g in df.groupby("ticker"):
        g = g.copy().sort_values("date").reset_index(drop=True)
        close, high, low, volume, open_ = g["close"], g["high"], g["low"],
g["volume"], g["open"]

        if use_technical:
            if TA_AVAILABLE:
                g["ema_12"] = ta.trend.ema_indicator(close, window=12,
fillna=True)
                g["ema_26"] = ta.trend.ema_indicator(close, window=26,
fillna=True)
                g["sma_20"] = ta.trend.sma_indicator(close, window=20,
fillna=True)
                g["sma_50"] = ta.trend.sma_indicator(close, window=50,
fillna=True)
                g["sma_200"] = ta.trend.sma_indicator(close, window=200,
fillna=True)
                g["macd"] = ta.trend.macd(close, fillna=True)
                g["macd_sig"] = ta.trend.macd_signal(close, fillna=True)
                g["macd_diff"] = ta.trend.macd_diff(close, fillna=True)
                g["rsi"] = ta.momentum.rsi(close, window=14, fillna=True)
                g["rsi_20"] = ta.momentum.rsi(close, window=20, fillna=True)
                g["stoch_k"] = ta.momentum.stoch(high, low, close, fillna=True)
                g["stoch_d"] = ta.momentum.stoch_signal(high, low, close,
fillna=True)
                g["williams_r"] = ta.momentum.williams_r(high, low, close,
fillna=True)
                g["roc"] = ta.momentum.roc(close, window=10, fillna=True)
                g["bb_upper"] = ta.volatility.bollinger_hband(close, fillna=True)
                g["bb_lower"] = ta.volatility.bollinger_lband(close, fillna=True)
                g["bb_mid"] = ta.volatility.bollinger_mavg(close, fillna=True)
                g["bb_pct"] = ta.volatility.bollinger_pband(close, fillna=True)
                g["bb_width"] = ta.volatility.bollinger_wband(close, fillna=True)
                g["atr"] = ta.volatility.average_true_range(high, low, close,
fillna=True)
                g["obv"] = ta.volume.on_balance_volume(close, volume, fillna=True)
                g["mfi"] = ta.volume.money_flow_index(high, low, close, volume,
fillna=True)
                g["vwap"] = ta.volume.volume_weighted_average_price(high, low,
close, volume, fillna=True)
            else:

```

```

g["ema_12"] = close.ewm(span=12, adjust=False).mean()
g["ema_26"] = close.ewm(span=26, adjust=False).mean()
g["sma_20"] = close.rolling(20, min_periods=1).mean()
g["sma_50"] = close.rolling(50, min_periods=1).mean()
g["sma_200"] = close.rolling(200, min_periods=1).mean()
g["macd"] = g["ema_12"] - g["ema_26"]
g["macd_sig"] = g["macd"].ewm(span=9, adjust=False).mean()
g["macd_diff"] = g["macd"] - g["macd_sig"]
delta = close.diff()
gain = delta.clip(lower=0).rolling(14, min_periods=1).mean()
loss = (-delta.clip(upper=0)).rolling(14, min_periods=1).mean()
g["rsi"] = 100 - (100 / (1 + gain / (loss + 1e-8)))
g["rsi_20"] = g["rsi"]
g["stoch_k"] = 0.5
g["stoch_d"] = 0.5
g["williams_r"] = 0.0
g["roc"] = close.pct_change(10)
g["bb_upper"] = g["sma_20"] + 2 * close.rolling(20,
min_periods=1).std().fillna(0)
g["bb_lower"] = g["sma_20"] - 2 * close.rolling(20,
min_periods=1).std().fillna(0)
g["bb_mid"] = g["sma_20"]
g["bb_pct"] = (close - g["bb_lower"]) / (g["bb_upper"] -
g["bb_lower"] + 1e-8)
g["bb_width"] = (g["bb_upper"] - g["bb_lower"]) / (g["bb_mid"] +
1e-8)

g["atr"] = (high - low).rolling(14, min_periods=1).mean()
g["obv"] = (np.sign(close.diff()) * volume).cumsum()
g["mfi"] = 50.0
g["vwap"] = (close * volume).cumsum() / (volume.cumsum() + 1e-8)

for lag in [1, 2, 3, 5, 10, 20]:
    g[f"ret_{lag}d"] = close.pct_change(lag)

if use_technical:
    g["price_vs_sma20"] = (close - g["sma_20"]) / (g["sma_20"] + 1e-8)
    g["price_vs_sma50"] = (close - g["sma_50"]) / (g["sma_50"] + 1e-8)
    g["price_vs_sma200"] = (close - g["sma_200"]) / (g["sma_200"] + 1e-8)
    g["ema_cross"] = (g["ema_12"] - g["ema_26"]) / (g["ema_26"] + 1e-8)
    g["regime"] = (g["sma_50"] > g["sma_200"]).astype(float)
else:
    sma_20 = close.rolling(20, min_periods=1).mean()
    sma_50 = close.rolling(50, min_periods=1).mean()
    sma_200 = close.rolling(200, min_periods=1).mean()
    ema_12 = close.ewm(span=12, adjust=False).mean()
    ema_26 = close.ewm(span=26, adjust=False).mean()

    g["price_vs_sma20"] = (close - sma_20) / (sma_20 + 1e-8)
    g["price_vs_sma50"] = (close - sma_50) / (sma_50 + 1e-8)
    g["price_vs_sma200"] = (close - sma_200) / (sma_200 + 1e-8)
    g["ema_cross"] = (ema_12 - ema_26) / (ema_26 + 1e-8)
    g["regime"] = (sma_50 > sma_200).astype(float)

g["52w_high"] = close.rolling(252, min_periods=1).max()
g["52w_low"] = close.rolling(252, min_periods=1).min()
g["price_52w_pct"] = (close - g["52w_low"]) / (g["52w_high"] -
g["52w_low"] + 1e-8)

g["vol_sma20"] = volume.rolling(20, min_periods=1).mean()
g["vol_ratio"] = volume / (g["vol_sma20"] + 1e-8)

```

Кафедра інтелектуальних інформаційних систем  
 Рекомендаційна система прийняття інвестиційних рішень на основі прогнозування поведінки акцій S&P 500

```

g["volatility_30d"] = close.pct_change().rolling(30).std() *
np.sqrt(252)

g["momentum_10"] = close - close.shift(10)
g["price_accel"] = close.diff().diff()
g["hl_oscillator"] = (close - g["52w_low"]) / (g["52w_high"] -
g["52w_low"] + 1e-8) * 100
g["bid_ask_spread"] = (high - low) / close
g["oc_pct"] = (close - open_) / (open_ + 1e-8)
g["hl_pct"] = (high - low) / close
g["cum_ret_20d"] = (close / close.shift(20) - 1) * 100
g["cum_ret_60d"] = (close / close.shift(60) - 1) * 100

roll_min = close.rolling(20, min_periods=1).min()
roll_max = close.rolling(20, min_periods=1).max()
g["norm_range"] = (close - roll_min) / (roll_max - roll_min + 1e-8)

ret_series = close.pct_change()
g["vol_price_div"] = (
    ret_series.rolling(5, min_periods=1).mean() *
    volume.pct_change().rolling(5, min_periods=1).mean()
)

for lag in [1, 5]:
    g[f"autocorr_{lag}"] = ret_series.rolling(20, min_periods=10).apply(
        lambda x: float(pd.Series(x).autocorr(lag=lag)) if len(x) > lag
    else 0.0,
        raw=False
    )

g["day_of_week"] = g["date"].dt.dayofweek / 4.0
g["month_sin"] = np.sin(2 * np.pi * g["date"].dt.month / 12)
g["month_cos"] = np.cos(2 * np.pi * g["date"].dt.month / 12)

log_ret = np.log(close / close.shift(1))

g["up_days_ratio_5"] = log_ret.rolling(5, min_periods=1).apply(
    lambda x: (x > 0).sum() / 5.0 if len(x) >= 5 else 0.5, raw=False
)

g["up_days_ratio_10"] = log_ret.rolling(10, min_periods=1).apply(
    lambda x: (x > 0).sum() / 10.0 if len(x) >= 10 else 0.5, raw=False
)

streak = 0
consecutive = []
for r in log_ret:
    if pd.isna(r):
        consecutive.append(0)
        streak = 0
    elif r > 0:
        streak = streak + 1 if streak > 0 else 1
        consecutive.append(np.clip(streak / 5.0, -1.0, 1.0))
    elif r < 0:
        streak = streak - 1 if streak < 0 else -1
        consecutive.append(np.clip(streak / 5.0, -1.0, 1.0))
    else:
        consecutive.append(0)
        streak = 0
g["consecutive_up"] = consecutive

```

```

ret_5d = g["ret_5d"].fillna(0)
g["zscore_ret_5"] = ret_5d.rolling(20, min_periods=10).apply(
    lambda x: (x.iloc[-1] - x.mean()) / (x.std() + 1e-8) if len(x) >= 10
else 0, raw=False
)
g["zscore_ret_5"] = g["zscore_ret_5"].clip(-3, 3)

if use_technical:
    g["direction_ema"] = torch.tanh(
        (g["ema_12"] - g["ema_26"]) / (g["ema_26"] *
(g["volatility_30d"].fillna(0.2) / np.sqrt(252)) + 1e-8)
    )
else:
    ema_12 = close.ewm(span=12, adjust=False).mean()
    ema_26 = close.ewm(span=26, adjust=False).mean()
    vol_30 = close.pct_change().rolling(30).std() * np.sqrt(252)
    g["direction_ema"] = np.tanh((ema_12 - ema_26) / (ema_26 *
(vol_30.fillna(0.2) / np.sqrt(252)) + 1e-8))

groups.append(g)

result = pd.concat(groups, ignore_index=True).replace([np.inf, -np.inf],
np.nan)

if dropna:
    before = len(result)
    result = result.dropna().reset_index(drop=True)
    print(f" Рядків: {before:,} → {len(result):,} (після dropna)")
else:
    print(f" Всього рядків: {len(result):,}")

feature_count = len([c for c in result.columns if c not in df.columns])
print(f" Додано ознак: {feature_count}")

return result

```

## ДОДАТОК В

### Робастне масштабування ознак

```

import numpy as np
import pandas as pd

class RobustPerTickerScaler:
    def __init__(self):
        self.stats: dict = {}

    def fit(self, df: pd.DataFrame, feature_cols: list):
        for ticker, g in df.groupby("ticker"):
            vals = g[feature_cols].values.astype(np.float32)
            q75, q25 = np.percentile(vals, 75, axis=0), np.percentile(vals, 25,
axis=0)
            iqr = q75 - q25
            iqr[iqr < 1e-8] = 1.0
            self.stats[ticker] = {"median": np.median(vals, axis=0), "iqr": iqr}
        return self

    def transform(self, df: pd.DataFrame, feature_cols: list) -> pd.DataFrame:
        df = df.copy()
        for ticker, g in df.groupby("ticker"):
            st = self.stats.get(ticker, {"median": np.zeros(len(feature_cols)),
            "iqr": np.ones(len(feature_cols))})
            df.loc[g.index, feature_cols] = (g[feature_cols].values - st["median"])
            / st["iqr"]
        return df

    def fit_transform(self, df, feature_cols):
        return self.fit(df, feature_cols).transform(df, feature_cols)

    def get_cross_ticker_stats(self, feature_cols: list):
        all_medians = []
        all_iqrs = []

        for ticker, st in self.stats.items():
            all_medians.append(st["median"])
            all_iqrs.append(st["iqr"])

        all_medians = np.array(all_medians)
        all_iqrs = np.array(all_iqrs)

        feature_medians = np.median(all_medians, axis=0)
        feature_iqrs = np.median(all_iqrs, axis=0)

        ret_idx = 0
        target_median = feature_medians[ret_idx]
        target_iqr = feature_iqrs[ret_idx]

        return feature_medians, feature_iqrs, target_median, target_iqr

```