

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)

Кафедра Інформаційних управляючих систем
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти другий (магістерський)

Дослідження методів та моделей прогнозування
попиту на товари в ІС фірми з реалізації продукції із кольорових металів
(тема)

Виконав:

здобувач 2 року навчання,
групи ІУСТМ-23-1

Сулятицький Денис Євгенович
(прізвище, ім'я, по батькові)

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


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

Освітня програма Інформаційні управляючі системи та технології
(повна назва освітньої програми)

Керівник: доц. Борисенко Т.І.
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри ІУС


(підпис)

Петров К.Е.
(прізвище, ініціали)

2025 р.

Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук

Кафедра Інформаційних управляючих систем

Рівень вищої освіти другий (магістерський)

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

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

Освітня програма Інформаційні управляючі системи та технології
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри



(підпис)

“ 09 ” грудня 20 24 р.

ЗАВДАННЯ**НА КВАЛІФІКАЦІЙНУ РОБОТУ**

здобувачеві Сулятицькому Денису Євгеновичу
(прізвище, ім'я, по батькові)

1. Тема роботи Дослідження методів та моделей прогнозування попиту на товари в ІС фірми з реалізації продукції із кольорових металів

затверджена наказом по університету від “ 27 ” листопада 2024 р. № 1249Ст

2. Термін подання здобувачем роботи до екзаменаційної комісії “ 18 ” січня 2025 р.


3. Вихідні дані до роботи матеріали передатестаційної практики, науково-технічні публікації та інтернет джерела з тематики кваліфікаційної роботи, дані продажів товарів фірми з реалізації продукції із кольорових металів.


4. Перелік питань, що потрібно опрацювати у роботі 1) аналіз методів та підходів до прогнозування попиту на товари із кольорових металів; 2) дослідження методів нейронних мереж для прогнозування попиту на товари; 3) програмна реалізація методу прогнозування попиту на товари із кольорових металів; 4) експериментальна перевірка методу прогнозування попиту на товари із кольорових металів.

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Аналіз методів та підходів до прогнозування попиту на товари із кольорових металів	09.12.2024 - 15.12.2024	Виконано
2	Постановка задач дослідження	16.12.2024 - 22.12.2024	Виконано
3	Дослідження методів нейронних мереж для прогнозування попиту на товари	23.12.2024 - 27.12.2024	Виконано
4	Обґрунтування вибору моделі нейронної мережі для прогнозування попиту	27.12.2024 - 31.12.2024	Виконано
5	Опис теоретичного вирішення задачі прогнозування попиту	01.01.2024 - 04.01.2024	Виконано
6	Програмна реалізація методу прогнозування попиту на товари із кольорових металів	05.01.2024 - 07.01.2024	Виконано
7	Експериментальна перевірка методу прогнозування попиту на товари із кольорових металів	08.01.2024 - 11.01.2024	Виконано
8	Оцінка якості прогнозування	12.01.2024 - 14.01.2024	Виконано
9	Оформлення пояснювальної записки до кваліфікаційної роботи	15.01.2025	Виконано
10	Перевірка на плагіат	16.01.2025	Виконано
11	Попередній захист кваліфікаційної роботи	19.01.2025	Виконано
12	Захист роботи	21.01.2025	Виконано

Дата видачі завдання 09 грудня 2024 р.

Здобувач 
(підпис)

Керівник роботи 
(підпис)

доц. Борисенко Т.І.
(посада, прізвище, ініціали)

РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 60 с., 5 рис., 4 табл., 1 дод., 19 джерел.

ІНФОРМАЦІЙНА СИСТЕМА, ІНФОРМАЦІЙНІ ТЕХНОЛОГІЇ, КОЛЬОРОВІ МЕТАЛИ, НЕЙРОННІ МЕРЕЖІ, ПРОГНОЗУВАННЯ ПОПИТУ, ТОВАР, ЧАСОВІ РЯДИ, LSTM.

Об'єктом дослідження кваліфікаційної роботи є процес прогнозування попиту на товари з кольорових металів.

Метою кваліфікаційної роботи є використання методу нейронних мереж для прогнозування попиту на товари із кольорових металів.

У процесі дослідження використовувалися сучасні методи аналізу даних і машинного навчання.

Робота містить аналіз методів прогнозування попиту на товари, опис інформаційної технології прогнозування попиту на товари з кольорових металів та програмної реалізації модуля прогнозування попиту, який інтегрується в інформаційну систему підприємства, опис експериментальної перевірки застосовності методу нейронної мережі типу LSTM для прогнозуванні попиту на товари із кольорових металів.

Новизна роботи полягає у використанні моделі LSTM для вирішення завдання прогнозування попиту в специфічній галузі – реалізації продукції із кольорових металів.

Отримані результати мають практичне значення для підприємств торгівлі.

Кваліфікаційну роботу виконано згідно методичних вказівок щодо розробки та оформлення кваліфікаційної роботи [1], ДСТУ 3008:2015 [2] та ДСТУ 8302:2015 [3].

ABSTRACT

Explanatory note to the qualification work contains: 60 pages, 5 figures, 4 tables, 1 appendices, 19 sources.

DEMAND FORECASTING, COMMODITY, INFORMATION SYSTEM, INFORMATION TECHNOLOGY, LSTM, NEURAL NETWORKS, NON-FERROUS METALS, TIME SERIES.

The object of research of the qualification work is the process of forecasting demand for non-ferrous metal products.

The purpose of the qualification work is to use the neural network method to forecast the demand for non-ferrous metal products.

In the course of the research, modern methods of data analysis and machine learning were used.

The work contains an analysis of methods for forecasting demand for goods, a description of the information technology for forecasting demand for non-ferrous metals and the software implementation of the demand forecasting module, which is integrated into the enterprise information system, a description of the experimental verification of the applicability of the LSTM neural network method for forecasting demand for non-ferrous metals.

The novelty of the work lies in the use of the LSTM model to solve the problem of forecasting demand in a specific industry - the sale of non-ferrous metal products.

The results obtained are of practical importance for trade enterprises.

ЗМІСТ

	С.
Скорочення та умовні позначки	8
Вступ.....	9
1 Аналіз методів та підходів до прогнозування попиту на товари із кольорових металів	11
1.1 Формування проблеми щодо вдосконалення процесу прогнозування попиту в ІС	11
1.2 Аналіз існуючих методів вирішення проблеми автоматизації прогнозування попиту.....	12
1.3 Обґрунтування вибору моделі нейронної мережі для прогнозування попиту	15
1.4 Постановка задач магістерської кваліфікаційної роботи.....	16
2 Дослідження методів нейронних мереж для прогнозування попиту на товари	18
2.1 Опис методу прогнозування попиту за допомогою CNN.....	18
2.2 Опис методу прогнозування попиту за допомогою RNN.....	20
2.3 Опис методу прогнозування попиту за допомогою LSTM.....	22
2.4 Обґрунтування вибору моделі нейронної мережі для прогнозування попиту	24
2.6 Опис теоретичного вирішення задачі прогнозування попиту.....	25
3 Програмна реалізація методу прогнозування попиту на товари із кольорових металів	29
3.1 Опис інформаційної технології прогнозування попиту на товари із кольорових металів	29
3.2 Опис реалізації модуля прогнозування у складі інформаційної системи	32
3.3 Опис зв'язків з іншими модулями ІС	38

4 Експериментальна перевірка методу прогнозування попиту на товари із кольорових металів	41
4.1 Опис вхідних даних	41
4.2 Навчання моделі прогнозування та тестове прогнозування.....	44
4.3 Оцінка якості прогнозування	45
Висновки	47
Перелік джерел посилання	49
Додаток А Графічний матеріал кваліфікаційної роботи.....	51

СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАКИ

БД – база даних

ІС – інформаційна система

ІТ – інформаційні технології

ПЗ – програмне забезпечення

СУБД – система управління базами даних

ШІ – штучний інтелект

CNN – згорткова нейронна мережа

LSTM – довгокороткочасна пам'ять

RNN – рекурентні нейронні мережі

ВСТУП

Сучасний ринок продукції із кольорових металів характеризується високою конкуренцією, динамічністю попиту та впливом численних зовнішніх факторів. В умовах нестабільності економіки та швидких змін споживчих уподобань компаніям необхідно постійно вдосконалювати свої підходи до управління ресурсами, зокрема до прогнозування попиту на продукцію. Ефективне прогнозування дозволяє оптимізувати процеси закупівлі, зберігання та збуту товарів, мінімізувати витрати та підвищити рівень обслуговування клієнтів.

Розробка та впровадження сучасних програмних засобів для прогнозування попиту є актуальним завданням, яке потребує інноваційних підходів і використання потужних інструментів аналізу даних. Особливе місце в цьому контексті займають методи машинного навчання, зокрема нейронні мережі. Їхнє використання дозволяє враховувати складну структуру даних, сезонні коливання, тренди та інші закономірності, які впливають на попит.

У даній кваліфікаційній роботі основна увага приділяється дослідженню методів і моделей прогнозування попиту на товари, зокрема із використанням рекурентних нейронних мереж (RNN) та їхніх модифікацій, таких як довгострокова короткострокова пам'ять (LSTM). Обґрунтовується доцільність використання цих підходів для вирішення завдань у бізнес-сфері, пов'язаній із реалізацією продукції із кольорових металів, а також розглядаються етапи інтеграції модуля прогнозування у загальну інформаційну систему підприємства.

Актуальність теми полягає у необхідності розробки таких рішень, які забезпечували б не тільки високу точність прогнозування, але й можливість інтеграції в існуючі бізнес-процеси компаній. Саме це дозволяє досягти конкурентних переваг, підвищити прибутковість підприємства та

задовольнити потреби клієнтів.

Результати роботи можуть бути використані підприємствами для оптимізації своїх бізнес-процесів, пов'язаних із закупівлями, управлінням запасами та реалізацією продукції. Це сприяє підвищенню ефективності діяльності організації та її стабільності в умовах ринкових змін.

Об'єктом дослідження є процеси управління попитом у фірмі з реалізації продукції із кольорових металів.

Предметом дослідження є методи прогнозування попиту, зокрема використання моделі LSTM у складі інформаційної системи (ІС).

Метою даної роботи є розробка й дослідження модуля прогнозування попиту на товари в інформаційній системі фірми, яка займається реалізацією продукції із кольорових металів. Завданням є аналіз існуючих методів прогнозування, обґрунтування вибору моделі LSTM, її адаптація до специфіки задачі, а також оцінка точності та ефективності моделі на практиці.

1 АНАЛІЗ МЕТОДІВ ТА ПІДХОДІВ ДО ПРОГНОЗУВАННЯ ПОПИТУ НА ТОВАРИ ІЗ КОЛЬОРОВИХ МЕТАЛІВ

1.1 Формування проблеми щодо вдосконалення процесу прогнозування попиту в ІС

Прогнозування попиту – це неоціненний інструмент для будь-якого бізнесу, який дозволяє оптимізувати виробництво, ефективно управляти запасами та приймати обґрунтовані стратегічні рішення. Завдяки прогнозуванню компанії можуть адаптуватися до змін ринку, задовольняти потреби клієнтів та мінімізувати ризики, пов'язані з непередбачуваністю попиту. Цей інструмент дозволяє компаніям бачити майбутнє та готуватися до нього, що є ключовим фактором успіху в динамічному бізнес-середовищі.[4]

Прогнозування попиту, яке здійснюється вручну одним співробітником, має як свої переваги, так і значні недоліки. З одного боку, такий підхід дозволяє гнучко реагувати на зміни ринку та враховувати нюанси бізнесу, які можуть бути недоступні для автоматизованих систем. З іншого боку, ручне прогнозування обмежене суб'єктивністю, залежить від досвіду однієї людини та обмеженого набору даних. Це призводить до зниження точності прогнозів, високих часових витрат та труднощів у масштабуванні процесу. Крім того, відсутність автоматизації ускладнює детальний аналіз причин відхилень фактичних продажів від прогнозованих.

Для покращення точності ручного прогнозування рекомендується використовувати різноманітні джерела даних, застосовувати прості статистичні методи та регулярно перевіряти точність прогнозів. Однак, для великих компаній та складних моделей попиту більш ефективним рішенням є перехід на автоматизовані системи прогнозування, які дозволяють використовувати складні алгоритми, обробляти великі обсяги даних та отримувати більш точні результати.

1.2 Аналіз існуючих методів вирішення проблеми автоматизації прогнозування попиту

У сучасному світі прогнозування попиту на товари є важливим напрямом досліджень, який широко розглядається в науковій літературі. Багато авторів приділяють увагу використанню математичних та статистичних методів для прогнозування попиту. Зокрема, у працях [5–7] розглядаються традиційні підходи, такі як аналіз часових рядів, регресійні моделі та методи ковзного середнього. Проте з розвитком обчислювальних технологій дедалі більшої популярності набувають моделі штучного інтелекту (ШІ), зокрема нейронні мережі.

У роботах [8–10] показано, що моделі LSTM здатні виявляти довготривалі залежності та враховувати сезонні коливання, що робить їх особливо ефективними для прогнозування попиту.

Існує широкий спектр методів прогнозування, які можна застосовувати для прогнозування попиту, починаючи від простих (припущення про стабільність попиту) і до застосування складних економічних і математичних теорій, включаючи використання нейронних мереж. Розглянемо найпопулярніші нині методи прогнозування попиту на продукцію:

1) методи прогнозування часових рядів: вони використовують попередні значення величини і включають моделі ковзного середнього та експоненційного згладжування, а також більш складні методи прогнозування майбутніх значень попиту на основі попередніх даних. Ці методи застосовні для короткострокового (від одного тижня до трьох місяців) та середньострокового (від трьох місяців до кількох років) прогнозування з урахуванням сезонних, циклічних та трендових факторів;

2) причинно-наслідкові методи: тут використовуються моделі статистичної регресії для виявлення взаємозв'язку між попитом та незалежними змінними, такими як ціна та рекламні бюджети. Створення

успішних моделей дозволяє проводити сценарний аналіз, але важливо враховувати можливість зміни взаємозв'язків із часом;

3) якісні методи: вони не спираються на математичний апарат і застосовні для прогнозування попиту нові товари та поточний асортимент. Ці методи включають експертні оцінки, такі як метод Делфі, що базується на анонімному зборі думок групи експертів;

4) методи прогнозування попиту на нові вироби: у цьому випадку використовуються допоміжні дані, такі як інформація про існуючі аналоги та дані дослідницьких агентств, оскільки статистичних даних про продаж відсутні;

5) нейронні мережі: обробка великої кількості даних, визначення оптимальних параметрів та оперативне відстеження змін на ринку можуть спричинити значні складнощі. Тому найефективніший метод вирішення цієї проблеми – використання нейромереж. Після попереднього навчання, ці програми автоматично знаходять оптимальні рішення без необхідності глибокого розуміння всіх задіяних теорій. Більше того, нейромережі враховують не лише очевидні тренди та сезонність, а й приховані закономірності, що дозволяє робити точні прогнози навіть у нестабільних умовах, коли прогнозування було ускладнене. [11]

Нейронні мережі є одним із найефективніших інструментів для прогнозування попиту на товари завдяки їх здатності працювати з великими обсягами даних та знаходити складні закономірності в них. В умовах сучасних інформаційних систем, де аналізуються багатовимірні дані, такі як історія продажів, сезонні коливання, маркетингові акції та економічні фактори, нейронні мережі здатні виявляти приховані нелінійні залежності, які складно помітити традиційними статистичними методами.

Їх адаптивність до змін дозволяє швидко реагувати на динаміку ринку, враховуючи нові тенденції та поведінку споживачів. Завдяки механізму навчання на потоках інформації, нейронні мережі можуть оновлювати свої моделі, інтегруючи свіжі дані. Це робить їх особливо корисними на

швидкозмінних ринках, де попит може різко змінюватися.

Окрім того, нейронні мережі можуть обробляти не лише структуровані дані, а й неструктуровані – наприклад, текст (відгуки клієнтів), зображення (візуальні особливості товарів) чи часові ряди. Ця універсальність дає змогу враховувати широкий спектр факторів, що впливають на попит. У результаті нейронні мережі часто забезпечують вищу точність прогнозів порівняно з методами часових рядів чи лінійними моделями.

Інтеграція з сучасними програмними інструментами машинного навчання, такими як TensorFlow чи PyTorch [12], спрощує реалізацію нейронних мереж у бізнес-процеси. Вони вже успішно застосовуються провідними компаніями, такими як Amazon, Walmart і Alibaba, що підтверджує їх ефективність у реальних умовах.

Компанія Amazon використовує такі моделі, як DeepAR, підхід рекурентної нейронної мережі (RNN), розроблений для прогнозування часових рядів. Ця модель спільно тренується на кількох пов'язаних часових рядах, що робить її особливо ефективною для великомасштабних програм, як-от прогнозування попиту на різні категорії продуктів. Ці моделі об'єднують історичні дані про продажі, сезонність і зовнішні фактори, забезпечуючи точні прогнози навіть у складних сценаріях. Amazon SageMaker надає екосистему для навчання, розгортання та моніторингу цих моделей, забезпечуючи безперервну оптимізацію з налаштуванням гіперпараметрів і автоматизованим повторним навчанням на основі оновлених даних.[13]

Компанія Walmart інтегрує нейронні мережі у своє прогнозування попиту, щоб керувати широким асортиментом і оптимізувати ланцюги поставок. Компанія зосереджується на масштабованих архітектурах, таких як мережі довгострокової короткочасної пам'яті (LSTM), щоб передбачити попит за часовими шаблонами. Системи штучного інтелекту Walmart аналізують дані про транзакції, демографічні показники клієнтів і дані про погоду, серед інших факторів, щоб забезпечити точні прогнози для

конкретного регіону. Це зводить до мінімуму надлишок або брак, підвищуючи ефективність роботи [14].

Таким чином, завдяки своїй здатності адаптуватися, враховувати складні взаємозв'язки та забезпечувати високу точність прогнозування, нейронні мережі є оптимальним вибором для прогнозування попиту на товари.

1.3 Обґрунтування вибору моделі нейронної мережі для прогнозування попиту

Вибір моделі нейронної мережі для прогнозування попиту на товари з кольорових металів є досить обґрунтованим з кількох причин.

Завдяки нелінійній залежності попит на кольорові метали зазвичай залежить від багатьох факторів, які можуть нелінійно впливати. Нейронні мережі можуть виявляти складні нелінійні залежності між змінними, що є головною перевагою.

Сучасні компанії накопичили багато даних про продаж, ціни, економічні показники і т.д. Нейронні мережі хороші в обробці великих обсягів даних і виявленні закономірностей, які можуть бути приховані.

Завдяки здатності до узагальнення нейронні мережі можуть узагальнювати отримані знання та робити прогнози на основі нових даних, навіть якщо вони відрізняються від даних навчання. Це особливо важливо для прогнозування у разі нестабільності ринку.

Багатошаровість дозволяє нейронній мережі мати багато рівнів та моделювати складні нелінійні залежності. Це особливо корисно при прогнозуванні часових рядів, оскільки історія даних може істотно вплинути на майбутні значення.

Є декілька моделей які можна використовувати для прогнозування

попиту:

- рекурентні нейронні мережі (RNN) особливо підходять для прогнозування часових рядів, оскільки можуть пояснити залежності між безперервними спостереженнями;

- LSTM (довготривала короткочасна пам'ять): варіанти rnn, які можуть зберігати довгострокові залежності;

- GRU (gated loop unit): проста версія lstm, яка також показує хороші результати;

- збудлива нейронна мережа (CNN): Дані можуть ефективно визначати сезонні закономірності та тенденції.

Чинники, які слід враховувати при виборі моделі:

- які дані можна використовувати для навчання моделі та яка їхня якість;

- наскільки складні залежності між змінними та який рівень шуму даних;

- вимоги до точності прогнозування. Яка точність прогнозування потрібна для прийняття рішень;

- тимчасові обмеження, яка швидкість обчислень потрібна.

1.4 Постановка задач магістерської кваліфікаційної роботи

Об'єктом дослідження в рамках магістерської кваліфікаційної роботи є процес прогнозування попиту в інформаційній системі фірми з реалізації продукції із кольорових металів.

Предметом дослідження є моделі та методи, які можна використовувати при дослідженні прогнозування попиту.

Проблемою дослідження є недостатній ступінь автоматизації та відсутність об'єктивності під час прогнозування попиту.

Метою дослідження є застосування методу нейронних мереж для прогнозування попиту на товари із кольорових металів для фірми з реалізації продукції та забезпечення автоматичного і об'єктивного процесу прогнозування для ефективного управління запасами продукції на складах фірми.

При виконанні магістерської роботи для досягнення поставленої мети потрібно вирішити такі задачі дослідження:

- провести аналіз об'єкта дослідження та сучасного стану вирішення проблеми;
- вибрати модель прогнозування попиту на товари із кольорових металів, яка базується на неронній мережі;
- розробити інформаційну технологію, що імплементує метод прогнозування попиту на товари із кольорових металів у складі ІС фірми;
- розробити програмну реалізацію інформаційної технології прогнозування попиту на товари із кольорових металів;
- виконати експериментальну перевірку моделі нейронної мережі для прогнозування попиту на товари із кольорових металів.

Вирішення задач дослідження, які поставлені, дозволить забезпечити ефективне управління запасами продукції у фірмі з реалізації продукції із кольорових металів та, як наслідок, ефективне функціонування фірми.

2 ДОСЛІДЖЕННЯ МЕТОДІВ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ ПОПИТУ НА ТОВАРИ

Методи прогнозування на основі нейронних мереж, зокрема довготривалої пам'яті (LSTM, Long Short-Term Memory), демонструють високу точність при аналізі складних часових рядів, таких як продажі товарів, які залежать від множини змінних.

Для прогнозування попиту на товари із кольорових металів для фірми з реалізації продукції та забезпечення автоматичного і об'єктивного процесу прогнозування для ефективного управління запасами продукції на складах фірми було запропоновано розглянути два типи нейронних мереж: LSTM та RNN.

2.1 Опис методу прогнозування попиту за допомогою CNN

Метод прогнозування попиту за допомогою згорткових нейронних мереж (Convolutional Neural Networks, CNN) базується на здатності цих моделей виявляти закономірності та особливості у складних структурах даних. Хоча CNN традиційно асоціюються з аналізом зображень, їх також успішно застосовують для прогнозування часових рядів, включно з попитом на товари. Це можливо завдяки їхній здатності захоплювати локальні залежності та виявляти патерни в багатовимірних і послідовних даних [15].

Основна ідея застосування CNN до прогнозування попиту полягає в тому, що часові ряди можна розглядати як послідовність значень із локальними та глобальними залежностями. У цьому контексті згорткові шари моделі виступають інструментом для автоматичного виділення ознак, які впливають на зміну попиту.

Однією з ключових функцій CNN є згортка, яка застосовує фільтри (ядра) до вхідних даних, щоб виділити локальні патерни. У випадку прогнозування попиту ці патерни можуть включати сезонні коливання, короткострокові піки або спадання. Згортка дозволяє моделі зосередитися на найбільш релевантних часових інтервалах, ігноруючи менш значущі зміни або шум.

Ще однією важливою функцією CNN є операція підвибірки (pooling), яка зменшує розмірність вихідних даних, зберігаючи при цьому основні характеристики. Наприклад, у задачі прогнозування попиту підвибірка може допомогти моделі зосередитися на основних трендах, не враховуючи дрібні коливання, що можуть бути випадковими або незначними. Це також сприяє зменшенню обчислювальної складності та підвищенню стійкості моделі до перенавчання [16].

Значною перевагою CNN є можливість роботи з багатовимірними даними. Для прогнозування попиту це дозволяє одночасно враховувати кілька факторів, таких як історичні дані продажів, ринкові індикатори, ціни, маркетингові кампанії тощо. CNN може виявляти складні взаємозв'язки між цими факторами, які складно визначити за допомогою традиційних методів.

Ще одна функція CNN, яка робить її ефективною для прогнозування попиту, – це використання глибоких шарів для моделювання складних патернів. Кожен додатковий шар дозволяє моделі виділяти більш високорівневі ознаки, що відповідають за довгострокові тенденції або комплексні взаємодії між змінними. Це особливо важливо в задачах, де попит залежить не лише від історичних даних, а й від зовнішніх чинників, таких як сезонність або економічні умови.

Функція активації, зазвичай ReLU (Rectified Linear Unit), яку застосовують після згорткових шарів, додає нелінійність у модель, що дозволяє враховувати складні залежності у даних. Це допомагає моделі адаптуватися до змін у попиті, навіть якщо вони є нелінійними.

Для прогнозування CNN працює в поєднанні з повнозв'язними шарами

на завершальному етапі. Після проходження через згорткові та підвибіркові шари дані передаються до цих шарів, які виконують узагальнення отриманих ознак і створюють кінцевий прогноз. Цей етап дозволяє моделі інтегрувати локальні й глобальні закономірності в єдине рішення.

Завдяки своїй архітектурі CNN здатні забезпечувати точні прогнози для широкого спектра задач, включно з прогнозуванням попиту. Їхня ефективність базується на здатності автоматично виділяти релевантні ознаки, виявляти складні залежності між змінними та адаптуватися до змін у даних. Це робить CNN потужним інструментом для аналізу та прогнозування навіть у складних бізнес-сценаріях.

2.2 Опис методу прогнозування попиту за допомогою RNN

Метод прогнозування попиту за допомогою RNN (Recurrent Neural Networks) базується на здатності цих мереж аналізувати часові залежності у даних. RNN є базовою архітектурою рекурентних нейронних мереж, яка передбачає зворотний зв'язок між нейронами, що дозволяє враховувати контекст попередніх значень для прийняття рішень у поточний момент часу. У контексті прогнозування попиту RNN використовується для моделювання патернів, трендів і сезонності в часових рядах [17].

Основна ідея RNN полягає в тому, щоб нейрони в мережі не лише отримували вхідні дані, але й враховували інформацію з попередніх станів мережі. Це досягається завдяки механізму зворотного зв'язку, що дозволяє передавати інформацію вперед у часі.

Реалізація RNN включає такі компоненти:

- прихований стан (hidden state). Зберігає інформацію про попередні вхідні дані, щоб враховувати їхній вплив на поточний вихід;
- агрегація вхідних даних. На кожному кроці до прихованого стану

додається інформація з поточного входу, що дозволяє моделі враховувати як короткострокові, так і довгострокові залежності.

Однак базові RNN мають обмеження, зокрема проблему затухання градієнтів, що ускладнює запам'ятовування дуже довгострокових залежностей.

Хоча RNN поступаються LSTM у роботі з довгими часовими рядами, вони мають свої переваги в ситуаціях, де залежності між даними є відносно короткими. Наприклад, вони добре справляються з таким аналізом:

- короткотермінових трендів. RNN швидко реагують на зміни в даних, що зручно для прогнозування попиту в умовах короткострокових змін;
- простих патернів. У випадках, де залежності між даними не є складними, RNN працюють ефективніше, оскільки мають простішу структуру порівняно з LSTM.

RNN має зручну реалізацію через API Keras, що дозволяє легко створювати та налаштовувати рекурентні мережі. Основні функції, які сприяють прогнозуванню, включають:

- шар SimpleRNN це базовий шар RNN, який зберігає прихований стан та оновлює його на кожному часовому кроці. Простота його реалізації робить навчання швидшим, особливо для невеликих наборів даних;
- активаційні функції наприклад, tanh або ReLU, які відповідають за нелінійну трансформацію вхідних даних та прихованого стану, що дозволяє моделі виявляти складні взаємозв'язки;
- оптимізатори: використання алгоритмів, таких як Adam або RMSprop, дозволяє ефективно налаштовувати параметри моделі;
- регуляризація: Dropout або L2-регуляризація допомагають уникнути перенавчання, що особливо важливо в ситуаціях, де дані містять шум.

RNN добре підходять для задач прогнозування попиту, де основна увага приділяється короткостроковим залежностям або невеликим часовим рядам. Однак їхні можливості обмежені для складних задач, що потребують врахування довгострокових взаємозв'язків. У таких випадках перевагу

надають LSTM або GRU, які усувають проблеми базової RNN, такі як затухання градієнтів [18].

Попри це, простота й швидкість навчання RNN роблять їх привабливим вибором для задач із простішими часовими даними.

2.3 Опис методу прогнозування попиту за допомогою LSTM

Метод прогнозування попиту за допомогою LSTM (Long Short-Term Memory) базується на здатності цієї архітектури нейронних мереж ефективно аналізувати тимчасові залежності в даних. Це досягається завдяки спеціальній структурі LSTM, яка вирішує ключову проблему традиційних рекурентних нейронних мереж – їхню неспроможність зберігати довгострокову інформацію через проблему затухання градієнтів [14]. LSTM включає в себе чотири основні компоненти: вхідний вентиль, забувальний вентиль, вентиль виходу та внутрішній стан. Формули для кожного з цих компонентів наведені нижче:

$$\begin{aligned}
 f_t &= \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \\
 i_t &= \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \\
 o_t &= \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \\
 c_t &= f_t \odot c_{t-1} + i_t \odot \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \\
 h_t &= o_t \odot \sigma_h(c_t),
 \end{aligned} \tag{2.1}$$

де x_t – вхідні дані в момент часу t ,

h_{t-1} – вихідні дані з попереднього кроку,

c_{t-1} – комірка пам'яті з попереднього часового кроку,

$W_f, W_i, W_o, W_c, U_f, U_i, U_o, U_c, b_f, b_i, b_o, b_c$ – це вагові матриці та параметри вектора зміщення;

σ_g , σ_c , та σ_h є функціями активації, такими як сигмоїдна функція або функція гіперболічного тангенса,

⊙ – позначає поелементне множення, яке використовується для застосування значення стробу до комірки пам'яті.

LSTM-мережа використовує комірки пам'яті та механізми керування інформаційними потоками для запам'ятовування та забування даних. У бібліотеці TensorFlow це реалізовано через спеціальні функції:

- стан комірки пам'яті – це основний компонент, який дозволяє зберігати інформацію упродовж довгих періодів часу. Через додавання чи видалення інформації зі стану мережа вирішує, що є важливим для прогнозу;

- гейтинг-механізми – вхідний гейт контролює, яку нову інформацію додати до пам'яті. Гейт забування визначає, яку інформацію потрібно видалити з пам'яті, щоб уникнути накопичення нерелевантних даних. Вихідний гейт відповідає за формування вихідного значення на основі поєднання поточного стану пам'яті та нових вхідних даних.

Ці механізми забезпечують LSTM-мережам здатність ефективно працювати з довгими часовими рядами та виявляти патерни, які можуть бути розтягнутими у часі.

Прогнозування попиту є складним завданням, оскільки воно залежить від великої кількості факторів, включаючи сезонність, тенденції та випадкові коливання. LSTM добре підходить для таких завдань завдяки кільком ключовим властивостям:

- урахування довгострокових залежностей. Наприклад, попит на продукцію може змінюватися сезонно. LSTM аналізує такі довгострокові шаблони, навіть якщо вони розтягнуті у часі;

- стійкість до шуму. Завдяки адаптивним механізмам, LSTM може ігнорувати нерелевантну інформацію або короткострокові коливання, зосереджуючись на важливих трендах;

- гнучкість у роботі з нерівномірними даними. У TensorFlow це реалізується за допомогою можливості працювати з векторами різної

довжини, що зручно при роботі з даними, де є пропуски.

LSTM має оптимізовану реалізацію через модуль Keras.

Переваги LSTM, які сприяють успішному прогнозуванню, включають таке:

- LSTM дозволяє легко створити багатошарову модель, що враховує як прості, так і складні залежності. Параметри, наприклад кількість нейронів і активаційна функція, налаштовуються для досягнення оптимального результату;

- оптимізатори (наприклад, Adam) і метрики (наприклад, MSE) сприяють точному налаштуванню моделі;

- масштабування та регуляризація. Використання нормалізації даних та регуляризації у TensorFlow дозволяє знизити ризик перенавчання, зберігаючи узагальнюючу здатність моделі;

- обробка великих даних. TensorFlow ефективно працює з великими наборами даних, використовуючи GPU/TPU, що є важливим для моделювання реальних бізнес-сценаріїв.

2.4 Обґрунтування вибору моделі нейронної мережі для прогнозування попиту

Обґрунтування вибору моделі нейронної мережі для прогнозування попиту базується на специфіці задачі, а саме необхідності аналізу залежностей у часових рядах та врахуванні довготривалих взаємозв'язків між даними. LSTM є одним із найефективніших інструментів для роботи з послідовними даними, що робить її придатною для прогнозування попиту на товари із кольорових металів.

Прогнозування попиту є складною задачею, оскільки воно залежить від численних чинників, таких як сезонність, економічні умови, коливання цін на

ринку, зміни у поведінці споживачів та зовнішні події. Дані про попит мають часовий характер, що вимагає врахування як короткострокових, так і довгострокових закономірностей.

Порівняння LSTM з іншими методами:

– статистичні моделі (ARIMA, ETS) добре працюють з простими часовими рядами, але обмежені у випадках, коли дані мають складну структуру, багатовимірність або нелінійні залежності. LSTM перевершує їх завдяки здатності до моделювання нелінійних і динамічних закономірностей;

– RNN теж здатні працювати з часовими рядами, але вони мають обмежену пам'ять і схильність до зникнення градієнтів. LSTM усуває ці недоліки завдяки своїй покращеній архітектурі;

– згорткові нейронні мережі (CNN) можуть використовуватися для обробки часових рядів, вони не враховують послідовну природу даних так ефективно, як LSTM.

LSTM-моделі демонструють високу точність у завданнях прогнозування попиту завдяки здатності адаптуватися до змін у даних і виявляти складні часові взаємозв'язки. Їх використання дозволяє компанії знижувати витрати, уникати дефіциту товарів, оптимізувати запаси та покращувати обслуговування клієнтів.

LSTM є оптимальним вибором для прогнозування попиту на товари із кольорових металів завдяки своїй здатності обробляти складні часові залежності, адаптуватися до змін у даних і працювати з багатофакторними входами. Її використання забезпечує точні прогнози, що сприяє ефективному плануванню виробництва, закупівель і логістики.

2.6 Опис теоретичного вирішення задачі прогнозування попиту

Модель прогнозування базується на нейронній мережі LSTM, яка

враховує довготривалі залежності та сезонні коливання. Вхідні дані моделі – часові ряди попиту, вихідні – прогноз на заданий період.

Попередньо данні потребують очищення, нормалізації та сегментації на навчальні та тестові вибірки.

Архітектура моделі базується на мережі LSTM з механізмом уваги, що дає змогу ефективно обробляти тимчасові ряди. Вхідні дані являють собою одновимірний часовий ряд, де кожне спостереження відповідає певному кварталу. Модель складається з 4 шарів.

Перший шар LSTM з 128 нейронами витягує тимчасові залежності, повертаючи послідовності для подальшої обробки. Потім застосовується шар Dropout з імовірністю 30%, щоб зменшити ризик перенавчання.

Після цього слідує другий шар LSTM з 64 нейронами, який поглиблює аналіз тимчасових залежностей. На цьому етапі підключається механізм уваги, який обчислює вагові коефіцієнти для кожного часового кроку, акцентуючи важливі дані. Вихід шару уваги об'єднується з виходом другого шару LSTM для створення багатшого уявлення.

Далі оброблені дані передаються до третього шару LSTM з 32 нейронами, який повертає компактне представлення даних. Для запобігання перенавчання знову використовується Dropout з імовірністю 20%. Потім дані надходять у щільний шар із 64 нейронами, який готує їх для фінального передбачення.

Вихідний шар містить один нейрон із лінійною активацією, що дає змогу моделі передбачати значення для наступного часового кроку.

Для оцінювання якості мережі потрібно розраховувати метрики точності моделі: середньоквадратичну похибку (MSE), середню абсолютну похибку (MAE), середню абсолютну відсоткову похибку (MAPE) та коефіцієнт детермінації (R2).

MSE вимірює середню квадратичну різницю між прогнозованими та фактичними значеннями. Вона дає повне уявлення про помилки прогнозування, але чутлива до похибок, оскільки більші помилки зводяться

до квадрату. MSE є особливо корисна, коли точна величина помилки є критично важливою, оскільки вона більш суттєво показує більші відхилення від прогнозу.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (2.2)$$

де n – кількість спостережень;

y_i – фактичне значення i -го спостереження;

\hat{y}_i – прогнозоване значення i -го спостереження.

Середня абсолютна похибка (MAE) показує середнє відхилення прогнозованих значень від фактичних, виражене у тих самих одиницях, і розраховується за формулою (2.3). Вона є простою для інтерпретації, але не відображає масштабу даних.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (2.3)$$

де n – кількість спостережень;

y_i – фактичне значення i -го спостереження;

\hat{y}_i – прогнозоване значення i -го спостереження.

Метрика MAPE виражає середню різницю у відсотках між прогнозованими та фактичними значеннями. Вона дає змогу оцінити точність моделі у відсотках, що робить її придатною для інтерпретації в різних масштабах. MAPE є особливо цінною метрикою при оцінці точності у відносному вираженні і менше залежить від масштабу даних. Вона розраховується за формулою (2.4).

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100, \quad (2.4)$$

де n – кількість спостережень;

y_i – фактичне значення i -го спостереження;

\hat{y}_i – прогнозоване значення i -го спостереження.

Коефіцієнт детермінації (R^2) відображає, яка частка варіації залежної змінної пояснюється моделлю. Значення наближається до 1, якщо модель добре пояснює дані. Він розраховується за формулою (2.5).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (2.5)$$

де n – кількість спостережень,

y_i – фактичне значення i -го спостереження,

\hat{y}_i – прогнозоване значення i -го спостереження

\bar{y}_i – середнє значення фактичних даних у тестовій вибірці

3 ПРОГРАМНА РЕАЛІЗАЦІЯ МЕТОДУ ПРОГНОЗУВАННЯ ПОПИТУ НА ТОВАРИ ІЗ КОЛЬОРОВИХ МЕТАЛІВ

3.1 Опис інформаційної технології прогнозування попиту на товари із кольорових металів

Для реалізації та вбудовування в ІС фірми з реалізації продукції із кольорових металів методу прогнозування попиту на товари була розроблена інформаційна технологія прогнозування попиту на товари. Послідовність етапів технології, яка була розроблена, описана з використанням методології функціонального моделювання IDEF0.

На рисунку 3.1 наведена діаграма IDEF0, яка описує інформаційну технологію прогнозування попиту на товари із кольорових металів.

На діаграмі показано, як дані збираються, очищуються і готуються до аналізу, як моделі навчаються на основі цих даних і як результати прогнозів інтегруються у бізнес-процеси компанії. Механізми, такі як технічні засоби, програмні інструменти та система управління даними, підтримують функціонування кожного етапу. Діаграма (рис 3.1) включає в себе етапи 1, 2, 3, 4 та 5.

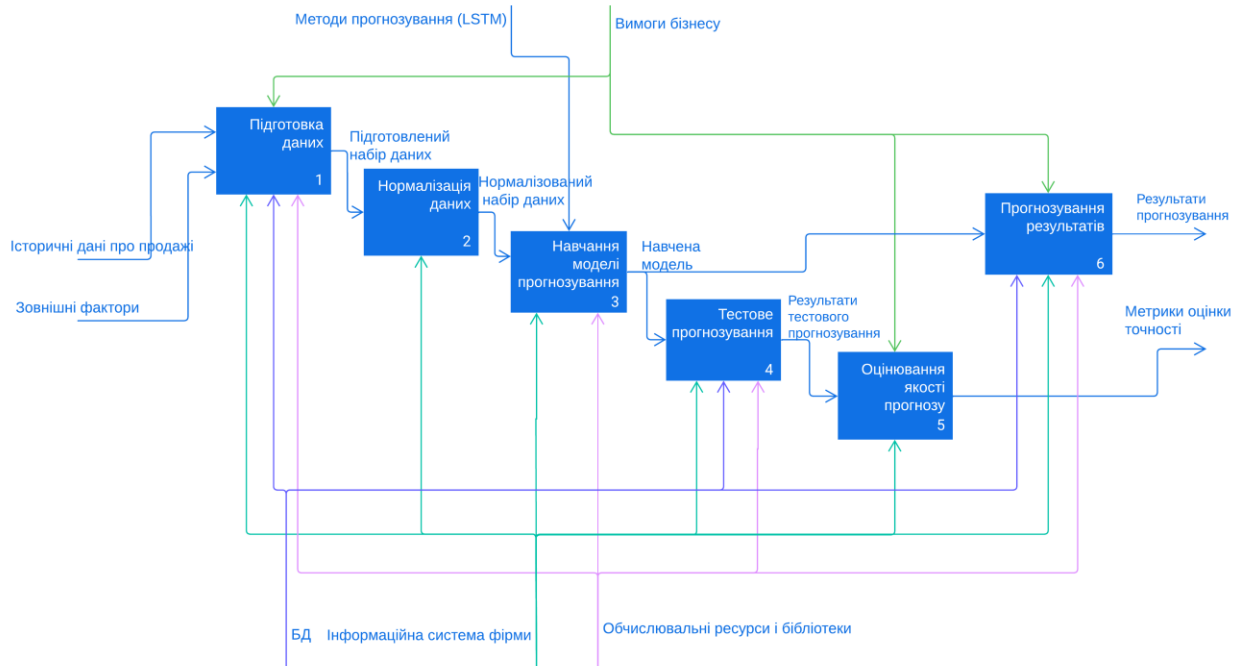


Рисунок 3.1 – Опис інформаційної технології прогнозування попиту на товари із кольорових металів

Етап 1 «Підготовка даних» відповідає за обробку вхідних даних для їх подальшого використання в прогнозуванні.

Вхідні дані етапу 1:

- історичні дані про продажі;
- зовнішні фактори.

Керуючі елементи етапу 1: вимоги до формату даних.

Механізми етапу 1:

- інформаційна система;
- база даних;
- модулі ETL (Extract, Transform, Load).

Вихідні дані етапу 1: підготовлений набір даних для аналізу.

Етап 2 «Нормалізація даних» відповідає за нормалізацію вхідних даних для їх подальшого використання в прогнозуванні.

Вхідні дані етапу 1: підготовлений набір даних.

Механізми етапу 1: інформаційна система.

Вихідні дані етапу 1: нормалізований набір даних для аналізу.

Етап 3 «Навчання моделі прогнозування» виконує процес побудови моделі на основі підготовлених історичних даних.

Вхідні дані етапу 3: нормалізований набір даних.

Керуючі елементи етапу 3: модель прогнозування (кількість епох, розмір партії).

Механізми етапу 3:

- програмні засоби (TensorFlow, Keras);
- обчислювальні ресурси (сервери, GPU).

Вихідні дані етапу 3: навчена модель.

Етап 4 «Тестове прогнозування» виконує прогнозування попиту.

Вхідні дані етапу 4: навчена модель.

Механізми етапу 4:

- програмне забезпечення для аналізу;
- інформаційна система;
- база даних.

Вихідні дані етапу 4: результат тестового прогнозування;

Етап 5 «Аналіз результатів» виконує аналіз результатів прогнозування попиту.

Вхідні дані етапу 5: прогноз попиту.

Керуючі елементи етапу 5: критерії оцінки точності прогнозів (MSE, MAE).

Механізми етапу 5: інформаційна система.

Вихідні дані етапу 5: метрики оцінки точності.

Етап 6 «Прогнозування результатів» виконує аналіз результатів прогнозування попиту.

Вхідні дані етапу 6: прогноз попиту.

Керуючі елементи етапу 6: вимоги бізнесу до форми подання прогнозу.

Механізми етапу 6:

- програмне забезпечення для прогнозу;
- інформаційна система;

– база даних.

Вихідні дані етапу б: метрики оцінки точності.

3.2 Опис реалізації модуля прогнозування у складі інформаційної системи

Модуль прогнозування на основі LSTM у складі інформаційної системи є важливим інструментом для аналізу та прогнозування попиту на товари із кольорових металів. Його реалізація починається з етапу збору та підготовки даних, що включає обробку історичних продажів, економічних показників і ринкових умов. Дані проходять очищення, нормалізацію та перетворення у формат, придатний для обробки моделлю LSTM.

Було розроблено програмні компоненти для обробки даних, включаючи завантаження інформації з бази даних (БД), нормалізацію часових рядів та формування послідовностей для навчання моделі прогнозування.

Модуль прогнозування використовує такі бібліотеки:

- TensorFlow – для роботи з нейронними мережами [12];
- Pandas – для обробки табличних даних;
- NumPy – для виконання математичних операцій;
- Scikit-learn – для нормалізації даних.

Зв'язок модуля прогнозування з іншими частинами ІС здійснюватиметься через БД ІС. Історичні дані продажів завантажуються в модуль із БД, де зберігаються відомості про позиції товарів та їхні продажі. Ці дані є результатом роботи відділу продажів, який використовує модуль продажів ІС. Результати прогнозування записуються до БД і стають доступними для використання в інших компонентах ІС, таких як аналітичний модуль та модуль закупівель.

Архітектура модуля базується на багаторівневій нейронній мережі LSTM. Вхідний шар приймає часові ряди, що складаються з упорядкованих послідовностей даних. Приховані шари LSTM обробляють ці послідовності, зберігаючи інформацію про короткострокові та довгострокові залежності між елементами. На виході мережа генерує прогноз для наступного періоду на основі отриманих патернів. Процес навчання моделі здійснюється з використанням оптимізаторів, таких як Adam, і функцій втрат, наприклад середньоквадратичної похибки. Навчання включає налаштування гіперпараметрів, таких як кількість епох і розмір партії, для досягнення оптимальної точності.

Модуль включає кілька основних підсистем, які взаємодіють між собою для забезпечення повного циклу прогнозування:

- підготовки даних. На цьому етапі здійснюється збір і обробка вхідних даних, таких як історичні обсяги продажів, ціни на продукцію, ринкові індикатори тощо. Дані очищуються, нормалізуються і перетворюються у формати, придатні для використання в моделі LSTM;

- навчання моделі. Модель навчається на базі підготовлених даних із використанням оптимізаторів, таких як Adam або RMSprop, і функції втрат (наприклад, MSE – середньоквадратичної похибки). Для запобігання перенавчанню використовуються техніки регуляризації, такі як Dropout;

- прогнозування. Навчена модель приймає нові вхідні дані (наприклад, показники попередніх місяців) і генерує прогноз попиту для наступного періоду.

Інтеграція модуля в інформаційну систему забезпечується через БД та мікросервісну архітектуру. Прогнози автоматично оновлюються й передаються у внутрішні бізнес-системи для подальшого використання у плануванні закупівель, виробництва та логістики. Результати прогнозування візуалізуються у вигляді графіків і аналітичних звітів, що доступні через інтерактивні інтерфейси.

Data Flow Diagram відображає потоки даних між компонентами модуля

прогнозування попиту в інформаційній системі. Діаграма складається з двох рівнів – контекстного (рис 3.2) і детального (рис 3.3), який пояснює, як дані обробляються і передаються між частинами модуля або до БД ІС.



Рисунок 3.2 – Концептуальна діаграма потоків даних модуля прогнозування

автоматично передаються для подальшого використання в процесах закупівель, виробництва та логістики.

Технічна реалізація модуля здійснюється на основі TensorFlow, що забезпечує високу гнучкість при створенні нейронної мережі. Навчена модель періодично оновлюється на нових даних для збереження актуальності прогнозів. Хмарні обчислювальні ресурси підтримують масштабованість і здатність обробляти великі обсяги інформації.

Реалізація модуля LSTM дозволяє точніше прогнозувати попит, враховуючи як історичні, так і поточні тенденції. Це забезпечує ефективність управління ресурсами компанії та гнучкість у прийнятті стратегічних рішень.

Особливості реалізації модуля прогнозування:

- автоматизація. Модуль прогнозування інтегрується з інформаційною системою через БД та мікросервісну архітектуру, що дозволяє автоматично оновлювати дані та генерувати прогнози;

- результати прогнозування відображаються у вигляді графіків і звітів, що спрощує аналіз для керівників, та зберігаються в БД;

- завдяки використанню хмарних обчислень (AWS, Google Cloud) модуль може обробляти великі обсяги даних і виконувати паралельні обчислення;

- система включає механізми періодичного донавчання моделі на нових даних, щоб забезпечити актуальність прогнозів.

Для реалізації модуля використовуються бібліотеки TensorFlow та PyTorch, які забезпечують гнучкість у налаштуванні архітектури нейронної мережі.

TensorFlow є основною бібліотекою для побудови та навчання LSTM-моделі. Вона забезпечує такі можливості:

- дозволяє створювати LSTM-шари, які обробляють часові ряди (модуль `keras.layers.LSTM`);

- підтримує широкий вибір функцій втрат і оптимізаторів для налаштування моделі (метод `Model.compile`);

- виконує навчання моделі на навчальних історичних даних (метод `Model.fit`).

- генерує прогнози на основі побудованої моделі (метод `Model.predict`).

TensorFlow забезпечує високу продуктивність завдяки підтримці апаратного прискорення (GPU/TPU).

Бібліотека NumPy використовується для роботи з багатовимірними масивами та матрицями. Вона забезпечує ефективну обробку числових даних, зокрема підготовку вхідних даних для LSTM-моделі (масштабування, нормалізація та сегментація часових рядів).

Бібліотека Pandas використовується для обробки табличних даних. Вона дозволяє завантажувати дані, виконувати їх очищення та трансформацію. Наприклад, з її допомогою можна обробити історичні продажі, створити нові ознаки та агрегувати дані за різними часовими періодами.

Бібліотеки Matplotlib і Seaborn використовуються для візуалізації даних. Matplotlib дозволяє створювати базові графіки, такі як графіки часових рядів, а Seaborn забезпечує більш розширені функції для створення аналітичних графіків. Використовується для попередньої обробки даних і оцінки якості моделі. Наприклад, вона пропонує функції для розподілу даних на навчальні та тестові вибірки, а також метрики для оцінки точності прогнозів (MAE, MSE, R^2).

Бібліотека TensorBoard є вбудованим інструментом TensorFlow для візуалізації процесу навчання. Він дозволяє відстежувати зміни функції втрат, точність моделі та інші параметри, що сприяє її оптимізації.

3.3 Опис зв'язків з іншими модулями ІС

Модуль прогнозування на основі LSTM є важливою складовою інформаційної системи. Він взаємодіє з іншими модулями для забезпечення цілісного процесу управління попитом і ресурсами компанії. Ці зв'язки гарантують обмін даними, інтеграцію результатів прогнозів у бізнес-процеси та ефективне прийняття рішень.

Зв'язок модуля прогнозування попиту на товари з іншими модулями ІС (Рис. 3.4) забезпечує точність прогнозів, інтеграції даних та підтримки бізнес-процесів.

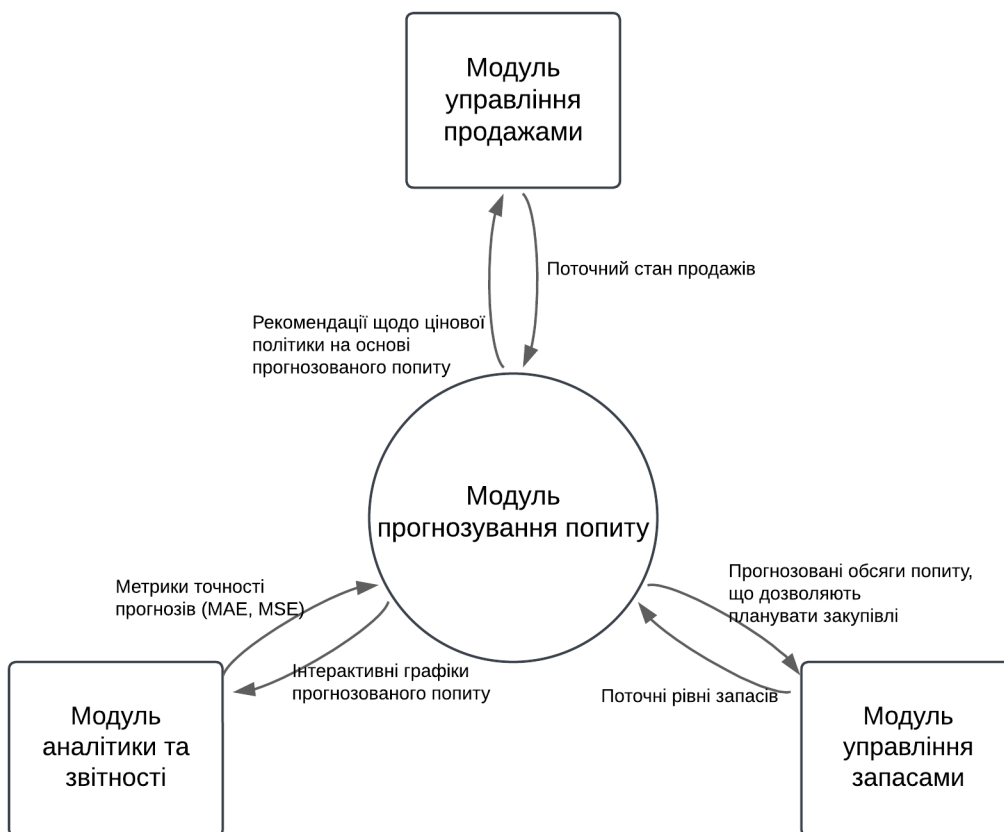


Рисунок 3.4 - Зв'язок модуля прогнозування попиту на товари з іншими модулями ІС

Результати прогнозів передаються до модуля аналітики для подальшої обробки та представлення у вигляді графіків та таблиць. Ця інформація дозволяє керівникам аналізувати тенденції попиту, виявляти ризики та можливості, а також приймати стратегічні рішення щодо закупівель і виробництва.

Модуль прогнозування надає дані про очікуваний попит модулю управління запасами. Це дозволяє оптимізувати рівень запасів, уникати дефіциту або надлишків продукції та знижувати витрати на зберігання.

Прогнози попиту впливають на планування логістичних операцій, таких як транспортування та розподіл товарів. Логістичний модуль використовує результати прогнозів для визначення обсягів і маршрутів перевезень, що сприяє підвищенню ефективності доставки.

Модуль прогнозування є частиною ІС, яка координує всі бізнес-процеси фірми. Прогнози попиту інтегруються у процеси виробничого планування, управління закупівлями та формування бюджетів, забезпечуючи узгодженість між різними відділами.

ІС може використовувати прогнози попиту для створення персоналізованих пропозицій, підвищення задоволеності клієнтів і розробки маркетингових кампаній.

Взаємодія між модулями забезпечується за допомогою обміну даними через бази даних. Такий підхід дозволяє легко масштабувати систему, додаючи нові компоненти або адаптуючи її до змін у бізнес-процесах. Зв'язок модуля прогнозування з іншими елементами інформаційної системи гарантує, що результати прогнозів використовуються максимально ефективно, сприяючи підвищенню продуктивності та конкурентоспроможності компанії.

Етапи впровадження модуля прогнозування на основі LSTM у складі інформаційної системи вимагають ретельного планування та поетапного виконання. Це дозволяє забезпечити високу точність роботи модуля, його інтеграцію з іншими компонентами системи та максимальну користь для

бізнесу.

Впровадження модуля дозволяє компанії отримати конкурентні переваги завдяки точному прогнозуванню попиту, оптимізації запасів та зменшенню витрат.

4 ЕКСПЕРИМЕНТАЛЬНА ПЕРЕВІРКА МЕТОДУ ПРОГНОЗУВАННЯ ПОПИТУ НА ТОВАРИ ІЗ КОЛЬОРОВИХ МЕТАЛІВ

4.1 Опис вхідних даних

На вхід модуль прогнозування отримує часові ряди продажів товарів (таблиці 4.1 та 4.2), структуровані за позиціями та часовими інтервалами, а також ідентифікатори товарів і опис часових інтервалів. Вхідні данні можна представити у вигляді матриці D (4.1):

$$D = \begin{pmatrix} p_1 & t_1 & x_1 \\ p_2 & t_2 & x_2 \\ \dots & \dots & \dots \\ p_n & t_n & x_n \end{pmatrix}, \quad (4.1)$$

де p_i – ідентифікатор товару;

t_i – часовий інтервал продажу товару p_i (в нашому випадку це номер кварталу визначеного року);

x_i – кількість товару p_i , що була продана у часовий інтервал t_i ;

n – кількість всіх даних про продану кількість товарів для навчання та тестування мережі.

Крім даних про продажі товарів задається кількість епох. Зазвичай для ефективного навчання нейронної мережі потрібно кілька епох, оскільки кожен прохід дозволяє моделі уточнювати свої параметри та покращувати свою продуктивність.

На виході модуль формує прогнози на заданий період часу для кожного товару. Результати прогнозування, які формуються, можна представити у вигляді матриці O (4.2):

$$O = \begin{pmatrix} p_1 & t_1 & y_1 \\ p_2 & t_2 & y_2 \\ \dots & \dots & \dots \\ p_m & t_m & y_m \end{pmatrix}, \quad (4.2)$$

де y_i – прогнозована кількість товару p_i , що буде продана у часовий інтервал t_i ;

m – величина яка дорівнює добутку кількості видів товарів на кількість годинних інтервалів, заданих для прогнозування.

Таким чином, модуль органічно інтегрується в ІС, забезпечуючи автоматизоване прогнозування та аналітичну підтримку діяльності фірми.

Таблиця 4.1 – Вхідні дані за 2016-2020

	1 кв. 2016	2 кв. 2016	3 кв. 2016	4 кв. 2016	1 кв. 2017	2 кв. 2017	3 кв. 2017	4 кв. 2017	1 кв. 2018	2 кв. 2018	3 кв. 2018	4 кв. 2018	1 кв. 2019	2 кв. 2019	3 кв. 2019	4 кв. 2019	1 кв. 2020	2 кв. 2020	3 кв. 2020	4 кв. 2020
cooper pipe	2236	172	3244	2374	1845	1297	4261	2943	2658	2565	3935	3524	3147	3974	3660	2574	3463	5058	4114	3159
cooper bar	189	73	345	390	198	73	359	348	214	123	395	215	244	125	277	228	245	163	234	138
cooper sheet	1662	540	938	3308	1243	653	1361	2755	1319	1086	1365	2092	1846	1038	1356	1795	1505	1285	1781	1093
cooper tire	36	48	6	40	52	85	60	32	71	150	174	29	75	198	181	13	96	246	291	10
cooper ribbon	33	20	103	0	31	25	68	0	23	42	16	7	33	59	59	0	28	59	0	0
cooper wire	49	14	4	0	42	9	8	12	36	7	9	35	23	10	10	47	14	11	12	61

Таблиця 4.2 – Вхідні дані за 2021-2024

	1 кв. 2021	2 кв. 2021	3 кв. 2021	4 кв. 2021	1 кв. 2022	2 кв. 2022	3 кв. 2022	4 кв. 2022	1 кв. 2023	2 кв. 2023	3 кв. 2023	4 кв. 2023	1 кв. 2024	2 кв. 2024	3 кв. 2024	4 кв. 2024
cooper pipe	3773	6073	4293	3589	1696	689	3722	2534	2706	4449	2885	4622	3976	6095	4440	3683
cooper bar	251	189	269	59	183	61	369	410	41	169	160	147	249	186	229	68
cooper sheet	1615	1545	2241	481	1360	465	848	3273	1131	1140	1211	1919	1669	1581	2068	599
cooper tire	115	305	369	6	50	51	17	36	40	32	76	43	103	297	354	4
cooper ribbon	19	78	51	2	33	12	78	1	99	0	614	172	25	85	10	0
cooper wire	6	8	14	79	54	8	5	0	2	88	11	20	6	10	13	78

4.2 Навчання моделі прогнозування та тестове прогнозування

Початковим кроком на етапі попередньої обробки даних є імпорт та перевірка набору даних. У цьому випадку набір даних - це поквартальний попит на товари. Дані зберігаються у файлі CSV, а бібліотека Pandas використовується для читання та дослідження набору даних.

Для прогнозування треба транспортувати (повернути) таблицю. Було виконано преобразування індексів таблиці в тип даних «Datetime».

Нормалізація є важливим кроком для забезпечення однорідності даних. MinMaxScaler застосовується для нормалізації стовпця даних, масштабуючи значення між 0.0 та 1.0. нормалізація даних є критично важливою для LSTM, оскільки вона допомагає моделі швидше конвергувати.

Для навчання методу були використані дані про продажі шести видів товарів за 9 роки – за кожний квартал року, що були надані фірмою з реалізації продукції із кольорових металів. Для навчання LSTM було використано 80% даних, для тестування мережі 20%. Кількість епох для навчання мережі дорівнювала 32. Час навчання моделі склав 4 хвилини. Вхідні данні описано в таблиці 4.1 та 4.2

Було проведено тестове прогнозування з використанням навченої мережі. Період тестового прогнозування становив 6 кварталів.

Модель LSTM складається з кількох основних шарів:

- вхідний шар приймає часові ряди у вигляді тривимірного тензора з розмірами.
- шар LSTM, основний рекурентний шар, який обробляє послідовні дані та зберігає інформацію про залежності між елементами часових рядів.
- Dropout шар для запобігання перенавчанню. Використовується для зменшення ризику перенавчання, особливо якщо навчальна вибірка невелика.
- вихідний повнозв'язний шар генерує прогноз на основі ознак, виділених попередніми шарами.

Результат прогнозування для товару ‘cooper pipe’ можна побачити на рисунку 4.1. Червоним на рисунку позначено спрогнозовані данні, а синім справжні данні на заданий період часу, які не брали участь в навчанні моделі. Сірим кольором позначено площу розбіжності між справжніми та спрогнозованими даними.

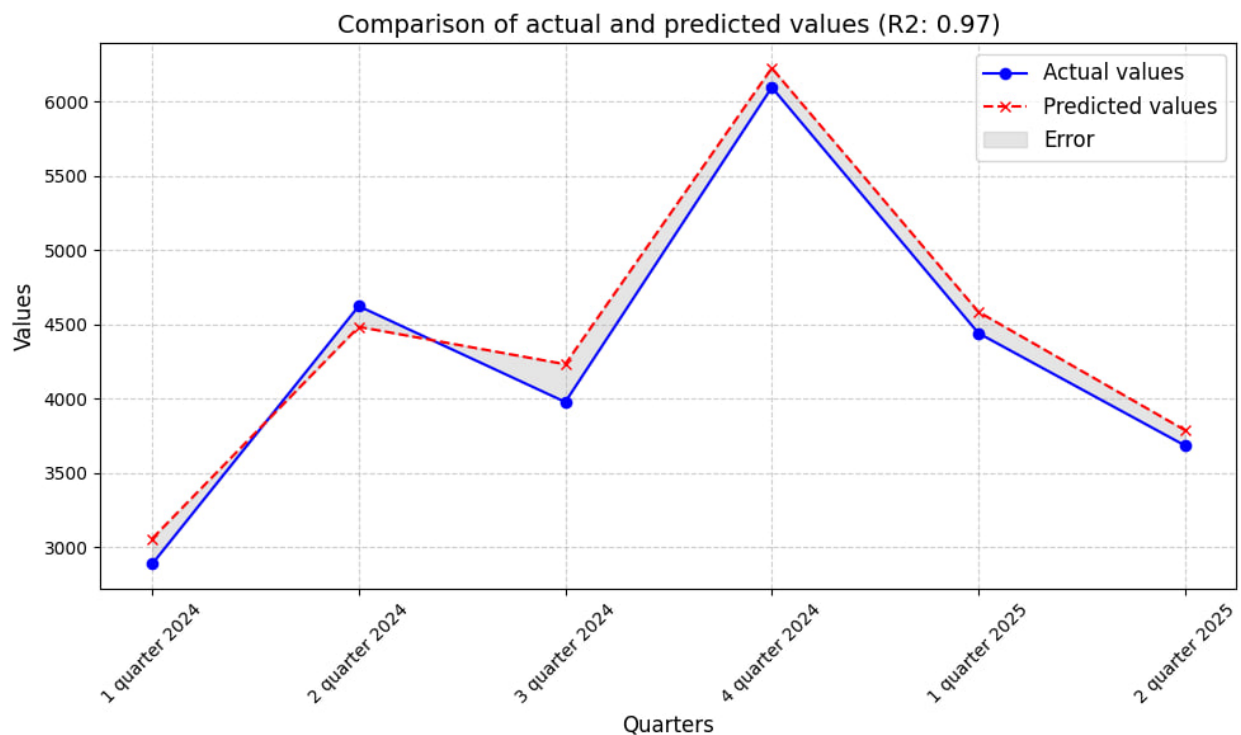


Рисунок 4.1 – Результат тестового прогнозування для товару ‘cooper pipe’

4.3 Оцінка якості прогнозування

Результати прогнозування є основним виходом модуля прогнозування попиту і слугують базою для подальших управлінських рішень. Вони представлені у вигляді числових даних, графіків, звітів та метрик точності (Таблиця 4.3).

Таблиця 4.3 – Результати прогнозування

	3 кв. 2023	4 кв. 2023	1 кв. 2024	2 кв. 2024	3 кв. 2024	4 кв. 2024
cooper pipe	3055.68	4482.22	4230.39	6224.71	4583.73	3786.29
cooper bar	161.13	141.41	249.88	189.92	229.60	68.96
cooper sheet	1172.72	1940.32	1588.48	1700.66	2096.47	557.94
cooper tire	102.45	56.41	126.0	276.64	306.91	0
cooper ribbon	563.45	147.04	34.92	142.58	18.35	1.98
cooper wire	13.11	23.57	5.07	11.83	19.51	79.84

Оцінка якості прогнозування (таблиця 4.4) є ключовим етапом для визначення ефективності моделі та її придатності для використання у реальних умовах. У контексті прогнозування попиту на товари із кольорових металів, основними критеріями оцінки є точність, узгодженість прогнозів із фактичними даними та здатність моделі адаптуватися до змін у часових рядах. Для оцінювання результатів

Таблиця 4.4 – Значення метрик точності моделі

Модель	MSE	MAE	MAPE	R2
LSTM	27132.13	136.66	3.25 %	0.97

Значення метрик точності моделі показали прийнятність результатів прогнозу побудованої моделі. Аналіз якості тестового прогнозування показав, що побудована модель LSTM забезпечує високу точність прогнозування. Це підтверджено низькими значеннями середньої абсолютної похибки (MAE) та середньоквадратичної похибки (RMSE), що свідчить про ефективність моделі LSTM під час вирішенні задач прогнозування попиту на товари із кольорових металів.

ВИСНОВКИ

У процесі виконання кваліфікаційної роботи було вирішено низку завдань, спрямованих на дослідження та впровадження сучасних методів прогнозування попиту на товари із кольорових металів у складі інформаційної системи (ІС) підприємства.

У рамках роботи проведено аналіз особливостей ринку продукції із кольорових металів, який характеризується динамічністю, сезонними коливаннями та залежністю від зовнішніх економічних факторів. Виявлено, що ефективне прогнозування попиту є ключовим елементом для підвищення ефективності бізнес-процесів, зокрема управління запасами, планування закупівель і продажів.

На основі аналізу існуючих методів і моделей прогнозування було обґрунтовано доцільність використання нейронної мережі LSTM. Ця модель виявилася здатною враховувати складну структуру часових рядів, тренди та сезонність. Було розроблено модуль прогнозування на основі LSTM, який інтегрується у загальну інформаційну систему підприємства.

У процесі роботи було розроблено інформаційна технологія прогнозування попиту на товари із кольорових металів, розроблена архітектура модуля прогнозування на рівні функцій. Визначено взаємодію модуля з іншими компонентами ІС фірми, такими як модулі збору даних, аналізу, управління запасами та звітності.

Проведена експериментальна перевірка моделі прогнозування LSTM на реальних даних. Результати роботи мають практичне значення для підприємств, які працюють у сфері реалізації продукції із кольорових металів.

Використання розробленого модуля прогнозування дозволяє:

- оптимізувати процеси управління запасами;
- знизити ризики дефіциту чи надлишків продукції;

– підвищити прибутковість завдяки ефективному плануванню продажів.

Таким чином, у ході кваліфікаційної роботи була досягнута поставлена мета – розроблено та досліджено модуль прогнозування попиту, який можна інтегрувати в ІС фірми. Використання цього дослідження сприятиме підвищенню конкурентоспроможності підприємства та ефективності його діяльності в умовах сучасного ринку.

Результати роботи були опубліковані на II Міжнародній науково-практичній конференції «Current problems of self-development and self-improvement of a person» (January 13-15, 2025). Antwerp, Brussels. Pp. 207-212. [19].

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Петров К.Е., Левикін В.М., Чалий С.Ф., Євланов М.В., Саєнко В.І., Міхнов Д.К., Міхнова А.В., Чала О.В., Методичні вказівки щодо розробки та оформлення кваліфікаційної роботи (для студентів усіх форм навчання другого (магістерського) рівня вищої освіти спеціальності 122 Комп'ютерні науки освітньо-професійної програми «Інформаційні управляючі системи та технології») – Харків: ХНУРЕ, 2021. – 30 с
2. ДСТУ 3008:2015. Інформація та документація. Звіти у сфері науки і техніки. Структура та правила оформлювання, Чинний від 22.06.2015. Київ: ДП «УкрНДНЦ», 2016. 26 с.
3. ДСТУ 8302:2015. Бібліографічне посилання. Загальні положення та правила складання / Нац. стандарт України. Вид. офіц. [Уведено вперше; чинний від 2016-07-01]. Київ : ДП «УкрНДНЦ», 2016. 17 с.
4. Грабовецький Б.Є. Економічне прогнозування та планування: Навч. посібник. – К.: Центр навчальної літератури, 2003. – 188 с.
5. Time Series Analysis: Forecasting and Control, 5th Edition, by George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel and Greta M. Ljung, 2015. Published by John Wiley and Sons Inc., Hoboken, New Jersey, pp. 712. ISBN: 978-1-118-67502-1
6. Forecasting: Principles and Practice. / Hyndman, Robin John; Athanasopoulos, George. 2nd ed. OTexts, 2018. 384 p.
7. Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. Neural Computation, 9, 1735-1780.
8. Brownlee, J. "Deep Learning for Time Series Forecasting." – Machine Learning Mastery, 2018.
9. Goodfellow, I., Bengio, Y., Courville, A. "Deep Learning." – MIT Press, 2016.
10. Chollet, F. "Deep Learning with Python." – Manning Publications, 2018.

11. Brown R.G. Smoothing forecasting and prediction of discrete time series / R.Brown. – N.Y., 1963.
12. TensorFlow Programming. URL: <https://www.kaggle.com/code/dansbecker/tensorflow-programming> .
13. Deep demand forecasting with Amazon SageMaker. URL: <https://aws.amazon.com/ru/blogs/machine-learning/deep-demand-forecasting-with-amazon-sagemaker/>.
14. O'Shea, K. & Nash, R. (2015). An Introduction to Convolutional Neural Networks.. CoRR, abs/1511.08458.
15. Short-Term Load Forecasting: Based on Hybrid CNN-LSTM Neural Network / A. Agga та ін. 2021 6th International Conference on Power and Renewable Energy (ICPRE), м. Shanghai, China, 17–20 верес. 2021 p. 2021.
16. Short-term power load forecasting based on LSTM neural network optimized by improved PSO / T. Wei та ін. Journal of System Simulation. 2021. T.33, № 8. С. 1866.
17. Hyndman R. J., Khandakar Y. Automatic Time Series Forecasting: TheforecastPackage forR. Journal of Statistical Software. 2008. T. 27, № 3.
18. Short-term power load forecasting based on LSTM neural network optimized by improved PSO / T. Wei та ін. Journal of System Simulation. 2021. T.33, № 8. С. 1866.
19. Suliatytskyi D., Borysenko T. FORECASTING DEMAND FOR GOODS IN THE INFORMATION SYSTEM OF A COMPANY SELLING NON-FERROUS METAL PRODUCTS // II International Scientific and Practical Conference «Current problems of self-development and self-improvement of a person» (January 13-15, 2025). Antwerp, Brussels. Pp. 207-212. URL: <https://eu-conf.com/en/events/current-problems-of-self-development-and-self-improvement-of-a-person/> .