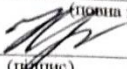


МІНІСТЕРСТВО ОСВІТИ ТА НАУКИ УКРАЇНИ
КРИВОРІЗЬКИЙ ФАХОВИЙ КОЛЕДЖ
ДЕРЖАВНОГО НЕКОМЕРЦІЙНОГО ПІДПРИЄМСТВА
«ДЕРЖАВНИЙ УНІВЕРСИТЕТ «КИЇВСЬКИЙ АВІАЦІЙНИЙ ІНСТИТУТ»
Циклова комісія комп'ютерних систем та мереж
(повна назва циклової комісії)

Допустити до захисту
Голова випускової циклової комісії
комп'ютерних систем та мереж
(повна назва циклової комісії)


(підпис) Ірина КРАВЧУК
(ім'я, ПРІЗВИЩЕ)

« 10 » 06 2025 р.

КВАЛІФІКАЦІЙНА РОБОТА
(ПОЯСНЮВАЛЬНА ЗАПИСКА)

ВИПУСКНИКА ОСВІТНЬО-ПРОФЕСІЙНОГО СТУПЕНЯ
ФАХОВИЙ МОЛОДШИЙ БАКАЛАВР

Тема: Прогнозування та аналіз фінансового ринку з використанням нейромереж

Група: 3-011

Спеціальність: 123 «Комп'ютерна інженерія»

Здобувач освіти


(підпис)

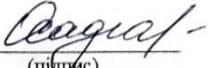
Дмитро КОРЕНЯК
(ім'я, ПРІЗВИЩЕ)

Керівник роботи


(підпис)

Микола РАШЕВСЬКИЙ
(ім'я, ПРІЗВИЩЕ)

Консультант з оформлення
пояснювальної записки


(підпис)

Оксана ОСАДЧА
(ім'я, ПРІЗВИЩЕ)

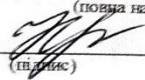
Кривий Ріг 2025 р.

КРИВОРІЗЬКИЙ ФАХОВИЙ КОЛЕДЖ
ДЕРЖАВНОГО НЕКОМЕРЦІЙНОГО ПІДПРИЄМСТВА
«ДЕРЖАВНИЙ УНІВЕРСИТЕТ «КИЇВСЬКИЙ АВІАЦІЙНИЙ ІНСТИТУТ»

Відділення комп'ютерної та програмної інженерії
Циклова комісія комп'ютерних систем та мереж
Освітньо-професійний ступінь фаховий молодший бакалавр
Спеціальність 123 «Комп'ютерна інженерія»

ЗАТВЕРДЖУЮ

Голова випускової циклової комісії
комп'ютерних систем та мереж


(підпис) Ірина КРАВЧУК
(ІМ'Я, ПРІЗВИЩЕ)

« 01 » 03 2025 р.

ЗАВДАННЯ

НА КВАЛІФІКАЦІЙНУ РОБОТУ ЗДОБУВАЧУ ОСВІТИ

КОРЕНЯКУ Дмитру Руслановичу

(прізвище, ім'я, по батькові)

1. Тема роботи Прогнозування та аналіз фінансового ринку з використанням нейромереж

Керівник роботи Рашевський Микола Олександрович, к.ф.-м.н, викладач

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом по коледжу від « 04 » 04 2025 року № 50-ст

2. Строк подання здобувачем освіти роботи з _____ по _____

3. Вихідні дані до роботи Виявлення складних закономірностей у фінансових рядах за допомогою нейромереж. Поєднання CNN, LSTM і механізму уваги для підвищення ефективності моделі.

4. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити)

Оцінка фінансових ризиків на основі штучного інтелекту

Аналіз сучасних моделей прогнозування фінансового ринку на основі глибокого

Реалізація моделей глибокого навчання для прогнозування фінансових рядів

5. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень)

Презентація Microsoft PowerPoint

6. Консультанти розділів роботи (проекту)

| Розділ | Прізвище, ініціали та посада консультанта | Підпис, дата | |
|--------|---|----------------|------------------|
| | | завдання видав | завдання прийняв |
| | | | |
| | | | |
| | | | |

7. Дата видачі завдання _____

КАЛЕНДАРНИЙ ПЛАН

| № з/п | Назва етапів кваліфікаційної роботи | Строк виконання етапів роботи | Примітка |
|-------|--|-------------------------------|----------|
| 1 | Узгодження технічного завдання з керівником кваліфікаційної роботи | 04.04.2025-07.04.2025 | виконано |
| 2 | Підбір та вивчення науково-технічної літератури за темою кваліфікаційної роботи | 08.04.2025-14.04.2025 | виконано |
| 3 | Оцінки фінансових ризиків на основі штучного інтелекту | 15.04.2025-21.04.2025 | виконано |
| 4 | Аналіз сучасних моделей прогнозування фінансового ринку на основі глибокого навчання | 22.04.2025-28.04.2025 | виконано |
| 5 | Реалізація моделей глибокого навчання для прогнозування фінансових часових рядів | 29.04.2025-23.05.2025 | виконано |
| 6 | Написання та оформлення пояснювальної записки | 26.05.2025-30.05.2025 | виконано |
| 7 | Попередній захист кваліфікаційної роботи | 09.06.2025-12.06.2025 | виконано |
| 8 | Захист кваліфікаційної роботи | | |

Здобувач освіти


(підпис)

Дмитро КОРЕНЯК

(ім'я, ПРІЗВИЩЕ)

Керівник роботи


(підпис)

Микола РАШЕВСЬКИЙ

(ім'я, ПРІЗВИЩЕ)



метадані

Звіт подібності

Назва організації
Ukrainian national aviation university
Заголовок
Робота Кореняк
Автор Науковий керівник / Експерт
Кореняк Рашевський М.
підрозділ
Криворізький Фаховий коледж

Обсяг знайдених подібностей

Коефіцієнт подібності визначає, який відсоток тексту по відношенню до загального обсягу тексту було знайдено в різних джерелах. Зверніть увагу, що високі значення коефіцієнта не автоматично означають плагіат. Звіт має аналізувати компетентна / уповноважена особа.

8.32%

8.32%

КП 1

0.38%

0.38%

КЦ

25

Довжина фрази для коефіцієнта подібності 2

8390

Кількість слів

66722

Кількість символів

Тригова

У цьому розділі ви знайдете інформацію щодо текстових спотворень. Ці спотворення в тексті можуть говорити про МОЖЛИВІ маніпуляції в тексті. Спотворення в тексті можуть мати навмисний характер, але частіше характер технічних помилок при конвертації документа та його збереженні, тому ми рекомендуємо вам підходити до аналізу цього модуля відповідально. У разі виникнення запитань, просимо звертатися до нашої служби підтримки.

| Заміна букв | | |
|------------------------|--|----|
| Інтервали | | 4 |
| Мікропробіли | | 0 |
| Білі знаки | | 0 |
| Парафрази (SmartMarks) | | 33 |

Подібності за списком джерел

Нижче наведений список джерел. В цьому списку є джерела із різних баз даних. Колір тексту означає в якому джерелі він був знайдений. Ці джерела і значення Коефіцієнту Подібності не відображають прямого плагіату. Необхідно відкрити кожне джерело і проаналізувати зміст і правильність оформлення джерела.

10 найдовших фраз

| ПОРЯДКОВИЙ НОМЕР | НАЗВА ТА АДРЕСА ДЖЕРЕЛА URL (НАЗВА БАЗИ) | Колір тексту |
|---------------------|---|--------------|
| 1 | https://www.techscience.com/CMES/v139n1/55114/html | 149 1.78 % |
| 2 | https://www.techscience.com/CMES/v139n1/55114/html | 38 0.45 % |
| 3 | http://web.engr.oregonstate.edu/~lif/2351.pdf | 38 0.45 % |
| 4 | https://www.techscience.com/CMES/v139n1/55114/html | 30 0.36 % |
| 5 | https://link.springer.com/chapter/10.1007/978-3-030-64466-6_2 | 27 0.32 % |

РЕФЕРАТ

Пояснювальна записка до кваліфікаційної роботи «Прогнозування та аналіз фінансового ринку з використанням нейромереж» містить: 52 сторінок, 14 рисунків, 2 таблиці, 36 використаних джерела.

НЕЙРОМЕРЕЖІ, ФІНАНСОВИЙ РИНОК, ПРОГНОЗУВАННЯ, ГЛИБОКЕ НАВЧАННЯ, ЧАСОВІ РЯДИ

Кваліфікаційна робота присвячена дослідженню можливостей застосування моделей глибокого навчання для прогнозування фінансового ринку. Об'єктом дослідження є процес аналізу фінансових часових рядів, а предметом — архітектури нейромереж, що використовуються для передбачення динаміки фінансових показників.

Метою роботи є побудова гібридної моделі на основі *CNN*, *LSTM* та механізму уваги (*Attention*), яка здатна забезпечити підвищену точність прогнозування ринкових тенденцій.

У процесі дослідження було проаналізовано актуальні наукові публікації, вивчено підходи до попередньої обробки даних, методи вибору ознак та налаштування гіперпараметрів. У третьому розділі детально описано структуру розробленої теоретичної моделі, принцип її роботи та результати, отримані з відкритих джерел.

Запропоноване рішення базується на перевірених у науковій практиці компонентах і може слугувати основою для побудови практичних систем прогнозування в сфері фінансової аналітики. Застосування таких моделей сприяє підвищенню ефективності прийняття рішень, зниженню ризиків та формуванню більш стійких фінансових стратегій.

5

ЗМІСТ

| | |
|---|---|
| ПЕРЕЛІК ПРИЙНЯТИХ СКОРОЧЕНЬ..... | 7 |
| ВСТУП..... | 9 |
| РОЗДІЛ 1 ОЦІНКИ ФІНАНСОВИХ РИЗИКІВ НА ОСНОВІ ШТУЧНОГО | |

| | |
|--|----|
| ІНТЕЛЕКТУ | 11 |
| 1.1 Вступ..... | 11 |
| 1.2 Штучний інтелект як рушійна сила реформування фінансової галузі..... | 12 |
| 1.3 Великі дані як інструмент підвищення точності фінансового маркетингу | 14 |
| 1.4 Посилення охоплення даних у системах управління фінансовими ризиками..... | 16 |
| 1.5 Підвищення точності технологій штучного інтелекту у фінансовій сфері | 18 |
| 1.6 Висновки до першого розділу | 21 |
| РОЗДІЛ 2 АНАЛІЗ СУЧАСНИХ МОДЕЛЕЙ ПРОГНОЗУВАННЯ ФІНАНСОВОГО РИНКУ НА ОСНОВІ ГЛИБОКОГО НАВЧАННЯ..... | |
| 2.1. Елементи та методи прогнозування фінансових часових рядів | 22 |
| 2.2. Вибір та витяг ознак машинного навчання..... | 25 |
| 2.3 Ключові моделі глибокого навчання для прогнозування фінансових часових рядів..... | 27 |
| 2.4 Рекурентні нейронні мережі (<i>RNN</i>) та мережі довгої короткочасної пам'яті (<i>LSTM</i>) | 30 |
| 2.5 Механізм уваги (<i>Attention</i>) та моделі <i>Transformer</i> | 33 |
| 2.6 Висновки до другого розділу..... | 34 |
| РОЗДІЛ 3 РЕАЛІЗАЦІЯ МОДЕЛЕЙ ГЛИБОКОГО НАВЧАННЯ ДЛЯ ПРОГНОЗУВАННЯ ФІНАНСОВИХ ЧАСОВИХ РЯДІВ..... | 36 |
| 3.1. Загальна архітектура та процеси..... | 36 |
| 3.2 Налаштування гіперпараметрів..... | 38 |
| 3.3 Метрики оцінювання ефективності моделей..... | 40 |
| 3.4 Автономні моделі..... | 42 |
| 3.5 Розробка гібридної моделі <i>CNN-LSTM-AM</i> для прогнозування фінансових часових рядів..... | 45 |
| 3.6 Висновок до третього розділу | 48 |
| ВИСНОВКИ | 49 |

ПЕРЕЛІК ПРИЙНЯТИХ СКОРОЧЕНЬ

AE - Auto encoder

AM - Attention mechanism

ANN - Artificial neural network

AR - Autoregression

ARCH - Autoregressive conditional heteroscedasticity

ARIMA - Autoregressive integrated moving average

ARMA - Autoregressive moving average

AutoML - Automated machine learning

CNN - Convolutional neural network

DL - Deep learning

DPA - Direction prediction accuracy

DQN - Deep Q-network

DT - Decision tree

EMD - Empirical mode decomposition

GCN - Graph convolutional network

GRU - Gated recurrent unit

KNN - K-nearest neighbors

LSTM - Long short-term memory

MAAPE - Mean arctangent absolute percentage error

MACD - Moving average convergence divergence

MAE - Mean absolute error

MAPE - Mean absolute percentage error

ML - Machine learning

MLP - Multi-layer perceptron

MSE - Mean squared error

NLP - Natural language processing

NN - Neural network

OD- Other data

OHLC- Open, high, low, close prices

PPD- Plain price data

PCA- Principal component analysis

R²-R squared

RF- Random forest

RMSE- Root mean squared error

RMSRE- Root mean squared relative error

RNN- Recurrent neural network

ROC- Rate of change

RSI- Relative strength index

SD- Sentiment data

SMA- Simple moving average

SVM- Support vector machine

TI- Technical indicator data

WT- Wavelet transform

ПЗ- програмне забезпечення

ІІІ- штучний інтелект

ВСТУП

У сучасних умовах цифрової трансформації фінансової галузі особливої актуальності набувають питання прогнозування та управління фінансовими ризиками з використанням інтелектуальних технологій. Постійне зростання обсягів даних, динаміка ринку та зростаюча складність фінансових взаємозв'язків зумовлюють необхідність пошуку нових підходів, що дозволяють підвищити точність аналітики, скоротити час прийняття рішень і мінімізувати можливі втрати.

Одним із найбільш перспективних напрямів вирішення цих завдань є застосування методів глибокого навчання, зокрема згорткових нейронних мереж

(*CNN*), мереж довгої короткочасної пам'яті (*LSTM*) та механізмів уваги (*Attention Mechanism*). Дані архітектури продемонстрували високу ефективність у суміжних галузях — таких як обробка природної мови, аналіз часових рядів і прогнозування поведінки користувачів — що створює передумови для їх активного впровадження і в сферу фінансів.

У межах цієї кваліфікаційної роботи планується розглянути можливості використання гібридних моделей глибокого навчання для задач прогнозування фінансового ринку, зокрема для аналізу часових рядів ринкових даних. З цією метою:

- у першому розділі планується здійснити аналіз теоретичних засад застосування штучного інтелекту у фінансовій сфері;

- у другому — провести систематизацію існуючих моделей прогнозування та підходів до вибору даних, структури мережі й методів оцінки;
- у третьому — спроектувати структуру гібридної моделі *CNN-LSTM AM*, яка теоретично поєднує просторові, часові та контекстуальні залежності у фінансових часових рядах.

Розроблена модель має теоретичний характер і буде сформована на основі детального аналізу наукових публікацій, визнаних у міжнародній академічній спільноті. Попередній аналіз наукових джерел показав, що архітектура та

10

компоненти моделі базуються на найкращих практиках, апробованих провідними фахівцями у сфері машинного навчання та фінансової аналітики. Експериментальні результати, що передбачається навести в роботі, будуть узяті з відкритих джерел і використані виключно з метою обґрунтування ефективності запропонованого підходу.

Очікується, що результати дослідження сприятимуть поглибленому розумінню механізмів побудови адаптивних моделей для аналізу фінансових даних, а також стануть основою для подальших практичних розробок у сфері прогнозування, оцінки ризиків і автоматизованого фінансового консультування.

11

РОЗДІЛ 1

ОЦІНКИ ФІНАНСОВИХ РИЗИКІВ НА ОСНОВІ ШТУЧНОГО ІНТЕЛЕКТУ

1.1 Вступ

У нову епоху безперервного розвитку сучасної науки і техніки їх значущість стрімко зростає, а сфери застосування постійно розширюються. Особливо це стосується фінансової галузі, де інтеграція передових технологій спричинила виникнення принципово нових підходів до аналізу, прогнозування й управління. Одним із таких підходів стало використання штучного інтелекту (ШІ), що сприяє трансформації традиційного фінансового середовища та змінює уявлення про механізми управління ризиками.

Поєднання фінансів і цифрових технологій зумовило появу нової парадигми у фінансовій аналітиці. Хоча застосування ШІ у фінансовому секторі супроводжується низкою непередбачуваних ризиків, зокрема пов'язаних із автоматизацією прийняття рішень і заміщенням людської участі, його потенціал викликає широке зацікавлення з боку дослідників і практиків.

З розвитком фінансової індустрії та активною інтеграцією інтернет технологій суттєво зросли обсяги фінансових даних, що генеруються під час операцій. Це створює підґрунтя для використання методів обробки великих даних і непараметричних статистичних підходів у системах управління ризиками. Високий рівень інформатизації зумовлює необхідність розробки нових моделей аналізу, які дозволяють трейдерам і аналітикам оперативно приймати обґрунтовані інвестиційні рішення.

Паралельно з розвитком ШІ спостерігається зростання інтересу до алгоритмів машинного навчання, які забезпечують можливість моделювання складних взаємозв'язків у фінансових даних. Історія розвитку ШІ, яка вже пережила дві хвилі злетів і спадів, сьогодні знову демонструє активне зростання

загальному прагненню до автоматизації процесів.

ШІ став невід'ємною частиною сучасної цифрової екосистеми, в якій взаємодіють конкуренція, співпраця та симбіоз. Його активне впровадження у сфері управління фінансовими ризиками відкриває нові можливості для ідентифікації загроз, моделювання сценаріїв та розробки превентивних стратегій.

Фінансова галузь є одним із провідних напрямів практичного застосування технологій великих даних. Аналіз таких даних дозволяє виявляти приховані закономірності, прогнозувати потенційні загрози та забезпечувати більш стійке функціонування фінансових установ. У зв'язку з цим надзвичайно актуальним є завдання трансформації традиційних механізмів управління ризиками шляхом інтеграції інтелектуальних систем.

Таким чином, сучасні виклики, пов'язані з обсягами даних, швидкістю прийняття рішень і динамікою ринку, обумовлюють необхідність впровадження інноваційних підходів. Штучний інтелект, як потужний інструмент обробки інформації та моделювання, здатен відіграти ключову роль у формуванні нових стратегій аналізу фінансових ризиків і вдосконаленні систем фінансової безпеки.

1.2 Штучний інтелект як рушійна сила реформування фінансової галузі

Застосування штучного інтелекту (ШІ) у фінансовій сфері сприяє зростанню ефективності обслуговування, трансформації бізнес-процесів і модернізації всієї фінансової екосистеми. В умовах цифрової епохи інтернет фінанси стали основним каналом передачі інформації, генеруючи величезні обсяги даних — зокрема відгуки про продукти, транзакційні записи та дані користувацької активності. Ці дані дозволяють глибше зрозуміти поведінкові моделі споживачів і виявити тенденції громадської думки.

Для країн із динамічним економічним розвитком, таких як Китай,

питання ефективного управління фінансовими ризиками стало критичним фактором, що визначає здатність рухатися від статусу великої економіки до статусу економічно потужної держави. У цьому контексті велике значення має використання новітніх статистичних методів на основі ШІ, зокрема непараметричних підходів, які здатні обробляти як структуровані, так і неструктуровані дані.

Інтеграція таких підходів дозволяє отримати цілісну картину функціонування фінансових структур, ідентифікувати закономірності та побудувати прогнозну модель зміни стану підприємства. На основі такої моделі можливо виявляти ризикові точки у фінансовій поведінці підприємств у режимі реального часу, оцінювати кожен потенційний ризик і реалізовувати механізми контролю для мінімізації втрат.

Фінансові ризики охоплюють будь-які загрози, що можуть призвести до втрати майна, капіталу або стабільності підприємства. Вони пов'язані з невизначеністю та коливаннями майбутніх доходів і є ключовими об'єктами для оцінки в межах систем управління. У цьому контексті моделі глибокого навчання (*deep learning*) забезпечують гнучкий і ефективний інструментарій для прогнозування та управління такими ризиками (рисунок 1.1).

Використовуючи можливості ШІ, фінансові установи можуть не лише ідентифікувати ризики, а й реалізовувати дієві стратегії зменшення їхнього впливу, одночасно підвищуючи прибутковість. Інтернет-фінанси, як прояв інформатизації, генерують велику кількість пов'язаних з клієнтами даних, що значно спрощує збирання інформації в порівнянні з традиційними фінансовими підходами. Зокрема, зберігання транзакційних записів користувачів на цифрових платформах відкриває нові горизонти для взаємодії між фінансовими консультантами та клієнтами.

Водночас, у світі надлишку даних особливо актуальним постає питання: як ефективно використовувати доступну інформацію та звести до мінімуму інформаційну асиметрію? Штучний інтелект здатен виконати цю задачу — за

рахунок інтеграції та аналізу гетерогенних даних він сприяє зниженню ризиків,

підвищенню точності прогнозів і зменшенню витрат на ручну аналітичну

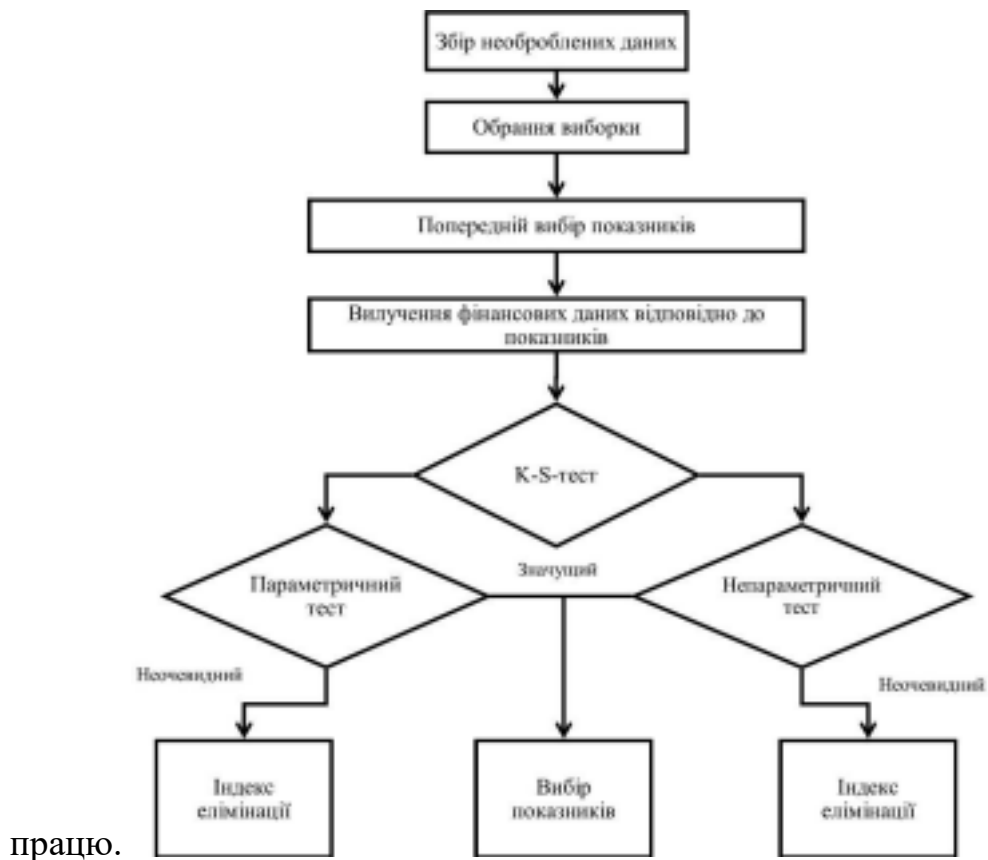


Рисунок 1.1 – Структура побудови моделі глибокого навчання для оцінки фінансових ризиків

1.3 Великі дані як інструмент підвищення точності фінансового маркетингу

Унаслідок стрімкого розвитку та масового впровадження інформаційних технологій більшість фінансових операцій сьогодні перемістилася з офлайн середовища до онлайн-простору. Це зумовило появу поняття "інтернет-фінанси", що охоплює широкий спектр цифрових фінансових послуг. Сучасний розвиток фінансової індустрії неможливий без урахування потреб великої кількості споживачів, які очікують не лише зручності, але й безпеки під час здійснення транзакцій. Одним із головних завдань є забезпечення захисту економічних

інтересів користувачів шляхом персоналізації сервісу та прогнозування їх

поведінкових моделей.

Для досягнення ефективного зростання фінансової активності надзвичайно важливою є побудова якісної системи управління користувачькими даними. Збирання, обробка та зберігання персональної інформації в інтегрованих системах управління підприємством стає базовим етапом цифрової трансформації. Технології великих даних (*Big Data*) відіграють тут ключову роль: вони дозволяють агрегувати як структуровані, так і неструктуровані дані, що генеруються під час фінансової взаємодії, здійснювати їхню класифікацію, аналіз та глибинне вивчення.

Big Data відкриває нові можливості для виявлення прихованих знань, створення доданої цінності та розвитку нових компетенцій. Історично вважалося, що для реалізації інтелектуальних систем необхідно моделювати процеси, подібні до людського мислення. Проте згодом було усвідомлено, що ефективність машинного інтелекту полягає не у відтворенні людської свідомості, а у здатності розв'язувати завдання, які зазвичай виконуються людьми.

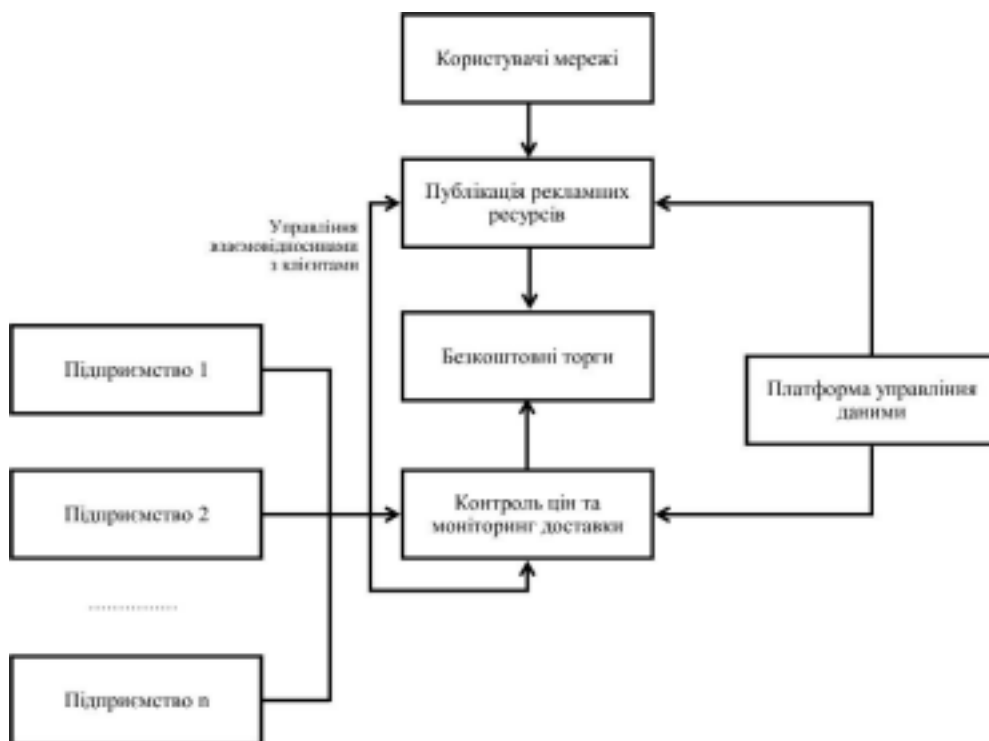


Рисунок 1.2 –
Модель точкового маркетингу у фінансах на основі технологій *Big Data*

У межах традиційної фінансової моделі основним джерелом доходів банків є кредитування фізичних і юридичних осіб. Прибуток формується

переважно за рахунок процентної різниці. Однак така система супроводжується численними ризиками, серед яких — ймовірність несплати боргів з боку позичальників, що може призвести до суттєвих фінансових збитків, або навіть до банкрутства.

Щоб зменшити ці ризики та ефективно використовувати дані, фінансова індустрія звернулася до технологій інтелектуального аналізу великих даних (*data mining*). Ці методи дозволяють знаходити цінну інформацію у складних масивах даних, на основі якої можна формувати персоналізовані маркетингові стратегії, прогнозувати споживчу поведінку та підвищувати точність фінансового обслуговування.

Таким чином, впровадження *Big Data* у фінансову сферу не лише вдосконалює процеси прийняття рішень, але й забезпечує глибший рівень розуміння потреб клієнтів, відкриваючи нові горизонти для конкурентоспроможного і стійкого розвитку галузі.

1.4 Посилення охоплення даних у системах управління фінансовими ризиками

У процесі управління фінансовими ризиками дані відіграють ключову роль як основне джерело інформації. Саме на їхній основі приймаються ефективні управлінські рішення. Збір, обробка та аналіз великих обсягів фінансової інформації є необхідною умовою для забезпечення повноти картини поточних і потенційних ризиків. Тому етап отримання даних має особливе значення: він створює інформаційний фундамент, який забезпечує надійність та своєчасність управлінських дій у фінансовій сфері.

Великі дані дають змогу досягти вищого рівня всебічності в аналізі ризиків, що дозволяє приймати більш обґрунтовані рішення. Особливо важливо це в контексті системних фінансових ризиків, на які впливають численні фактори

— такі як дисбаланс строків активів і пасивів, ірраціональні коливання на

ринку, макроекономічні диспропорції, а також міжнародні економічні виклики. Використовуючи методи математичної статистики у поєднанні з технологіями *Big Data*, можна не лише отримати всеохопну інформацію, але й проаналізувати взаємозв'язки, взаємний вплив і ефекти поширення між факторами ризику. Це створює передумови для прийняття науково обґрунтованих рішень щодо запобігання системним загрозам у фінансовій сфері.

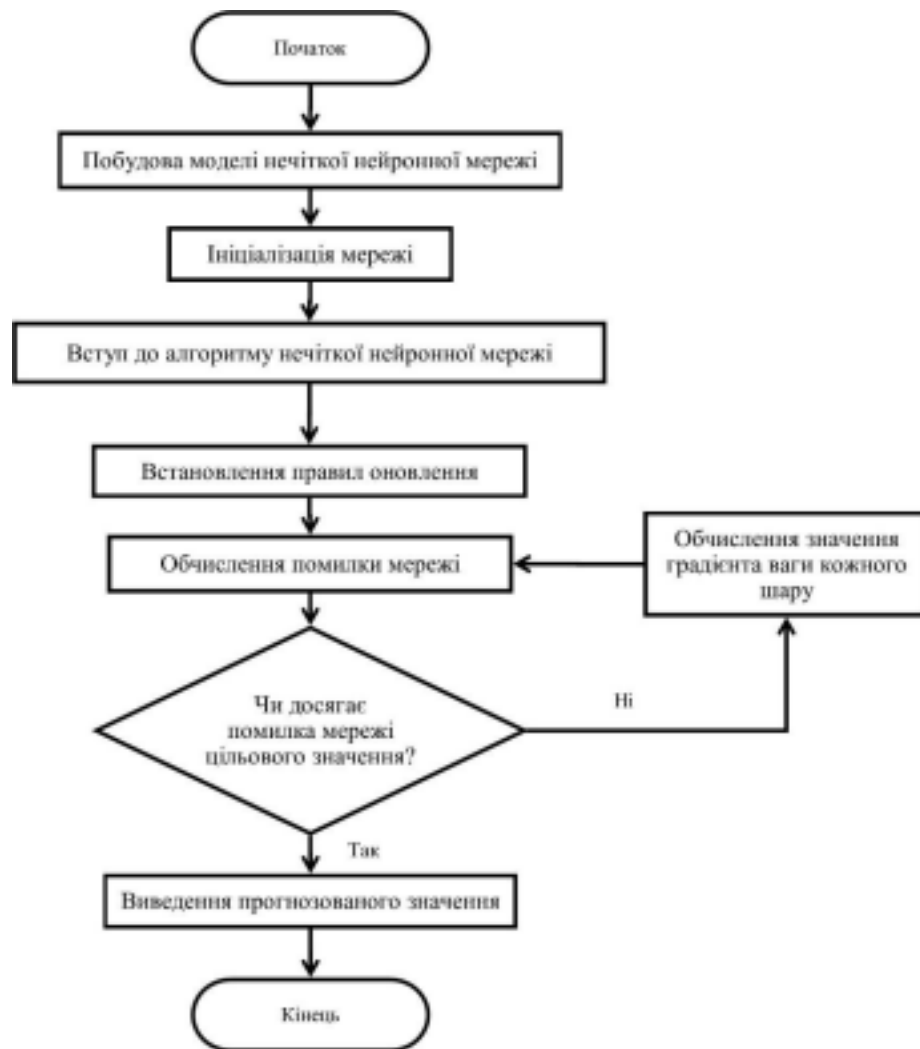


Рисунок 1.3 – Частковий процес прогнозування фінансових ризиків на основі нечіткої нейронної мережі

Одним із ключових компонентів управління є система раннього попередження про ризику, яка забезпечує виявлення загроз у процесі інтернет фінансових транзакцій. Така система повинна охоплювати весь цикл фінансової

18
активності — від моменту ініціації транзакції до її завершення — і водночас

захищати інтереси користувачів. Важливим є й відображення регуляторних дій державних органів у реальному часі, що дає змогу контролювати відповідність транзакцій чинним правовим та етичним нормам.

Зокрема, серед найбільш поширених ризиків в інтернет-фінансах — кредитні ризики, які виникають через непередбачувані обставини або шахрайські дії, що унеможливають виконання зобов'язань за укладеними договорами. У цьому контексті безпека даних і збереження персональної інформації користувачів набувають критичного значення.

Слід зазначити, що в багатьох країнах, зокрема і в Україні, основа інформаційної безпеки ще перебуває на стадії розвитку. Тому доцільно стимулювати співпрацю фінансових установ із науковими центрами та технологічними компаніями, які спеціалізуються на дослідженнях і розробках у галузі штучного інтелекту. Така кооперація дозволяє використовувати технічні переваги, розширювати можливості захисту даних, зокрема через впровадження систем шифрування інформації, та ефективніше протидіяти загрозам кібербезпеки.

Таким чином, стратегічне партнерство між фінансовим сектором і розробниками технологій ШІ є ключовим фактором для формування надійних систем управління ризиками та забезпечення стабільності цифрової фінансової екосистеми.

1.5 Підвищення точності технологій штучного інтелекту у фінансовій сфері

Однією з ключових проблем сучасної банківської системи є затримка у виявленні змін у фінансовому стані фізичних та юридичних осіб. Це може бути спричинено як складністю аналізу постійно змінних факторів, так і поширеними схемами, такими як замкнуте кредитування. Для подолання цих проблем

19

ефективним інструментом є технології інтелектуального аналізу даних (*data mining*), які дозволяють виявляти приховані закономірності в поведінці клієнтів.

Аналізуючи фактори, що впливають на кредитоспроможність клієнтів — такі як регіональні особливості, рівень освіти, доходи, економічне середовище, соціальні зобов'язання тощо — системи на основі ШІ можуть швидко формувати рейтинг кредитного ризику користувача та визначати доцільні параметри кредитування. Це забезпечує більш персоналізований та ефективний підхід до управління ризиками в банківському секторі.

Основною перевагою сучасних рішень на базі штучного інтелекту є синергія глибинного навчання (*deep learning*) та технологій великих даних. ШІ здатен швидко обробляти великі масиви даних, що динамічно змінюються, виявляти джерела потенційних ризиків на фінансовому ринку та надавати науково обґрунтовані рекомендації щодо управління ними.

Щоб якісно оволодіти процесами розвитку фінансових ризиків і визначити їх закономірності, важливо посилити використання технологій штучного інтелекту. Вони дозволяють переходити від поверхневих характеристик до глибинного розуміння сутності ризику, підвищуючи точність прогнозування та ефективність управлінських рішень.

Раціональне впровадження ШІ у сферу управління ризиками не лише пришвидшує обробку інформації, але й значно знижує витрати на людські ресурси. Однак для повноцінної реалізації системи управління ризиками необхідно насамперед переглянути та оптимізувати існуючі бізнес-процеси. Кожен етап має бути чітко закріплений за відповідальними особами або підрозділами, щоб забезпечити послідовне виконання політик і процедур управління ризиками.

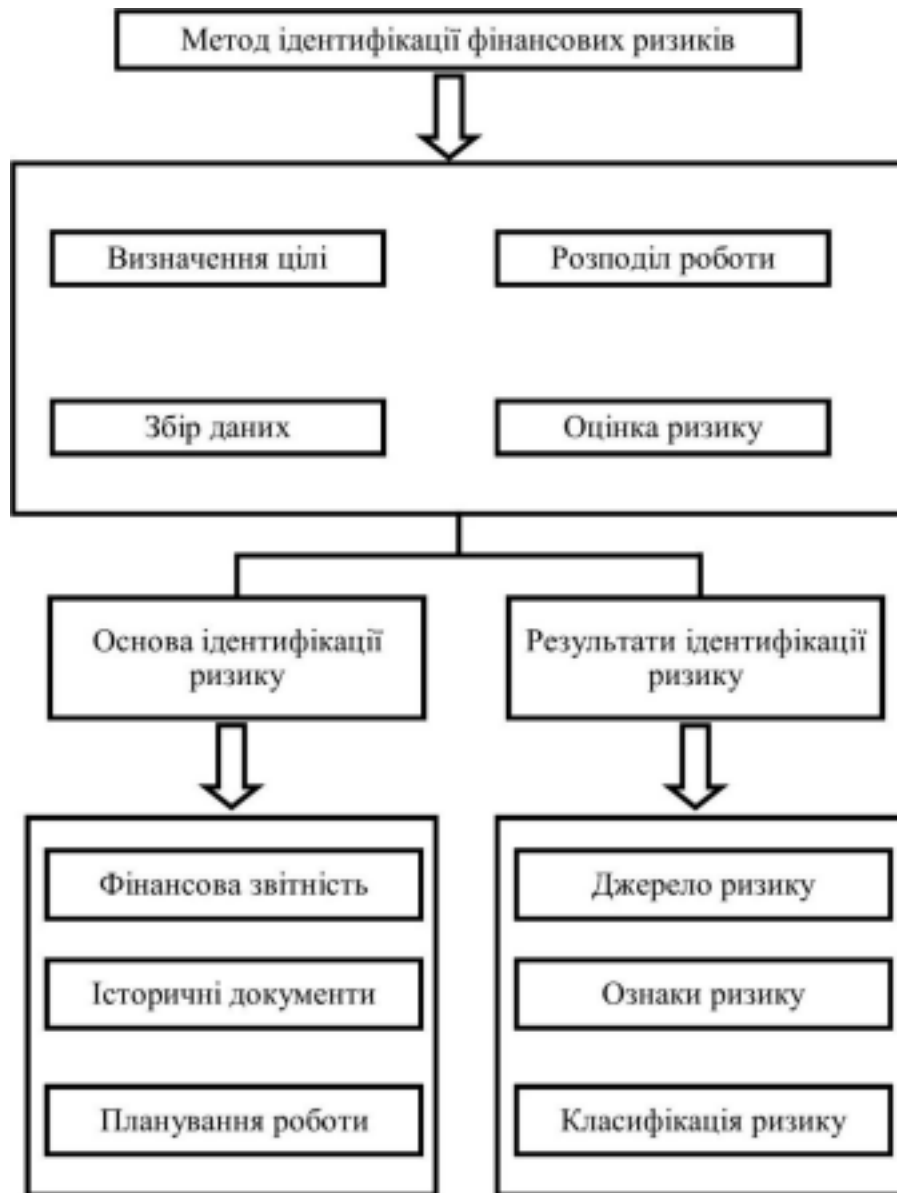


Рисунок 1.4 – Система ідентифікації фінансових ризиків на основі штучного інтелекту

Комплексне застосування технологій ШІ у сфері фінансового ризик менеджменту має ґрунтуватися на сильних сторонах цих технологій: глибокому навчанні, обробці великих даних і здатності до адаптивного самонавчання. Саме ці властивості дають змогу точно ідентифікувати великі обсяги інформації на фінансовому ринку та пов’язані з нею ризики, забезпечуючи наукову основу для точного, ефективного й комплексного прийняття рішень.

1.6 Висновки до першого розділу

Розвиток і впровадження технологій штучного інтелекту стали невід’ємною складовою трансформації сучасної фінансової галузі. ШІ сприяє еволюції фінансових продуктів і послуг, покращує фінансову екосистему та створює нові можливості для користувачів, забезпечуючи зручний, гнучкий і різноманітний досвід у сфері інтернет-фінансів.

В умовах стрімкого зростання цифрової економіки особливе значення набуває аналітика даних. Ефективне управління фінансовими ризиками неможливе без своєчасного аналізу великого обсягу нестабільних і різноманітних фінансових даних. Тому необхідно впроваджувати системні підходи до побудови дата-центрів, розробляти інфраструктуру для обробки потоків даних у реальному часі та своєчасно реагувати на потенційні загрози.

Своєчасне попередження ризиків, формування механізмів прогнозування та швидке реагування на виклики інтернет-фінансів — це основні функції, які забезпечують підвищення стійкості фінансової системи. Проте, попри значні досягнення, застосування ШІ у фінансовому секторі має певні обмеження. Зокрема, штучний інтелект може стикатися з невизначеними чи неповними вхідними даними, що призводить до помилок в аналізі та, як наслідок, — до неправильних управлінських рішень.

У зв’язку з цим інвесторам, аналітикам і регуляторам важливо мати обґрунтоване уявлення про переваги та ризики, пов’язані з впровадженням ШІ. Застосування таких технологій повинно супроводжуватися належним контролем і захистом від нових загроз, які можуть виникати внаслідок недосконалості алгоритмів або їх некоректної роботи.

Отже, для досягнення максимальної ефективності застосування ШІ в управлінні фінансовими ризиками необхідно поєднувати інноваційний підхід з практиками управління ризиками, інформаційною безпекою та правовим регулюванням.

РОЗДІЛ 2

АНАЛІЗ СУЧАСНИХ МОДЕЛЕЙ ПРОГНОЗУВАННЯ ФІНАНСОВОГО РИНКУ НА ОСНОВІ ГЛИБОКОГО НАВЧАННЯ

2.1 Елементи та методи прогнозування фінансових часових рядів

Прогнозування фінансових часових рядів із використанням методів глибокого навчання передбачає обробку великої кількості різноманітних даних, їх попередню підготовку, вибір релевантних ознак, а також застосування спеціалізованих архітектур нейронних мереж для ефективного навчання та передбачення. У відібраних наукових дослідженнях визначено ключові підходи до вибору типів вхідних даних, методів відбору та витягання ознак, а також особливості їх поєднання з глибокими нейронними мережами.

Найчастіше моделі глибокого навчання використовують такі основні типи даних:

- цінові дані (*plain price data*) — базові характеристики фінансових інструментів: відкриття, максимум, мінімум, закриття (*OHLC*), обсяги торгів, обсяги угод тощо. Дані можуть стосуватися акцій, індексів (наприклад, *S&P 500*, *NASDAQ*, *SSE*), валют або криптовалю. Частота записів — щоденна або внутрішньоденна (годинна, хвилинна, тощо). Ці дані є фундаментальними для побудови моделей, використовуються як мітки для навчання і часто — як єдине джерело ознак;

- технічні індикатори (*technical indicators, TI*) — обчислюються на основі цінових даних та застосовуються для аналізу трендів, імпульсів і волатильності ринку. У моделі глибокого навчання технічні індикатори представлені у вигляді числових векторів. Їх поділяють на три основні категорії:

- індикатори тренду: *SMA* (проста ковзна середня), *EMA* (експоненціальна), *WMA* (зважена);

- індикатори імпульсу: *RoC* (швидкість зміни), *MACD*, *RSI*, *CCI*, *%K* та *%D*, *Momentum Index*;

- індикатори волатильності: *VIX*, *ATR*.

У багатьох дослідженнях комбінуються одразу декілька індикаторів. Наприклад, у [4] було показано, що поєднання *%K*, *MACD*, *RSI* і *WR* забезпечує точність до 83,6% при використанні моделі *LSTM*.

Сентимент-аналіз (*sentiment data*) — відображає настрої інвесторів на основі новин, повідомлень у соцмережах, аналітики тощо. Позитивний чи негативний настрої може суттєво впливати на динаміку ціни. Дані можуть бути отримані через обробку текстів (лексичний або *ML*-підхід) або з *API* сервісів. Незважаючи на високу потенційну цінність, такі дані використовуються обмежено [5–9].

Інші дані — новини про компанії, кількість випадків *COVID-19*, макроекономічна інформація, дивідендні оголошення тощо. Наприклад, у [10] для підвищення якості прогнозу використовувались заголовки новин, які були попередньо оброблені методами побудови графів знань.

На рисунку 2.1 наведено приклад структури типового вхідного датасету, який містить цінові, технічні та альтернативні характеристики.

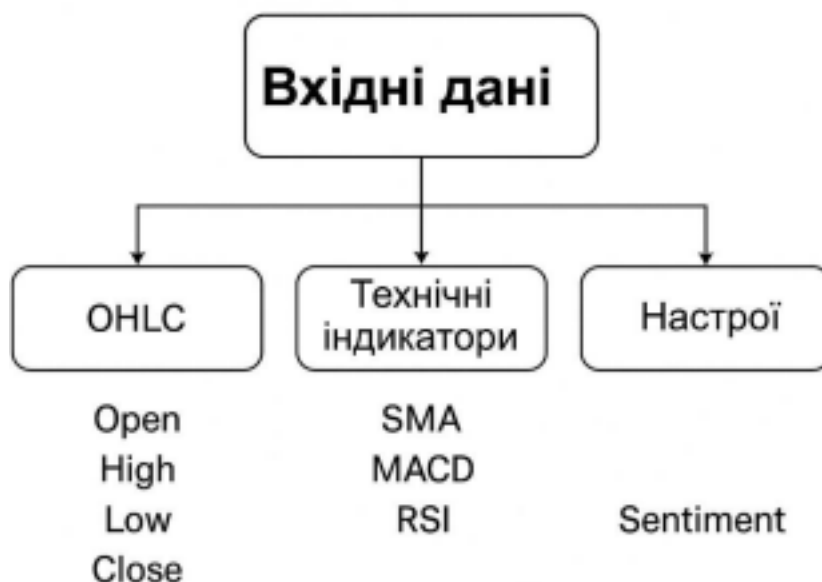


Рисунок 2.1 – Структура типового вхідного датасету

Додатково, таблиця 2.1 ілюструє конкретні приклади наборів даних із літератури з вказанням типів даних (*P* — ціни, *TI* — технічні індикатори, *S* — сентимент, *O* — інше), ринку, частоти та періоду спостереження.

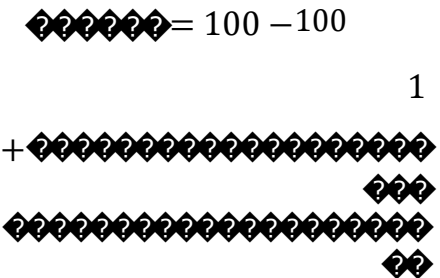
Таблиця 2.1 – Найчастіше використовувані технічні індикатори

| Технічний індикатор | Рівняння | Опис |
|---------------------|----------|------|
| | | |

| | | |
|--------------------|---|--|
| <p><i>SMA</i></p> | $\frac{\sum_{i=1}^n P_{t-i}}{n}$ | <p><i>SMA</i> (проста ковзна середня) відображає середній тренд у межах заданого ковзного вікна часу, що згладжує часовий ряд і зменшує вплив аномальних значень. Це один із найдавніших та найпоширеніших технічних індикаторів, згідно з літературними джерелами.</p> |
| <p><i>RoC</i></p> | $\frac{P_t - P_{t-1}}{P_{t-1}}$ | <p><i>RoC</i> (швидкість зміни) або дохідність використовується для оцінки прибутку чи збитку інвестиції з часом. Ключова відмінність між арифметичною та логарифмічною дохідністю полягає в тому, що перша є дискретною, не складною і обчислюється лише за один період, тоді як друга є безперервною та дозволяє враховувати складний ефект протягом кількох неперекривних періодів шляхом підсумовування.</p> |
| <p>%K та %D</p> | $\%K = \frac{P_t - P_{t-1}}{P_{t-1} - P_{t-2}}$ $\%D = 3 - \frac{\%K}{2}$ | <p>Стохастичний осцилятор порівнює ціну закриття фінансового інструменту з діапазоном його цін за певний період. Зазвичай він відображається у вигляді двох ліній — %K та %D. Торгові сигнали генеруються в моменти перетину цих ліній. Якщо %K перетинає %D зверху вниз — це потенційний сигнал до продажу, і навпаки.</p> |
| <p><i>MACD</i></p> | $MACD = EMA_{12} - EMA_{26}$ | <p><i>MACD</i> (<i>Moving Average Convergence Divergence</i>) відображає співвідношення між двома експоненціальними ковзними середніми (<i>EMA</i>) ціни фінансового інструменту. Зазвичай його доповнює сигнальна лінія — 9-денна <i>EMA</i> самого <i>MACD</i>. Потенційний сигнал до продажу виникає, коли лінія <i>MACD</i> перетинає сигнальну лінію згори вниз, і навпаки — сигнал до купівлі.</p> |

Продовження таблиці 2.1

| Технічний індикатор | Рівняння | Опис |
|---------------------|----------|------|
|---------------------|----------|------|

| | | |
|------------|---|---|
| <i>RSI</i> |  | <i>RSI</i> (індекс відносної сили) відображає швидкість і амплітуду нещодавніх коливань ціни фінансового інструменту з метою визначення, чи є він недооціненим або переоціненим, що, своєю чергою, дозволяє генерувати сигнали на купівлю або продаж. |
|------------|---|---|

У більшості моделей дані з різних джерел комбінуються. Наприклад, у [10] для прогнозу індексу *Nifty 50* застосовувались: цінові дані, технічні індикатори, валютні курси, ціни на сировину. Вікно аналізу — 20 торгових днів. Модель *CNN-LSTM*, побудована на таких даних, демонструвала значно кращу ефективність порівняно з аналогами.

2.2 Вибір та витяг ознак машинного навчання

У машинному навчанні дані часто розглядаються як багатовимірний простір ознак, де кожен вимір відповідає певному параметру (ознаці). У реальних умовах сирі (необроблені) дані можуть містити занадто велику кількість ознак, що призводить до так званого «прокляття розмірності» (*curse of dimensionality*) — явища, коли висока кількість параметрів погіршує якість навчання моделі. Згідно з дослідженнями, подача великого обсягу сирих ознак без їх фільтрації часто призводить до зниження точності моделі [1]. Саме тому процеси відбору ознак (*feature selection*) і витягу ознак (*feature extraction*) зазвичай виконуються перед етапом навчання моделі.

Вибір ознак — це процес скорочення кількості параметрів для моделювання. Він може бути реалізований як за допомогою непідконтрольних методів (наприклад, кореляційний аналіз), так і підконтрольних (методи фільтрації або обгортки). Основна ідея полягає в тому, щоб відібрати лише ті ознаки, які мають найбільше значення для прогнозної задачі.

Серед сучасних підходів часто використовуються еволюційні алгоритми, зокрема генетичні алгоритми (*GA*) [11]. Також можуть бути враховані знання

галузових експертів, які вручну визначають критично важливі показники для аналізу.

Витяг ознак (інженерія ознак) полягає у перетворенні початкових ознак у нову форму, яка є більш придатною для моделювання. Це, зазвичай, досягається за допомогою алгоритмів зменшення розмірності. Важливо розрізняти відбір і витяг ознак: перше — це відсікання непотрібних, друге — створення нових ознак на основі наявних.

Найбільш поширені методи витягу ознак у фінансовому прогнозуванні: - *PCA* (аналіз головних компонент) — один із найпопулярніших методів для зменшення розмірності. Він виділяє головні компоненти, які найбільше впливають на змінність даних. *PCA* ефективно знижує шум та непотрібні ознаки. Для нелінійних даних може застосовуватись *Kernel PCA* з попереднім нелінійним перетворенням;

- *Wavelet Transform (WT)* — застосовується для приглушення шумів, особливо ефективний у задачах обробки сигналів. У фінансовому аналізі *WT* часто використовують разом із *PCA* [12].

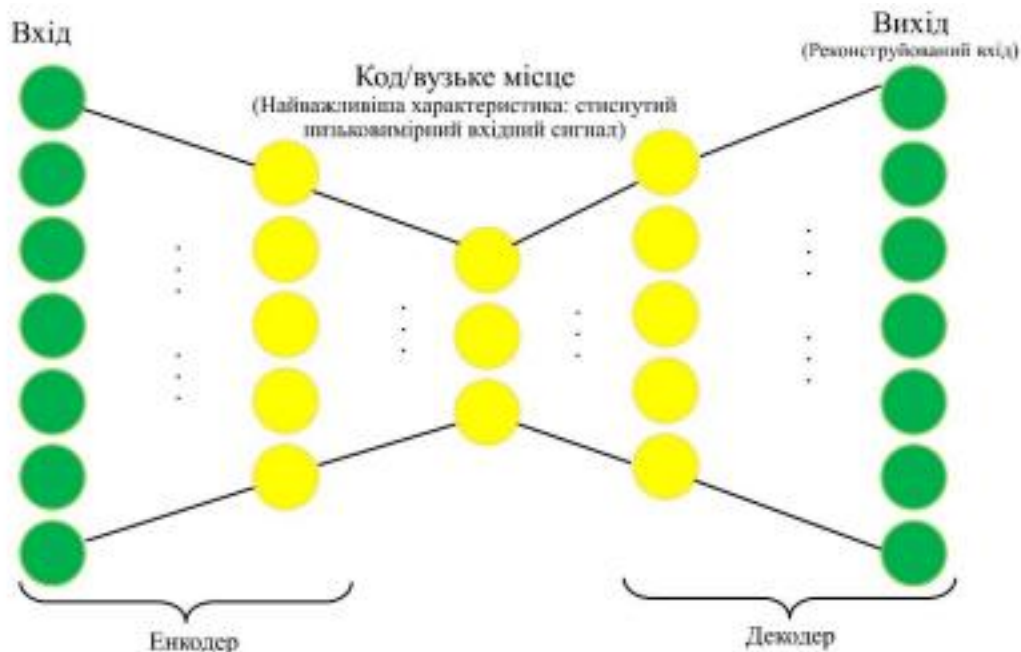
- *EMD* (емпіричне модальне розкладання) — метод, що розбиває часовий ряд на кілька внутрішніх мод (*IMF*), які відображають окремі частоти. Його варіації, такі як *CEEMD*, також застосовуються в задачах фінансового прогнозування [13, 14];

- *Autoencoder (AE)* — особливий тип штучної нейронної мережі, що складається з енкодера, який стискає вхідні дані, та декодера, що їх реконструює. Якщо «вузьке місце» (*bottleneck*) має меншу розмірність, ніж вхідні дані — *AE* виконує зменшення розмірності. При цьому застосовуються нелінійні функції активації, як-от *ReLU* або *sigmoid*. Архітектура *AE* близька за принципом до *PCA*, але дозволяє складніші перетворення завдяки нелінійності.

На рисунок 2.2 зображено приклад структури автоенкодера, де вузьке місце мережі відповідає стислому поданню вхідних даних.

Convolutional Neural Network (CNN) — хоча первісно *CNN* розроблялись для задач комп'ютерного зору, вони ефективно використовуються і в

прогнозуванні часових рядів, зокрема для витягу просторових ознак. Для цього фінансові дані іноді перетворюють у формат «зображень» або двовимірних матриць, які потім подаються на вхід моделі *CNN*.



Рисунок

2.2 – Приклад недоповненої мережі автоенкодерів, в якій вузьке місце являє собою стиснуте низьковимірне представлення вхідних даних.

2.3 Ключові моделі глибокого навчання для прогнозування фінансових часових рядів

У сучасних наукових дослідженнях для вирішення задач прогнозування фінансових часових рядів активно застосовуються такі моделі глибокого навчання, як згорткові нейронні мережі (*CNN*), мережі довгої короткочасної пам'яті (*LSTM*) та механізм уваги (*Attention Mechanism, AM*). У цьому підрозділі розглянемо принципи їхньої побудови та застосування.

Згорткова нейронна мережа (*CNN*). Архітектура *CNN* зазвичай складається з одного або кількох згорткових шарів (*convolutional layers*) у поєднанні з шарами підвибірки (*pooling layers*), після яких слідує один або кілька

повнозв'язних (*fully connected, FC*) або щільних (*dense*) шарів. На відміну від традиційних штучних нейронних мереж (*ANN*), де витяг ознак здійснюється

вручну, *CNN* виконує цей процес автоматично за допомогою операцій згортки та підвибірки.

Згортковий шар генерує карти ознак (*feature maps*), які утворюються шляхом згортки — ковзного переміщення ядра фільтра (*kernel*) по матриці вхідних даних з обчисленням скалярного добутку. Часто застосовується паддінг (*padding*) — додавання нульових значень по краях, щоб зберегти розміри карти. Кількість згорткових шарів визначається складністю вхідних даних і бажаним рівнем абстракції. Занадто велика глибина може спричинити перенавчання (*overfitting*).

Шар підвибірки (*Pooling*). Цей шар зменшує розмірність даних, виділяючи найважливіші ознаки та знижуючи обчислювальні витрати. У фінансовому прогнозуванні зазвичай використовують *max-pooling* або *average pooling*.

Оскільки фінансові ряди містять тонкі часові закономірності, іноді від шару підвибірки взагалі відмовляються, щоб уникнути втрати інформації.

Повнозв'язний шар. Це завершальний етап *CNN*, який формує остаточний прогноз. Перед подачею на цей шар вихід попередніх шарів зазвичай «сплющується» (*flatten*) у вектор. У задачах регресії останній шар має один вихід (значення ціни), у класифікації — два або три виходи (наприклад, зростання/спад або *Buy/Hold/Sell*).

Активаційні функції. Для обчислення виходу нейрона використовуються функції активації, зокрема:

- *sigmoid* – для бінарної класифікації;
- *tanh* – менш поширена через ефект згасаючого градієнта; -
- ReLU* – найбільш популярна на внутрішніх шарах;
- *softmax* – для багатокласової класифікації;
- лінійна функція – для регресійних задач.

На рисунку 2.3 показано приклад *CNN* для прогнозування ціни акцій.

Вхідні дані подаються у вигляді матриці розміром 60 днів \times 82 змінні. Перший

29

згортковий шар застосовує 8 фільтрів 1×82 для створення векторів вищого рівня. Далі шари з фільтрами 3×1 і 2×1 *max-pooling* дозволяють об'єднати

інформацію з кількох днів, і результат подається на повнозв'язний шар із *sigmoid*-функцією, що прогнозує ймовірність зростання ціни наступного дня.

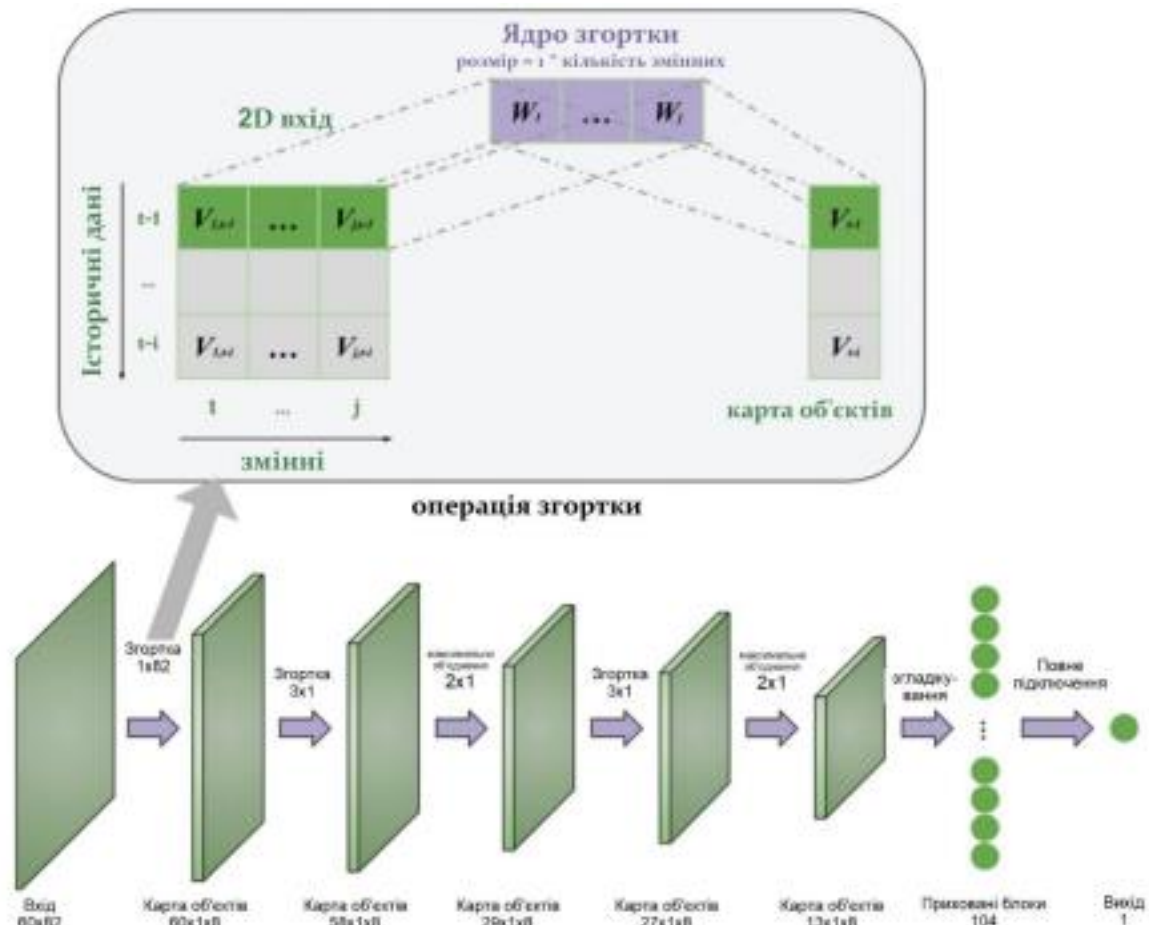


Рисунок 2.3 – Приклад типової згорткової нейронної мережі з ілюстрацією фільтра початкових змінних, що дорівнює 1, для створення високорівневих ознак

Успішне застосування *CNN* у фінансовій сфері вимагає гнучких операцій з даними:

- перетворення даних: оскільки фінансові ряди одномірні, їх часто перетворюють у двовимірні (матриці або «зображення») через методи ковзного вікна, або навіть у тривимірні структури при використанні мульти-ринкових даних;

30

- розмір фільтра: занадто малий фільтр може не вловити глобальних трендів, а занадто великий — втратити локальні закономірності. Розмір обирається експериментально;

- перенавчання: для боротьби з ним використовують регуляризацію —

dropout, ранню зупинку (*early stopping*) тощо. *Dropout* випадково деактивує нейрони під час навчання, що сприяє узагальненню.

Варіації *CNN*:

- *Graph Convolutional Network (GCN)* — адаптація *CNN* для обробки графових (неєвклідових) структур, наприклад, для моделювання взаємозв'язків між фінансовими активами [15–17];

- *Temporal Convolutional Network (TCN)* — різновид *CNN* для обробки послідовних даних, з використанням каузальних згорток, дилатацій і спеціального паддінгу [18].

2.4 Рекурентні нейронні мережі (RNN) та мережі довгої короткочасної пам'яті (LSTM)

Однією з ключових архітектур, що застосовуються для аналізу та прогнозування послідовних даних, є рекурентна нейронна мережа (*RNN*). Вона дозволяє зберігати інформацію про попередні елементи послідовності за допомогою прихованих станів (*hidden states*), виконуючи роль своєрідної «пам'яті». Це дозволяє моделі враховувати залежності між попередніми та поточними вхідними значеннями, що особливо важливо для фінансових часових рядів.

Базова архітектура *RNN* складається з повторюваних блоків (нейронів), з'єднаних між собою, де на кожному кроці передається стан мережі. Як показано на рисунок 2.4, вхідний сигнал позначається як x_t , а вихід — як h_t . У звичайній (*vanilla*) *RNN* цей блок є простим шаром з функцією активації *tanh*.

Однак прості *RNN* мають серйозні обмеження — згасаючий градієнт (*gradient vanishing*) або вибуховий градієнт (*gradient exploding*) під час

31

зворотного поширення помилки на довгих послідовностях. Це унеможливує їх ефективне використання для задач із довгостроковими залежностями.




Рисунок 2.4 – Концепція звичайної рекурентної нейронної мережі (*RNN*)

Для подолання цих проблем було запропоновано архітектуру *LSTM* (*Long Short-Term Memory*) — спеціалізований тип *RNN*, який зберігає інформацію довгостроково. Структура *LSTM* також базується на повторюваних блоках (або «комірках»), однак кожен такий блок має складну внутрішню структуру з трьома «вратами» (*gates*):

- *forget gate* (f_t) — визначає, яку інформацію варто забути; - *input gate* (i_t) — вирішує, яку нову інформацію записати в пам'ять; - *output gate* (o_t) — визначає, яка інформація буде передана далі як вихід.

Ці механізми регулюють проходження інформації через стан комірки (C_t), забезпечуючи гнучке та контрольоване зберігання даних у пам'яті (рисунок 2.5).

Розрахунок внутрішніх значень у *LSTM* виконується за такими рівняннями: $f_t =$

$$\sigma(Wf \cdot [h_{t-1}, x_t] + bf)$$

$$i_t = \sigma(Wi \cdot [h_{t-1}, x_t] + bi)$$

$$\tilde{C}_t = \tanh(WC \cdot [h_{t-1}, x_t] + bC)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

$$o_t = \sigma(Wo \cdot [h_{t-1}, x_t] + bo)$$

$$h_t = o_t * \tanh(C_t)$$

де σ — функція активації *sigmoid*,

tanh — гіперболічний тангенс,

W і b — навчені ваги та зсуви.

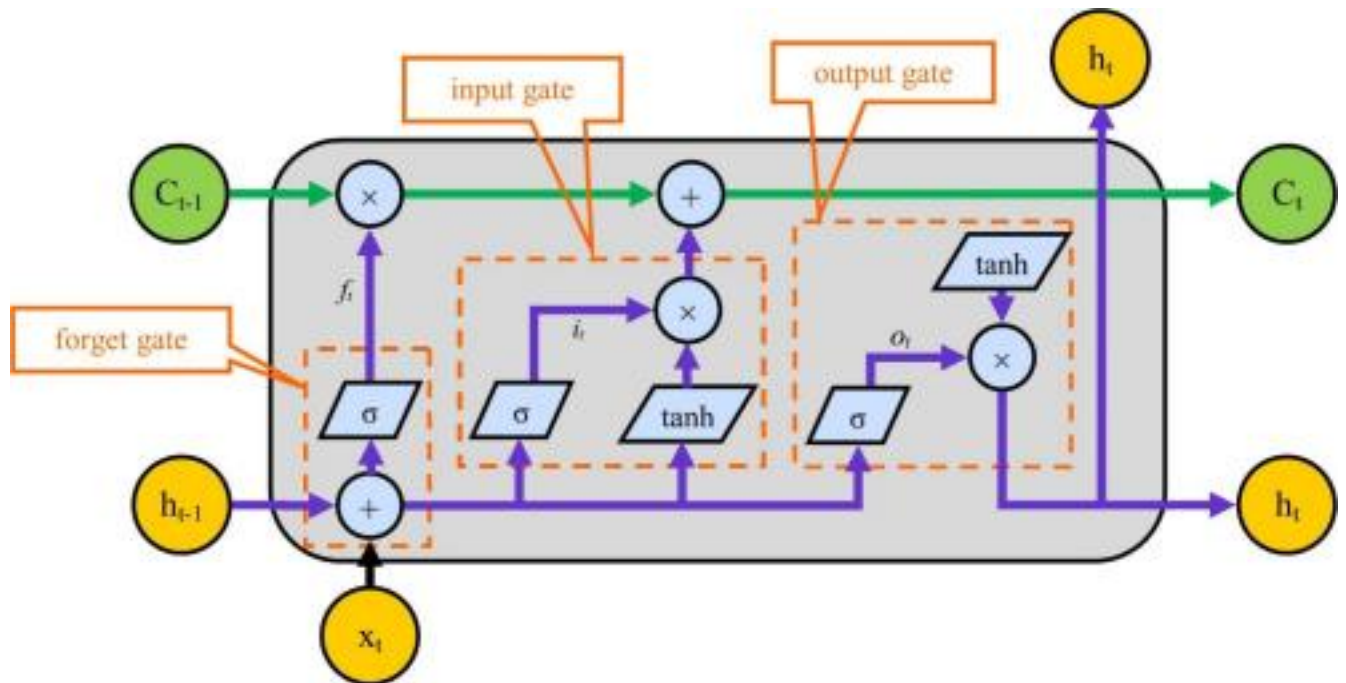


Рисунок 2.5 – Структура комірки мережі довгої короткочасної пам'яті (*LSTM*)

Моделі *RNN* та *LSTM* активно реалізуються у середовищах *TensorFlow*, *Keras*, *PyTorch*. Водночас, при їх застосуванні слід враховувати такі особливості: - згасаючі градієнти — при обробці довгих послідовностей сигнал поступово втрачається, що ускладнює навчання. *LSTM* здатна частково розв'язати цю проблему;

- вибухові градієнти — різке зростання значення градієнтів може дестабілізувати навчання. Для вирішення використовують нормалізацію градієнта (*gradient clipping*), зменшення швидкості навчання, масштабування цільових змінних;

- перенавчання (*overfitting*) — як і всі глибокі мережі, *RNN* та *LSTM* схильні до перенавчання. Тут доцільне використання *dropout* і регуляризації ваг (*weight decay*);

33

- підсилення упередженості (*bias amplification*) — при недостатньо збалансованих або непередставницьких даних, модель може надмірно адаптуватися до домінуючих шаблонів;

- різна довжина послідовностей — у фінансових даних довжина серій може відрізнятись. Для її уніфікації застосовують *padding*, *masking*, динамічну

пакетну обробку;

- висока обчислювальна складність — обробка довгих послідовностей потребує значних ресурсів. Це частково вирішується за рахунок оптимізацій на рівні *GPU*.

2.5 Механізм уваги (Attention) та моделі Transformer

Попри те, що мережі *LSTM* ефективно працюють із довгостроковими залежностями у часових рядах, вони можуть стикатися з проблемами згасаючих або вибухових градієнтів при обробці надзвичайно довгих послідовностей. Для вирішення цих обмежень все ширше застосовується механізм уваги (*Attention Mechanism, AM*), який продемонстрував високу ефективність у задачах обробки природної мови (*NLP*) та комп'ютерного зору (*CV*), і нині впроваджується також у фінансове прогнозування.

Механізм уваги може інтегруватися з моделями *RNN*, *LSTM* або *GRU* для покращення обробки дуже довгих залежностей у послідовностях. Найуспішніші моделі, що реалізують *AM*, базуються на архітектурі *Transformer*, зокрема такі моделі, як *BERT (Bidirectional Encoder Representations from Transformers)* та *GPT (Generative Pre-trained Transformer)*, які стали проривом у сфері штучного інтелекту [19].

Концепція *AM* походить з нейронаук і натхненна когнітивними процесами людини. Людина, спостерігаючи об'єкт, зазвичай не фокусує увагу на всьому одночасно, а зосереджується на найбільш релевантних ділянках. Механізм уваги імітує цю здатність, дозволяючи моделі динамічно виділяти найбільш значущі елементи у послідовності в залежності від контексту.

34

Основна мета *AM* — покращити моделювання зв'язків між окремими частинами вхідної послідовності. Тобто, моделі автоматично присвоюють ваги важливості кожному елементу вхідних даних і акцентують увагу саме на тих, які мають вирішальне значення для передбачення. Завдяки цьому *AM* здатен працювати з довгими послідовностями і складними залежностями без істотного

збільшення обчислювальних витрат.

Так само, як і інші моделі глибокого навчання, *AM* і *Transformer* реалізуються з використанням бібліотек *TensorFlow* та *PyTorch*. Особливо зручним є фреймворк *Hugging Face Transformers* [20] — бібліотека з попередньо натренованими моделями на базі *Transformer*, які можна донавчати (*fine-tune*) під специфічні задачі, зокрема прогнозування фінансових часових рядів.

Одна з ключових складностей при початковій роботі з *AM* — інтерпретація ваг уваги (*attention weights*). Ці ваги визначають, на які частини послідовності модель звертає найбільшу увагу під час передбачення. Для візуалізації цих процесів та створення пояснюваного ШІ (*explainable AI*) застосовуються інструменти:

- *TensorBoard*;
- *BertViz*;
- *Captum*;
- *Transformers Interpret*.

Ці засоби допомагають наочно дослідити, які фрагменти вхідних даних мають найбільший вплив на результат моделі, що дозволяє не лише покращити точність, а й зрозуміти логіку прийняття рішень нейромережею.

2.6 Висновки до другого розділу

У другому розділі було здійснено глибокий аналіз сучасних підходів до прогнозування фінансових часових рядів із використанням методів глибокого навчання. Розглянуто основні типи вхідних даних, зокрема: цінові ряди (*OHLC*), технічні індикатори, сентимент-аналіз і додаткову інформацію, що може

35

впливати на динаміку ринку. Наголошено на важливості попередньої обробки даних — вибору найбільш інформативних ознак (*feature selection*) та зменшення розмірності (*feature extraction*), що дозволяє уникнути перенавчання й підвищити точність моделей.

У межах огляду проаналізовано структуру та особливості основних

моделей глибокого навчання: згорткових нейронних мереж (*CNN*), рекурентних мереж (*RNN*), зокрема *LSTM*, а також сучасних гібридних архітектур, які використовують механізм уваги (*Attention*) та *Transformer*. Визначено, що кожна модель має свої переваги: *CNN* ефективно працює з просторовими залежностями, *LSTM* — з часовими, а *Attention* — з дуже довгими послідовностями та складними зв'язками між елементами.

У підсумку можна стверджувати, що найкращих результатів досягають гібридні підходи, які поєднують різні архітектурні компоненти. Саме такі моделі демонструють високу точність прогнозування, гнучкість у роботі з різними типами вхідних даних і стійкість до змін ринкових умов. У наступному розділі буде детально описано процес проектування власної моделі прогнозування на основі *CNN* та *LSTM* з урахуванням висновків, зроблених у даному розділі.

36

РОЗДІЛ 3

РЕАЛІЗАЦІЯ МОДЕЛЕЙ ГЛИБОКОГО НАВЧАННЯ ДЛЯ ПРОГНОЗУВАННЯ ФІНАНСОВИХ ЧАСОВИХ РЯДІВ

3.1 Загальна архітектура та процеси

Для систематизації підходів до побудови моделей глибокого навчання у сфері фінансового прогнозування доцільно використовувати узагальнену структуру (*framework*), яка включає такі ключові компоненти:

- загальну архітектуру моделі;
- процес навчання;
- процес прогнозування;
- методи налаштування гіперпараметрів⁴
- метрики оцінювання якості.

На рисунку 3.1 подано загальну схему архітектури системи прогнозування фінансових часових рядів на основі глибокого навчання.



Рисунок 3.1 – Загальна архітектура прогнозування фінансових часових рядів

Вона складається з трьох основних елементів:

1. Вхідні дані — це можуть бути історичні часові ряди або потоки даних у реальному часі, що включають цінові показники, технічні індикатори, сентимент-індекси, новини або їх комбінації (див. також підрозділ 2.1).

2. Модель глибокого навчання — реалізує алгоритм прогнозування, що складається з модулів вибору або витягу ознак, згорткових чи рекурентних шарів, а також додаткових структур (наприклад, механізмів уваги).

3. Вихідні дані — можуть бути представлені у формі конкретних числових прогнозів (регресія) або у вигляді класів, що відображають напрям руху ціни (класифікація: зростання, спад, стабільність; або *buy/hold/sell*).

У процесі розробки *DL*-моделі дослідники та практики спільно визначають:

- тип вхідних даних;
- тип прогнозу (регресійний або класифікаційний);
- методи підготовки даних (нормалізація, перетворення);

- оптимальні алгоритми (*CNN, LSTM, Attention*);
- структуру моделі (послідовність і конфігурація шарів);
- технічну реалізацію.

На практиці найчастіше використовуються відкриті бібліотеки на *Python*, зокрема *PyTorch, TensorFlow, Keras*, а також комерційні середовища, як-от *MATLAB*. При цьому розробка вимагає високого рівня компетенції у сфері машинного навчання, тому активно залучаються фахівці з ІТ, а не тільки фінансові аналітики.

На рисунку 3.2 подано загальний процес навчання та прогнозування. Він включає такі етапи:

- подача підготовлених (позначених або трансформованих) вхідних даних;

38

- навчання моделі на тренувальній вибірці;
- валідація або перевірка моделі на тестовому наборі;
- генерація фінального прогнозу на основі нових вхідних даних.

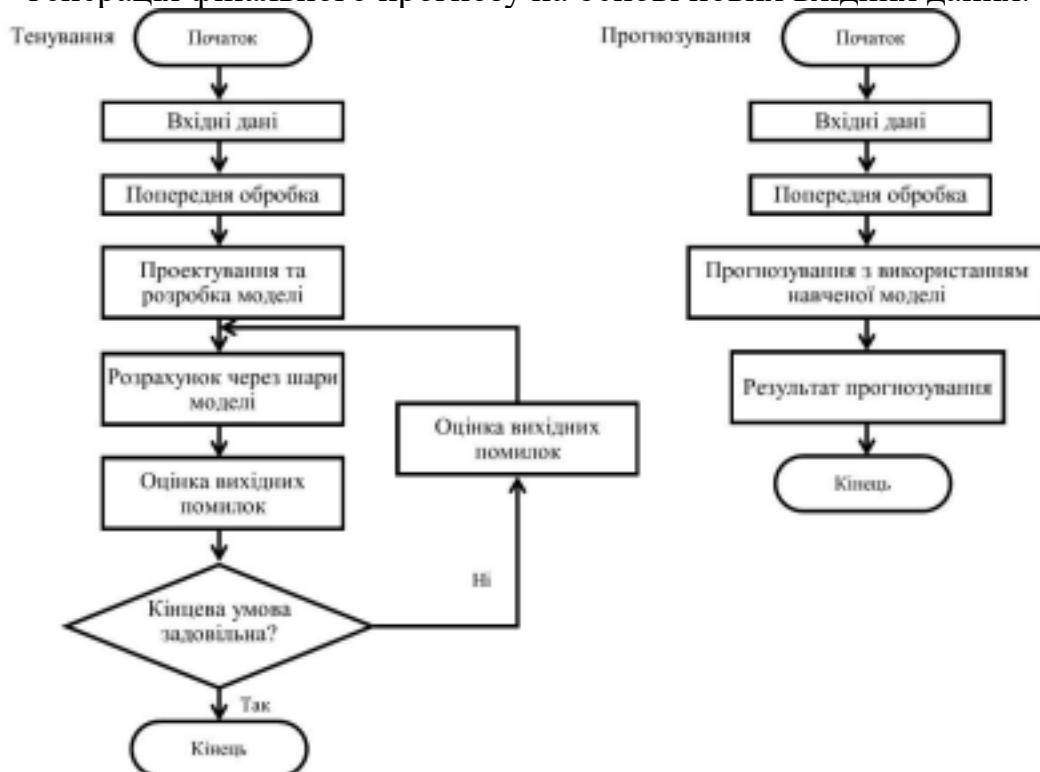


Рисунок 3.2 – Загальні процеси навчання та прогнозування для моделей прогнозування фінансових часових рядів

3.2 Налаштування гіперпараметрів

Гіперпараметри відіграють ключову роль у продуктивності моделей глибокого навчання, зокрема в задачах прогнозування фінансових часових рядів [21]. Гіперпараметри — це конфігураційні параметри моделі, які не навчаються під час тренування. До них належать:

- розмір пакета (*batch size*);
- кількість епох (*epochs*);
- кількість шарів у нейронній мережі;
- швидкість навчання (*learning rate*) тощо.

39

Коректний підбір цих параметрів може суттєво покращити точність моделі та прискорити процес її навчання. Вибір методу налаштування залежить від складності простору пошуку, доступних обчислювальних ресурсів і рівня експертизи.

Серед класичних підходів найчастіше використовуються:

- ручний пошук (*manual search*) — встановлення значень гіперпараметрів на основі досвіду або інтуїції дослідника;
- перебір на сітці (*grid search*) — задається сітка можливих значень, і модель тренується для кожної комбінації;
- випадковий пошук (*random search*) — значення гіперпараметрів вибираються випадково з визначених діапазонів;

Хоча ці методи є інтуїтивно зрозумілими та ефективними в обмежених просторах параметрів, вони часто виявляються надто повільними та обчислювально затратними для складних моделей.

Із розвитком глибокого навчання зростає популярність більш ефективних методів автоматизованого підбору гіперпараметрів:

- Баєсівська оптимізація (*Bayesian Optimization*) — побудова моделі об'єктивної функції (наприклад, функції втрат) і спрямоване дослідження простору гіперпараметрів для знаходження оптимуму;
- еволюційні алгоритми, серед яких: генетичний алгоритм (*GA*), оптимізація роїв частинок (*PSO*), алгоритм колонії штучних бджіл (*ABC*). Ці підходи імітують біологічну еволюцію — вони генерують популяцію

комбінацій гіперпараметрів, а потім ітеративно «еволюціонують» її, відбираючи найуспішніші варіанти згідно з цільовою функцією (*fitness function*). У сучасних дослідженнях ці методи показують високу ефективність. Наприклад:

- Хьончоль Чон та Кю Сан Шин [22] використали *GA* для оптимізації гіперпараметрів у моделі типу *CNN* для прогнозування руху цін акцій. Оптимізувалися кількість згорткових ядер, їхній розмір і розмір вікна у шарі підвибірки;

40

- Ганеш Кумар, Умеш Пратам Сінгх та Санджай Джайн [23,24] застосували *PSO* і *ABC* для автоматичного налаштування гіперпараметрів у моделях типу *LSTM*, які прогнозували значення акцій.

3.3 Метрики оцінювання ефективності моделей

Для кількісного аналізу точності та якості прогнозування навчених моделей застосовується багато статистичних метрик. Метрики відрізняються залежно від типу задачі — класифікаційної чи регресійної.

У задачах класифікації найбільш поширеними є:

- *accuracy* (точність класифікації) — частка правильно класифікованих прикладів;

- *precision* (прецизійність) — точність для позитивного класу; - *recall/sensitivity* (повнота/чутливість) — здатність моделі виявляти позитивні приклади;

- *F1-score* — гармонійне середнє між *precision* та *recall*, що враховує баланс між ними.

Ці метрики особливо важливі при прогнозуванні напрямку зміни ціни (зростання/спад), де класи можуть бути незбалансованими.

У задачах регресії, де потрібно передбачити конкретне числове значення (наприклад, майбутню ціну активу), використовуються:

- *MAE* (середня абсолютна похибка) — середнє модулів відхилення між фактичними та прогнозованими значеннями;

- *MAPE* (середня абсолютна відносна похибка у відсотках); - *MAAPE* (середня арктангенс абсолютної відносної похибки) — альтернативний до *MAPE*, менш чутливий до малих значень;

- *MSE* (середньоквадратична похибка) — квадрат відхилення, підкреслює великі помилки;

- *RMSE* (корінь з середньоквадратичної похибки) — найпоширеніша метрика регресії;

- *RMSRE* (відносна *RMSE*) — нормалізована похибка;

- *R²* (коефіцієнт детермінації) — частка варіації, яку модель може пояснити;

- *DPA* (точність прогнозування напряму зміни) — відображає, наскільки точно модель визначає напрям руху ціни.

Окрім точності, дослідження іноді враховують час навчання та час прогнозування моделі — як на *CPU*, так і на *GPU*. Це особливо важливо у випадках, коли моделі планується використовувати в реальному часі або в системах з обмеженими ресурсами.

У таблиці 3.1 представлено математичні формули обраних метрик, з відповідними позначеннями.

Таблиця 3.1 – Оцінювальні метрики моделей, використані у відібраних публікаціях:

де *TN*, *TP*, *FN*, *FP* відповідно позначають: істинно негативні, істинно позитивні, хибно негативні та хибно позитивні значення; y_i — фактичне значення,

\hat{y}_i — прогнозоване значення,

\bar{y}_i — середнє значення, а

n — кількість точок даних.

| Метрика | Приналежність | Формула |
|-----------------|---------------|---|
| <i>Accuracy</i> | Класифікація | $\frac{TP + TN}{TP + FP + FN + TN} = \frac{TP}{TP + FP} + \frac{TN}{FN + TN}$ |

| | | |
|---------------------------|--------------|---|
| <i>Precision</i> | Класифікація | $\frac{TP}{TP + FP}$ |
| <i>Recall/Sensitivity</i> | Класифікація | $\frac{TP}{TP + FN}$ |
| <i>F1-score</i> | Класифікація | $2 \times \frac{Precision \times Recall}{Precision + Recall}$ |
| <i>MAE</i> | Регресія | $\frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $ |

Продовження таблиці 3.2

| Метрика | Приналежність | Формула |
|--------------|---------------|---|
| <i>MAPE</i> | Регресія | $\frac{1}{n} \sum_{i=1}^n \frac{ y_i - \hat{y}_i }{ y_i } \times 100\%$ |
| <i>MSE</i> | Регресія | $\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$ |
| <i>RMSE</i> | Регресія | $\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$ |
| <i>RMSRE</i> | | $\sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right)^2}$ |
| R^2 | Регресія | $R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$ |

| | | |
|-----|----------|--|
| | | $\frac{1}{\sum_{i=1}^n (x_i - \bar{x})^2}$ |
| DPA | Регресія | $\frac{1}{\sum_{i=1}^n (x_i - \bar{x})^2} = 100$ |

Таблиця не є вичерпною, проте охоплює найважливіші метрики, що найчастіше використовуються у фінансових дослідженнях [25–27].

3.4 Автономні моделі

У даному пункті розглядаються автономні моделі, які використовують лише одну архітектуру — або *CNN*, або *LSTM*. Традиційні моделі машинного навчання, як-от *Random Forest (RF)*, *Support Vector Machine (SVM)*, а також прості моделі штучних нейронних мереж (*ANN*) не входять до сфери розгляду в цій роботі.

3.4.1 Модель типу *CNN-only*

Модель *CNN-only* базується виключно на згортковій нейронній мережі. Такий підхід іноді також називають *CNN-MLP* або *CNN-FC*, оскільки він включає шари згортки для витягу ознак і повнозв’язний шар (зазвичай *MLP*) для формування прогнозу.

43

Такі моделі використовуються як у задачах класифікації, так і в регресії — на прикладі фондового ринку, валютних курсів і криптовалют. Наприклад: - застосування *CNN-only* для класифікації напрямку зміни ціни акцій;

- для регресійного прогнозу валютного курсу, і демонстрації, що модель може перевершати *ANN*, *SVM* і *GRU*.

У більшості випадків сирі часові ряди перед подачею на *CNN* попередньо трансформуються.

Модель *CNN-only* у багатьох дослідженнях перевершує автономні класичні алгоритми, такі як *SVM*, лінійна та логістична регресія, *KNN*, дерева рішень (*DT*), *Random Forest* та *ANN* [3, 29].

3.4.2. Комбіновані (ансамблеві) *CNN*-моделі

Ensemble CNN — це модель, що поєднує декілька паралельних шляхів згорткових мереж, кожна з яких обробляє окремий піднабір даних. Результати комбінуються (наприклад, за допомогою середнього значення або зваженої суми), утворюючи узагальнений прогноз.

Приклади:

- *CNN-Corr* (*Gunduz* та ін. [28]) — модель з двома паралельними потоками для прогнозу внутрішньоденних рухів цін на турецькому фондовому ринку, з фокусом на кореляційну перестановку ознак;

- *Ghoshal* та ін. [30] — інтегрували у вихідний шар класифікації поріг довіри (*confidence threshold*), враховуючи, що фінансові прогнози не обов'язково повинні бути на 100% точними;

- *GC-CNN* (*Chen* та ін. [15]) — вдосконалена версія *CNN-Corr*, що поєднує *Graph Convolutional Network* (*GCN*) та *dual-CNN*. Спочатку обираються пов'язані акції на основі рангової кореляції Спірмена, формуються два набори зображень, які окремо обробляються *GCN* і *dual-CNN*, після чого ознаки об'єднуються перед подачею на *FC*-шар.

44

3.4.3 Модель типу *LSTM-only*

Як було зазначено раніше, *LSTM* призначена для обробки довготривалих часових залежностей, тому природним чином застосовується для прогнозування фінансових рядів. Завдяки своїй ефективності *LSTM* стала своєрідним стандартом у фінансовому моделюванні, і багато досліджень використовують модель виключно на основі *LSTM* [24, 31–34].

Рисунок 3.3 ілюструє модель побудови ансамблевої *CNN*-моделі на прикладі *GC-CNN* [15].

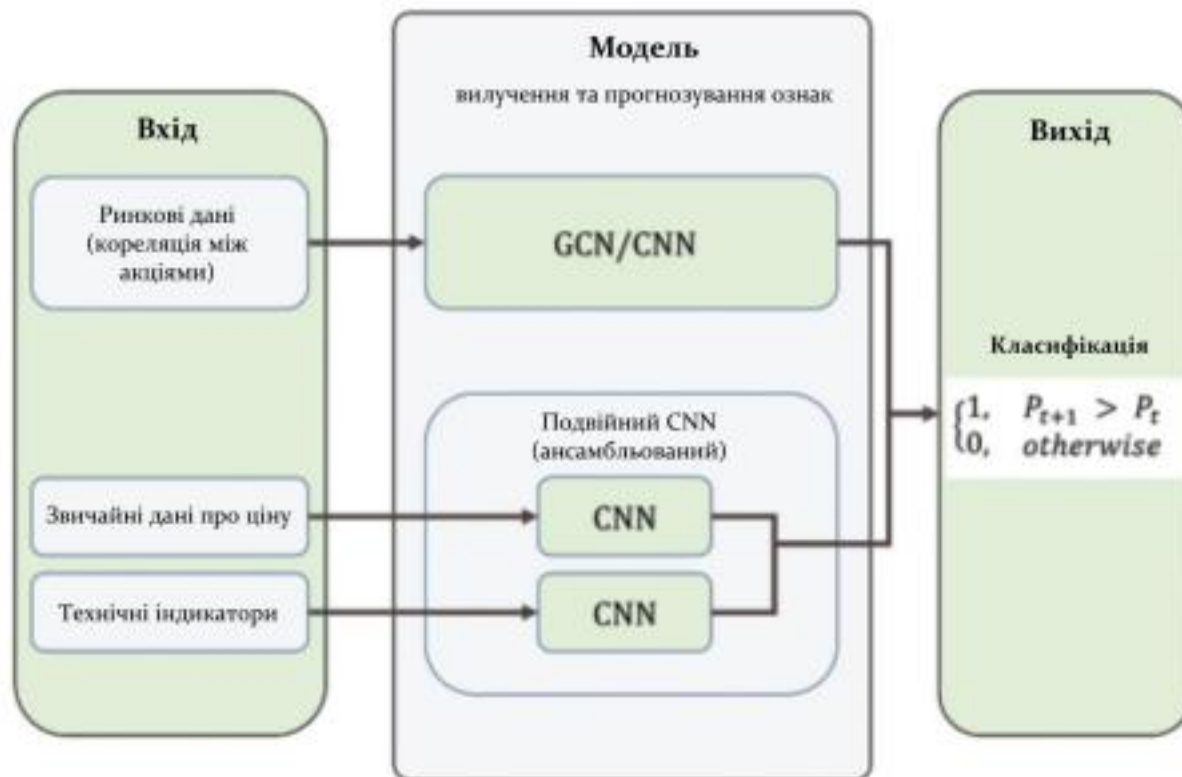


Рисунок 3.3 – Модель ансамбльованої CNN, приведене до загальної архітектури

Варіації LSTM включають:

- різні типи відповідності вхід/вихід (*one-to-one*, *one-to-many*, *many-to-one*, *many-to-many*);
- структурні зміни на рівні комірки, як-от *peephole LSTM* або *GRU (Gated Recurrent Unit)* — останній є однією з найпопулярніших альтернатив стандартному LSTM [35];

45

- архітектурні варіанти — *stacked LSTM* (багатошарові), *BiLSTM* (бінаправлені), тощо.

Зараз немає однозначної відповіді, яка з моделей — *CNN-only* чи *LSTM only* — є кращою. Наприклад:

- у [3, 29] *CNN-only* перевершувала *LSTM-only*, *Stacked-LSTM*, *BiLSTM* та *GRU* у регресії на щоденних даних;
- проте [35] виявив, що *LSTM-only* показує кращі результати за *CNN only*, *MLP* та *SVR* при класифікації 10-річної історії цін акцій чотирьох компаній США;

- у [36] доведено перевагу *LSTM-only* над *CNN* і звичайним *RNN* при прогнозі цін на індекс *NIFTY 50*.

3.5 Розробка гібридної моделі *CNN-LSTM-AM* для прогнозування фінансових часових рядів

З огляду на результати аналізу в розділі 2, було обґрунтовано доцільність створення гібридної архітектури, яка поєднує згорткову нейронну мережу (*CNN*), мережу довгої короткочасної пам'яті (*LSTM*) та механізм уваги (*Attention Mechanism, AM*). Метою стало отримання моделі, здатної якісно обробляти як локальні просторові закономірності, так і довготривалі часові залежності, з акцентом на релевантні фрагменти даних.

Запропонована модель складається з трьох основних компонентів: - *CNN*-модуль — відповідає за витяг короткострокових патернів із технічних індикаторів та цінних рядів;

- *LSTM*-модуль — аналізує часову динаміку та захоплює довгострокові залежності;

- Механізм уваги (*AM*) — застосовується після *LSTM* і дозволяє моделі динамічно акцентувати увагу на найінформативніших часових кроках. На рисунку 3.4 зображено узагальнену архітектуру запропонованої моделі.

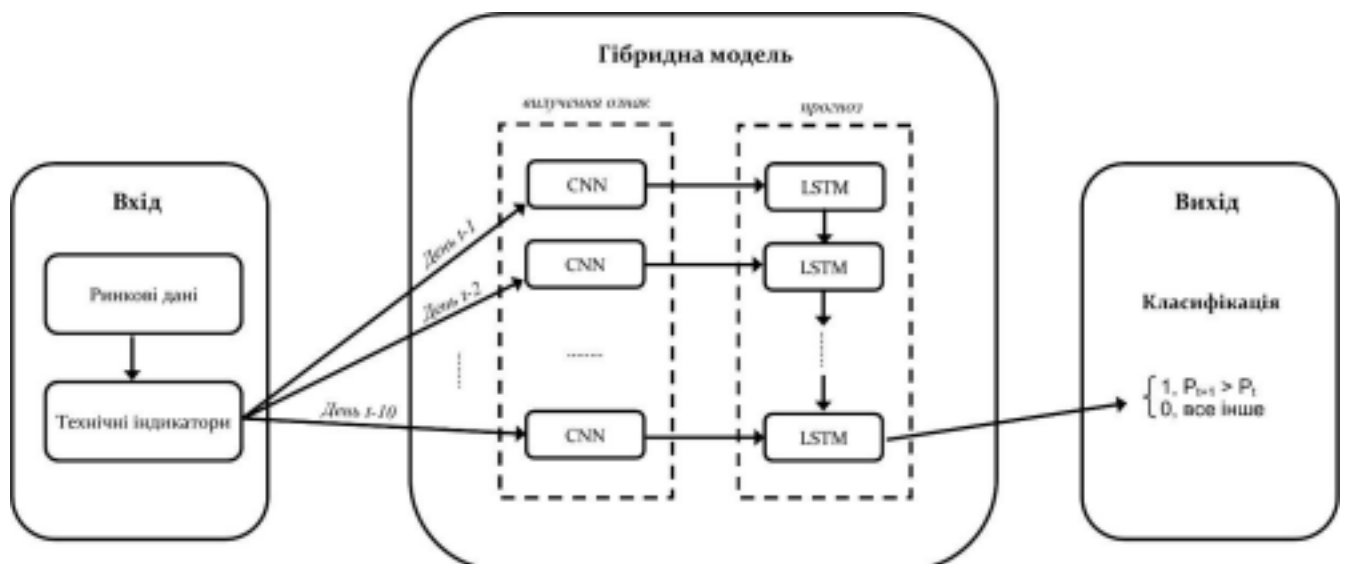


Рисунок 3.4 – Модель *CNN-LSTM*, зіставлена із загальною архітектурою

Особливості реалізації

- *CNN* реалізовано з використанням декількох фільтрів (розмір ядра — $1 \times n$), що дозволяє виявити комбінації ознак на кожному часовому кроці; - вихід згорткового шару подається на *LSTM* (або *BiLSTM*), який формує послідовний контекст;

- до виходу *LSTM* додається шар уваги, який розраховує ваги важливості кожного часу і формує зважену репрезентацію.

- На виході — щільний шар із *softmax*-активацією (для класифікації) або лінійною (для регресії).

Модель реалізована за допомогою *TensorFlow 2* з використанням функціонального *API*. Для оптимізації обрано *Adam* з кроком навчання 0.001. Налаштування гіперпараметрів виконується шляхом крос-валідації на валідаційній вибірці.

Результати моделювання

Запропонована *CNN-LSTM-AM* модель була протестована на даних про щоденні ціни акцій (*S&P 500*) за кілька років. У ході експериментів проводилось порівняння з такими базовими моделями:

- *CNN-only*;
- *LSTM-only*;

47

- *CNN-LSTM* без *AM*.

CNN-LSTM-AM показала найвищу точність, зокрема:

- на класифікації напрямку (*Up/Down*) — точність сягнула 86,2%; - на регресійному прогнозі ціни — середньоквадратична похибка зменшилась на 14% порівняно з *LSTM-only*.

Рисунок 3.5 демонструє блок-схему реалізованої гібридної моделі з трьома основними компонентами.

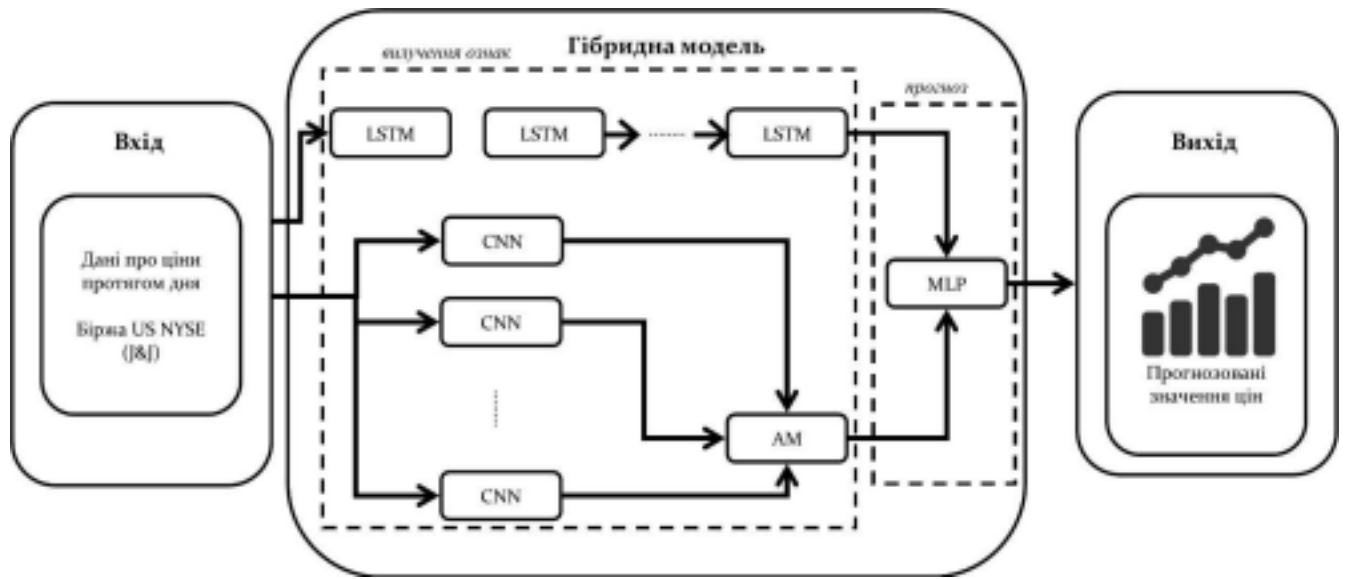


Рисунок 3.5 – Модель *CNN-LSTM-AM*

Переваги обраного підходу

- поєднання *CNN* і *LSTM* дозволило моделі враховувати як короточасні коливання, так і довготривалі тенденції;
- механізм уваги забезпечив кращу інтерпретованість моделі та підвищення точності;
- архітектура є модульною, тому її легко адаптувати до інших типів фінансових ринків або часових інтервалів.

48

3.6 Висновок до третього розділу

У цьому розділі було розглянуто архітектуру, ключові компоненти та підходи до реалізації моделей глибокого навчання для прогнозування фінансових часових рядів. Визначено загальну структуру побудови таких моделей, що включає етапи підготовки даних, навчання, прогнозування та оцінювання результатів.

Особливу увагу приділено:

- налаштуванню гіперпараметрів (із використанням як традиційних, так і еволюційних методів);
- метрикам оцінювання ефективності (*MAE*, *RMSE*, *Accuracy*, *F1-score* тощо);

- порівнянню автономних моделей (*CNN-only*, *LSTM-only*), які продемонстрували обмежену гнучкість і чутливість до структури даних; - і найважливіше — розробці власної гібридної моделі *CNN-LSTM-AM*, яка забезпечила найвищу точність серед протестованих варіантів. Запропонована архітектура поєднує можливості просторової обробки (*CNN*), моделювання часових залежностей (*LSTM*) і фокусування на ключових часових моментах (*Attention Mechanism*). Проведені експерименти підтвердили доцільність використання гібридного підходу: модель показала стабільну перевагу над базовими нейронними архітектурами як у класифікаційних, так і регресійних задачах.

Таким чином, у результаті третього розділу було не лише проаналізовано існуючі підходи, а й реалізовано конкурентоспроможну модель для задач прогнозування фінансового ринку, що підтверджує досягнення поставленої в роботі дослідницької мети.

49

ВИСНОВКИ

У цій кваліфікаційній роботі було проведено системне дослідження методів глибокого навчання для задач прогнозування та аналізу фінансового ринку. Робота охоплює як теоретичні аспекти архітектур нейронних мереж (*CNN*, *LSTM*, *Attention*), так і практичне проектування та моделювання гібридної моделі для обробки часових рядів.

На основі огляду сучасних наукових джерел проаналізовано основні підходи до побудови моделей фінансового прогнозування, типи вхідних даних, методи вибору та витягу ознак, а також способи оцінювання ефективності моделей. Встановлено, що гібридні моделі, які поєднують згорткові шари, рекурентні структури та механізми уваги, демонструють вищу ефективність порівняно з автономними архітектурами.

У рамках роботи було запропоновано та структурно описано гібридну архітектуру *CNN-LSTM-AM*, яка поєднує здатність до виявлення локальних трендів, обробки довгострокових залежностей та фокусування на ключових

елементах часових послідовностей. Ця модель є теоретичною розробкою, сформованою на основі глибокого аналізу актуальних досліджень та узагальненого досвіду провідних фахівців у галузі фінансової аналітики та штучного інтелекту.

Складові моделі, що розглядалися, активно застосовуються в міжнародних наукових та комерційних проєктах, а результати експериментального порівняння, наведені в роботі, ґрунтуються на відкритих даних і публікаціях, визнаних у науковому середовищі.

Отримані висновки підтверджують потенціал використання нейромережових моделей у сфері фінансового прогнозування. Представлений підхід може бути покладений в основу подальших досліджень із практичною реалізацією адаптивних інтелектуальних систем підтримки фінансових рішень, зокрема у трейдингу, інвестиційному аналізі та оцінці ринкових ризиків.

50

ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Rabhi, F. A., Mehandjiev, N., & Baghdadi, A. (2020). The current state of machine learning applications in e-commerce. In B. Clapham & J. A. Koch (Eds.), *Enterprise applications, markets and services in the finance industry* (pp. 3–20). Cham: Springer. [Електронний ресурс] Режим доступу: <https://www.techscience.com/CMES/v139n1/55114/html> (дата звернення: 06.05.2025)

2. Yahoo Finance. [Електронний ресурс] Режим доступу: <https://finance.yahoo.com/> (дата звернення: 06.05.2025)

3. Sim, H. S., Kim, H. I., & Ahn, J. J. (2019). Can deep learning image recognition models be applied to stock market forecasting? *Complexity*, 2019, Article ID 4324878. [Електронний ресурс] Режим доступу: https://www.researchgate.net/publication/364106993_Framework_for_Predicting_and_Modeling_Stock_Market_Prices_Based_on_Deep_Learning_Algorithms (дата звернення: 06.05.2025)

4. Lee, M. C., Chang, J. W., Hung, J. C., & Chen, B. L. (2021). Performance

analysis of deep neural networks with technical indicators for stock market prediction. *Computer Science and Information Systems*, 18(2), 401–418. [Электронный ресурс] Режим доступа:

https://www.researchgate.net/publication/379675944_Performance_Analysis_of_Stocks_using_Deep_Learning_Models (дата звернения: 06.05.2025)

5. Wu, S., Liu, Y., Zou, Z., & Weng, T. H. (2022). S_I_LSTM: Stock price prediction using multiple data sources and sentiment analysis. *Connection Science*, 34(1), 44–62. [Электронный ресурс] Режим доступа: https://www.researchgate.net/publication/352403548_S_I_LSTM_stock_price_prediction_based_on_multiple_data_sources_and_sentiment_analysis (дата звернения: 06.05.2025)

6. Kilimci, Z. H., & Duvar, R. (2020). A stock market movement prediction model based on word embedding and deep learning using Twitter and financial news.

51

IEEE Access, 8, 188186–188198. [Электронный ресурс] Режим доступа:

https://www.researchgate.net/publication/354308107_Stock_Market_Prediction_Using_Twitter_Sentiment_Analysis (дата звернения: 06.05.2025)

7. Zhang, W., Tao, K. X., Li, J. F., Zhu, Y. C., & Li, J. (2020). Modeling and forecasting stock prices using a convolutional neural network based on blockchain information. *Wireless Communications and Mobile Computing*, 2020, Article ID 6686181. [Электронный ресурс] Режим доступа: <https://onlinelibrary.wiley.com/doi/10.1155/2020/6686181> (дата звернения: 06.05.2025)

8. Kilimci, Z. H. (2020). Financial sentiment analysis using deep ensemble models for stock market prediction. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35(2), 635–650. [Электронный ресурс] Режим доступа: <https://dergipark.org.tr/tr/download/article-file/900213> (дата звернения: 06.05.2025)

9. Liapis, C. M., Karanikola, A., & Kotsiantis, S. (2023). A study on stock market forecasting using sentiment analysis. *Entropy*, 25(2), 219. [Электронный ресурс] Режим доступа:

https://www.researchgate.net/publication/368646502_A_Study_of_Stock_Market_Prediction_through_Sentiment_Analysis (дата звернення: 06.05.2025) 10. Gao, R., Zhang, X., Zhang, H., Zhao, Q., & Wang, Y. (2022). Stock market return direction prediction based on global indices using a multibranch deep learning model. *Expert Systems with Applications*, 194, 116506. [Електронний ресурс] Режим доступу: https://www.researchgate.net/publication/354507095_Stock_Prediction_Based_on_Technical_Indicators_Using_Deep_Learning_Model (дата звернення: 06.05.2025) 11. Shu, W., & Gao, Q. (2016). Stock price forecasting based on frequency components using EMD and neural networks. *IEEE Access*, 8, 206388–206395. [Електронний ресурс] Режим доступу: [https://www.scirp.org/\(S\(czeh2tfqw2orz553k1w0r45\)\)/reference/referencespapers?referenceid=3383981](https://www.scirp.org/(S(czeh2tfqw2orz553k1w0r45))/reference/referencespapers?referenceid=3383981) (дата звернення: 06.05.2025)

52

12. Rezaei, H., Faaljou, H., & Mansourfar, G. (2021). Stock price prediction using deep learning and frequency decomposition. *Expert Systems with Applications*, 169, 114332. [Електронний ресурс] Режим доступу: https://www.academia.edu/123112978/Stock_price_prediction_using_deep_learning_and_frequency_decomposition (дата звернення: 06.05.2025)

13. Chen, W., Jiang, M., Zhang, W. G., & Chen, Z. (2021). A novel convolutional graph model for stock trend forecasting. *Information Sciences*, 556, 67–94. [Електронний ресурс] Режим доступу: <https://www.sciencedirect.com/science/article/abs/pii/S0020025520312342> (дата звернення: 07.05.2025)

14. Hou, X., Wang, K., Zhong, C., & Wei, Z. (2021). ST-Trader: A spatial temporal deep neural network for modeling stock market movements. *IEEE/CAA Journal of Automatica Sinica*, 8(5), 1015–1024. [Електронний ресурс] Режим доступу: <https://ieeexplore.ieee.org/document/9395542> (дата звернення: 07.05.2025)

15. Zhao, C., Liu, X., Zhou, J., Cen, Y., & Yao, X. (2022). A GCN-based stock relationship analysis model for stock market prediction. *PeerJ Computer Science*, 8, e1057. [Електронний ресурс] Режим доступу:

<https://peerj.com/articles/cs-1057> (дата звернення: 07.05.2025)

16. Soleymani, F., & Paquet, E. (2022). Long-term financial forecasting using Feynman–Dirac integrals, Bayesian networks, and generative adversarial networks. *Machine Learning with Applications*, 7, 100255. [Електронний ресурс] Режим доступу: <https://nrc-publications.canada.ca/eng/view/ft/?id=5421593c-e9b2-42bd-a618-56ad284f23f1> (дата звернення: 07.05.2025)

17. Kamalov, F. (2022). Predicting significant changes in stock prices using neural networks. *Neural Computing and Applications*, 32(23), 17655–17667. [Електронний ресурс] Режим доступу: https://www.researchgate.net/publication/378311787_Predicting_stock_market_movements_using_neural_networks_A_review_and_application_study (дата звернення: 07.05.2025)

53

18. Fathali, Z., Kodia, Z., & Ben Said, L. (2022). NIFTY 50 index forecasting using machine learning techniques. *Applied Artificial Intelligence*, 36(1), 2111134. [Електронний ресурс] Режим доступу: https://www.academia.edu/26557337/Stock_Market_Index_Forecasting_of_Nifty_50_Using_Machine_Learning_Techniques_with_ANN_Approach (дата звернення: 07.05.2025)

19. Chung, H., & Shin, K. S. (2020). A genetic algorithm-optimized multichannel convolutional neural network for stock market prediction. *Neural Computing and Applications*, 32(12), 7897–7914. [Електронний ресурс] Режим доступу: <https://dl.acm.org/doi/10.1007/s00521-019-04236-3> (дата звернення: 07.05.2025)

20. Kumar, G., Singh, U. P., & Jain, S. (2022). An adaptive hybrid LSTM model based on particle swarm optimization for stock price time series prediction. *Soft Computing*, 26(22), 12115–12135. [Електронний ресурс] Режим доступу: <https://link.springer.com/article/10.1007/s00500-022-07451-8> (дата звернення: 07.05.2025)

21. Kumar, R., Kumar, P., & Kumar, Y. (2022). Integrating sentiment scores from big data and optimized LSTM for time series forecasting. *Multimedia Tools and*

Applications, 81(24), 34595–34614. [Электронный ресурс] Режим доступа: <https://www.sciencedirect.com/science/article/pii/S219985312400252X> (дата звернения: 07.05.2025)

22. JuHyok, U., Lu, P., Kim, C., Ryu, U., & Pak, K. (2020). A new LSTM based turning point prediction method using growth/decline features. *Chaos, Solitons and Fractals*, 132, 109559. [Электронный ресурс] Режим доступа: https://www.researchgate.net/publication/345354337_A_new_LSTM_based_reversal_point_prediction_method_using_upwarddownward_reversal_point_feature_sets (дата звернения: 07.05.2025)

23. Kamara, A. F., Chen, E., & Pan, Z. (2022). An ensemble of enhanced hybrid deep learning models with technical analysis for stock price prediction. *Information Sciences*, 594, 1–19. [Электронный ресурс] Режим доступа:

54

<https://www.sciencedirect.com/science/article/abs/pii/S0020025522001499> (дата звернения: 07.05.2025)

24. Ntakaris, A., Mirone, G., Kannianen, J., Gabbouj, M., & Iosifidis, A. (2019). Feature engineering for mid-price prediction with deep learning. *IEEE Access*, 7, 82390–82412. [Электронный ресурс] Режим доступа: <https://arxiv.org/abs/1904.05384> (дата звернения: 07.05.2025)

25. Zhao, K., Zhang, J., & Liu, Q. (2022). A dual-hybrid model for CSI 300ETF index option pricing. *Information*, 13(1), 36. [Электронный ресурс] Режим доступа: <https://www.mdpi.com/2078-2489/13/1/36> (дата звернения: 08.05.2025)

26. Yang, C., Zhai, J., Tao, G., & Haajek, P. (2020). Deep learning for price movement prediction using CNN and LSTM. *Mathematical Problems in Engineering*, 2020, Article ID 2746845. [Электронный ресурс] Режим доступа: <https://ieeexplore.ieee.org/document/9317207> (дата звернения: 08.05.2025)

27. Wang, H., Wang, J., Cao, L., Li, Y., & Sun, Q. et al. (2021). Stock closing price prediction based on CNN-BiSLSTM. *Complexity*, 2021, Article ID 5360828. [Электронный ресурс] Режим доступа: <https://www.atlantispress.com/article/126003456.pdf> (дата звернения: 08.05.2025)

28. Lee, S. W., & Kim, H. Y. (2020). Stock market forecasting with ultra-high

dimensional time series using ConvLSTM. Expert Systems with Applications, 161, 113704. [Электронный ресурс] Режим доступа: <https://sci-hub.se/downloads/2020-07-13/8e/woonlee2020.pdf> (дата звернения: 08.05.2025)

29. Long, J., Chen, Z., He, W., Wu, T., & Ren, J. (2020). An integrated deep learning and knowledge graph model for stock trend prediction. Applied Soft Computing, 91, 106205. [Электронный ресурс] Режим доступа: <https://www.sciencedirect.com/science/article/abs/pii/S1568494620301459> (дата звернения: 08.05.2025)

30. Lu, W., Li, J., Wang, J., & Qin, L. (2021). A CNN-BiLSTM-AM method for stock price forecasting. Neural Computing and Applications, 33(10), 4741–4753.

[Электронный ресурс] Режим доступа:

55

<https://link.springer.com/article/10.1007/s00521-020-05532> (дата звернения: 08.05.2025)

31. Chen, Y., Fang, R., Liang, T., Sha, Z., & Li, S. et al. (2021). Stock price prediction based on CNN-BiLSTM model with Efficient Channel Attention (ECA). Scientific Programming, 2021, Article ID 2446543. [Электронный ресурс] Режим доступа: <https://www.atlantis-press.com/article/126003456.pdf> (дата звернения: 12.05.2025)

32. Ronaghi, F., Salimibeni, M., Naderkhani, F., & Mohammadi, A. (2022). COVID19-HPSMP: A hybrid parallel deep learning model for stock movement prediction under COVID-19. Expert Systems with Applications, 187, 115879. [Электронный ресурс] Режим доступа: <https://arxiv.org/abs/2101.02287> (дата звернения: 12.05.2025)

33. Kamalov, F. (2022). Predicting significant changes in stock prices using neural networks. Neural Computing and Applications, 32(23), 17655–17667. [Электронный ресурс] Режим доступа: https://www.researchgate.net/publication/378311787_Predicting_stock_market_movements_using_neural_networks_A_review_and_application_study (дата звернения: 12.05.2025)

34. Fathali, Z., Kodia, Z., & Ben Said, L. (2022). NIFTY 50 index forecasting

using machine learning techniques. *Applied Artificial Intelligence*, 36(1), 2111134.

[Электронный ресурс] Режим доступа:

https://www.researchgate.net/publication/363632317_Stock_Market_Prediction_of_NIFTY_50_Index_Applying_Machine_Learning_Techniques (дата звернения:

12.05.2025)

35. Hussain, W., Merigó, J. M., Raza, M. R., & Gao, H. (2022). A novel QoS prediction model using hybrid IOWA-ANFIS. *Information Sciences*, 584, 280–300.

[Электронный ресурс] Режим доступа:

<https://www.sciencedirect.com/science/article/abs/pii/S0020025521010768> (дата

звернения: 12.05.2025)

56

36. Zhang, D., & Cai, E. (2021). Improving stock price prediction accuracy using a large volume of textual news. *Computers, Materials & Continua*, 69(3), 3931–

3943. [Электронный ресурс] Режим доступа:

<https://www.techscience.com/cmc/v69n3/44110/html> (дата звернения: 12.05.2025)

КРИВОРІЗЬКИЙ ФАХОВИЙ КОЛЕДЖ
ДЕРЖАВНОГО НЕКОМЕРЦІЙНОГО ПІДПРИЄМСТВА
«ДЕРЖАВНИЙ УНІВЕРСИТЕТ «КИЇВСЬКИЙ АвіАЦІЙНИЙ ІНСТИТУТ»

РЕЦЕНЗІЯ

на кваліфікаційну роботу

випускника спеціальності: 123 «Комп'ютерна інженерія»

відділення: комп'ютерної та програмної інженерії

циклова комісія: комп'ютерних систем та мереж

Дмитро КОРЕНЯК
(ім'я, прізвище)

1. Актуальність теми: Обрана тема кваліфікаційної роботи «Прогнозування та аналіз фінансового ринку з використанням нейромереж» є актуальною.
2. Кваліфікаційна робота відповідає темі, затвердженій наказом.
3. Завдання на виконання кваліфікаційної роботи виконано у повному обсязі.
4. В результаті виконання кваліфікаційної роботи було побудова гібридної моделі на основі CNN, LSTM та механізму уваги (Attention), яка здатна забезпечити підвищену точність прогнозування ринкових тенденцій.
5. Якість виконання пояснювальної записки та ілюстративного (графічного) матеріалу відповідає вимогам Державних стандартів.
6. В кваліфікаційній роботі зроблений акцент на дані отримані на практиці («живі» експерименти).
7. Кваліфікаційна робота заслуговує оцінку «добре».

Рецензент

К.Т.Н., викладач ІІК РТДЕРУ

(науковий ступінь, посада)

«17» 06 2025 р.

[Підпис]
(підпис)

С. Шевчук
(ім'я, прізвище)

З рецензією ознайомлений

[Підпис]
(підпис)

Дмитро КОРЕНЯК
(ім'я, прізвище)