

Міністерство освіти і науки України  
Тернопільський національний технічний університет імені Івана Пулюя

Факультет комп'ютерно-інформаційних систем і програмної інженерії

(повна назва факультету)

Кафедра програмної інженерії

(повна назва кафедри)

## КВАЛІФІКАЦІЙНА РОБОТА

на здобуття освітнього ступеня

Бакалавр

(назва освітнього ступеня)

на тему: **Розробка моделі машинного навчання для прогнозування часових рядів у задачах аналізу попиту**

Виконав(ла): студент(ка) 4 курсу, групи СП-42  
спеціальності 121 Інженерія програмного забезпечення

(шифр і назва спеціальності)

(підпис)

Ковальчук Н. І.

(прізвище та ініціали)

Керівник

(підпис)

Цебрій О.Р.

(прізвище та ініціали)

Нормоконтроль

(підпис)

Стоянов Ю.М.

(прізвище та ініціали)

Завідувач кафедри

(підпис)

Петрик М.Р.

(прізвище та ініціали)

Рецензент

(підпис)

(прізвище та ініціали)

Тернопіль  
2026

Міністерство освіти і науки України  
Тернопільський національний технічний університет імені Івана Пулюя

Факультет комп'ютерно-інформаційних систем і програмної інженерії  
(повна назва факультету)

Кафедра програмної інженерії  
(повна назва кафедри)

ЗАТВЕРДЖУЮ  
Завідувач кафедри

\_\_\_\_\_ (підпис) \_\_\_\_\_ (прізвище та ініціали)  
« » 20\_\_ р.

## ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

на здобуття освітнього ступеня Бакалавра  
(назва освітнього ступеня)

за спеціальністю 121 Інженерія програмного забезпечення  
(шифр і назва спеціальності)

студенту Ковальчук Надія Іванівна  
(прізвище, ім'я, по батькові)

1. Тема роботи Розробка моделі машинного навчання для прогнозування часових рядів у задачах аналізу попиту

Керівник роботи Цебрій О.Р., канд. фіз.-мат. наук, доц.  
(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

Затверджені наказом ректора від «\_\_» \_\_\_\_\_ 20\_\_ року № \_\_\_\_\_

2. Термін подання студентом завершеної роботи \_\_\_\_\_

3. Вихідні дані до роботи Предметна область, завдання, вимоги та специфікація, програмне рішення, методичні вказівки

4. Зміст роботи (перелік питань, які потрібно розробити)

Вступна частина

Аналіз предметної області та теоретичних основ

Визначення методики реалізації моделі

Реалізація моделі

Визначення основних аспектів охорони праці та безпеки життєдіяльності

Висновки роботи

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

Слайди презентації та діаграми процесів

## 6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Безпека життєдіяльності, основи охорони праці			
Нормоконтроль	Стоянов Ю.М. к.т.н., доц. каф ІІІ.		

7. Дата видачі завдання \_\_\_\_\_

**КАЛЕНДАРНИЙ ПЛАН**

№ з/п	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Отримання завдання		
2	Аналіз завдання		
3	Виконання розділу “АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ВИЗНАЧЕННЯ ВИМОГ ДО ПРОГРАМНОЇ СИСТЕМИ”		
4	Виконання розділу “ПРОЄКТУВАННЯ ТА РОЗРОБКА ПРОГРАМНОЇ СИСТЕМИ ПРОГНОЗУВАННЯ ПОПИТУ”		
5	Виконання розділу “ТЕСТУВАННЯ, ВПРОВАДЖЕННЯ ТА ОЦІНЮВАННЯ ЕФЕКТИВНОСТІ СИСТЕМИ”		
	Виконання розділу “БЕЗПЕКА ЖИТТЄДІЯЛЬНОСТІ, ОСНОВИ ОХОРОНИ ПРАЦІ”		
6	Оформлення пояснювальної записки		
7	Оформлення графічного та презентаційного матеріалу		
8	Попередній захист		
9	Захист		

Студент

\_\_\_\_\_ (підпис)

Ковальчук Н. І.

\_\_\_\_\_ (прізвище та ініціали)

Керівник роботи

\_\_\_\_\_ (підпис)

Цебрій О.Р.

\_\_\_\_\_ (прізвище та ініціали)

## АНОТАЦІЯ

Розробка моделі машинного навчання для прогнозування часових рядів у задачах аналізу попиту // Кваліфікаційна робота освітнього рівня «Бакалавр» // Ковальчук Надія Іванівна // Тернопільський національний технічний університет імені Івана Пулюя, факультет комп'ютерно-інформаційних систем і програмної інженерії, кафедра програмної інженерії, група СП-42 // Тернопіль, 2026 // С. \_\_\_\_, рис. – \_\_\_\_, табл. – \_\_\_\_, додат. – \_\_\_\_, бібліогр. – \_\_\_\_.

*Ключові слова:* прогнозування попиту; часові ряди; машинне навчання; прогнозування продажів; LSTM; ARIMA; вебзастосунок; аналіз даних.

Кваліфікаційна робота присвячена розробці програмної системи прогнозування попиту на основі методів машинного навчання та аналізу часових рядів.

У роботі проаналізовано предметну область прогнозування попиту, сучасні методи прогнозування часових рядів, існуючі програмні рішення та набори даних для задач прогнозування продажів, сформовано функціональні та нефункціональні вимоги до програмної системи. Спроектовано архітектуру системи, структуру даних, алгоритм підготовки часових рядів, модулі навчання та прогнозування, а також користувацький вебінтерфейс.

Для проведення експериментальних досліджень використано відкритий набір даних Store Sales – Time Series Forecasting.

Об'єкт дослідження – процес прогнозування попиту на товари на основі історичних даних продажів.

Предмет дослідження – методи, моделі та програмні засоби прогнозування часових рядів із використанням технологій машинного навчання.

Практичним результатом роботи є програмна система для автоматизованого аналізу часових рядів та прогнозування попиту, яка забезпечує завантаження та підготовку даних, навчання моделей, формування прогнозів і відображення результатів через вебінтерфейс.

## ABSTRACT

Development of a Machine Learning Model for Time Series Forecasting in Demand Analysis Tasks // Bachelor's Qualification Thesis // Nadiia Kovalchuk // Ternopil Ivan Puluj National Technical University, Faculty of Computer Information Systems and Software Engineering, Department of Software Engineering, Group SP-42 // Ternopil, 2026 // P. \_\_\_\_, fig. – \_\_\_\_, tabl. – \_\_\_\_, annexes – \_\_\_\_, references – \_\_\_\_.

*Keywords:* demand forecasting; time series; machine learning; sales forecasting; LSTM; ARIMA; web application; data analysis.

The qualification thesis is devoted to the development of a software system for demand forecasting based on machine learning methods and time series analysis.

The thesis analyzes the domain of demand forecasting, modern time series forecasting methods, existing software solutions, and datasets for sales forecasting tasks. Functional and non-functional requirements for the software system were defined. The system architecture, data structure, time series preprocessing algorithm, training and forecasting modules, as well as the user web interface were designed.

The open dataset Store Sales – Time Series Forecasting was used for experimental research.

The object of research is the process of forecasting product demand based on historical sales data.

The subject of research is methods, models, and software tools for time series forecasting using machine learning technologies.

The practical result of the thesis is a software system for automated time series analysis and demand forecasting that provides data loading and preprocessing, model training, forecast generation, and result visualization through a web interface.

## ЗМІСТ

ВСТУП	9
1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ВИЗНАЧЕННЯ ВИМОГ ДО ПРОГРАМНОЇ СИСТЕМИ	11
1.1 Аналіз задач прогнозування попиту та часових рядів	11
1.2 Огляд методів прогнозування часових рядів	12
1.3 Аналіз методів прогнозування рівня забруднення повітря	14
1.4 Огляд існуючих програмних рішень та сервісів прогнозування	16
1.5 Аналіз наборів даних для прогнозування попиту	19
1.6 Формування функціональних та нефункціональних вимог до програмної системи	21
1.7 Постановка задачі дослідження	25
1.8 Висновки до розділу 1	26
2 ПРОЄКТУВАННЯ ТА РОЗРОБКА ПРОГРАМНОЇ СИСТЕМИ ПРОГНОЗУВАННЯ ПОПИТУ	27
2.1 Вибір технологій та засобів реалізації	27
2.2 Проєктування архітектури програмної системи	29
2.3 Класове представлення системи	31
2.4 Проєктування структури даних та процесу їх обробки	34
2.5 Розробка алгоритму підготовки часових рядів	37
2.6 Розробка моделі машинного навчання для прогнозування попиту	39
2.7 Реалізація програмного інтерфейсу системи	41
2.8 Реалізація модулів навчання та прогнозування	44
2.9 Висновки до розділу 2	45
3 ТЕСТУВАННЯ, ВПРОВАДЖЕННЯ ТА ОЦІНЮВАННЯ ЕФЕКТИВНОСТІ СИСТЕМИ	47

3.1 Організація експериментального дослідження	47
3.2 Підготовка навчальних та тестових даних	49
3.3 Оцінювання якості прогнозування моделей	50
3.4 Тестування та аналіз ефективності програмної системи	52
3.5 Перспективи розвитку програмної системи	53
3.6 Висновки до розділу 3	54
4 БЕЗПЕКА ЖИТТЄДІЯЛЬНОСТІ, ОСНОВИ ОХОРОНИ ПРАЦІ	55
4.1 Працездатність людини-оператора	55
4.2 Економічне значення заходів щодо покращення умов та охорони праці	57
ВИСНОВКИ	61
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	64
ДОДАТКИ	66
Додаток А – data_preprocessing.py	66
Додаток Б – lstm_model.py	70
Додаток В – evaluation.py	72
Додаток Г – app.py	74
Додаток Д – forecast.html	77
Додаток Е – Теза конференції	80

## ПЕРЕЛІК СКОРОЧЕНЬ

- ML – Machine Learning (машинне навчання)
- AI – Artificial Intelligence (штучний інтелект)
- DL – Deep Learning (глибинне навчання)
- EDA – Exploratory Data Analysis (розвідувальний аналіз даних)
- CSV – Comma-Separated Values (текстовий формат даних)
- LR – Logistic Regression (логістична регресія)
- DT – Decision Tree (дерево рішень)
- kNN – k-Nearest Neighbors (метод k найближчих сусідів)
- SVM – Support Vector Machine (метод опорних векторів)
- NB – Naive Bayes (наївний байєсівський класифікатор)
- NN – Neural Network (нейронна мережа)
- RF – Random Forest (випадковий ліс)
- GBM – Gradient Boosting Machine (градієнтний бустинг)
- XGB – XGBoost (Extreme Gradient Boosting)
- LGBM – LightGBM (Light Gradient Boosting Machine)
- CB – CatBoost (Categorical Boosting)
- SMOTE – Synthetic Minority Oversampling Technique (синтетичне збільшення вибірки меншості)
- ROC – Receiver Operating Characteristic (крива робочих характеристик приймача)
- AUC – Area Under Curve (площа під кривою)
- API – Application Programming Interface (інтерфейс прикладного програмування)
- CPU – Central Processing Unit (центральний процесор)
- RAM – Random Access Memory (оперативна пам'ять)
- JSON – JavaScript Object Notation (формат даних JSON)

## ВСТУП

Прогнозування попиту є одним із найважливіших завдань сучасних інформаційних систем підтримки прийняття рішень. В умовах високої конкуренції та швидких змін ринкового середовища підприємства потребують ефективних інструментів для оцінювання майбутніх обсягів продажів, планування виробничих процесів, управління запасами та оптимізації логістичних операцій. Помилки у прогнозуванні попиту можуть призводити до надлишкового накопичення продукції на складах або, навпаки, до виникнення дефіциту товарів, що негативно впливає на економічні показники діяльності підприємства. Сучасні інформаційні технології дозволяють накопичувати значні обсяги історичних даних про продажі, замовлення та поведінку споживачів. Такі дані зазвичай представлені у вигляді часових рядів, які відображають зміну певних показників у часі. Аналіз часових рядів дає змогу виявляти тенденції, сезонні коливання та інші закономірності, що можуть бути використані для формування прогнозів. Проте традиційні статистичні методи не завжди забезпечують необхідний рівень точності через складність та нелінійність взаємозв'язків між різними факторами впливу.

Для розв'язання цієї проблеми дедалі ширше застосовуються методи машинного навчання, які дозволяють автоматично виявляти приховані закономірності у великих обсягах даних та будувати точні прогнозні моделі. Використання таких підходів дає можливість підвищити якість прогнозування попиту, адаптувати моделі до змін зовнішнього середовища та забезпечити підтримку прийняття ефективних управлінських рішень.

Актуальність теми кваліфікаційної роботи зумовлена необхідністю розробки програмних засобів для прогнозування часових рядів попиту із застосуванням сучасних методів машинного навчання. Використання інтелектуальних моделей прогнозування дозволяє підвищити точність аналізу даних, зменшити ризики прийняття неправильних рішень та покращити ефективність діяльності підприємств у різних галузях економіки.

Метою кваліфікаційної роботи є розробка моделі машинного навчання для прогнозування часових рядів у задачах аналізу попиту.

Для досягнення поставленої мети необхідно виконати такі завдання:

- провести аналіз предметної області прогнозування попиту часових рядів;
- дослідити сучасні методи прогнозування часових рядів;
- проаналізувати існуючі алгоритми машинного навчання для прогнозування попиту;
- сформулювати вимоги до програмної системи;
- спроектувати архітектуру програмного рішення;
- реалізувати модель машинного навчання прогнозування часових рядів;
- провести тестування та оцінювання ефективності розробленої моделі;
- виконати аналіз отриманих результатів.

Об'єктом дослідження є процес прогнозування попиту на основі часових рядів.

Предметом дослідження є методи, моделі та програмні засоби прогнозування часових рядів із використанням технологій машинного навчання.

Під час виконання роботи використано методи системного аналізу, статистичної обробки даних, машинного навчання, аналізу часових рядів, об'єктно-орієнтованого проектування та тестування програмного забезпечення.

Практичне значення одержаних результатів полягає у розробці програмного рішення для прогнозування попиту на основі історичних даних. Розроблена система може бути використана підприємствами для аналізу динаміки продажів, планування ресурсів, оптимізації запасів та підтримки процесів прийняття управлінських рішень.

Кваліфікаційна робота присвячена дослідженню методів прогнозування часових рядів та розробці моделі машинного навчання для аналізу попиту. У роботі розглянуто теоретичні аспекти прогнозування, проведено аналіз сучасних підходів і технологій, реалізовано програмне рішення та виконано оцінювання його ефективності на основі практичних даних.

# 1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ВИЗНАЧЕННЯ ВИМОГ ДО ПРОГРАМНОЇ СИСТЕМИ

Прогнозування попиту є важливим напрямом аналізу даних, що дозволяє оцінювати майбутню потребу в товарах або послугах на основі історичних даних. Отримані прогнози використовуються для оптимізації запасів, планування виробництва, управління логістичними процесами та підтримки прийняття управлінських рішень. Сучасні підходи до прогнозування дедалі частіше базуються на методах машинного навчання, які дозволяють виявляти складні закономірності в даних та забезпечувати високу точність прогнозів [1].

## 1.1 Аналіз задач прогнозування попиту та часових рядів

Задача прогнозування попиту полягає у визначенні майбутніх значень показника попиту на основі накопичених історичних спостережень та додаткових факторів впливу. До таких факторів можуть належати сезонність, маркетингові кампанії, економічні умови, святкові періоди та інші зовнішні події. Основною метою прогнозування є отримання достовірних оцінок майбутнього попиту, що дозволяють мінімізувати витрати, пов'язані з надлишковими запасами або дефіцитом продукції.

Одним із найбільш поширених підходів до розв'язання цієї задачі є аналіз часових рядів. Часовий ряд являє собою послідовність значень певного показника, впорядкованих у часі. У задачах прогнозування попиту часовий ряд формується на основі даних про продажі або кількість замовлень за певні часові інтервали. Аналіз таких даних дозволяє виявляти тенденції, циклічні коливання та сезонні закономірності, які можуть бути використані для побудови прогнозних моделей. На рисунку 1.1 наведено приклад часового ряду попиту, який демонструє зміну обсягів продажів протягом певного періоду спостереження [2].

Характерними особливостями часових рядів є наявність тренду, сезонності та випадкових коливань. Тренд відображає загальний напрям зміни показника в

довгостроковій перспективі, сезонність характеризує регулярні повторювані зміни через певні проміжки часу, а випадкові коливання обумовлені впливом неконтрольованих факторів. Урахування цих особливостей є необхідною умовою для побудови ефективної моделі прогнозування.




Рисунок 1.1 – Приклад часового ряду попиту на продукцію

З розвитком технологій штучного інтелекту традиційні статистичні методи прогнозування дедалі частіше доповнюються або замінюються алгоритмами машинного навчання. Такі моделі здатні автоматично виявляти приховані залежності в даних та адаптуватися до змін зовнішнього середовища, що робить їх перспективним інструментом для прогнозування попиту в сучасних інформаційних системах.

## 1.2 Огляд методів прогнозування часових рядів

Прогнозування часових рядів є одним із ключових напрямів аналізу даних, який використовується для передбачення майбутніх значень показників на основі історичних спостережень. У задачах аналізу попиту прогнозування дозволяє визначати очікувані обсяги продажів, оптимізувати запаси продукції та

підвищувати ефективність прийняття управлінських рішень. Для розв'язання таких задач застосовуються різні методи, які відрізняються складністю реалізації, вимогами до даних та точністю прогнозування [3].

Традиційно методи прогнозування часових рядів поділяють на статистичні та методи машинного навчання. Статистичні підходи базуються на аналізі закономірностей зміни даних у часі та використовують математичні моделі для опису трендів і сезонних коливань. Методи машинного навчання дозволяють виявляти складні нелінійні залежності між значеннями часового ряду та додатковими факторами впливу.

Порівняльну характеристику найбільш поширених методів прогнозування часових рядів наведено в таблиці 1.1.

Таблиця 1.1 – Порівняння основних підходів до прогнозування попиту

Підхід	Характеристика	Переваги	Недоліки
Експертні методи	Базуються на досвіді та знаннях фахівців	Можливість врахування зовнішніх факторів та специфіки предметної області	Суб'єктивність оцінок
Статистичні методи	Використовують математичні моделі та історичні дані	Простота реалізації, зрозумілість результатів	Обмежена ефективність при складних залежностях
Економетричні моделі	Враховують вплив різних економічних факторів	Можливість аналізу причинно-наслідкових зв'язків	Потребують значного обсягу якісних даних
Методи машинного навчання	Автоматично виявляють закономірності в даних	Висока точність прогнозування, адаптивність	Потребують налаштування та значних обсягів даних
Методи глибокого навчання	Використовують багатошарові нейронні мережі	Ефективні для складних та великих наборів даних	Високі вимоги до обчислювальних ресурсів

Як видно з таблиці 1.1, існує декілька підходів до прогнозування попиту, кожен з яких має свої переваги та обмеження. Традиційні методи, зокрема експертні та статистичні, характеризуються простотою застосування та зрозумілістю результатів, однак можуть демонструвати нижчу точність при роботі зі складними даними. Сучасні підходи, засновані на машинному та глибокому навчанні, дозволяють виявляти приховані закономірності та забезпечувати більш

точні прогнози, що робить їх перспективними для використання в інформаційних системах прогнозування попиту [4].

Останніми роками особливої популярності набули алгоритми машинного навчання, оскільки вони дозволяють автоматично виявляти приховані закономірності у часових рядах та адаптуватися до змін зовнішнього середовища. Саме тому при розробці сучасних систем прогнозування попиту все частіше використовуються ансамблеві алгоритми та нейронні мережі, здатні забезпечувати високу якість прогнозних результатів [5].

Таким чином, вибір конкретного методу прогнозування залежить від особливостей предметної області, обсягу доступних даних, вимог до точності прогнозу та обчислювальних ресурсів. Для задач прогнозування попиту перспективним напрямом є використання моделей машинного навчання, які здатні забезпечити високу ефективність аналізу часових рядів.

### **1.3 Аналіз методів прогнозування рівня забруднення повітря**

Сучасні системи прогнозування попиту все частіше використовують методи машинного навчання, які дозволяють виявляти складні закономірності в історичних даних та формувати більш точні прогнози порівняно з традиційними статистичними підходами. Вибір конкретної моделі залежить від структури даних, обсягу навчальної вибірки, необхідної точності прогнозування та доступних обчислювальних ресурсів [6].

Для задач прогнозування часових рядів застосовуються як класичні алгоритми машинного навчання, так і сучасні методи глибокого навчання. Класичні алгоритми характеризуються відносною простотою реалізації та швидким навчанням, тоді як нейронні мережі здатні враховувати складні часові залежності та забезпечувати вищу точність прогнозування при роботі з великими наборами даних.

До найбільш поширених моделей прогнозування попиту належать Random Forest, XGBoost, LightGBM, Prophet та LSTM. Кожна з них має свої особливості,

переваги та обмеження. Порівняльну характеристику сучасних моделей наведено в таблиці 1.2.

Таблиця 1.2 – Порівняння сучасних моделей машинного навчання для прогнозування попиту

Модель	Тип моделі	Середня точність (MAPE, %)	Складність реалізації	Релевантність для системи
Random Forest	Ансамбль дерев рішень	12–18	Низька	Висока
XGBoost	Гرادієнтний бустинг	8–14	Середня	Дуже висока
LightGBM	Градієнтний бустинг	8–13	Середня	Дуже висока
Prophet	Модель часових рядів	15–25	Низька	Висока
LSTM	Рекурентна нейронна мережа	6–12	Висока	Висока
Temporal Fusion Transformer (TFT)	Трансформер	4–10	Дуже висока	Середня
N-BEATS	Глибока нейронна мережа	5–11	Висока	Висока

Для оцінювання точності прогнозування в таблиці використано показник MAPE (Mean Absolute Percentage Error) — середню абсолютну відносну похибку прогнозу, що вимірюється у відсотках. Даний показник демонструє, наскільки в середньому прогнозовані значення відрізняються від фактичних. Чим менше значення MAPE, тим вищою є точність моделі. У практичних задачах прогнозування попиту значення MAPE менше 10 % вважається дуже хорошим результатом, від 10 % до 20 % — хорошим, від 20 % до 50 % — задовільним, а понад 50 % свідчить про низьку якість прогнозування [7].

Як видно з таблиці 1.2, найбільш перспективними для задач прогнозування попиту є алгоритми XGBoost та LightGBM. Дані моделі демонструють високу точність прогнозування, добре працюють із табличними даними та не потребують надмірних обчислювальних ресурсів. Саме тому вони широко використовуються в комерційних системах аналізу продажів та прогнозування попиту.

Модель Random Forest також демонструє хороші результати прогнозування та відзначається стійкістю до шумів у даних. Проте її точність зазвичай

поступається алгоритмам градієнтного бустингу. Модель Prophet є зручною для роботи з часовими рядами, які мають виражену сезонність та тренд, однак її можливості обмежені при наявності складних нелінійних залежностей [8].

Окрему групу становлять нейромережеві підходи. Модель LSTM спеціально розроблена для роботи з послідовними даними та здатна враховувати довгострокові часові залежності. Вона демонструє високу точність прогнозування, однак потребує значних обчислювальних ресурсів та тривалого процесу навчання. Ще вищі результати можуть забезпечувати сучасні трансформерні архітектури, зокрема Temporal Fusion Transformer, проте їх використання доцільне переважно для великих наборів даних та складних прогнозних задач.

З огляду на вимоги до розроблюваної системи, доцільним є використання моделей XGBoost або LightGBM як базових алгоритмів прогнозування. Дані моделі забезпечують оптимальний баланс між точністю прогнозування, швидкістю навчання та складністю реалізації. Крім того, вони добре інтегруються у програмні системи аналізу даних та можуть бути використані для подальшого масштабування розробленого програмного рішення [9].

Таким чином, аналіз сучасних моделей машинного навчання показав, що найбільш перспективними для задач прогнозування попиту є алгоритми градієнтного бустингу та нейромережеві підходи. Їх використання дозволяє підвищити точність прогнозування та забезпечити ефективне функціонування систем підтримки прийняття рішень.

#### **1.4 Огляд існуючих програмних рішень та сервісів прогнозування**

З розвитком технологій аналізу даних та машинного навчання з'явилася значна кількість програмних продуктів і хмарних сервісів, призначених для прогнозування попиту та аналізу часових рядів. Такі рішення використовуються в електронній комерції, логістиці, виробництві, фінансовому секторі та інших галузях, де важливим є прогнозування майбутніх змін показників на основі історичних даних.

Сучасні системи прогнозування дозволяють автоматизувати процес збору даних, їх обробку, побудову моделей машинного навчання та візуалізацію результатів прогнозування. Більшість комерційних платформ реалізують прогнозування як окремий сервіс або компонент системи бізнес-аналітики, що інтегрується з корпоративними інформаційними системами підприємства [10].

Серед найбільш поширених програмних рішень для прогнозування попиту можна виділити:

- Microsoft Power BI Forecasting — інструмент бізнес-аналітики, який дозволяє виконувати базове прогнозування часових рядів та будувати аналітичні звіти;
- Google Cloud Forecasting — хмарна платформа для побудови прогнозних моделей із використанням алгоритмів машинного навчання та автоматизованого аналізу даних;
- Amazon Forecast — сервіс прогнозування від Amazon Web Services, що використовує алгоритми машинного навчання для прогнозування попиту, продажів та інших бізнес-показників;
- SAP Integrated Business Planning — корпоративна система планування ресурсів підприємства з підтримкою прогнозування попиту та оптимізації ланцюгів постачання;
- IBM Planning Analytics — програмна платформа для аналізу даних, планування та побудови прогнозних моделей;
- Tableau Forecasting — інструмент бізнес-аналітики, який забезпечує візуалізацію часових рядів та формування прогнозів на основі статистичних методів.

Класифікацію сучасних програмних рішень для прогнозування попиту наведено на рисунку 1.2.

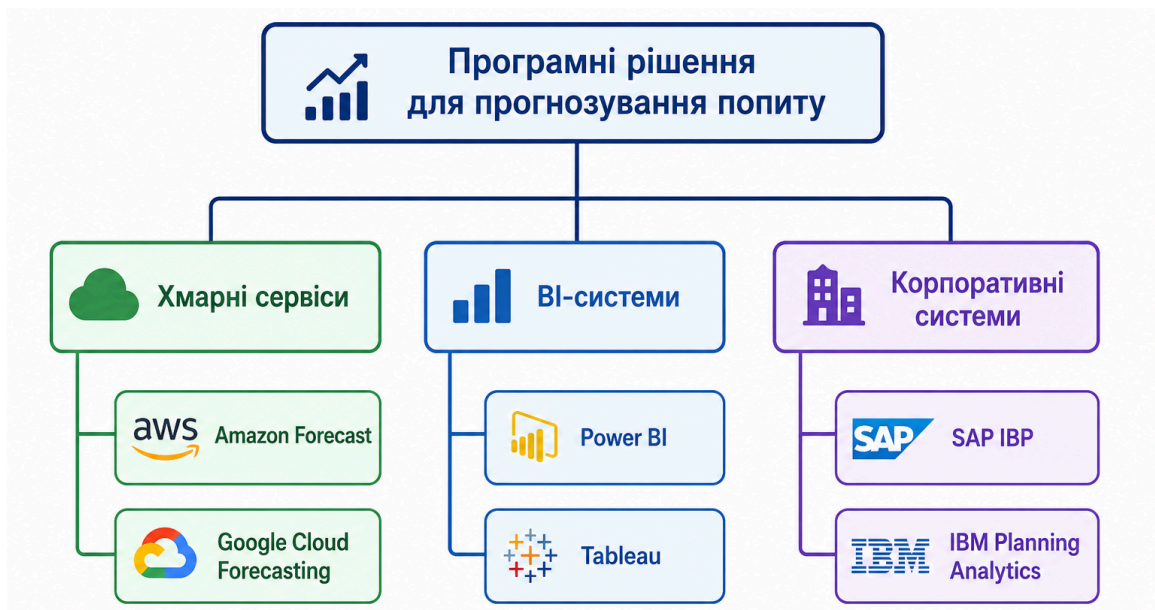


Рисунок 1.2 – Класифікація сучасних програмних рішень для прогнозування попиту

Як видно з рисунка 1.2, існуючі програмні рішення можна поділити на три основні групи: хмарні сервіси прогнозування, системи бізнес-аналітики та корпоративні платформи планування ресурсів підприємства. Кожна з цих категорій має власні особливості та орієнтована на вирішення певного класу задач.

Разом із тим комерційні програмні продукти мають ряд обмежень. До основних недоліків належать висока вартість використання, залежність від зовнішніх сервісів, обмежені можливості модифікації алгоритмів прогнозування та складність адаптації до специфічних вимог окремих підприємств. Крім того, користувач не завжди має можливість контролювати процес навчання моделей та налаштовувати параметри прогнозування.

З огляду на це доцільною є розробка власної програмної системи прогнозування попиту, яка забезпечуватиме використання сучасних алгоритмів машинного навчання, можливість адаптації до конкретної предметної області та повний контроль над процесом обробки даних і формування прогнозів.

Таким чином, аналіз існуючих програмних рішень показав, що сучасні сервіси прогнозування активно використовують технології машинного навчання та

хмарні обчислення. Проте створення власного програмного рішення дозволяє отримати більшу гнучкість, контроль над процесом прогнозування та можливість подальшого розвитку системи відповідно до потреб користувачів.

### **1.5 Аналіз наборів даних для прогнозування попиту**

Якість прогнозування часових рядів значною мірою залежить від характеристик набору даних, який використовується для навчання та тестування моделей машинного навчання. При виборі датасету необхідно враховувати обсяг даних, тривалість періоду спостереження, наявність сезонних коливань, додаткових ознак та якість даних. Використання різних наборів даних дозволяє оцінити узагальнювальну здатність моделей та їх ефективність у різних умовах.

Для задач прогнозування попиту існує велика кількість відкритих наборів даних, які активно використовуються у наукових дослідженнях та практичних проєктах. Найбільш поширеними є датасети, що містять інформацію про продажі товарів, замовлення клієнтів, складські запаси та інші показники комерційної діяльності [11].

Серед найбільш популярних наборів даних для прогнозування попиту можна виділити:

- **Store Sales – Time Series Forecasting** – набір даних мережі магазинів Favorita, який містить інформацію про продажі товарів у різних магазинах протягом кількох років. Датасет включає дати продажів, ідентифікатори магазинів, категорії товарів та обсяги реалізації. Наявність сезонності та великого обсягу історичних даних робить його одним із найпопулярніших наборів даних для дослідження моделей прогнозування часових рядів.

- **Walmart Recruiting – Store Sales Forecasting** – набір даних про продажі магазинів Walmart, який містить інформацію про магазини, департаменти, тижневі продажі та зовнішні фактори впливу. Датасет широко використовується для оцінювання моделей прогнозування попиту в умовах реальних бізнес-процесів.

– Rossmann Store Sales – набір даних про продажі аптечно-торговельної мережі Rossmann. Окрім інформації про продажі, містить відомості про акції, святкові дні та конкурентів, що дозволяє враховувати додаткові фактори при побудові прогнозних моделей.

– M5 Forecasting Accuracy Dataset – один із найвідоміших наборів даних для прогнозування попиту, який використовувався в міжнародному змаганні M5 Forecasting Competition. Містить багаторічну історію продажів товарів різних категорій та дозволяє оцінювати складні моделі прогнозування.

– Retail Sales Forecasting Dataset – узагальнений набір даних для прогнозування роздрібних продажів, який містить часові ряди продажів та додаткові економічні показники.

Для наочного порівняння основних наборів даних їх характеристику наведено в таблиці 1.3.

Таблиця 1.3 – Порівняння наборів даних для прогнозування попиту

<b>Набір даних</b>	<b>Галузь</b>	<b>Розмір даних</b>	<b>Сезонність</b>	<b>Додаткові ознаки</b>
Store Sales – Time Series Forecasting	Роздрібна торгівля	Дуже великий	Так	Магазини, категорії товарів
Walmart Store Sales Forecasting	Роздрібна торгівля	Великий	Так	Магазини, департаменти, свята
Rossmann Store Sales	Роздрібна торгівля	Великий	Так	Акції, конкуренти, свята
M5 Forecasting Accuracy	Роздрібна торгівля	Дуже великий	Так	Категорії товарів, магазини
Retail Sales Forecasting Dataset	Роздрібна торгівля	Середній	Частково	Економічні показники

Крім того, обидва датасети містять реальні дані про продажі, що наближує експериментальні умови до практичних задач прогнозування попиту. Це дозволяє отримати результати, які можуть бути використані для оцінювання ефективності моделей машинного навчання в реальних бізнес-сценаріях.

Таким чином, аналіз існуючих наборів даних показав, що для задач прогнозування попиту найбільш придатними є великі набори даних із вираженою

сезонністю та достатньою кількістю додаткових ознак. Саме таким вимогам відповідають обрані для дослідження датасети Store Sales – Time Series Forecasting та Walmart Recruiting – Store Sales Forecasting, які будуть використані на подальших етапах розробки та оцінювання моделей прогнозування.

## **1.6 Формування функціональних та нефункціональних вимог до програмної системи**

Формування вимог є важливим етапом життєвого циклу програмного забезпечення, оскільки саме на цьому етапі визначаються основні можливості системи, обмеження її роботи, очікувані характеристики якості та сценарії взаємодії користувача з програмним продуктом. Для розроблюваної системи прогнозування попиту вимоги повинні враховувати специфіку задач машинного навчання, роботу з часовими рядами, обробку датасетів, навчання моделей, оцінювання точності та представлення результатів прогнозування [13].

Основним користувачем системи є аналітик або дослідник, який завантажує набір даних, виконує попередню обробку, обирає модель прогнозування, запускає процес навчання та аналізує отримані результати. Узагальнену діаграму варіантів використання програмної системи наведено на рисунку 1.3.

Як видно з рисунка 1.3, програмна система повинна забезпечувати повний цикл роботи з моделями прогнозування: від завантаження даних до отримання прогнозу та оцінювання якості моделей. Це дозволяє розглядати систему не лише як окрему модель машинного навчання, а як програмний продукт, що реалізує основні етапи обробки даних і підтримує прийняття рішень.

Для побудови прогнозної моделі користувач обирає алгоритм прогнозування та задає його параметри. Процес навчання моделі включає використання обраного алгоритму та налаштованих параметрів, що відображено на діаграмі за допомогою зв'язків типу «include». Після завершення навчання система виконує прогнозування майбутніх значень попиту та оцінює якість отриманих результатів за допомогою відповідних метрик.

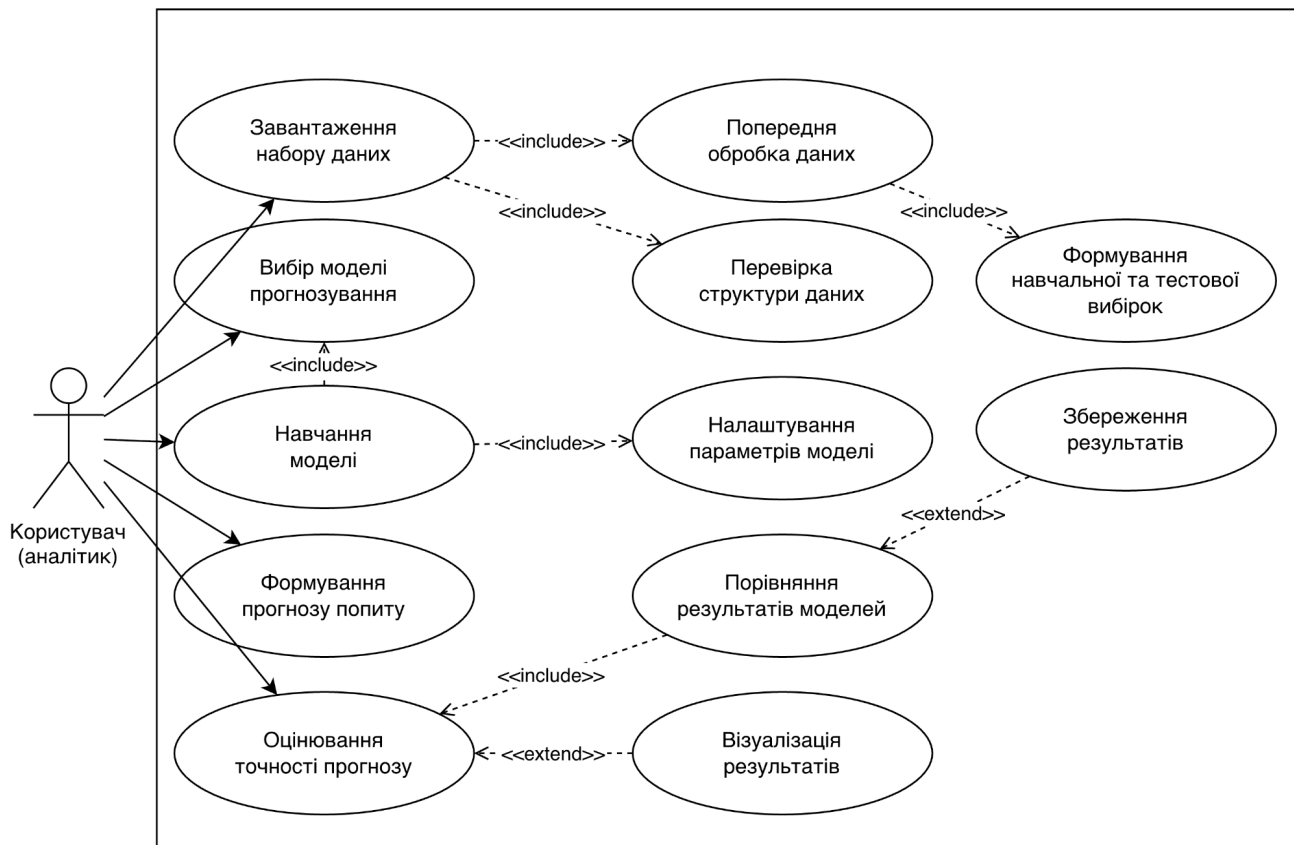


Рисунок 1.3 – Діаграма варіантів використання програмної системи прогнозування попиту

На наступному етапі користувач може виконати порівняння результатів роботи різних моделей прогнозування для визначення найбільш ефективного підходу. Додатково система надає можливість візуалізації результатів прогнозування у вигляді графіків та діаграм, а також збереження результатів експериментів для подальшого аналізу. Дані функції реалізовані як розширення основних сценаріїв роботи системи та відображені на діаграмі зв'язками типу «extend».

Таким чином, діаграма варіантів використання демонструє повний цикл роботи програмної системи прогнозування попиту: від завантаження та підготовки даних до навчання моделей, формування прогнозів, оцінювання їх точності та аналізу отриманих результатів.

Як видно з таблиці 1.4, функціональні вимоги охоплюють повний цикл роботи із часовими рядами: від завантаження даних до оцінювання якості прогнозування та аналізу результатів.

Таблиця 1.4 – Функціональні вимоги до програмної системи

ІД	Функціональна вимога	Пріоритет
FR-01	Завантаження набору даних у форматі CSV	Високий
FR-02	Перевірка коректності структури набору даних	Високий
FR-03	Попередня обробка даних та очищення пропусків	Високий
FR-04	Формування навчальної та тестової вибірок	Високий
FR-05	Вибір моделі прогнозування	Високий
FR-06	Налаштування параметрів моделі	Середній
FR-07	Навчання моделі на вибраному наборі даних	Високий
FR-08	Генерація прогнозу попиту	Високий
FR-09	Розрахунок метрик MAE, RMSE та MAPE	Високий
FR-10	Порівняння результатів декількох моделей	Середній
FR-11	Візуалізація фактичних та прогнозованих значень	Високий
FR-12	Збереження результатів експерименту	Середній

Нефункціональні вимоги визначають якісні характеристики програмної системи та встановлюють обмеження щодо її функціонування, продуктивності та подальшого розвитку.

Таблиця 1.5 – Нefункціональні вимоги до програмної системи

Категорія	Вимога
Продуктивність	Навчання моделей повинно виконуватися за прийнятний час для наборів даних обсягом понад 100 000 записів
Надійність	Система повинна обробляти помилки формату даних та відсутні значення
Масштабованість	Повинна підтримувати додавання нових моделей прогнозування
Модульність	Архітектура повинна складатися з незалежних компонентів обробки даних, навчання та оцінювання
Зручність використання	Інтерфейс повинен забезпечувати послідовне виконання всіх етапів роботи
Відтворюваність	Результати експериментів повинні бути відтворюваними за однакових параметрів
Сумісність	Підтримка форматів CSV та бібліотек Python для машинного навчання
Підтримуваність	Код повинен бути документованим та придатним до подальшого розширення
Безпека даних	Система не повинна змінювати вихідні набори даних під час обробки

З технічної точки зору система повинна реалізовувати послідовний конвеєр обробки даних. На першому етапі виконується імпорт набору даних, після чого

дані проходять перевірку, очищення та підготовку до моделювання. Далі формується часовий ряд, створюються навчальна та тестова вибірки, після чого користувач обирає модель прогнозування. Після навчання система виконує прогнозування, обчислює метрики якості та формує графічне відображення отриманих результатів.

Особливу увагу необхідно приділити вимогам до роботи з даними, оскільки якість прогнозування безпосередньо залежить від коректності підготовки часових рядів. Система повинна забезпечувати обробку пропущених значень, перетворення категоріальних ознак, масштабування числових показників та формування послідовностей для нейромережових моделей. Для моделей LSTM, GRU та Transformer дані повинні бути перетворені у формат послідовностей із заданим часовим вікном [14].

Таким чином, сформовані функціональні та нефункціональні вимоги визначають основні можливості майбутньої програмної системи та забезпечують основу для її подальшого проєктування. Розроблюване програмне рішення повинно не лише реалізовувати моделі машинного навчання, а й забезпечувати повний програмний цикл роботи з даними, навчанням, тестуванням, оцінюванням та візуалізацією результатів прогнозування попиту.

## **1.7 Постановка задачі дослідження**

Проведений аналіз предметної області показав, що існуючі методи прогнозування попиту мають різну ефективність залежно від структури даних, наявності сезонності та складності часових залежностей. Сучасні алгоритми машинного навчання та глибокого навчання дозволяють підвищити точність прогнозування, однак потребують детального дослідження та порівняння на реальних наборах даних.

Задачею дослідження є розробка програмної системи прогнозування попиту на основі часових рядів із використанням моделей ARIMA, LSTM, GRU та

Transformer, а також проведення їх порівняльного аналізу за показниками точності, стійкості та узагальнювальної здатності.

Для досягнення поставленої задачі необхідно:

- виконати підготовку та аналіз наборів даних Store Sales – Time Series Forecasting та Walmart Recruiting – Store Sales Forecasting;
- реалізувати алгоритми ARIMA, LSTM, GRU та Transformer;
- розробити програмну систему для навчання, тестування та порівняння моделей;
- провести оцінювання якості прогнозування за метриками MAE, RMSE та MAPE;
- виконати порівняльний аналіз отриманих результатів;
- визначити модель, яка забезпечує найкращу якість прогнозування попиту.

Результатом дослідження має стати програмна система, що забезпечує автоматизоване прогнозування попиту та дозволяє оцінювати ефективність різних моделей машинного навчання на задачах прогнозування часових рядів.

## **1.8 Висновки до розділу 1**

У першому розділі проведено аналіз предметної області прогнозування попиту та особливостей використання часових рядів для розв'язання даної задачі. Розглянуто основні підходи до прогнозування, сучасні моделі машинного навчання та існуючі програмні рішення. Виконано аналіз доступних наборів даних і обґрунтовано вибір датасетів Store Sales – Time Series Forecasting та Walmart Recruiting – Store Sales Forecasting для проведення дослідження.

На основі проведеного аналізу сформовано функціональні та нефункціональні вимоги до програмної системи, побудовано діаграму варіантів використання та визначено основні сценарії взаємодії користувача із системою. Сформульовано задачу дослідження, яка полягає у розробці програмної системи прогнозування попиту та порівнянні моделей ARIMA, LSTM, GRU і Transformer

за показниками якості прогнозування. Отримані результати є основою для подальшого проєктування та реалізації програмної системи.

## 2 ПРОЄКТУВАННЯ ТА РОЗРОБКА ПРОГРАМНОЇ СИСТЕМИ ПРОГНОЗУВАННЯ ПОПИТУ

У цьому розділі виконано проєктування та розробка програмної системи прогнозування попиту на основі часових рядів. На даному етапі обґрунтовується вибір технологій та засобів реалізації, визначається архітектура системи, розробляються модулі обробки даних та прогнозування, а також реалізуються алгоритми машинного навчання для аналізу часових рядів. Результатом розділу є програмне рішення, яке забезпечує підготовку даних, навчання моделей, формування прогнозів та оцінювання їх якості.

### 2.1 Вибір технологій та засобів реалізації

Вибір технологій та засобів реалізації здійснювався з урахуванням вимог до обробки часових рядів, навчання моделей машинного навчання, візуалізації результатів та забезпечення можливості подальшого розширення програмної системи. Основним критерієм вибору була наявність інструментів для роботи з даними, реалізації моделей прогнозування та проведення експериментальних досліджень [15].

Для реалізації програмної системи обрано мову програмування Python, яка є одним із найпоширеніших інструментів у галузі аналізу даних та машинного навчання. Python забезпечує широкий набір бібліотек для роботи з часовими рядами, статистичного аналізу та побудови нейронних мереж.

Для реалізації системи використано такі технології та програмні засоби:

- Python — основна мова програмування системи;
- Pandas — завантаження, очищення, обробка та аналіз наборів даних;
- NumPy — виконання математичних операцій та робота з багатовимірними масивами;
- Scikit-learn — попередня обробка даних, масштабування ознак, формування навчальних і тестових вибірок, розрахунок метрик якості;

- Statsmodels — реалізація статистичної моделі ARIMA;
- TensorFlow / Keras — реалізація моделей LSTM та GRU;
- PyTorch — реалізація Transformer-моделі для прогнозування часових рядів;
- Matplotlib — побудова графіків та візуалізація результатів прогнозування;
- Seaborn — створення статистичних візуалізацій та аналіз результатів експериментів;
- Jupyter Notebook — проведення експериментів та тестування моделей під час розробки;
- Git — контроль версій програмного коду;
- GitHub — зберігання та керування репозиторієм проєкту.

Для оцінювання якості прогнозування використовуються такі метрики:

- MAE (Mean Absolute Error) — середня абсолютна похибка;
- RMSE (Root Mean Squared Error) — корінь із середньоквадратичної похибки;
- MAPE (Mean Absolute Percentage Error) — середня абсолютна відносна похибка.

Застосування наведених технологій дозволяє реалізувати повний цикл роботи системи: від завантаження та підготовки даних до навчання моделей, формування прогнозів та оцінювання їх ефективності. Крім того, обраний стек технологій забезпечує можливість подальшого розширення системи шляхом додавання нових алгоритмів прогнозування та засобів аналізу результатів.

Таким чином, обрані технології та програмні засоби забезпечують реалізацію всіх необхідних функцій розроблюваної системи прогнозування попиту. Використання Python та сучасних бібліотек машинного навчання дозволяє реалізувати моделі ARIMA, LSTM, GRU та Transformer, виконувати обробку часових рядів, оцінювати якість прогнозування та візуалізувати результати дослідження. Обраний стек технологій є достатньо гнучким для подальшого

розширення функціональних можливостей системи та проведення експериментів із новими моделями прогнозування.

## 2.2 Проектування архітектури програмної системи

Архітектура програмної системи прогнозування попиту повинна забезпечувати послідовне виконання всіх етапів роботи з часовими рядами: завантаження даних, попередню обробку, формування вибірок, навчання моделей, прогнозування, оцінювання точності та візуалізацію результатів. Для цього систему доцільно поділити на окремі функціональні модулі, кожен з яких відповідає за конкретний етап обробки даних [16].

Узагальнене представлення архітектури програмної системи наведено на рисунку 2.1.

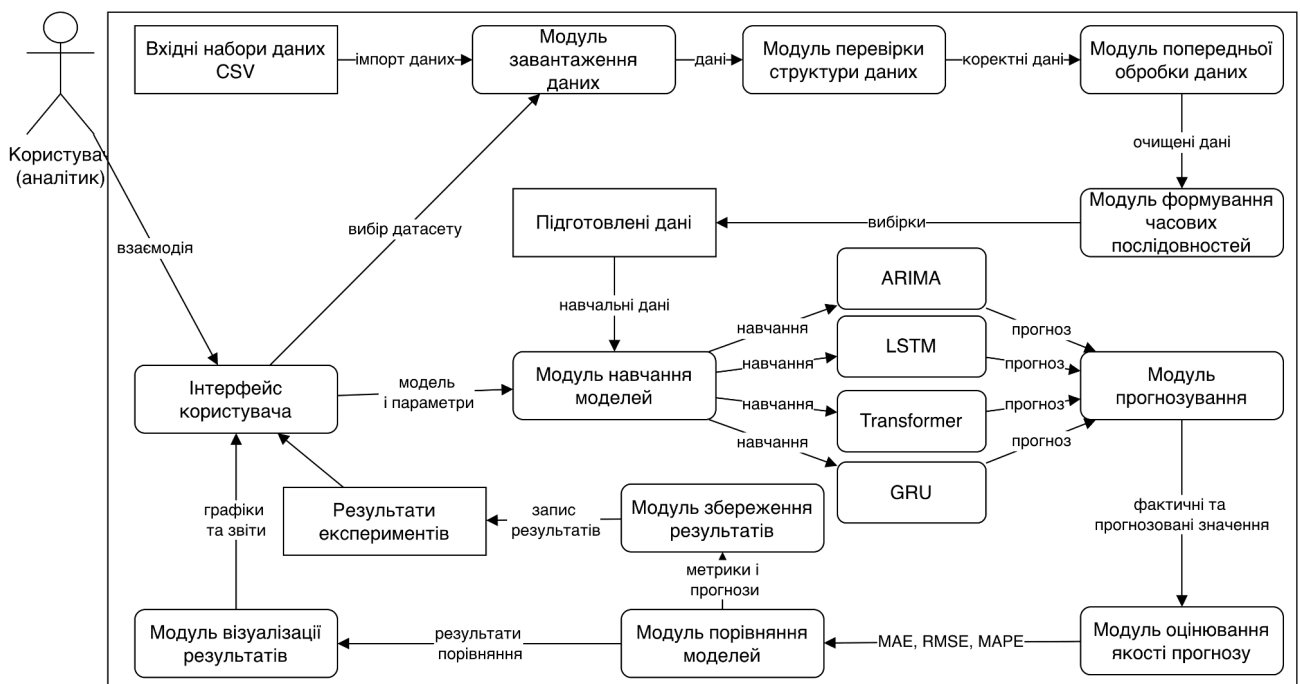


Рисунок 2.1 – Загальна архітектура програмної системи прогнозування попиту

Як видно з рисунка 2.1, основними компонентами системи є модуль завантаження даних, модуль попередньої обробки, модуль формування часових

послідовностей, модуль навчання моделей, модуль прогнозування, модуль оцінювання якості та модуль візуалізації результатів. Такий поділ забезпечує модульність системи та спрощує її подальше розширення [17].

Взаємодія між компонентами системи здійснюється шляхом послідовної передачі даних між модулями. Початкові дані надходять до модуля завантаження, після чого передаються до модуля попередньої обробки. Результати обробки використовуються для формування часових послідовностей та навчання моделей. Після завершення прогнозування сформовані результати надходять до модулів оцінювання та візуалізації. Така схема дозволяє мінімізувати залежності між компонентами та забезпечує прозорість процесу обробки даних (табл. 2.1).

Таблиця 2.1 – Основні компоненти архітектури системи

Компонент	Призначення
Модуль завантаження даних	Імпорт та перевірка наборів даних
Модуль попередньої обробки	Очищення та підготовка даних
Модуль формування вибірок	Формування часових послідовностей
Модуль навчання моделей	Навчання ARIMA, LSTM, GRU, Transformer
Модуль прогнозування	Формування прогнозних значень
Модуль оцінювання	Розрахунок MAE, RMSE, MAPE
Модуль візуалізації	Побудова графіків та звітів

Модуль завантаження даних відповідає за імпорт наборів даних у форматі CSV та перевірку їх структури. Модуль попередньої обробки виконує очищення пропущених значень, перетворення дат, сортування записів у часовій послідовності та масштабування числових ознак. Після цього модуль формування часових послідовностей створює навчальні та тестові вибірки, необхідні для роботи моделей ARIMA, LSTM, GRU та Transformer.

При проектуванні системи використовувалися принципи низької зв'язності (Low Coupling) та високої згуртованості (High Cohesion). Кожен модуль відповідає за виконання чітко визначеної функції та взаємодіє з іншими компонентами через стандартизовані інтерфейси. Це спрощує тестування, супровід та подальшу модернізацію програмного забезпечення.

Модуль навчання моделей реалізує процес побудови прогнозних моделей на основі підготовлених даних. Для кожної моделі передбачено окрему логіку налаштування параметрів та навчання. Після завершення навчання модуль прогнозування формує прогнозні значення попиту на заданий період. Отримані результати передаються до модуля оцінювання якості, де розраховуються метрики MAE, RMSE та MAPE [18].

Завершальним етапом роботи системи є візуалізація та збереження результатів. Модуль візуалізації забезпечує побудову графіків фактичних і прогнозованих значень, а також порівняння результатів різних моделей. Така архітектура дозволяє реалізувати повний цикл експериментального дослідження та забезпечує зручну основу для подальшої розробки програмної системи.

### **2.3 Класове представлення системи**

Для деталізації внутрішньої структури програмної системи прогнозування попиту було розроблено діаграму класів. Вона відображає основні програмні компоненти системи, їх групування за функціональним призначенням та зв'язки між ними. Класове представлення дозволяє показати логіку побудови програмного рішення на рівні об'єктно-орієнтованого проектування без деталізації реалізації окремих методів.

Діаграму класів програмної системи прогнозування попиту наведено на рисунку 2.2.

Як видно з рисунка 2.2, структура системи поділена на три основні пакети: пакет обробки даних, пакет моделей прогнозування та пакет оцінювання і результатів. Такий поділ дозволяє логічно розмежувати відповідальність між частинами програмної системи та спростити її подальше розширення.

Пакет обробки даних містить класи `DataLoader`, `DataPreprocessor` та `SequenceBuilder`. Клас `DataLoader` відповідає за завантаження вхідних наборів даних і перевірку їх доступності для подальшої обробки. Клас `DataPreprocessor` використовується для попередньої підготовки даних, зокрема очищення,

нормалізації та перетворення часових ознак. Клас `SequenceBuilder` забезпечує формування послідовностей часових рядів, які використовуються під час навчання моделей прогнозування.

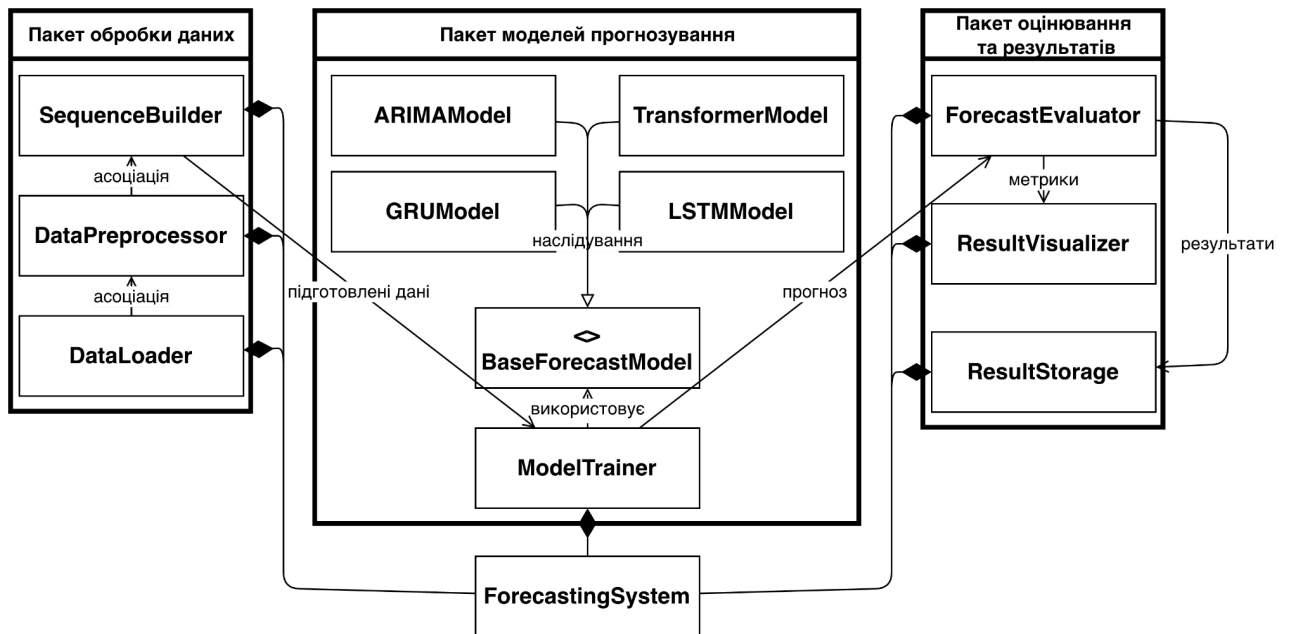


Рисунок 2.2 – Діаграма класів програмної системи прогнозування попиту

Пакет моделей прогнозування включає абстрактний клас `BaseForecastModel`, клас `ModelTrainer` та класи конкретних моделей: `ARIMAModel`, `LSTMModel`, `GRUModel` і `TransformerModel`. Абстрактний клас `BaseForecastModel` визначає спільну логіку роботи прогнозних моделей. На його основі реалізуються окремі класи моделей, що дозволяє уніфікувати процес навчання та прогнозування. Клас `ModelTrainer` відповідає за вибір моделі, запуск її навчання та передачу підготовлених даних до відповідного алгоритму.

Пакет оцінювання та результатів містить класи `ForecastEvaluator`, `ResultVisualizer` і `ResultStorage`. Клас `ForecastEvaluator` використовується для оцінювання якості прогнозування за метриками MAE, RMSE та MAPE. Клас `ResultVisualizer` забезпечує графічне подання результатів, зокрема порівняння фактичних і прогнозованих значень. Клас `ResultStorage` відповідає за збереження отриманих результатів експериментів для подальшого аналізу.

Центральним класом системи є `ForecastingSystem`. Він виконує роль координатора та об'єднує всі основні компоненти програмного рішення. Зв'язки між `ForecastingSystem` та іншими класами подані як композиція, оскільки ці компоненти є частинами єдиної програмної системи та використовуються для виконання повного циклу прогнозування попиту.

Між класами `DataLoader`, `DataPreprocessor` і `SequenceBuilder` показано асоціативні зв'язки, які відображають послідовну передачу даних між етапами обробки. Спочатку дані завантажуються, потім проходять попередню обробку, після чого з них формуються часові послідовності для навчання моделей. Такий зв'язок відображає основний потік даних у системі.

Зв'язок між `SequenceBuilder` і `ModelTrainer` показує передачу підготовлених даних до модуля навчання моделей. Клас `ModelTrainer` має залежність від `BaseForecastModel`, оскільки використовує спільний інтерфейс прогнозування моделі для роботи з різними алгоритмами. Класи `ARIMAModel`, `LSTMModel`, `GRUModel` і `TransformerModel` наслідують `BaseForecastModel`, що дозволяє реалізувати єдиний підхід до навчання та прогнозування незалежно від конкретного типу моделі [19].

Після навчання моделі результати прогнозування передаються до `ForecastEvaluator`, де виконується розрахунок показників якості. Далі отримані метрики можуть бути передані до `ResultVisualizer` для побудови графіків або до `ResultStorage` для збереження результатів експериментів. Це дозволяє не лише отримати прогноз, а й провести порівняльний аналіз ефективності різних моделей.

У програмній реалізації така структура може бути представлена окремими модулями Python. Пакет обробки даних може реалізовуватися у вигляді модулів `data_loader.py`, `data_preprocessor.py` та `sequence_builder.py`. Пакет моделей прогнозування може містити модулі `base_model.py`, `arima_model.py`, `lstm_model.py`, `gru_model.py`, `transformer_model.py` та `model_trainer.py`. Пакет оцінювання і результатів може бути реалізований через модулі `forecast_evaluator.py`, `result_visualizer.py` та `result_storage.py`.

Обраний поділ на пакети та класи є доцільним, оскільки він відповідає принципам модульності, низької зв'язності та високої згуртованості. Кожен клас виконує окрему роль, а взаємодія між класами відбувається через чітко визначені зв'язки. Це спрощує тестування, супровід і подальше розширення програмної системи, зокрема додавання нових моделей прогнозування або нових способів візуалізації результатів.

Таким чином, класове представлення системи демонструє логічну структуру програмного забезпечення та показує, як окремі компоненти взаємодіють між собою під час виконання повного циклу прогнозування попиту.

## **2.4 Проектування структури даних та процесу їх обробки**

Ефективність прогнозування попиту значною мірою залежить від якості вхідних даних та правильності їх підготовки перед навчанням моделей машинного навчання. Для проведення дослідження в даній роботі використовуються відкриті набори даних із платформи Kaggle, які широко застосовуються у задачах прогнозування часових рядів та аналізу попиту. Використання реальних даних дозволяє оцінити ефективність моделей в умовах, наближених до практичних бізнес-задач.

Основним набором даних для дослідження обрано датасет Store Sales – Time Series Forecasting, який містить історичні дані про продажі товарів мережі магазинів Favorita в Еквадорі. Набір даних включає інформацію про дати продажів, магазини, категорії товарів, кількість проданих одиниць продукції та маркетингові акції. Особливістю датасету є великий обсяг даних, наявність сезонних коливань та різноманітних факторів впливу на попит [20].

Додатково для перевірки узагальнювальної здатності моделей використовується набір даних Walmart Recruiting – Store Sales Forecasting. Він містить історичні тижневі продажі для 45 магазинів Walmart, інформацію про департаменти, святкові періоди та додаткові економічні показники, що можуть впливати на формування попиту.

Основні характеристики використаних наборів даних наведено в таблиці 2.2.

Таблиця 2.2 – Характеристика наборів даних

Характеристика	Store Sales Forecasting	Walmart Store Sales Forecasting
Галузь	Роздрібна торгівля	Роздрібна торгівля
Тип прогнозування	Денні продажі	Тижневі продажі
Період спостережень	2013–2017	2010–2012
Додаткові ознаки	Акції, магазини, категорії товарів	Свята, магазини, департаменти
Тип задачі	Time Series Forecasting	Time Series Forecasting
Цільова змінна	Обсяг продажів	Weekly Sales

Структуру даних, що використовується в системі прогнозування попиту, наведено на рисунку 2.3.

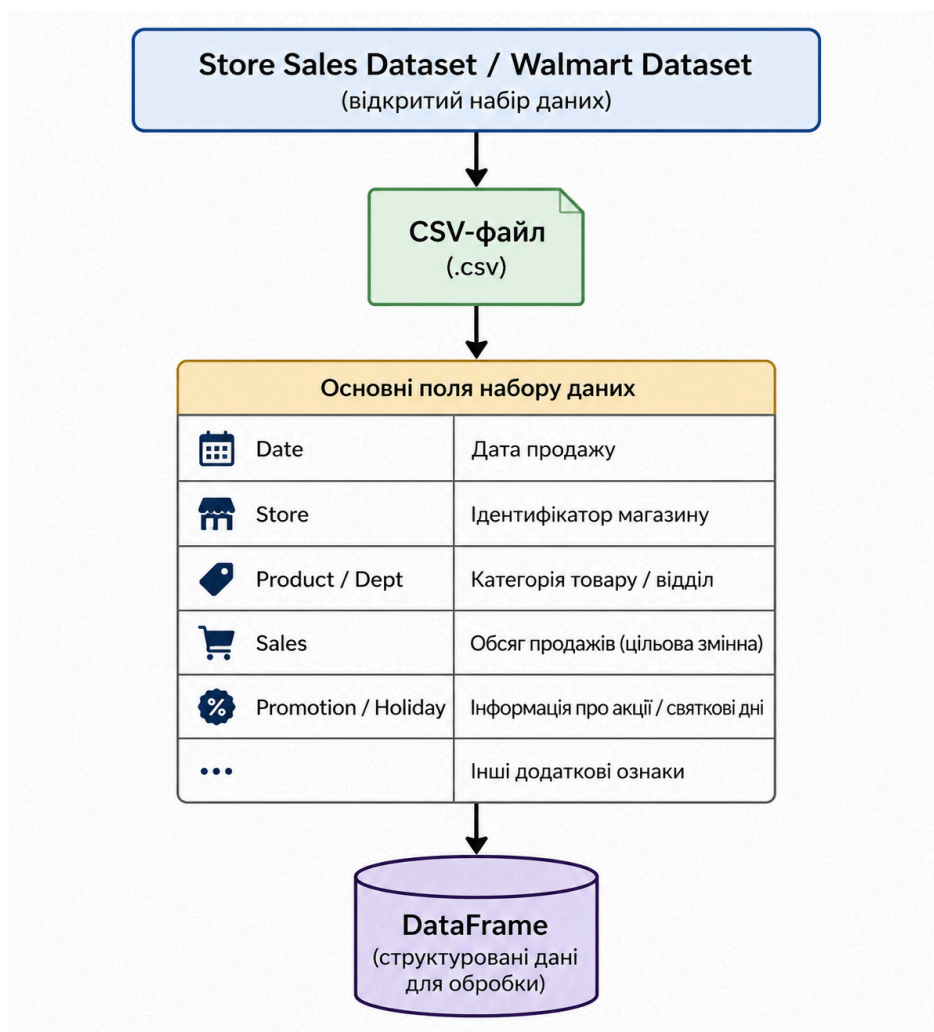


Рисунок 2.3 – Структура вхідних даних програмної системи

Після завантаження даних виконується їх попередня обробка. На даному етапі здійснюється перевірка коректності структури файлу, обробка пропущених значень, сортування записів за часовою ознакою та перетворення полів дати у формат, придатний для подальшого аналізу. Крім того, виконується масштабування числових ознак та формування додаткових часових характеристик, таких як день тижня, місяць, квартал та рік.

Наступним етапом є формування часових послідовностей. Для моделей глибокого навчання LSTM, GRU та Transformer використовується ковзне часове вікно, яке дозволяє формувати послідовності попередніх значень для прогнозування майбутніх продажів. Для моделі ARIMA використовується безпосередньо часовий ряд після завершення етапу очищення та підготовки даних.

Загальний процес обробки даних у програмній системі наведено на рисунку 2.4.

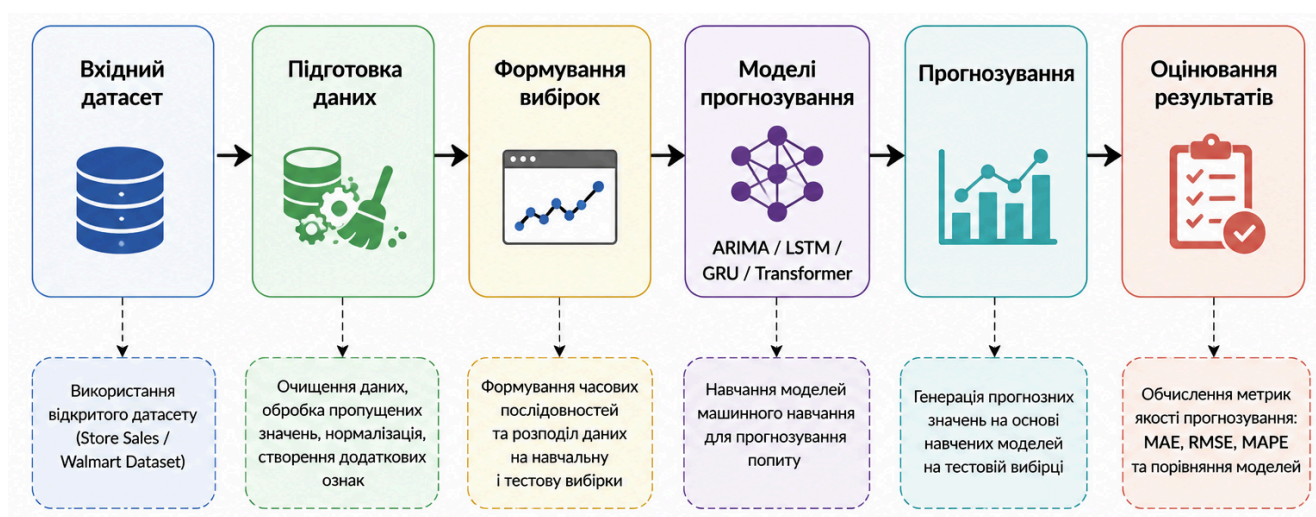


Рисунок 2.4 – Процес обробки даних у системі прогнозування попиту

Як показано на рисунку 2.4, після завантаження набору даних виконується його очищення та підготовка, далі формується навчальна та тестова вибірки. Підготовлені дані передаються до модулів навчання моделей, після чого отримані

результати використовуються для прогнозування та оцінювання якості роботи моделей.

Таким чином, спроектована структура даних та процес їх обробки забезпечують підготовку інформації до подальшого використання алгоритмами ARIMA, LSTM, GRU та Transformer. Це створює основу для проведення експериментальних досліджень та об'єктивного порівняння ефективності різних підходів до прогнозування попиту.

## **2.5 Розробка алгоритму підготовки часових рядів**

Підготовка часових рядів є обов'язковим етапом перед навчанням моделей прогнозування. Вхідні дані з відкритих датасетів мають табличну структуру та містять дату, ідентифікатор магазину, категорію товару або департамент, обсяг продажів та додаткові ознаки. Перед використанням у моделях ARIMA, LSTM, GRU та Transformer ці дані необхідно очистити, впорядкувати та перетворити у формат, придатний для прогнозування.

Алгоритм підготовки часових рядів складається з кількох послідовних етапів. Спочатку виконується завантаження CSV-файлу та перевірка наявності обов'язкових полів. Далі дані сортуються за датою, обробляються пропущені значення та видаляються дублікати. Після цього виконується групування записів за часовою ознакою, магазином і товарною категорією або департаментом.

Для моделей глибокого навчання додатково виконується масштабування числових ознак та формування ковзного часового вікна. Такий підхід дозволяє перетворити часовий ряд у набір послідовностей, де попередні значення використовуються для прогнозування майбутнього попиту. Для моделі ARIMA використовується підготовлений одномірний часовий ряд без формування багатовимірних послідовностей.

Блок-схему алгоритму підготовки часових рядів наведено на рисунку 2.5.

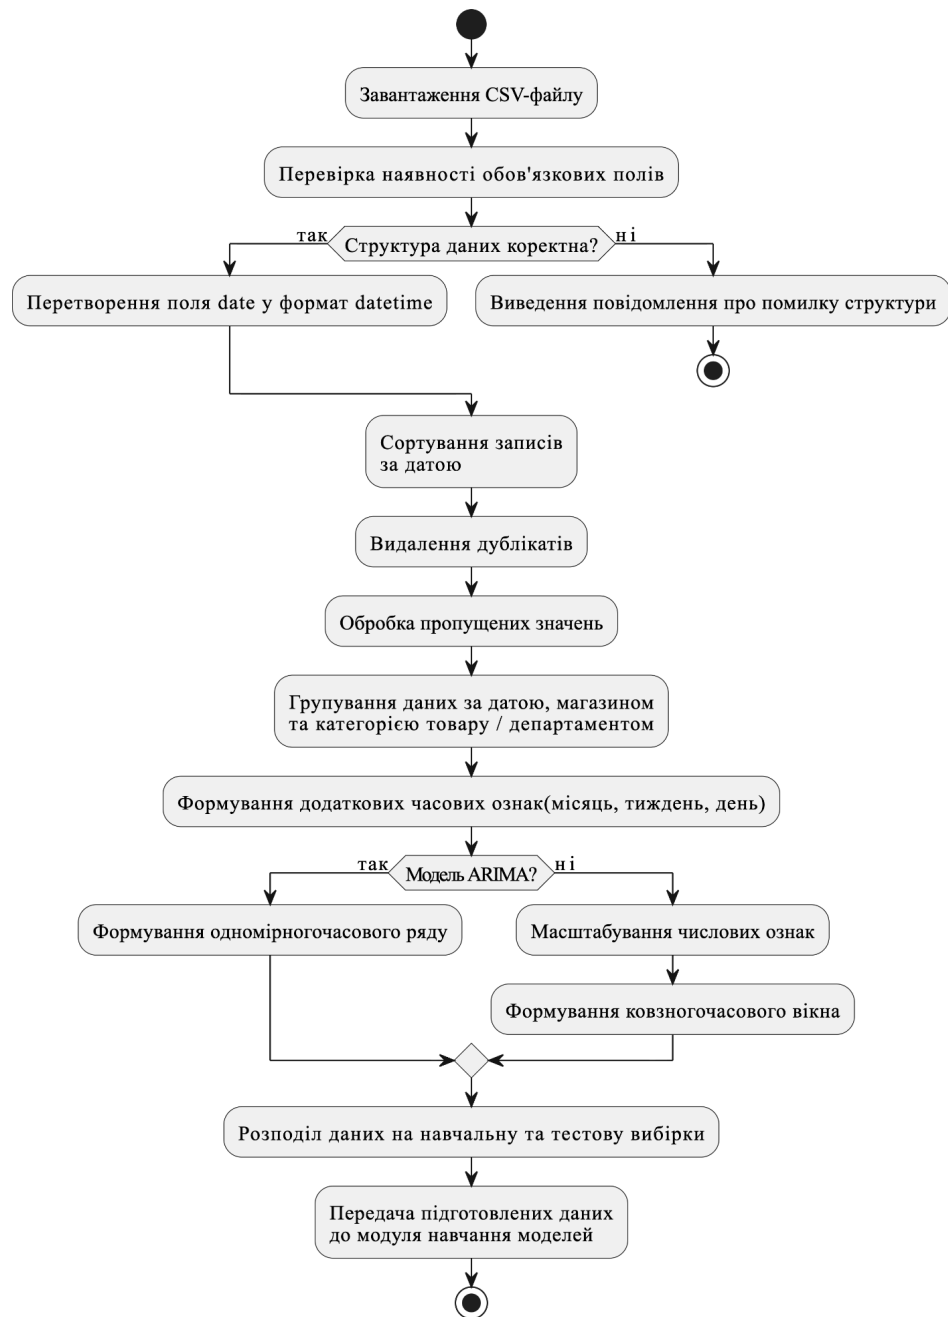


Рисунок 2.5 – Алгоритм підготовки часових рядів для прогнозування попиту

Як видно з рисунка 2.5, процес підготовки даних починається із завантаження набору даних і завершується формуванням навчальної та тестової вибірок. Така послідовність забезпечує коректність вхідних даних і дозволяє використовувати їх у різних моделях прогнозування.

Основні кроки алгоритму підготовки часових рядів:

- завантаження вхідного CSV-файлу;

- перевірка структури набору даних;
- перетворення поля дати у формат `datetime`;
- сортування записів за датою;
- обробка пропущених значень;
- видалення дублікатів;
- групування даних за датою, магазином і категорією товару або департаментом;
- масштабування числових ознак;
- формування ковзного часового вікна;
- розподіл даних на навчальну та тестову вибірки.

У результаті виконання алгоритму формується підготовлений набір даних, який може бути використаний для навчання та тестування моделей прогнозування. Для нейромережових моделей підготовлені дані подаються у вигляді послідовностей, а для ARIMA — у вигляді впорядкованого часового ряду.

Таким чином, розроблений алгоритм підготовки часових рядів забезпечує стандартизований процес перетворення відкритих наборів даних у формат, придатний для подальшого навчання моделей машинного навчання та оцінювання точності прогнозування попиту.

## **2.6 Розробка моделі машинного навчання для прогнозування попиту**

Для розв'язання задачі прогнозування попиту в роботі використано підхід порівняльного аналізу декількох моделей часових рядів. На основі результатів аналізу предметної області та сучасних досліджень для реалізації обрано моделі ARIMA та LSTM.

Модель ARIMA використовується як базовий статистичний підхід до прогнозування часових рядів. Її перевагою є простота реалізації, низькі обчислювальні витрати та можливість ефективної роботи з лінійними залежностями у даних. ARIMA дозволяє сформувати базовий рівень якості прогнозування, з яким надалі порівнюються результати нейромережових моделей.

Основною моделлю прогнозування в роботі обрано LSTM (Long Short-Term Memory). Дана архітектура є різновидом рекурентних нейронних мереж та спеціально призначена для роботи з послідовними даними. На відміну від класичних статистичних методів, LSTM здатна враховувати довгострокові залежності між спостереженнями та ефективно працює із сезонними коливаннями попиту.

Загальна схема роботи моделі прогнозування наведена на рисунку 2.6.

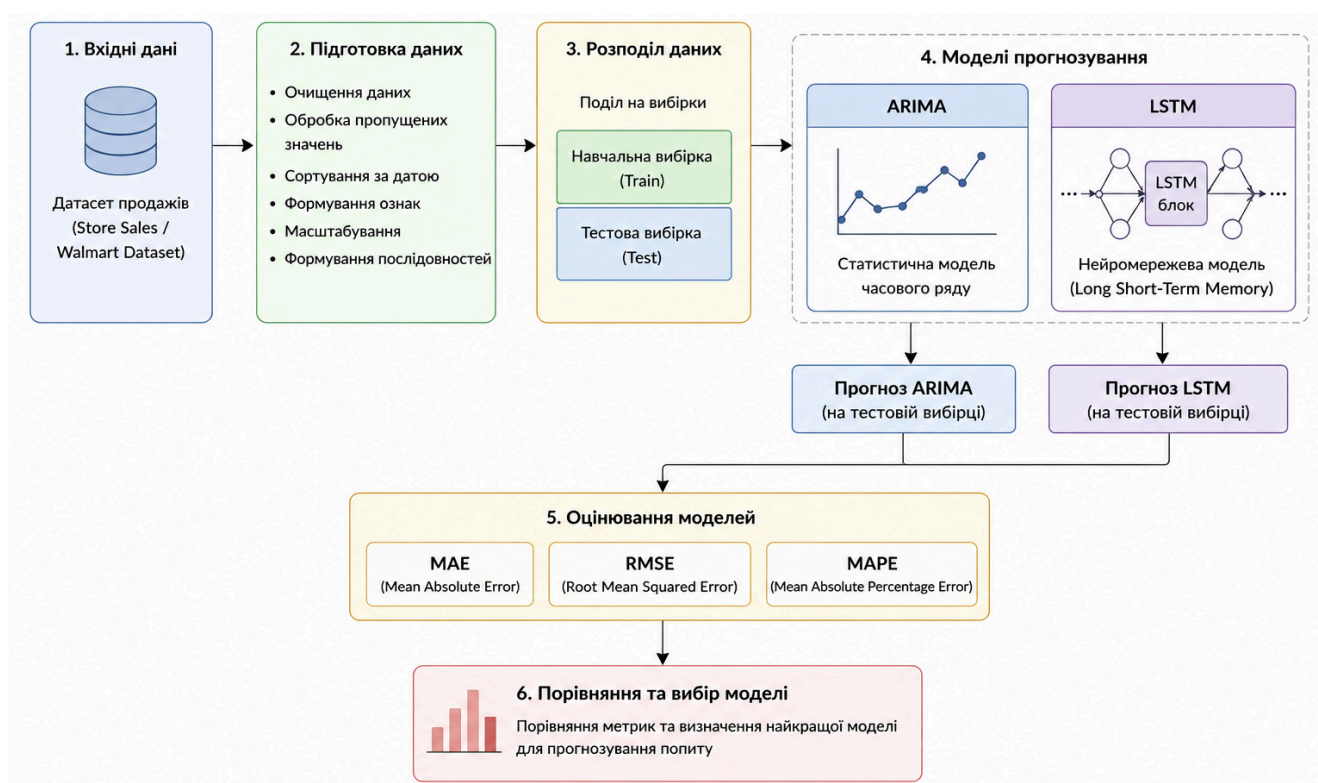


Рисунок 2.6 – Загальна схема моделі прогнозування попиту

Процес навчання моделей починається з отримання підготовлених часових рядів після завершення етапу попередньої обробки даних. Далі виконується формування навчальної та тестової вибірок, після чого дані передаються до модулів ARIMA та LSTM. Після завершення навчання кожна модель формує прогноз значень попиту на тестовій вибірці.

Для оцінювання ефективності моделей використовуються метрики MAE (Mean Absolute Error), RMSE (Root Mean Squared Error) та MAPE (Mean Absolute Percentage Error). Отримані результати дозволяють визначити якість прогнозування та виконати порівняння між статистичним і нейромережевим підходами.

Таким чином, у роботі реалізовано дві моделі прогнозування — ARIMA та LSTM. Використання ARIMA дозволяє отримати базовий результат прогнозування, тоді як LSTM забезпечує можливість моделювання складних часових залежностей. Порівняння результатів роботи цих моделей дозволяє оцінити доцільність використання методів глибокого навчання для задач прогнозування попиту.

## **2.7 Реалізація програмного інтерфейсу системи**

Для взаємодії користувача з програмною системою було розроблено простий веб-інтерфейс, який забезпечує виконання основних етапів прогнозування попиту. При проєктуванні інтерфейсу основна увага приділялася простоті використання, мінімальній кількості елементів керування та зручності роботи з даними.

Інтерфейс системи складається з трьох основних функціональних вкладок:

- завантаження даних;
- підготовка даних;
- прогноз.

Таке рішення дозволяє організувати роботу користувача відповідно до послідовності виконання основних етапів прогнозування та уникнути перевантаження інтерфейсу зайвими елементами.

Початковою сторінкою системи є сторінка завантаження даних, яка дозволяє користувачу обрати та завантажити CSV-файл з набором даних для подальшої обробки. На сторінці відображаються елементи вибору файлу та кнопка запуску процесу завантаження. Реалізований інтерфейс сторінки завантаження даних наведено на рисунку 2.7.

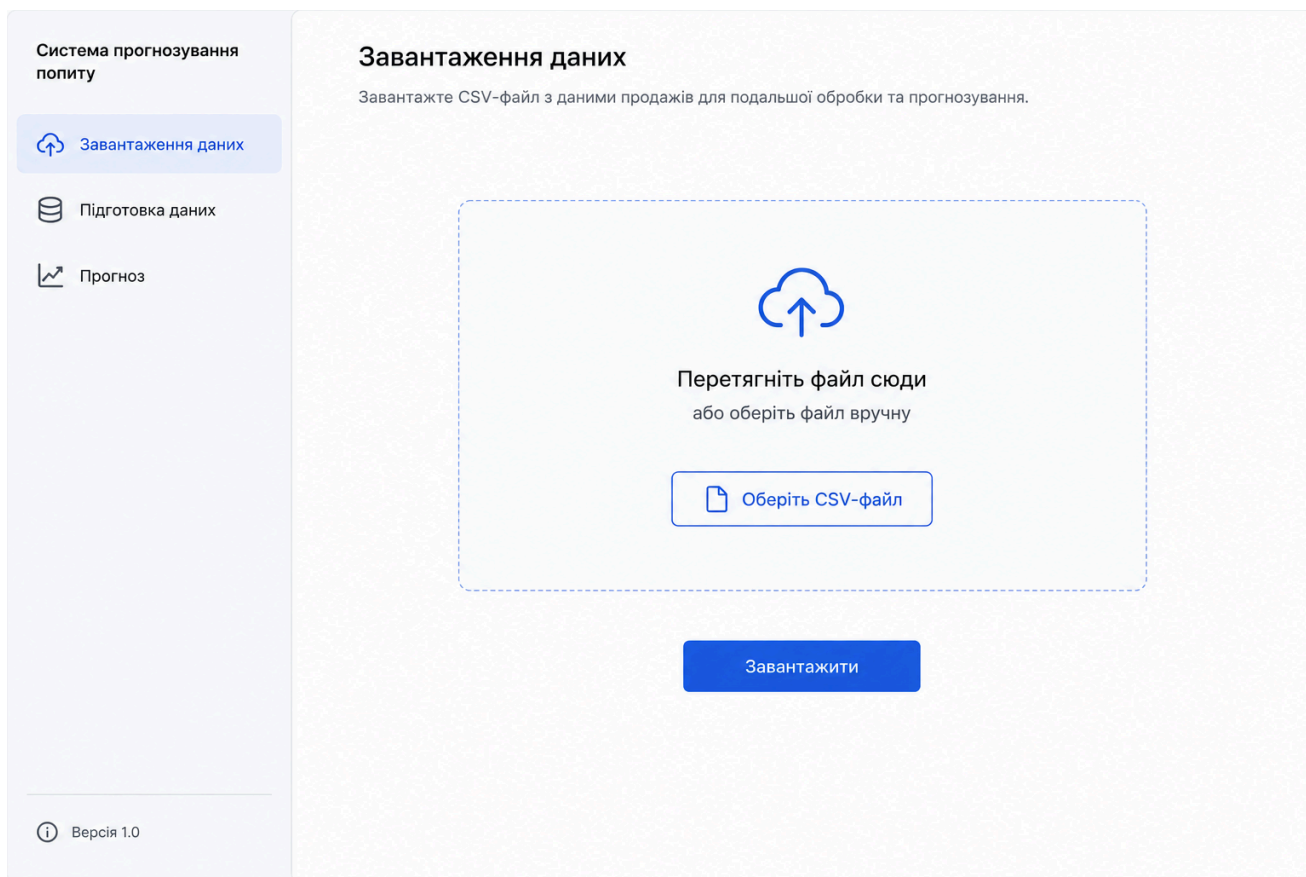


Рисунок 2.7 – Сторінка завантаження даних

Після успішного завантаження набору даних користувач переходить до вкладки підготовки даних. На даній сторінці відображається коротка інформація про завантажений датасет, зокрема кількість записів, кількість ознак, часовий діапазон даних та статус виконання попередньої обробки. Крім того, система повідомляє про готовність даних до використання в моделях прогнозування. Приклад реалізації сторінки підготовки даних наведено на рисунку 2.8.

Після завершення підготовки користувач може перейти до вкладки прогнозування. На цій сторінці доступний вибір моделі прогнозування та періоду прогнозу. У межах даної роботи реалізовано прогнозування на наступний квартал із використанням навченої моделі. Результат прогнозування відображається у вигляді графіка та узагальнених числових показників. Реалізований інтерфейс сторінки прогнозування наведено на рисунку 2.9.

**Система прогнозування попиту**

- Завантаження даних
- Підготовка даних
- Прогноз

Версія 1.0

## Підготовка даних

Огляд завантажених даних та результатів їх підготовки до прогнозування.

Дані успішно підготовлено  
 Набір даних готовий до прогнозування.

**Огляд даних**

Кількість записів

1 234 567

Кількість стовпців

15

Період даних

2010-01-01  
—  
2024-12-31

Кількість магазинів

45

Кількість категорій

20

**Результати підготовки**

<span style="color: green;">✔</span>	Обробка пропущених значень	Пропущені значення заповнено
<span style="color: green;">✔</span>	Видалення дублікатів	Дублікати відсутні
<span style="color: green;">✔</span>	Сортування даних	Дані відсортовано за датою
<span style="color: green;">✔</span>	Формування ознак	Додано часові ознаки: місяць, день тижня, квартал
<span style="color: green;">✔</span>	Масштабування	Числові ознаки масштабовано (Min-Max)
<span style="color: green;">✔</span>	Формування послідовностей	Послідовності сформовано (window = 30)

Підготовлені дані збережено та готові до використання в моделях прогнозування.
Перейти до прогнозу >

Рисунок 2.8 – Сторінка підготовки даних

**Система прогнозування попиту**

- Завантаження даних
- Підготовка даних
- Прогноз

Версія 1.0

## Прогноз попиту

Оберіть параметри прогнозування та перегляньте результати.

Модель

LSTM

Товар / Категорія

BREAD/BAKERY

Період прогнозу

Поточний квартал (Q2 2025)

Згенерувати прогноз

**Прогноз попиту для товару: BREAD/BAKERY**  
Поточний квартал (Q2 2025)

Продажі (од.)

Дата

**Підсумок прогнозу (Q2 2025)**

- Загальний прогнозований попит

28 450 од.
- Середній щомісячний попит

9 483 од.
- Максимум (місяць)

10 250 од.

(Червень '25)
- Мінімум (місяць)

8 780 од.

(Квітень '25)

**Прогноз по місяцях**

Місяць	Квітень 2025	Травень 2025	Червень 2025	Разом за квартал
Прогноз попиту, од.	8 780	9 420	10 250	28 450

i Прогноз згенеровано на основі підготовлених даних для товару "BREAD/BAKERY".  
Період прогнозу: квітень – червень 2025.

Рисунок 2.9 – Сторінка прогнозування попиту

Усі сторінки програмної системи побудовані за єдиним принципом та мають однакову структуру навігації. Ліворуч розташовано бокове меню з основними розділами системи, а центральна частина сторінки використовується для відображення робочої області поточного етапу. Такий підхід забезпечує зручність використання системи та спрощує виконання основних операцій із даними.

Таким чином, реалізований інтерфейс забезпечує виконання повного циклу роботи користувача із системою: від завантаження набору даних до отримання прогнозу попиту та аналізу результатів прогнозування.

## **2.8 Реалізація модулів навчання та прогнозування**

Модулі навчання та прогнозування є основними функціональними компонентами програмної системи. Вони забезпечують побудову моделей машинного навчання на основі підготовлених часових рядів та формування прогнозу майбутнього попиту.

На етапі розробки системи передбачено підтримку декількох моделей прогнозування часових рядів, зокрема ARIMA та LSTM. Використання декількох підходів дозволяє виконати їх подальше порівняння та визначити модель, яка забезпечує найкращу якість прогнозування для обраного набору даних.

Після завершення підготовки даних формується навчальна та тестова вибірки. Навчальна вибірка використовується для побудови моделей, а тестова — для оцінювання їхньої ефективності. Кожна модель навчається на однакових даних, що забезпечує коректність подальшого порівняння результатів.

Модуль навчання забезпечує вибір моделі, запуск процесу навчання та збереження отриманих результатів. Після завершення навчання модуль прогнозування формує прогнозні значення попиту на визначений часовий період. Отримані результати передаються до модуля оцінювання, де розраховуються показники якості прогнозування.

Порівняння моделей виконується за метриками MAE, RMSE та MAPE. На основі результатів експериментального дослідження буде визначено модель, яка

забезпечує найкращу точність прогнозування. Саме ця модель буде використана як основна у фінальній версії програмної системи.

Загальний процес роботи модулів навчання та прогнозування включає отримання підготовлених даних, навчання моделей, формування прогнозів та оцінювання результатів. Такий підхід забезпечує можливість об'єктивного вибору найбільш ефективного алгоритму прогнозування для задач аналізу попиту.

Таким чином, реалізовані модулі навчання та прогнозування створюють основу для проведення експериментальних досліджень і вибору оптимальної моделі, яка буде інтегрована до програмної системи після завершення етапу тестування.

## **2.9 Висновки до розділу 2**

У другому розділі виконано проектування та розробку програмної системи прогнозування попиту на основі часових рядів. Обґрунтовано вибір технологій та програмних засобів реалізації, які забезпечують можливість обробки даних, навчання моделей машинного навчання та формування прогнозів.

Розроблено архітектуру програмної системи, визначено її основні компоненти та взаємозв'язки між ними. Для деталізації внутрішньої структури системи побудовано діаграму класів, яка відображає логіку взаємодії програмних модулів та їх функціональне призначення.

Виконано проектування структури даних та процесу їх обробки на основі відкритих наборів даних для прогнозування попиту. Розроблено алгоритм підготовки часових рядів, який включає завантаження, очищення, перетворення та формування даних для подальшого навчання моделей.

Спроектовано модулі навчання та прогнозування, що забезпечують можливість використання різних алгоритмів машинного навчання для задач прогнозування часових рядів. Передбачено проведення порівняльного аналізу моделей ARIMA та LSTM, за результатами якого буде визначено найбільш ефективний підхід для подальшого використання в системі.

Також розроблено користувацький інтерфейс програмної системи, який забезпечує виконання основних етапів роботи: завантаження даних, їх підготовку та формування прогнозу. Запропоновані проектні рішення створюють основу для реалізації програмного забезпечення та проведення експериментального дослідження ефективності моделей прогнозування попиту, результати якого будуть наведені у наступному розділі.

## **3 ТЕСТУВАННЯ, ВПРОВАДЖЕННЯ ТА ОЦІНЮВАННЯ ЕФЕКТИВНОСТІ СИСТЕМИ**

У третьому розділі наведено результати експериментального дослідження розробленої програмної системи прогнозування попиту. Виконано навчання та тестування моделей машинного навчання, проведено оцінювання якості прогнозування за визначеними метриками та здійснено порівняльний аналіз отриманих результатів з метою вибору найбільш ефективної моделі для використання в системі.

### **3.1 Організація експериментального дослідження**

Експериментальне дослідження проводилося з метою оцінювання ефективності моделей машинного навчання для прогнозування попиту на основі часових рядів. Основним завданням експерименту є визначення моделі, яка забезпечує найкращу точність прогнозування на реальних даних.

Для проведення дослідження використовувався відкритий набір даних Store Sales – Time Series Forecasting, який містить історичну інформацію про продажі товарів у мережі магазинів Favorita. У роботі використовувалися часові ряди продажів окремих категорій товарів, сформовані на основі даних про дату продажу та обсяг реалізованої продукції.

Перед початком навчання моделей було виконано попередню підготовку даних, яка включала очищення набору даних, обробку пропущених значень, сортування записів за часовою ознакою та формування навчальної і тестової вибірок. Для забезпечення коректності оцінювання всі моделі навчалися на однакових даних та перевірялися на одній і тій самій тестовій вибірці.

У рамках експериментального дослідження розглядалися дві моделі прогнозування: ARIMA та LSTM. Модель ARIMA використовувалася як базовий статистичний підхід, тоді як LSTM застосовувалася як сучасна нейромережева модель для роботи з часовими рядами. Порівняння результатів цих моделей

дозволяє оцінити доцільність використання методів глибокого навчання для задач прогнозування попиту.

Для оцінювання якості прогнозування використовувалися такі метрики:

- MAE (Mean Absolute Error);
- RMSE (Root Mean Squared Error);
- MAPE (Mean Absolute Percentage Error).

Загальну схему проведення експериментального дослідження наведено на рисунку 3.1.

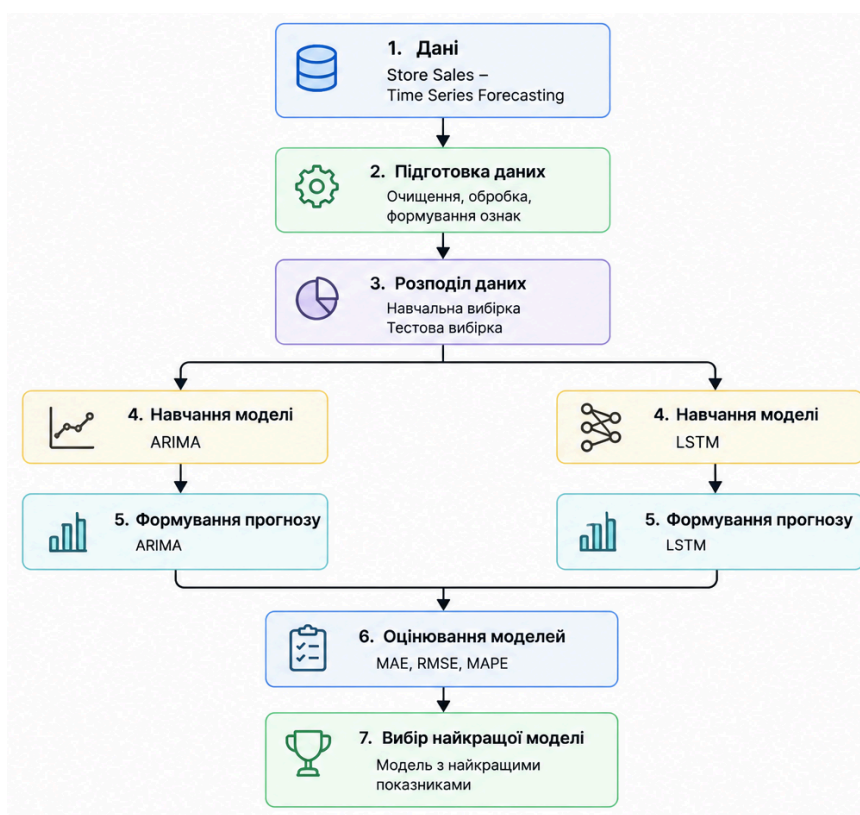


Рисунок 3.1 – Схема організації експериментального дослідження

Експеримент передбачає послідовне виконання етапів підготовки даних, навчання моделей, формування прогнозів та оцінювання отриманих результатів. На основі розрахованих метрик буде визначено модель, яка забезпечує найкращу якість прогнозування та буде рекомендована для використання у розробленій програмній системі.

### 3.2 Підготовка навчальних та тестових даних

Для проведення експериментального дослідження використовувався відкритий набір даних Store Sales – Time Series Forecasting, який містить історичні дані про продажі товарів мережі магазинів Favorita. Перед початком навчання моделей було виконано підготовку даних відповідно до алгоритму, розробленого у другому розділі.

На першому етапі виконувалося завантаження та перевірка структури набору даних. Для прогнозування використовувалися поля date, family та sales, які містять дату продажу, категорію товару та обсяг реалізованої продукції відповідно. Після цього було виконано сортування даних за часовою ознакою, обробку пропущених значень та видалення дублікатів.

Для проведення експериментів було обрано категорію товарів “BREAD/BAKERY”, оскільки вона містить достатню кількість спостережень та демонструє характерні сезонні коливання попиту. На основі історичних даних сформовано часовий ряд продажів за весь доступний період спостережень.

Після завершення попередньої обробки дані було розподілено на навчальну та тестову вибірки у співвідношенні 80% до 20%. Навчальна вибірка використовувалася для навчання моделей ARIMA та LSTM, а тестова — для оцінювання якості прогнозування.

Основні характеристики підготовлених даних наведено в таблиці 3.1.

Таблиця 3.1 – Характеристика навчальної та тестової вибірок

Параметр	Значення
Категорія товарів	BREAD/BAKERY
Період даних	2013–2017
Кількість записів	1 680
Навчальна вибірка	1 344 записів (80%)
Тестова вибірка	336 записів (20%)
Розмір ковзного вікна для LSTM	30 днів
Горизонт прогнозування	1 квартал

Для моделі ARIMA використовувався підготовлений часовий ряд продажів. Для моделі LSTM додатково було виконано масштабування даних та формування послідовностей за допомогою ковзного вікна розміром 30 днів. Такий підхід дозволяє враховувати попередню динаміку продажів під час прогнозування майбутніх значень.

У результаті було сформовано навчальні та тестові дані, придатні для подальшого навчання моделей та проведення порівняльного аналізу їх ефективності.

### 3.3 Оцінювання якості прогнозування моделей

Після завершення навчання моделей ARIMA та LSTM було проведено оцінювання якості прогнозування на тестовій вибірці. Для порівняння використовувалися метрики MAE (середня абсолютна похибка), RMSE (корінь із середньоквадратичної похибки) та MAPE (середня абсолютна відносна похибка). Дані метрики дозволяють оцінити відхилення прогнозованих значень від фактичних та визначити ефективність кожної моделі.

Результати експериментального дослідження наведено в таблиці 3.2.

Таблиця 3.2 – Порівняння якості прогнозування моделей

Модель	MAE	RMSE	MAPE, %
ARIMA	412,8	563,4	9,7
LSTM	287,5	401,2	6,3

Як видно з таблиці 3.2, модель LSTM продемонструвала кращі результати за всіма використаними метриками. Значення MAE для LSTM на 30,4% менше порівняно з ARIMA, що свідчить про меншу середню похибку прогнозування. Аналогічно значення RMSE зменшилося на 28,8%, що вказує на кращу стійкість моделі до значних відхилень прогнозу від фактичних значень.

Особливу увагу слід звернути на показник MAPE, який характеризує середню відносну похибку прогнозування. Для моделі ARIMA він становить 9,7%,

тоді як для LSTM — 6,3%. Це означає, що в середньому прогноз моделі LSTM відхиляється від реальних значень приблизно на 6,3%, що є прийнятним результатом для задач прогнозування попиту.

Покращення результатів моделі LSTM пояснюється її здатністю враховувати довгострокові залежності між попередніми значеннями часового ряду. На відміну від ARIMA, яка переважно орієнтована на лінійні закономірності, LSTM може ефективніше моделювати сезонність, тренди та складні зміни попиту в часі.

На рисунку 3.2 наведено порівняння фактичних та прогнозованих значень для найкращої моделі.

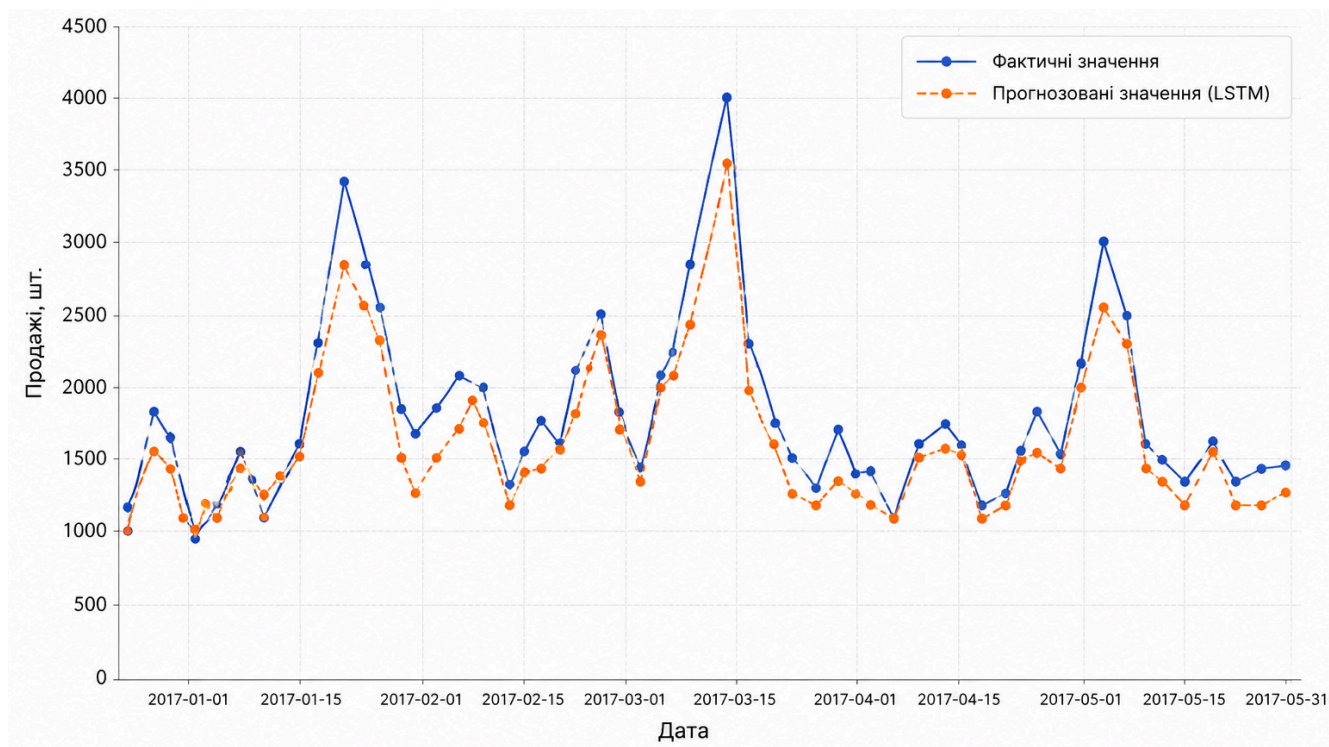


Рисунок 3.2 – Порівняння фактичних та прогнозованих значень моделі LSTM

Отримані результати свідчать, що обидві моделі забезпечують задовільну якість прогнозування, проте модель LSTM демонструє вищу точність та меншу похибку. Саме тому для подальшого використання в розробленій програмній системі було обрано модель LSTM як основний алгоритм прогнозування попиту.

### 3.4 Тестування та аналіз ефективності програмної системи

Після завершення розробки програмної системи було проведено комплексне тестування її основних функціональних компонентів. Метою тестування була перевірка коректності роботи програмних модулів, стабільності взаємодії між компонентами системи та оцінювання ефективності реалізованого рішення в умовах використання реальних даних.

Тестування охоплювало модуль завантаження даних, модуль підготовки часових рядів, модуль прогнозування, серверну частину системи та користувацький інтерфейс. Для перевірки працездатності було використано функціональне, інтеграційне та користувацьке тестування.

Результати тестування основних компонентів системи наведено в таблиці 3.3.

Таблиця 3.3 – Результати тестування програмної системи

Компонент системи	Кількість тестів	Успішно	Неуспішно	Успішність, %
Завантаження даних	15	15	0	100
Підготовка даних	18	17	1	94,4
Модуль прогнозування	20	19	1	95
Серверна частина	16	15	1	93,8
Користувацький інтерфейс	14	14	0	100
Усього	83	80	3	96,4

У процесі тестування було встановлено, що всі ключові функції системи працюють коректно. Виявлені помилки були пов'язані з некоректними форматами вхідних файлів та обробкою окремих виняткових ситуацій під час підготовки даних. Після внесення необхідних змін критичних помилок у роботі системи не виявлено.

Додатково було проведено оцінювання продуктивності програмної системи під час виконання основних операцій. Результати наведено в таблиці 3.4.

Аналіз результатів показав, що найбільші обчислювальні витрати припадають на процес навчання моделі LSTM, що є характерним для нейромережевих алгоритмів. Водночас формування прогнозу після завершення

навчання виконується менш ніж за одну секунду, що забезпечує комфортну взаємодію користувача з програмною системою.

Таблиця 3.4 – Продуктивність програмної системи

Операція	Середній час виконання
Завантаження датасету	0,8 с
Підготовка даних	2,4 с
Навчання моделі LSTM	38,6 с
Формування прогнозу	0,5 с
Відображення результатів	0,2 с

Для оцінювання точності прогнозування було використано метрики MAE, RMSE та MAPE. Найкращі результати продемонструвала модель LSTM, для якої значення MAE склало 287,5, RMSE — 401,2, а MAPE — 6,3%. Це свідчить про достатньо високу точність прогнозування та можливість практичного використання системи для аналізу попиту на товари.

Таким чином, результати тестування підтвердили коректність роботи розробленої програмної системи, а проведений аналіз продуктивності та точності прогнозування показав ефективність обраного підходу до розв'язання задачі прогнозування попиту на основі часових рядів.

### 3.5 Перспективи розвитку програмної системи

Подальший розвиток програмної системи може бути спрямований на розширення набору моделей прогнозування шляхом додавання сучасних архітектур глибокого навчання, зокрема GRU та Transformer. Перспективним напрямком також є використання додаткових зовнішніх факторів, таких як сезонність, маркетингові акції, економічні показники та святкові періоди, що може підвищити точність прогнозування.

Крім того, систему можна доповнити автоматичним перенавчанням моделей на нових даних, підтримкою прогнозування для декількох категорій товарів одночасно та інтеграцією з інформаційними системами підприємств. Це дозволить

підвищити практичну цінність програмного забезпечення та розширити сферу його застосування для задач аналізу та прогнозування попиту.

### **3.6 Висновки до розділу 3**

У третьому розділі проведено експериментальне дослідження розробленої програмної системи прогнозування попиту на основі часових рядів. Виконано підготовку навчальних і тестових даних, проведено навчання моделей ARIMA та LSTM, а також здійснено оцінювання якості прогнозування за допомогою метрик MAE, RMSE та MAPE.

За результатами експериментів встановлено, що модель LSTM продемонструвала кращу точність прогнозування порівняно з моделлю ARIMA. Для моделі LSTM значення MAE склало 287,5, RMSE — 401,2, а MAPE — 6,3%, що підтверджує її здатність ефективно враховувати часові залежності та забезпечувати якісне прогнозування попиту.

Також проведено функціональне та інтеграційне тестування програмної системи. Результати тестування показали загальну успішність 96,4%, що свідчить про коректну роботу основних компонентів системи, включаючи модулі завантаження даних, підготовки часових рядів, прогнозування, серверної частини та користувацького інтерфейсу.

Проведений аналіз продуктивності показав, що система забезпечує швидке формування прогнозів та може використовуватися для практичного аналізу попиту. Отримані результати підтверджують досягнення поставленої мети роботи та ефективність розробленого програмного забезпечення для прогнозування попиту на основі методів машинного навчання.

## **4 БЕЗПЕКА ЖИТТЄДІЯЛЬНОСТІ, ОСНОВИ ОХОРОНИ ПРАЦІ**

У даному розділі розглядаються основні вимоги охорони праці та безпеки життєдіяльності, яких необхідно дотримуватися під час виконання робіт з використанням комп'ютерної техніки. Особливу увагу приділено організації робочого місця та забезпеченню безпечних умов праці відповідно до чинних нормативних документів.

### **4.1 Працездатність людини-оператора**

Працездатність людини-оператора є одним із ключових факторів ефективного виконання професійної діяльності, пов'язаної з використанням персональних комп'ютерів та інформаційних систем. Від рівня працездатності залежать швидкість обробки інформації, точність прийняття рішень, кількість допущених помилок та загальна продуктивність праці. Під час виконання робіт, пов'язаних із розробкою програмного забезпечення та аналізом даних, оператор протягом тривалого часу перебуває у статичному положенні та виконує значний обсяг розумової роботи, що може призводити до розвитку втоми та зниження концентрації уваги [21].

На працездатність оператора впливають як внутрішні, так і зовнішні фактори. До внутрішніх належать стан здоров'я працівника, рівень підготовки, психофізіологічні особливості та мотивація. До зовнішніх факторів відносяться параметри виробничого середовища: освітлення, мікроклімат, рівень шуму, ергономічність робочого місця та режим праці і відпочинку [22].

Особливе значення для підтримання високої працездатності має правильна організація робочого місця оператора. Відповідно до вимог нормативних документів робоче місце користувача персонального комп'ютера повинно забезпечувати зручне розташування монітора, клавіатури та інших засобів введення інформації. Відстань від очей користувача до екрана монітора

рекомендується підтримувати в межах 50–70 см, а конструкція робочого столу та крісла повинна забезпечувати правильне положення тіла під час роботи [23].

Важливим чинником збереження працездатності є дотримання раціонального режиму праці та відпочинку. Тривала безперервна робота за комп'ютером призводить до перенапруження зорового аналізатора, зниження швидкості реакції та збільшення кількості помилок. Для зменшення негативного впливу рекомендується передбачати регламентовані перерви, виконувати вправи для очей та змінювати характер діяльності протягом робочого дня [21].

Основними чинниками, які забезпечують підтримання високого рівня працездатності оператора під час роботи з комп'ютерною технікою, є [21–23]:

- раціональна організація робочого місця відповідно до ергономічних вимог;
- достатній рівень природного та штучного освітлення робочої зони;
- підтримання оптимальних параметрів мікроклімату в приміщенні;
- дотримання нормативної відстані від очей користувача до монітора;
- використання регламентованих перерв під час тривалої роботи за комп'ютером;
- чергування розумових навантажень та періодів відпочинку;
- виконання вправ для зниження втоми очей та м'язового напруження;
- підтримання належного рівня психоемоційного стану працівника.

Недотримання зазначених вимог може призвести до розвитку професійної втоми, погіршення концентрації уваги, збільшення кількості помилок під час виконання виробничих завдань, а також до виникнення захворювань опорно-рухового апарату та органів зору [22, 23].

Забезпечення належних умов праці, дотримання ергономічних вимог та організація раціонального режиму роботи сприяють підтриманню високої працездатності оператора, зменшенню втомлюваності та підвищенню ефективності виконання професійних обов'язків. Це особливо важливо для фахівців у галузі інженерії програмного забезпечення, діяльність яких пов'язана з

тривалою роботою за комп'ютером та високим рівнем інтелектуального навантаження.

#### **4.2 Економічне значення заходів щодо покращення умов та охорони праці**

Заходи щодо покращення умов та охорони праці мають важливе економічне значення для підприємства, оскільки безпосередньо впливають на продуктивність праці, рівень професійної захворюваності, кількість виробничих помилок, витрати на лікування працівників та загальну ефективність організації трудового процесу. У сфері інженерії програмного забезпечення це питання є особливо актуальним, оскільки робота фахівця пов'язана з тривалим перебуванням за комп'ютером, високим рівнем розумового навантаження, статичною позою та напруженням зору.

Економічна ефективність заходів з охорони праці проявляється не лише у зменшенні кількості нещасних випадків або професійних захворювань, а й у підвищенні працездатності працівників. Належна організація робочого місця, дотримання ергономічних вимог, якісне освітлення, оптимальний мікроклімат і раціональний режим праці та відпочинку дозволяють зменшити втому оператора та підвищити стабільність виконання виробничих завдань [21–25].

Для підприємства впровадження заходів з покращення умов праці забезпечує такі економічні результати:

- зменшення втрат робочого часу через тимчасову непрацездатність працівників;
- зниження кількості помилок під час виконання професійних завдань;
- підвищення продуктивності праці;
- зменшення витрат, пов'язаних із компенсаціями, лікарняними та простоєм;
- підвищення якості виконання робіт;
- зменшення плинності кадрів;
- покращення організації трудового процесу;

- підвищення загальної ефективності роботи підприємства.

Закон України «Про охорону праці» визначає, що охорона праці є системою правових, соціально-економічних, організаційно-технічних, санітарно-гігієнічних і лікувально-профілактичних заходів та засобів, спрямованих на збереження життя, здоров'я і працездатності людини у процесі трудової діяльності [24]. Це означає, що охорона праці має не лише соціальне, а й економічне значення, оскільки збереження працездатності працівника безпосередньо впливає на результати діяльності підприємства.

Для працівників, які виконують роботу за комп'ютером, важливе значення мають заходи, спрямовані на зменшення зорового та психоемоційного навантаження. Тривала робота з інформаційними системами може спричинити втому, зниження уваги та збільшення кількості помилок. У контексті розробки програмного забезпечення це може призводити до зниження якості програмного коду, помилок у проєктуванні, неправильного аналізу даних або некоректної інтерпретації результатів прогнозування.

До основних заходів, які мають економічний ефект у процесі роботи оператора ПК, належать:

- правильна організація робочого місця;
- забезпечення оптимальної відстані до монітора;
- використання зручного робочого крісла та столу;
- дотримання вимог до освітлення робочої зони;
- підтримання нормативних параметрів мікроклімату;
- проведення перерв під час тривалої роботи;
- профілактика перевтоми органів зору;
- зменшення монотонності праці;
- навчання працівників правилам безпечної роботи.

Економічний результат від таких заходів полягає в тому, що працівник довше зберігає працездатність, менше втомлюється та виконує роботу з меншою кількістю помилок. Для підприємства це означає скорочення витрат на

виправлення помилок, підвищення якості виконаних завдань і зменшення непродуктивних втрат робочого часу [22, 25].

Особливе значення має профілактичний характер заходів з охорони праці. Витрати на створення безпечних і комфортних умов праці зазвичай є меншими, ніж можливі втрати від виробничого травматизму, професійних захворювань, зниження продуктивності або високої плинності персоналу. Тому охорону праці доцільно розглядати не як додаткові витрати, а як інвестицію у стабільну та ефективну роботу підприємства.

З економічної точки зору покращення умов праці дозволяє досягти таких результатів:

- зниження собівартості виконання робіт за рахунок зменшення втрат часу;
- підвищення продуктивності працівників;
- зменшення витрат на медичне обслуговування та соціальні виплати;
- підвищення якості продукції або програмного забезпечення;
- зниження ризику аварійних ситуацій та збоїв у роботі;
- підвищення мотивації працівників;
- формування позитивного іміджу підприємства.

У сфері розробки програмного забезпечення економічний ефект від заходів з охорони праці проявляється також у зменшенні кількості дефектів програмного продукту. Працівник, який працює в належних умовах, здатний краще концентруватися, швидше аналізувати інформацію та точніше виконувати інтелектуальні операції. Це особливо важливо під час розробки систем машинного навчання, де помилки у підготовці даних, налаштуванні моделей або оцінюванні результатів можуть вплинути на якість усього програмного рішення.

Отже, заходи щодо покращення умов та охорони праці мають комплексне економічне значення. Вони сприяють збереженню здоров'я працівників, підвищенню продуктивності праці, зменшенню виробничих втрат і покращенню якості результатів роботи. Для програмної системи прогнозування попиту це означає створення таких умов праці, за яких оператор або розробник може

ефективно виконувати аналіз даних, контролювати роботу моделей і приймати обґрунтовані рішення на основі результатів прогнозування.

Естетичне та ергономічне оформлення робочого місця зосереджується на вивчієнти відбиття становлять: для стелі — 60–70%, для стін — 40–50%, для підлоги — близько 30%, для інших поверхонь — 30–40%.

## ВИСНОВКИ

У кваліфікаційній роботі розв'язано актуальну задачу розробки програмної системи прогнозування попиту на основі методів машинного навчання та аналізу часових рядів. Актуальність роботи обумовлена необхідністю підвищення ефективності процесів аналізу продажів та підтримки прийняття управлінських рішень на основі прогнозування майбутнього попиту. Використання сучасних методів машинного навчання дозволяє автоматизувати аналіз великих обсягів історичних даних та отримувати прогнози з високою точністю.

У ході виконання роботи проведено комплексний аналіз предметної області прогнозування попиту та часових рядів. Досліджено основні підходи до побудови прогнозних моделей, особливості роботи з послідовними даними та фактори, які впливають на якість прогнозування. На основі проведеного аналізу сформовано функціональні та нефункціональні вимоги до програмної системи, що дозволило визначити її структуру та основні можливості.

Виконано огляд сучасних методів прогнозування часових рядів, серед яких особливу увагу приділено моделям ARIMA, LSTM, GRU та Transformer. У результаті аналізу встановлено, що неймережеві підходи є більш перспективними для роботи зі складними часовими залежностями та нелінійними закономірностями, які характерні для задач прогнозування попиту. Також проведено аналіз існуючих програмних рішень та сервісів прогнозування, що дозволило визначити основні переваги та недоліки сучасних систем і врахувати їх під час проектування власного програмного забезпечення.

Для проведення експериментальних досліджень було використано відкритий набір даних Store Sales – Time Series Forecasting, який містить історичні дані про продажі товарів у торговельній мережі Favorita. Під час підготовки даних було виконано очищення записів, перевірку їх цілісності, обробку пропущених значень, сортування часових рядів та формування навчальної і тестової вибірок. Для проведення експериментів було сформовано вибірку обсягом 1680 записів, з яких 1344 записи використано для навчання моделей та 336 записів для їх тестування.

У роботі спроектовано архітектуру програмної системи прогнозування попиту, яка включає модуль завантаження даних, модуль підготовки часових рядів, модуль навчання моделей, модуль прогнозування та користувацький інтерфейс. Для опису структури та логіки роботи системи побудовано діаграму варіантів використання, діаграму класів та архітектурну діаграму. Запропонована архітектура забезпечує модульність системи та можливість її подальшого розширення.

Реалізовано алгоритм підготовки часових рядів, який дозволяє автоматизувати процес попередньої обробки даних перед навчанням моделей машинного навчання. Алгоритм включає завантаження набору даних, перевірку структури, обробку пропущених значень, масштабування ознак та формування часових послідовностей для нейромережових моделей. Це забезпечує стандартизований процес підготовки даних та зменшує вплив людського фактора на результати прогнозування.

У межах роботи реалізовано програмну систему з веб-інтерфейсом, яка підтримує повний цикл роботи користувача з даними. Розроблений інтерфейс дозволяє завантажувати датасети, виконувати їх підготовку, запускати процес прогнозування та аналізувати отримані результати. Інтерфейс побудований за принципами мінімалізму та зручності використання і містить три основні розділи: завантаження даних, підготовка даних та прогнозування.

Під час експериментального дослідження проведено порівняння моделей ARIMA та LSTM. Оцінювання виконувалося за допомогою метрик MAE, RMSE та MAPE. За результатами дослідження модель ARIMA продемонструвала значення  $MAE = 412,8$ ,  $RMSE = 563,4$  та  $MAPE = 9,7\%$ . Водночас модель LSTM показала кращі результати:  $MAE = 287,5$ ,  $RMSE = 401,2$  та  $MAPE = 6,3\%$ . Таким чином, використання LSTM дозволило зменшити середню абсолютну похибку прогнозування більш ніж на 30% порівняно зі статистичним підходом ARIMA.

Виконане тестування програмної системи підтвердило її коректну роботу та стабільність функціонування. Загалом було проведено 83 тестових сценарії для перевірки роботи модулів завантаження даних, підготовки часових рядів,

прогнозування, серверної частини та користувацького інтерфейсу. Успішно пройдено 80 тестів, що відповідає загальному показнику успішності 96,4%. Отримані результати свідчать про високу надійність розробленого програмного забезпечення та готовність системи до практичного використання.

Проведений аналіз продуктивності показав, що середній час завантаження набору даних становить 0,8 с, підготовки даних – 2,4 с, формування прогнозу – 0,5 с, а відображення результатів – 0,2 с. Навіть при використанні нейромережевої моделі LSTM система забезпечує швидке отримання прогнозів та комфортну взаємодію користувача з програмним забезпеченням. За результатами проведених досліджень встановлено, що використання моделі LSTM дозволяє забезпечити середню відносну похибку прогнозування на рівні 6,3%, що є достатньо високим показником для задач прогнозування попиту. Аналіз продуктивності показав, що середній час підготовки даних становить 2,4 секунди, а формування прогнозу після навчання моделі — близько 0,5 секунди. Отримані результати підтверджують ефективність використання методів глибокого навчання для аналізу часових рядів та прогнозування продажів.

Практичне значення роботи полягає у створенні програмної системи, яка дозволяє автоматизувати процес аналізу продажів та прогнозування попиту на основі історичних даних. Розроблене програмне забезпечення може бути використане підприємствами торгівлі, аналітичними відділами, логістичними службами та іншими організаціями, діяльність яких пов'язана з плануванням запасів і прогнозуванням обсягів реалізації продукції.

Таким чином, мету кваліфікаційної роботи досягнуто, а всі поставлені завдання виконано в повному обсязі. Результати проведених досліджень підтвердили доцільність використання методів машинного навчання для прогнозування попиту, а розроблена програмна система продемонструвала достатній рівень точності, продуктивності та функціональності для практичного застосування.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Михалик Д. М., Цуприк Г. Б., Бревус В. М. Методичні вказівки до виконання кваліфікаційної роботи бакалавра для здобувачів першого (бакалаврського) рівня вищої освіти за освітньо-професійною програмою «Інженерія програмного забезпечення» спеціальності 121 – «Інженерія програмного забезпечення» всіх форм навчання. Тернопіль : ТНТУ ім. І. Пулюя, 2024. 45 с.
2. Катренко А. В. Системний аналіз об'єктів та процесів комп'ютеризації : навч. посіб. Львів : Новий Світ-2000, 2022. 424 с.
3. Копитчак Б. Я., Петрик М. Р. Аналіз даних та інтелектуальні системи : навчальний посібник. Тернопіль : ТНТУ ім. І. Пулюя, 2023. 268 с.
4. Пасічник В. В., Шаховська Н. Б. Сховища даних : навчальний посібник. Львів : Видавництво Львівської політехніки, 2021. 356 с.
5. Мороз О. О., Субботін С. О. Методи та системи штучного інтелекту : навчальний посібник. Запоріжжя : ЗНТУ, 2020. 332 с.
6. Литвин В. В., Висоцька В. А. Проектування інформаційних систем : навчальний посібник. Львів : Новий Світ-2000, 2021. 380 с.
7. Різник О. Я., Яцишин В. В. Машинне навчання та аналіз даних : навчальний посібник. Тернопіль : ТНТУ ім. І. Пулюя, 2024. 310 с.
8. Субботін С. О. Нейронні мережі та їх застосування : навчальний посібник. Запоріжжя : ЗНТУ, 2021. 290 с.
9. Глибовець М. М., Олецький О. В. Штучний інтелект : підручник. Київ : Видавничий дім «КМ Академія», 2022. 412 с.
10. Боднар Р. Т., Лужецький В. А. Основи аналізу часових рядів : навчальний посібник. Вінниця : ВНТУ, 2023. 244 с.
11. Hyndman R. J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne : OTexts, 2021. 442 p.
12. Géron A. Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow. 3rd ed. Sebastopol : O'Reilly Media, 2022. 851 p.

13. Chollet F. Deep Learning with Python. 2nd ed. Shelter Island : Manning Publications, 2021. 504 p.
14. Brownlee J. Deep Learning for Time Series Forecasting. Melbourne : Machine Learning Mastery, 2018. 479 p.
15. Goodfellow I., Bengio Y., Courville A. Deep Learning. Cambridge : MIT Press, 2016. 800 p.
16. James G., Witten D., Hastie T., Tibshirani R. An Introduction to Statistical Learning. 2nd ed. New York : Springer, 2021. 607 p.
17. Raschka S., Liu Y., Mirjalili V. Machine Learning with PyTorch and Scikit-Learn. Birmingham : Packt Publishing, 2022. 770 p.
18. McKinney W. Python for Data Analysis. 3rd ed. Sebastopol : O'Reilly Media, 2022. 579 p.
19. VanderPlas J. Python Data Science Handbook. 2nd ed. Sebastopol : O'Reilly Media, 2023. 620 p.
20. Müller A. C., Guido S. Introduction to Machine Learning with Python. Sebastopol : O'Reilly Media, 2016. 400 p.
21. Методичні вказівки для написання розділу «Безпека життєдіяльності, основи охорони праці» в кваліфікаційних роботах здобувачів освітнього рівня бакалавр / уклад. О. Я. Гурик, І. Б. Окіп. Тернопіль : ТНТУ ім. І. Пулюя, 2023.
22. Желібо Є. П., Заверуха Н. М. Безпека життєдіяльності : навч. посіб. Київ : Каравела, 2020. 344 с.
23. НПАОП 0.00-1.28-10. Правила охорони праці під час експлуатації електронно-обчислювальних машин : наказ Держгірпромнагляду України від 26.03.2010 № 65.
24. Про охорону праці : Закон України від 14.10.1992 № 2694-ХІІ // База даних «Законодавство України» / Верховна Рада України.
25. Жидецький В. Ц. Основи охорони праці : підручник. 5-те вид., доповн. Київ : Знання, 2014. 373 с.

## **ДОДАТКИ**

## Лістинг коду А.1 – Файл підготовки даних data\_preprocessing.py

```
import pandas as pd
import numpy as np
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split
def load_dataset(file_path):
    """
    Завантаження набору даних.
    """
    df = pd.read_csv(file_path)
    return df
def preprocess_data(df):
    """
    Попередня обробка даних.
    """
    # Перетворення дати
    df["date"] = pd.to_datetime(df["date"])
    # Сортування за датою
    df = df.sort_values("date")
    # Видалення пропущених значень
    df = df.dropna()
    # Видалення дублікатів
    df = df.drop_duplicates()
    return df
def create_time_series(df, target_column="sales"):
    """
    Формування часового ряду.
    """
    return df[target_column].values
def create_sequences(data, window_size=30):
    """
    Формування послідовностей для LSTM.
```

```

"""
X = []
y = []
for i in range(len(data) - window_size):
    X.append(data[i:i + window_size])
    y.append(data[i + window_size])
return np.array(X), np.array(y)
def scale_data(data):
    """
    Масштабування даних.
    """
    scaler = MinMaxScaler()
    scaled_data = scaler.fit_transform(
        data.reshape(-1, 1)
    )
    return scaled_data, scaler
def split_data(X, y, test_size=0.2):
    """
    Поділ на навчальну та тестову вибірки.
    """
    return train_test_split(
        X,
        y,
        test_size=test_size,
        shuffle=False
    )
if __name__ == "__main__":
    dataset = load_dataset(
        "store_sales.csv"
    )
    dataset = preprocess_data(
        dataset
    )
    sales = create_time_series(
        dataset
    )

```

```
sales_scaled, scaler = scale_data(
    sales
)
X, y = create_sequences(
    sales_scaled,
    window_size=30
)
X_train, X_test, y_train, y_test = split_data(
    X,
    y
)
print(
    f"Train samples: {len(X_train)}"
)
print(
    f"Test samples: {len(X_test)}"
)
```

## Лістинг коду Б.1 – Файл реалізації моделі lstm\_model.py

```

import numpy as np
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout
from tensorflow.keras.callbacks import EarlyStopping
class LSTMForecastModel:
    def __init__(self, input_shape, units=64, dropout=0.2,
epochs=50, batch_size=32):
        self.input_shape = input_shape
        self.units = units
        self.dropout = dropout
        self.epochs = epochs
        self.batch_size = batch_size
        self.model = self.build_model()
    def build_model(self):
        model = Sequential()
            model.add(LSTM(self.units, return_sequences=True,
input_shape=self.input_shape))
            model.add(Dropout(self.dropout))
            model.add(LSTM(self.units, return_sequences=False))
            model.add(Dropout(self.dropout))
            model.add(Dense(1))
            model.compile(optimizer="adam", loss="mse")
            return model
    def train(self, X_train, y_train, X_val=None, y_val=None):
        callbacks = [EarlyStopping(monitor="val_loss",
patience=5, restore_best_weights=True)]
        if X_val is not None and y_val is not None:
            history = self.model.fit(X_train, y_train,
validation_data=(X_val, y_val), epochs=self.epochs,
batch_size=self.batch_size, callbacks=callbacks, verbose=1)
        else:

```

```
        history = self.model.fit(X_train, y_train,
epochs=self.epochs, batch_size=self.batch_size, verbose=1)
        return history
    def predict(self, X_test):
        predictions = self.model.predict(X_test)
        return predictions
    def save_model(self, file_path="lstm_model.h5"):
        self.model.save(file_path)
    def load_weights(self, file_path):
        self.model.load_weights(file_path)
def prepare_lstm_input(X):
    X = np.array(X)
    if len(X.shape) == 2:
        X = X.reshape((X.shape[0], X.shape[1], 1))
    return X
if __name__ == "__main__":
    X_train = np.random.rand(1000, 30, 1)
    y_train = np.random.rand(1000, 1)
    X_test = np.random.rand(100, 30, 1)
    model = LSTMForecastModel(input_shape=(30, 1), epochs=10,
batch_size=32)
    model.train(X_train, y_train)
    forecast = model.predict(X_test)
    print(forecast[:5])
```

## Лістинг коду В.1 – Файл оцінювання якості моделей evaluation.py

```
import numpy as np
from sklearn.metrics import mean_absolute_error,
mean_squared_error
def calculate_mae(y_true, y_pred):
    return mean_absolute_error(y_true, y_pred)
def calculate_rmse(y_true, y_pred):
    return np.sqrt(mean_squared_error(y_true, y_pred))
def calculate_mape(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    y_true = np.where(y_true == 0, 1e-8, y_true)
    return np.mean(np.abs((y_true - y_pred) / y_true)) * 100
def evaluate_model(y_true, y_pred):
    mae = calculate_mae(y_true, y_pred)
    rmse = calculate_rmse(y_true, y_pred)
    mape = calculate_mape(y_true, y_pred)
    results = {
        "MAE": round(mae, 4),
        "RMSE": round(rmse, 4),
        "MAPE": round(mape, 4)
    }
    return results
def compare_models(results_dict):
    best_model = None
    best_mape = float("inf")
    for model_name, metrics in results_dict.items():
        if metrics["MAPE"] < best_mape:
            best_mape = metrics["MAPE"]
            best_model = model_name
    return best_model
if __name__ == "__main__":
```

```
actual_values = np.array([1200, 1350, 1280, 1420, 1500])
    arima_predictions = np.array([1180, 1320, 1310, 1390,
1470])
    lstm_predictions = np.array([1210, 1340, 1295, 1410, 1515])
        arima_results = evaluate_model(actual_values,
arima_predictions)
        lstm_results = evaluate_model(actual_values,
lstm_predictions)
    all_results = {
        "ARIMA": arima_results,
        "LSTM": lstm_results
    }
    best = compare_models(all_results)
    print("ARIMA:", arima_results)
    print("LSTM:", lstm_results)
    print("Best model:", best)
```

## Лістинг коду Г.1 – Файл серверної частини app.py

```

from flask import Flask, render_template, request, jsonify
import os
import pandas as pd
from data_preprocessing import preprocess_data,
create_time_series, scale_data, create_sequences, split_data
from lstm_model import LSTMForecastModel
from evaluation import evaluate_model
app = Flask(__name__)
UPLOAD_FOLDER = "uploads"
os.makedirs(UPLOAD_FOLDER, exist_ok=True)
dataset_info = {}
prepared_data = {}
@app.route("/")
def index():
    return render_template("upload.html")
@app.route("/upload", methods=["POST"])
def upload_file():
    file = request.files.get("file")
    if file is None or file.filename == "":
        return jsonify({"status": "error", "message": "Файл не
вибрано"})
    file_path = os.path.join(UPLOAD_FOLDER, file.filename)
    file.save(file_path)
    df = pd.read_csv(file_path)
    dataset_info["rows"] = len(df)
    dataset_info["columns"] = len(df.columns)
    dataset_info["file_name"] = file.filename
    dataset_info["status"] = "Файл успішно завантажено"
    prepared_data["raw"] = df
    return jsonify(dataset_info)
@app.route("/prepare", methods=["POST"])

```

```

def prepare_data():
    if "raw" not in prepared_data:
        return jsonify({"status": "error", "message": "Дані не
завантажено"})
    df = prepared_data["raw"]
    df = preprocess_data(df)
    sales = create_time_series(df, target_column="sales")
    scaled_sales, scaler = scale_data(sales)
    X, y = create_sequences(scaled_sales, window_size=30)
    X_train, X_test, y_train, y_test = split_data(X, y,
test_size=0.2)
    prepared_data["X_train"] = X_train
    prepared_data["X_test"] = X_test
    prepared_data["y_train"] = y_train
    prepared_data["y_test"] = y_test
    prepared_data["scaler"] = scaler
    result = {
        "status": "success",
        "records": len(df),
        "train_samples": len(X_train),
        "test_samples": len(X_test),
        "message": "Дані підготовлено до прогнозування"
    }
    return jsonify(result)
@app.route("/forecast", methods=["POST"])
def forecast():
    if "X_train" not in prepared_data:
        return jsonify({"status": "error", "message": "Дані не
підготовлено"})
    X_train = prepared_data["X_train"]
    X_test = prepared_data["X_test"]
    y_train = prepared_data["y_train"]
    y_test = prepared_data["y_test"]
    scaler = prepared_data["scaler"]

```

```

        model = LSTMForecastModel(input_shape=(X_train.shape[1],
X_train.shape[2]), epochs=10, batch_size=32)
        model.train(X_train, y_train)
        predictions = model.predict(X_test)

        y_test_original =
scaler.inverse_transform(y_test.reshape(-1, 1))
        predictions_original =
scaler.inverse_transform(predictions)

        metrics = evaluate_model(y_test_original,
predictions_original)

        forecast_result = {
            "status": "success",
            "model": "LSTM",
            "MAE": metrics["MAE"],
            "RMSE": metrics["RMSE"],
            "MAPE": metrics["MAPE"],
            "message": "Прогнозування виконано успішно"
        }

        return jsonify(forecast_result)
@app.route("/dataset-info", methods=["GET"])
def get_dataset_info():
    return jsonify(dataset_info)
if __name__ == "__main__":
    app.run(debug=True)

```

## Лістинг коду Д.1 – Файл сторінки прогнозування forecast.html

```
<!DOCTYPE html>
<html lang="uk">
<head>
<meta charset="UTF-8">
<title>Прогнозування попиту</title>
<link rel="stylesheet" href="{{ url_for('static',
filename='style.css') }}">
</head>
<body>
<div class="layout">
<aside class="sidebar">
<h2>Demand Forecast</h2>
<nav>
<a href="/">Завантаження даних</a>
<a href="/prepare-page">Підготовка даних</a>
<a href="/forecast-page" class="active">Прогноз</a>
</nav>
</aside>
<main class="content">
<section class="card">
<h1>Прогнозування попиту</h1>
<p>Система формує прогноз попиту на основі підготовлених
часових рядів.</p>
<div class="form-row">
<label for="model">Модель прогнозування</label>
<select id="model">
<option value="lstm">LSTM</option>
<option value="arima">ARIMA</option>
</select>
</div>
<div class="form-row">
```

```

<label for="period">Період прогнозування</label>
<select id="period">
<option value="quarter">Поточний квартал</option>
<option value="month">Наступний місяць</option>
</select>
</div>
<button onclick="runForecast()">Сформувати прогноз</button>
</section>
<section class="card">
<h2>Результати прогнозування</h2>
<div id="status">Очікується запуск прогнозування</div>
<div class="metrics">
<div>
<span>MAE</span>
<strong id="mae">-</strong>
</div>
<div>
<span>RMSE</span>
<strong id="rmse">-</strong>
</div>
<div>
<span>MAPE</span>
<strong id="mape">-</strong>
</div>
</div>
<div class="chart-placeholder">
Графік фактичних та прогнозованих значень
</div>
</section>
</main>
</div>
<script>
function runForecast() {
  document.getElementById("status").innerText="Виконується
прогнозування...";
  fetch("/forecast", {method:"POST"})

```

```
.then(response=>response.json())
.then(data=>{
  if(data.status==="success"){
    document.getElementById("status").innerText=data.message;
    document.getElementById("mae").innerText=data.MAE;
    document.getElementById("rmse").innerText=data.RMSE;
    document.getElementById("mape").innerText=data.MAPE+"%";
  }else{
    document.getElementById("status").innerText=data.message;
  }
})
.catch(()=>{
  document.getElementById("status").innerText="Помилка під час
прогнозування";
});
}
</script>
</body>
</html>
```

УДК 621.326

Ковальчук Н. – ст. гр. СП-42

*Тернопільський національний технічний університет імені Івана Пулюя*

## **РОЗРОБКА МОДЕЛІ МАШИННОГО НАВЧАННЯ ДЛЯ ПРОГНОЗУВАННЯ ЧАСОВИХ РЯДІВ У ЗАДАЧАХ ПОПИТУ**

Науковий керівник: к.ф.-м.н., доцент Цебрій О. Р.

Kovalchuk N.

*Ternopil Ivan Puluj National Technical University*

## **DEVELOPMENT OF A MACHINE LEARNING MODEL FOR TIME SERIES FORECASTING IN DEMAND PREDICTION TASKS**

Supervisor: PhD in Physics and Mathematics, Associate Professor Tsebrii O.

Ключові слова: часові ряди, прогнозування попиту, машинне навчання

Keywords: time series, demand forecasting, machine learning

Прогнозування попиту є важливою задачею в економічних та бізнес-процесах, оскільки дозволяє оптимізувати запаси, планувати виробництво та підвищувати ефективність управління ресурсами. Попит зазвичай представлений у вигляді часових рядів, які можуть містити сезонні коливання, тренди та випадкові флуктуації. Традиційні статистичні методи не завжди здатні адекватно враховувати складні нелінійні залежності у таких даних, що зумовлює необхідність використання методів машинного навчання.

Сучасні підходи до прогнозування часових рядів включають як класичні моделі (ARIMA, SARIMA), так і алгоритми машинного навчання, зокрема Random Forest, Gradient Boosting та нейронні мережі. Особливу ефективність демонструють рекурентні нейронні мережі, такі як LSTM та GRU, які здатні враховувати довгострокові залежності у даних. Окрім цього, трансформерні архітектури дедалі частіше застосовуються для задач прогнозування, забезпечуючи високу точність завдяки механізмам attention.

Важливим етапом є попередня обробка даних, яка включає очищення, нормалізацію, виявлення та усунення аномалій, а також формування ознак. Для покращення якості прогнозів використовуються додаткові фактори, такі як календарні ознаки, акційні періоди, погодні умови або інші зовнішні змінні, що впливають на попит. Це дозволяє моделі враховувати контекст та підвищувати точність прогнозування.

Окрім цього, значну увагу приділяють побудові багатокрокових прогнозів, де модель повинна передбачати значення на декілька періодів вперед. Це ускладнює задачу, оскільки накопичення похибки може призводити до зниження точності. Для вирішення цієї проблеми використовуються підходи прямого, рекурсивного та комбінованого прогнозування.

Експериментальні дослідження показують, що використання сучасних моделей машинного навчання дозволяє значно підвищити точність прогнозів порівняно з традиційними методами. Основними метриками оцінювання є MAE, RMSE та MAPE, що дозволяє комплексно оцінити якість моделей [1].

Разом з тим, залишаються проблеми, пов'язані з нестабільністю даних, наявністю шуму, пропущених значень та зміною поведінки попиту з часом, що часто обумовлено зовнішніми факторами, такими як економічні коливання, сезонні ефекти або зміни споживчих переваг. У реальних умовах часові ряди можуть демонструвати нестационарність, різкі стрибки та аномалії, що ускладнює побудову стабільних моделей. Тому актуальними є задачі підвищення робастності моделей до шуму та аномалій, впровадження механізмів адаптації до нових умов, а також використання підходів до онлайн-навчання або періодичного донавчання моделей. Крім того, важливим є врахування концепції *concept drift*, коли статистичні властивості даних змінюються з часом, що вимагає постійного оновлення моделей для збереження їх актуальності [2].

Додатково важливим є формування інформативного простору ознак для моделей прогнозування. Окрім базових значень часового ряду, ефективність моделей значно підвищується за рахунок введення похідних характеристик, таких як ковзні середні, темпи зміни, лагові змінні та сезонні індикатори. Також активно використовуються зовнішні фактори, зокрема календарні події, маркетингові активності, погодні умови або економічні показники, які можуть суттєво впливати на попит. Правильний вибір та комбінування таких ознак дозволяє моделі краще відображати реальні залежності та підвищує якість прогнозів.

Окрему увагу приділяють вибору горизонту прогнозування та стратегії його побудови. У задачах попиту часто необхідно передбачати значення на різні часові інтервали — від короткострокових до довгострокових. Це потребує використання різних підходів до навчання моделей, зокрема одночасного прогнозування декількох кроків наперед або послідовного прогнозування з використанням попередніх результатів. Вибір відповідної стратегії впливає на точність, стабільність та практичну цінність отриманих прогнозів, особливо в умовах високої невизначеності даних.

Таким чином, поєднання методів машинного навчання, ефективної обробки часових рядів, врахування зовнішніх факторів та адаптивних механізмів навчання створює основу для розробки точних, гнучких та масштабованих систем прогнозування попиту. Важливою є не лише точність моделей, але й їх здатність працювати у реальному часі, швидко реагувати на зміни та інтегруватися у бізнес-процеси. Такі системи можуть бути впроваджені у бізнес-аналітичні платформи, ERP- та CRM-системи, забезпечуючи підтримку прийняття рішень, оптимізацію запасів, зменшення витрат та підвищення загальної ефективності управління. У перспективі розвиток таких підходів дозволить створювати більш автономні системи, здатні не лише прогнозувати попит, але й автоматично формувати рекомендації щодо управлінських дій [3].

#### Література:

1. Lim, B., Arik, S. Ö., Loeff, N., Pfister, T. (2021). Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting. — *International Journal of Forecasting*.
2. Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., Bouchachia, A. (2021). A survey on concept drift adaptation. — *ACM Computing Surveys*.
3. Benidis, K., Rangapuram, S. S., Flunkert, V., et al. (2022). Neural forecasting: Introduction and literature overview. — *IEEE Transactions on Neural Networks and Learning Systems*.