

Факультет інформатики та обчислювальної техніки
Кафедра обчислювальної техніки

«На правах рукопису»
УДК 004.94

До захисту допущено:
В. О. Завідувача кафедри
_____ Михайло Новотарський
« » 2025 р.

Магістерська дисертація

Виконав:
студент II курсу, групи ІО-31мн
Дмитришин Андрій Дмитрович

Керівник:
проф., д.т.н., проф.
Клименко Ірина Анатоліївна

Консультант з нормоконтролю:
асистент каф. ОТ, к.т.н.
Кулаков Олексій Юрійович

Рецензент:
Посада, науковий ступінь, вчене звання,
Прізвище, ім'я, по батькові

Засвідчую, що у цій магістерській дисертації немає запозичень з праць інших авторів без відповідних посилань.

Студент _____
(підпис)

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

Факультет (інститут) Інформатики та обчислювальної техніки
(повна назва)

Кафедра Обчислювальної техніки
(повна назва)

Освітньо-кваліфікаційний ступінь магістр
(назва ОКР)

Спеціальність 123. Комп'ютерна інженерія
(код і назва)

Спеціалізація 123. Комп'ютерні системи та мережі
(код і назва)

ЗАТВЕРДЖУЮ
В. О. Завідувача кафедри
Михайло Новотарський
(підпис) (ініціали, прізвище)

« » _____ 2025 р.

ЗАВДАННЯ
на магістерську дисертацію студенту
Дмитришину Андрію Дмитровичу
(прізвище, ім'я, по батькові)

1. Тема дисертації Аналітична система на основі хмарних обчислень для інтелектуальної системи IoT

Науковий керівник дисертації проф., д.т.н., проф.. Клименко І. А.
(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом по університету від «13» 03 2025 р. № 1128-с

2. Строк подання студентом дисертації 5 травня 2025

3. Об'єкт дослідження Інтелектуальна система управління паркувальним простором, що базується на технологіях Інтернету речей (IoT) та хмарних обчисленнях.

4. Предмет дослідження Методи обробки, прогнозування та аналітики даних про зайнятість паркомісць у хмарному середовищі на основі даних з IoT-сенсорів.

5. Перелік завдань, які потрібно розробити:

1. Провести огляд сучасних рішень у сфері інтелектуального паркування, хмарних обчислень та прогнозування.
2. Визначити вимоги до аналітичної системи, обрати моделі прогнозування.
3. Спроектувати архітектуру системи збору, обробки та аналітики даних.
4. Реалізувати програмний модуль для прогнозування зайнятості паркомісць.
5. Провести експериментальне тестування моделей та порівняльний аналіз їх ефективності.

6. Консультанти розділів дисертації:

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
1	проф. каф. ОТ д.т.н., Кулаков Ю.О.		
2	проф. каф. ОТ д.т.н., Кулаков Ю.О.		
3	проф. каф. ОТ д.т.н., Кулаков Ю.О.		
4	проф. каф. ОТ д.т.н., Кулаков Ю.О.		
5	проф. каф. ОТ д.т.н., Кулаков Ю.О.		

7. Дата видачі завдання 01 вересня 2024

Календарний план

№ з/п	Назва етапів виконання магістерської дисертації	Строк виконання етапів дисертації	Примітка
1.	Затвердження теми роботи	28.09.2024	
2.	Аналіз предметної області, огляд літератури	23.10.2024	
3.	Визначення вимог до аналітичної системи	18.11.2024	
4.	Проектування системи збору та агрегації даних	02.12.2024	
5.	Розробка програмного прототипу	12.01.2025	
6.	Опис особливостей реалізації системи	06.02.2025	
7.	Реалізація та аналіз моделей прогнозування	22.03.2025	
8.	Оформлення матеріалів дисертації	15.04.2025	
9.	Проходження нормоконтролю	05.05.2025	
10.	Захист	19.05.2025	

Студент _____
(підпис)

Андрій Дмитришин
(ініціали, прізвище)

Науковий керівник дисертації _____
(підпис)

Ірина Клименко
(ініціали, прізвище)

РЕФЕРАТ

на магістерську дисертацію

виконану на тему: Аналітична система на основі хмарних обчислень для інтелектуальної системи IoT

студентом: Дмитришином Андрієм Дмитровичем

Обсяг та структура роботи. Дисертація складається зі вступу та чотирьох розділів. Повний обсяг роботи: 83 аркушів основного тексту, 8 ілюстрацій, 15 таблиць. При проведенні підготовки була використана література з 28 джерел.

Актуальність роботи.

Сучасні міста стикаються з викликами стрімкої урбанізації та зростанням кількості автомобілів. Однією з найбільш відчутних проблем стає неефективне управління паркувальними просторами. Це спричиняє затори, перевитрату пального, забруднення повітря та зниження якості життя. При цьому наявна інфраструктура часто використовується нераціонально через відсутність інструментів прогнозування та аналітики.

Водночас технології Інтернету речей (IoT), хмарні обчислення та методи прогнозування на основі машинного навчання дають змогу створювати системи, які не тільки фіксують стан паркомісць у реальному часі, а й надають прогнози зайнятості. Це відкриває нові підходи до управління транспортними потоками та оптимізації простору.

Мета і завдання дослідження.

Мета: створити аналітичну систему для прогнозування зайнятості паркомісць на основі даних з IoT-сенсорів, що обробляються у хмарному середовищі.

Завдання:

1. Провести огляд наявних рішень у сфері інтелектуального паркування та хмарної аналітики.
2. Визначити вимоги до аналітичної системи, враховуючи структуру даних, особливості прогнозування та потреби користувачів.

3. Побудувати архітектуру аналітичної системи, яка поєднує IoT-сенсори, хмарну платформу та модуль прогнозування.
4. Реалізувати та налаштувати моделі прогнозування на основі часових рядів (LSTM, Prophet, SARIMA).
5. Порівняти точність і стабільність моделей, оцінити результати на основі відповідних метрик.

Методи дослідження.

- Методи системного та порівняльного аналізу — для оцінки існуючих підходів до управління паркуванням.
- Методи аналізу часових рядів — для вивчення динаміки зміни зайнятості паркомісць.
- Моделі машинного навчання (LSTM, Prophet, SARIMA) — для прогнозування на основі історичних даних.
- Методи імітаційного моделювання — для перевірки роботи аналітичного модуля на тестових даних.
- Статистичний аналіз — для оцінки точності та обґрунтування вибору моделі.

Об'єкт дослідження.

Інтелектуальна система управління паркуванням, яка базується на використанні IoT-сенсорів та хмарної інфраструктури.

Предмет дослідження.

Методи та моделі обробки й прогнозування даних про зайнятість паркомісць у хмарному середовищі.

Наукова новизна одержаних результатів.

Запропоновано поєднання хмарної аналітики з методами глибинного навчання для задач прогнозування у системах «розумного паркування».

Проведено порівняльний аналіз моделей LSTM, Prophet і SARIMA, адаптованих до специфіки паркувальних даних.

Показано доцільність використання нейромережевих підходів для обробки нестационарних та сезонних часових рядів у міських умовах.

Практичне значення одержаних результатів.

Результати дослідження можуть бути впроваджені в системи міського управління транспортом. Аналітичний модуль дозволяє в реальному часі оцінювати навантаження на паркувальні зони, формувати прогнози на найближчі години або дні та надавати користувачам рекомендації щодо вибору зони паркування. Це дозволяє зменшити затори, знизити викиди, економити час та покращувати екологічну ситуацію.

Особистий внесок здобувача.

Самостійно здійснив аналітичний огляд літературних джерел, обрав моделі прогнозування, адаптував їх до особливостей задачі, виконав реалізацію та порівняльне тестування, сформулював висновки на основі результатів моделювання.

Ключові слова.

Інтернет речей (IoT), хмарні обчислення, розумна парковка, прогнозування, машинне навчання, часові ряди, LSTM, Prophet, SARIMA, аналітична система, міська інфраструктура.

ABSTRACT

for a master's thesis

“Cloud-based Analytical Solution for a Smart IoT System”

author: Dmytryshyn Andrii

Volume and Structure of the Thesis

The thesis consists of an introduction and four chapters. The total volume of the thesis is 83 pages of main text, 8 illustrations, and 15 tables. During the preparation, literature from 28 sources was used.

Relevance of the Study

Modern cities face challenges caused by rapid urbanization and the growing number of vehicles. One of the most pressing issues is inefficient management of parking spaces, which leads to traffic congestion, fuel overuse, air pollution, and a general decline in the quality of life. At the same time, the existing infrastructure is often used inefficiently due to the lack of forecasting and analytics tools.

Meanwhile, the development of Internet of Things (IoT) technologies, cloud computing, and machine learning-based forecasting methods opens the way for systems that not only monitor parking space occupancy in real time but also provide predictions. This enables new approaches to managing traffic flows and optimizing urban space.

Aim and Objectives of the Research

Aim:

To develop an analytical system for forecasting parking space occupancy based on data collected from IoT sensors and processed in a cloud environment.

Objectives:

1. Review existing solutions in the field of smart parking and cloud-based analytics.
2. Define the requirements for the analytical system, considering data structure, forecasting features, and user needs.
3. Design the architecture of the analytical system integrating IoT sensors, a cloud platform, and a forecasting module.
4. Implement and configure time-series forecasting models (LSTM, Prophet,

SARIMA).

5. Compare model accuracy and stability; evaluate the results using relevant performance metrics.

Research Methods

- Systematic and comparative analysis methods – for evaluating current parking management approaches.
- Time series analysis methods – for studying the dynamics of parking occupancy changes.
- Machine learning models (LSTM, Prophet, SARIMA) – for forecasting based on historical data.
- Simulation modeling methods – for testing the analytical module on sample datasets.

Statistical analysis – for measuring model accuracy and justifying the model selection.

Object of the Research

A smart parking management system based on the use of IoT sensors and cloud infrastructure.

Subject of the Research

Methods and models for processing and forecasting parking occupancy data in a cloud environment.

Scientific Novelty of the Obtained Results

A combination of cloud analytics and deep learning methods is proposed for forecasting tasks in smart parking systems.

A comparative analysis of LSTM, Prophet, and SARIMA models adapted to parking data specifics is presented.

The applicability of neural network approaches for processing non-stationary and seasonal time series in urban conditions is demonstrated.

Practical Significance of the Obtained Results

The results of the study can be implemented in urban transport management systems. The analytical module enables real-time evaluation of parking zone load, generates short-term and medium-term forecasts, and provides users with

recommendations for parking area selection. This contributes to reducing traffic congestion, lowering emissions, saving time, and improving the environmental situation.

Personal Contribution of the Author

The author independently conducted a literature review, selected appropriate forecasting models, adapted them to the specifics of the task, implemented and tested the models, and formulated conclusions based on the modeling results.

Keywords

Internet of Things (IoT), cloud computing, smart parking, forecasting, machine learning, time series, LSTM, Prophet, SARIMA, analytical system, urban infrastructure.

ЗМІСТ

ПЕРЕЛІК СКОРОЧЕНЬ.....	13
ВСТУП.....	14
РОЗДІЛ 1	16
АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ІСНУЮЧИХ РІШЕНЬ	16
1.1. Сучасний стан та тенденції розвитку інтелектуальних транспортних систем та IoT.....	16
1.1.1. Концепція Інтернету речей (IoT) та її застосування у міській інфраструктурі	16
1.1.2. Роль хмарних обчислень в архітектурі IoT-систем (зберігання, обробка, аналітика).....	18
1.1.3. Огляд технологій Edge Computing та їх значення для IoT	20
1.2. Проблематика управління паркувальними місцями в сучасних містах	23
1.2.1. Економічні та соціальні наслідки неефективного паркування	23
1.2.2. Вимоги до сучасних систем "Розумна парковка".....	24
1.3. Огляд існуючих архітектур та технологій для систем "Розумна парковка"	26
1.3.1. Сенсорні технології для детектування зайнятості паркомісць (ультразвукові, магнітометричні, відеоаналіз)	26
1.3.2. Протоколи передачі даних в IoT-системах паркування (LoRaWAN, NB-IoT, MQTT).....	28
1.3.3. Хмарні платформи для IoT (AWS IoT, Azure IoT Hub, Google Cloud IoT).....	29
1.4. Аналіз методів аналізу даних та прогнозування в системах "Розумна парковка"	32
1.4.1. Статистичні методи аналізу даних про зайнятість	32
1.4.2. Методи машинного навчання для прогнозування доступності паркомісць (регресія, часові ряди, класифікація).....	33
Висновки до розділу 1.....	36
РОЗДІЛ 2	37

МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ ТА ОБҐРУНТУВАННЯ МЕТОДІВ АНАЛІТИЧНОЇ СИСТЕМИ.....	37
2.1. Формалізація задачі прогнозування зайнятості паркувальних місць	37
2.1.1. Опис вхідних даних (дані з сенсорів, часові мітки, зовнішні фактори)	37
2.1.2. Визначення цільових показників прогнозування (ймовірність зайнятості, очікуваний час звільнення).....	39
2.2. Математичні моделі для опису потоків транспортних засобів та процесів паркування.....	41
2.2.1. Застосування елементів теорії масового обслуговування (СМО)	41
2.2.2. Стохастичні моделі прибуття та обслуговування	42
2.3. Обґрунтування вибору методів машинного навчання.....	44
2.3.1. Порівняльний аналіз алгоритмів (ARIMA, LSTM, Prophet, XGBoost)	44
2.3.2. Метрики оцінки якості прогнозів (MAE, RMSE, MAPE).....	47
2.4. Математичний опис алгоритмів первинної обробки даних на Edge-рівні	49
Висновки до розділу 2.....	52
РОЗДІЛ 3	53
ПРОЕКТУВАННЯ ТА РОЗРОБКА АНАЛІТИЧНОЇ СИСТЕМИ.....	53
3.1. Розробка загальної архітектури системи.....	53
3.1.1. Рівні архітектури (сенсорний, Edge, хмарний, рівень додатків)	53
3.1.2. Взаємодія між компонентами системи.....	55
3.1.3. Вибір технологічного стеку (хмарна платформа, база даних, мови програмування)	56
3.2. Проектування підсистеми збору та передачі даних.....	58
3.2.1. Моделювання роботи IoT-сенсорів.....	58
3.2.2. Вибір та конфігурація протоколу передачі даних (MQTT).....	60
3.2.3. Проектування структури даних для передачі	61
3.3. Розробка модуля Edge Computing	63
3.3.1. Реалізація алгоритмів первинної обробки даних	63

3.3.2. Забезпечення взаємодії з хмарною платформою.....	64
3.4. Розробка хмарної аналітичної платформи	65
Висновки до розділу 3.....	68
РОЗДІЛ 4	69
МОДЕЛЮВАННЯ РОБОТИ СИСТЕМИ, АНАЛІЗ РЕЗУЛЬТАТІВ ТА ОЦІНКА ЕФЕКТИВНОСТІ	69
4.1. Розробка середовища для моделювання та тестування системи.....	69
4.1.1. Вибір інструментів симуляції.....	69
4.1.2. Генерація набору даних для тестування.....	71
4.2. Проведення експериментів з моделювання	73
4.2.1. Тестування модуля збору та передачі даних	73
4.2.2. Оцінка ефективності алгоритмів на Edge-рівні.....	75
4.2.3. Навчання та тестування моделей прогнозування.....	77
4.3. Аналіз результатів моделювання	80
4.3.1. Оцінка точності прогнозів за обраними метриками	80
4.3.2. Аналіз затримок та пропускнуої здатності	82
4.3.3. Порівняння ефективності алгоритмів.....	85
4.4. Оцінка доцільності	88
4.4.1. Переваги впровадження системи	88
Висновки до розділу 4.....	91
ВИСНОВКИ	93
СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ.....	96
ДОДАТОК А.....	Помилка! Закладку не визначено.

ПЕРЕЛІК СКОРОЧЕНЬ

IoT – Internet of Things (Інтернет речей)

ML – Machine Learning (Машинне навчання)

LSTM – Long Short-Term Memory (Довготривала короткочасна пам'ять)

SLA – Service Level Agreement (Угода про рівень сервісу)

API – Application Programming Interface (Інтерфейс прикладного програмування)

ETL – Extract, Transform, Load (Витяг, трансформація, завантаження)

RMSE – Root Mean Square Error (Корінь середньоквадратичної похибки)

MAE – Mean Absolute Error (Середня абсолютна похибка)

MQTT – Message Queuing Telemetry Transport (Протокол телеметрії на базі черг повідомлень)

SARIMA – Seasonal Autoregressive Integrated Moving Average (Сезонна авторегресивна інтегрована модель ковзного середнього)

ВСТУП

Сучасні міста дедалі частіше стикаються з критичними викликами, що виникають унаслідок стрімкої урбанізації, зростання кількості транспортних засобів та обмеженості міської інфраструктури. Одним із найбільш поширених та болючих питань, з яким щодня стикаються як міські адміністрації, так і пересічні водії, є проблема паркування. Пошук вільного паркомісця у великих містах перетворюється на тривалу та неефективну процедуру, що призводить до втрати часу, перевитрати пального, зростання кількості викидів у навколишнє середовище та погіршення якості життя громадян.

Водночас технічний прогрес, зокрема розвиток Інтернету речей (IoT), хмарних обчислень та штучного інтелекту, створює підґрунтя для розробки інноваційних рішень, які дозволяють суттєво підвищити ефективність міського паркувального простору. Впровадження інтелектуальних систем управління парковкою вже не є перспективним напрямом — це сучасна необхідність для міст, що прагнуть стати по-справжньому «розумними».

Одним із перспективних підходів до розв’язання проблеми є створення аналітичної системи, здатної не лише фіксувати зайнятість паркомісць у реальному часі, а й здійснювати прогнозування майбутньої доступності паркувального простору на основі аналізу історичних даних. Вирішення такої задачі передбачає комплексну інтеграцію IoT-сенсорів, алгоритмів обробки та агрегування даних, хмарної інфраструктури для зберігання і масштабованої обробки інформації, а також моделей машинного навчання для побудови точних прогнозів.

Розробка системи "Розумна парковка" на основі IoT та хмарних обчислень дозволяє впровадити новий рівень керованості міською інфраструктурою. У такій системі сенсори встановлюються безпосередньо на паркувальних місцях або поблизу, реєструючи зайнятість у реальному часі. Зібрана інформація передається через протоколи LoRaWAN або MQTT на обчислювальні вузли (Edge-пристрої), де здійснюється первинна обробка, фільтрація та форматування даних. Далі очищені дані надходять до хмарної платформи, де зберігаються, аналізуються і

використовуються для тренування та запуску прогнозних моделей.

Центральною частиною розроблюваної системи є аналітична платформа, яка реалізує машинне навчання для прогнозування зайнятості паркомісць. У роботі передбачено використання та порівняння декількох моделей — таких як LSTM, Prophet та SARIMA — з метою визначення найефективнішої з точки зору точності, стійкості до сезонних коливань і здатності працювати в умовах нестабільних або неповних даних.

Дослідження має не лише теоретичну, а й вагому практичну цінність. Впровадження подібних рішень може істотно зменшити середній час пошуку паркувального місця, знизити трафік у центральних районах міста, зменшити обсяги викидів CO₂ та покращити якість планування міської інфраструктури. Крім того, система може бути інтегрована у мобільні додатки, надаючи водіям актуальну інформацію про наявність вільних паркомісць та прогноз їх зайнятості.

Таким чином, актуальність теми дослідження обумовлена гострою потребою у впровадженні ефективних, автоматизованих та інтелектуальних рішень у сфері міського паркування. Магістерська робота спрямована на створення повноцінної аналітичної системи, яка базується на хмарних обчисленнях, застосуванні технологій IoT та методів прогнозної аналітики. Комплексний підхід до проектування, реалізації та тестування цієї системи дозволяє зробити вагомий внесок у розвиток інтелектуальної міської інфраструктури.

РОЗДІЛ 1

АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ІСНУЮЧИХ РІШЕНЬ

1.1. Сучасний стан та тенденції розвитку інтелектуальних транспортних систем та IoT

1.1.1. Концепція Інтернету речей (IoT) та її застосування у міській інфраструктурі

Інтернет речей (Internet of Things, IoT) — це концепція, що передбачає інтеграцію фізичних об'єктів з мережевими технологіями з метою обміну даними та взаємодії в режимі реального часу. Ці об'єкти, що оснащені сенсорами, мікроконтролерами, інтерфейсами зв'язку, здатні фіксувати стан навколишнього середовища та передавати інформацію для подальшої обробки й прийняття рішень без участі людини [1]. Основна ідея IoT полягає у створенні цифрового простору, в якому фізичні пристрої — датчики, лічильники, камери, елементи управління — можуть автоматично взаємодіяти між собою або з централізованими обчислювальними платформами. Це дає змогу впроваджувати системи моніторингу, автоматичного реагування та прогнозування, що особливо важливо в контексті розумного міста.

У міській інфраструктурі застосування IoT охоплює такі сфери, як: розумне освітлення — автоматичне керування вуличними ліхтарями на основі присутності людей або рівня освітлення; моніторинг якості повітря — виявлення вмісту пилу, CO₂, NO_x та інших шкідливих речовин для екологічного контролю; керування водними ресурсами — дистанційне управління насосними станціями, контроль витоків; інтелектуальне паркування — визначення зайнятості паркомісць у режимі реального часу та надання рекомендацій водіям [2].

Особливу роль у цьому відіграє доступність недорогих енергоефективних сенсорів і розвиток бездротових технологій зв'язку (LPWAN, ZigBee, LoRaWAN), які дозволяють розгорнути великомасштабні системи з низьким споживанням

енергії. Завдяки цьому можлива реалізація десятків тисяч точок збору даних навіть у великих містах без необхідності прокладання дорогих дротових мереж. На рисунку 1.1 представлено базову схему концепції IoT у міському середовищі, яка ілюструє взаємозв'язок сенсорного рівня, комунікаційної інфраструктури та хмарної платформи.




Рис.1.1. Загальна концепція застосування IoT у міській інфраструктурі

Ключовим елементом IoT-систем є потік даних, що формується сенсорами. Його можна формально подати як множину:

$$D = \{ (t_i, s_i, v_i) \},$$

де t_i — мітка часу, s_i — ідентифікатор сенсора, v_i — зафіксоване значення. Така структура дозволяє зберігати дані у хмарі у вигляді потокових таблиць або часових рядів, що пізніше використовуються для аналітики та побудови прогнозів.

Таким чином, концепція Інтернету речей є базовою технологією для побудови систем «розумного міста», в тому числі й інтелектуальних систем паркування. Її широке застосування дозволяє перейти від реактивного до проактивного управління міською інфраструктурою, зменшуючи навантаження на ресурси та підвищуючи якість життя населення [3].

1.1.2. Роль хмарних обчислень в архітектурі IoT-систем (зберігання, обробка, аналітика)

Хмарні обчислення (cloud computing) є критичним елементом архітектури сучасних IoT-систем, адже саме вони надають можливість централізовано обробляти, зберігати й аналізувати великі обсяги даних, що генеруються численними пристроями в режимі реального часу. Сенсорні вузли, зокрема в міських умовах, мають обмежені ресурси — вони не здатні виконувати складні обчислення, зберігати історичні дані або реалізовувати аналітичну логіку. Таким чином, хмара виступає обчислювальним ядром, яке зв'язує фізичну інфраструктуру з алгоритмами аналізу та прийняття рішень [4].

- IoT-архітектура зазвичай організовується за багаторівневою схемою, де хмарна платформа реалізує наступні функції:
- Збір і агрегація потоків даних від великої кількості розподілених сенсорів;
- Трансформація й очищення даних за допомогою ETL-процесів (Extract, Transform, Load);
- Організація довготривалого сховища даних у форматі, зручному для часових рядів або ключ-значення;
- Побудова аналітичних моделей, включаючи прогностичні алгоритми та механізми рекомендацій;
- Інтеграція з інтерфейсами доступу — мобільними застосунками, веб-панелями або API для зовнішніх систем.

Хмарні обчислення мають перевагу у забезпеченні гнучкості завантаження. У типових IoT-проектах трафік даних нерівномірний: у години пік надходить максимум запитів, уночі — мінімум. Хмара дозволяє автоматично масштабувати потужності обробки в залежності від поточного навантаження. У традиційній серверній моделі це вимагало б додаткового обладнання, що простоювало б частину часу [5].

Реалізація системи «Розумна парковка» з використанням хмарної інфраструктури дозволяє ефективно поєднати низькорівневі сенсори з

високорівневою аналітикою. Наприклад, у місті Сан-Франциско була впроваджена система SFpark, де дані з сенсорів паркування збираються на центральному хмарному сервері. Далі вони проходять агрегацію й аналіз — на їх основі будується прогноз попиту, а також змінюються тарифи на паркування в реальному часі залежно від зайнятості районів. Ефектом стало зменшення середнього часу пошуку паркомісця на 43% і зниження викидів вуглекислого газу на 30% у зонах впровадження [6].

На Рис.1.2 зображено компонентну модель хмарної IoT-системи в контексті міського паркування, що ілюструє розподіл обов'язків між рівнями обробки.




Рис.1.2. Компонентна структура хмарної IoT-системи для управління паркуванням

Пояснення до схеми:

1. Датчики — виявляють наявність транспортного засобу на паркомісці.
2. Шлюзи (gateway) — агрегують трафік із кількох сенсорів, здійснюють буферизацію.
3. Брокер повідомлень — наприклад, MQTT-сервер для передачі повідомлень від пристроїв до хмари.
4. Хмарна функція — безсерверний компонент, що реагує на подію (наприклад, AWS Lambda).
5. База даних — спеціалізована система для зберігання часових рядів (наприклад, InfluxDB, TimescaleDB).

6. Модуль прогнозування — інтегрує моделі машинного навчання.
7. Інтерфейс користувача — надає доступ до прогнозів та статистики.

У таблиці нижче наведено типові типи задач, які виконує хмарна система в рамках IoT-проєкту, з розподілом за фазами життєвого циклу даних:

Таблиця 1.1.

Класифікація задач хмарної обробки у IoT-системах

Фаза	Тип задачі	Приклад інструменту
Збір	Буферизація, потокова фільтрація	AWS IoT Core, Azure IoT Hub
Агрегація	Групування, валідація	Apache Kafka, Kinesis
Зберігання	Архівація часових рядів	TimescaleDB, Amazon Timestream
Аналітика	Побудова прогнозів, візуалізація	Prophet, Amazon Forecast
Вивід	Сповіщення, дашборди	Grafana, Power BI

Таким чином, хмарні обчислення виступають не лише як технічна складова IoT-систем, а як платформа, що дозволяє організувати повноцінний життєвий цикл даних від моменту фіксації до прогнозу й прийняття рішення. Завдяки такій структурі, системи розумного міста, включно з аналітикою паркувальних місць, можуть функціонувати надійно, масштабовано та інтегровано з іншими міськими службами.

1.1.3. Огляд технологій Edge Computing та їх значення для IoT

Зі зростанням кількості IoT-пристроїв та обсягів даних, які вони генерують, виникає потреба у частковому перенесенні обчислень ближче до джерела даних. У відповідь на це з'явилася парадигма Edge Computing — обробка даних на периферії мережі, тобто безпосередньо на пристроях або вузлах, які розташовані поблизу сенсорів [7]. Вона не замінює хмарні обчислення, а доповнює їх, дозволяючи реалізувати попередню обробку, фільтрацію, агрегацію або навіть інтелектуальне прийняття рішень на місці, ще до передачі інформації до хмари.

У контексті розумного паркування, Edge Computing дозволяє виявляти зайнятість паркомісця без необхідності передавати кожне «сире» спрацювання сенсора у хмару. Замість цього пристрій або локальний вузол (наприклад, контролер парковки) агрегує ці події, розраховує середній час стоянки, визначає нестандартні ситуації (двійне зайняття, нетипова поведінка), і лише після цього надсилає оптимізований пакет даних. Це дозволяє зменшити: обсяг переданої інформації; затримку між подією і реакцією; навантаження на хмарну інфраструктуру.




Рис.1.3. Взаємодія між сенсором, Edge та хмарною платформою у системі розумного паркування

Пояснення:

1. Сенсор фіксує подію (в'їзд авто)
2. Edge-модуль виконує обробку сигналу (вираховує зміну статусу)
3. Рішення або агреговані дані надсилаються у хмару
4. У хмарі зберігається лог, виконується прогноз, відображення користувачу

Переваги використання Edge Computing:

- Швидка реакція на події в реальному часі — затримка може бути менше 50 мс.
- Менше навантаження на мережу — передаються лише стиснені або агреговані дані.
- Стійкість до втрати зв'язку з хмарою — пристрій продовжує працювати автономно.
- Підвищення приватності — обробка персональних або чутливих даних локально.

Таблиця 1.2.

Поширені рішення Edge Computing для міських IoT-систем

Рівень	Пристрій / платформа	Опис / особливості
Edge-контролери	Raspberry Pi, Jetson Nano	Можуть запускати локальні ML-моделі
Програмні фреймворки	EdgeX Foundry, AWS Greengrass	Підтримка обробки подій, шифрування, локальних правил
Операційні системи	Ubuntu Core, BalenaOS	Спеціально оптимізовані під edge-виконання
Інтеграція з хмарою	Azure IoT Edge, Google Edge ML	Працюють у зв'язці з відповідною хмарною платформою

Завдяки можливості виконання локальних скриптів або легких моделей на основі історичних даних, Edge-обробка дозволяє реалізувати такі сценарії, як: відхилення стандартної поведінки (наприклад, надто довге паркування); короткострокове прогнозування в локальній зоні (наприклад, зміна трафіку біля ТЦ); попереднє прийняття рішень при тимчасовій втраті інтернету.

Також Edge-обчислення є важливою ланкою у забезпеченні реального часу для систем критичного значення — наприклад, у смарт-транспорті, енергетиці або громадській безпеці.

З огляду на це, Edge Computing набуває все більшого значення як стратегічне доповнення до хмари у побудові комплексних IoT-рішень. У рамках розробки системи аналітики розумного паркування, використання Edge дозволяє ефективно

перерозподілити обчислювальні навантаження, зменшити вартість експлуатації та забезпечити стабільну роботу навіть в умовах непостійного інтернет-з'єднання.

1.2. Проблематика управління паркувальними місцями в сучасних містах

1.2.1. Економічні та соціальні наслідки неефективного паркування

Неефективне використання паркувального простору в містах спричиняє ланцюгову реакцію економічних втрат, транспортного перевантаження, зниження екологічних показників та психологічного дискомфорту мешканців. Паркування, яке в ідеалі має бути «непомітною» частиною щоденного життя, перетворюється на джерело щоденних проблем — і для водіїв, і для міських адміністрацій, і для бізнесу.

Насамперед, час пошуку паркувального місця є значним фактором втрати продуктивності. Згідно з дослідженням INRIX (США, 2022), середній водій витрачає щороку понад 90 годин на пошук місця для паркування в густонаселених районах [10]. У Лондоні цей показник сягає 67 годин, а у Нью-Йорку — 107 годин [11]. За підрахунками, це створює сукупну втрату економіки на мільярди доларів через непродуктивне використання часу, затрати пального і втрачений дохід бізнесу, до якого водії не дісталися через відсутність місця.

Другий важливий аспект — перевитрати пального. Автомобілі, які кружляють у пошуках вільного місця, генерують значну частину міського трафіку. Наприклад, у дослідженні UCLA [12] було показано, що до 30% дорожнього трафіку в центрі Лос-Анджелеса створюється саме через водіїв, які шукають місце для паркування. У великих містах це сприяє формуванню заторів навіть у непікові години, збільшуючи загальне навантаження на інфраструктуру.

Екологічні наслідки прямо пов'язані з надлишковими поїздками: зайвий рух означає більше викидів CO₂, особливо в умовах недостатньої електрифікації транспорту. В одній зі статей European Environment Agency було наведено, що оптимізація паркування в містах дозволяє скоротити загальні міські викиди на 4–8% [13], що є значним внеском у боротьбу зі змінами клімату.

Соціальний вимір не менш важливий. Відсутність прогнозованого доступу до паркувальних місць створює: стрес і тривожність у водіїв, особливо в умовах часових обмежень або ризику штрафу; нерівний доступ до міських центрів: люди, які не можуть дозволити собі платні паркінги, уникають поїздок у певні райони, що впливає на їхню мобільність і соціальну інтеграцію; зниження прибутків малого бізнесу — відвідувачі можуть змінювати місце покупок або відпочинку через складність з паркуванням.

Згідно з результатами досліджень у Мілані (Італія), більше 40% респондентів вказали, що вони уникають відвідування певних районів у години пік лише через відсутність гарантованого місця для авто. А в Торонто зростання кількості доступних місць навіть на 15% показало підвищення пішохідного трафіку на 8% і зростання доходів торгових точок на 6% [14].

Окрім цього, виникає непряма нерівність: у районах з погано організованим паркуванням часто відбувається зниження вартості нерухомості, погіршення репутації мікрорайону та зростання соціального напруження.

Ще один наслідок — неефективне використання вже існуючих паркувальних зон. Часто трапляється ситуація, коли частина місць у районі вільна, але водії не мають інформації про це, тому продовжують шукати у перевантажених зонах. Це можна вважати прямим результатом відсутності аналітики та систем прогнозування.

Отже, сучасне місто, яке не має інструментів моніторингу та прогнозування паркувального простору, стикається з низкою втрат — від прямих економічних до структурно-соціальних. Саме тому розробка інтелектуальних систем управління паркуванням на основі IoT та хмарних обчислень стає не лише технічним завданням, а й необхідною умовою сталого розвитку міської інфраструктури.

1.2.2. Вимоги до сучасних систем "Розумна парковка"

Успішне функціонування системи «Розумна парковка» залежить від здатності задовольнити широкий спектр технічних, функціональних та користувацьких вимог. Зростання урбаністичних центрів, динаміка руху транспорту, зміни кліматичних

умов та поведінки водіїв потребують, щоб такі системи були гнучкими, масштабованими, інтероперабельними й безпечними.

Одна з ключових вимог — це надійне виявлення факту присутності автомобіля на паркомісці. Сенсорна частина повинна працювати в різних погодних умовах, мати низьке енергоспоживання та високу точність. Наприклад, магнітометричні сенсори ефективно працюють у сніг та дощ, однак мають високу чутливість до зовнішніх магнітних полів. Ультразвукові сенсори, в свою чергу, мають обмеження щодо кута огляду. Отже, вибір типу сенсора є критичним для точності системи [15].

Друга вимога — підтримка актуального обміну даними у реальному часі. Для цього застосовуються протоколи MQTT, CoAP або HTTP/2, які забезпечують низьку затримку та ефективну передачу повідомлень. У випадках, коли йдеться про інтеграцію з іншими транспортними або муніципальними системами, необхідна підтримка відкритих API та стандартизованих форматів даних, наприклад, JSON або XML.

Крім технічних аспектів, важливо забезпечити зручний інтерфейс користувача. Система має надавати водієві доступ до інформації про наявність вільних місць, прогноз завантаження паркувальних зон, маршрути до найближчих доступних місць, а також підтримку електронної оплати. Прикладом може слугувати мобільний додаток ParkMobile або EasyPark, що інтегрує картографію, оплату та аналітику.

Ще одним важливим компонентом є модуль прогнозування — він повинен враховувати сезонність, час доби, день тижня, погодні умови та історичну динаміку попиту. Для цього використовуються моделі на основі часових рядів (LSTM, Prophet, SARIMA), що можуть бути розгорнуті на хмарній платформі або частково реалізовані на edge-рівні. Прогнозування допомагає не лише водіям, а й операторам паркінгів — оптимізувати тарифи, планувати розширення зон або зміну організації руху.

Загалом сучасна система «Розумна парковка» має відповідати наступним узагальненим вимогам:

- Точність детекції (не менше 95%).

- Затримка передачі даних — не більше 1 с.
- Інтеграція з навігаційними та платіжними системами.
- Висока масштабованість (від кількох до тисяч паркомісць).
- Захист даних і аутентифікація користувачів.
- Можливість локальної обробки у випадку втрати зв'язку з хмарою.

Виконання цих вимог забезпечує високу якість сервісу, економічну ефективність та прийняття рішень на основі даних, що особливо актуально для міст із динамічним транспортним навантаженням.

1.3. Огляд існуючих архітектур та технологій для систем "Розумна парковка"

1.3.1. Сенсорні технології для детектування зайнятості паркомісць (ультразвукові, магнітометричні, відеоаналіз)

У системах «Розумна парковка» саме сенсори виконують ключову роль — вони є джерелом первинної інформації про зайнятість паркомісць. Від точності та надійності цих сенсорів залежить ефективність усієї аналітичної системи. Залежно від типу покриття, вартості та умов експлуатації, обираються різні типи сенсорів, кожен із яких має свої переваги й обмеження.

Серед найпоширеніших — магнітометричні сенсори. Вони визначають зміни у магнітному полі при наявності великого металевго об'єкта (автомобіля) над сенсором. Їхня перевага — низьке енергоспоживання, можливість автономної роботи до 5 років та простота установки без порушення асфальтного покриття. Але такі сенсори вразливі до сторонніх магнітних перешкод, і тому потребують додаткової фільтрації сигналу [16].

Інший популярний варіант — ультразвукові сенсори. Вони вимірюють відстань до найближчого об'єкта, розміщені, як правило, над місцем для паркування. Їхня точність висока, особливо в гаражах або критих зонах, однак вуличні умови (опад,

пил, сонячне світло) можуть впливати на роботу. Також вони вимагають енергоживлення та періодичного обслуговування.

Відеоаналітика — новітній напрямок у детектуванні зайнятості. Відеокамери з вбудованими модулями штучного інтелекту можуть виявляти автомобілі, розпізнавати номери, визначати напрям руху. Такий підхід дорогий в реалізації, вимагає постійного зв'язку та значних обчислювальних потужностей, однак відкриває широкі аналітичні можливості.

Для кращого порівняння основних сенсорних технологій нижче наведено таблицю з ключовими характеристиками. Таблиця 1.3 демонструє порівняльний аналіз сенсорів з точки зору функціональності, надійності та вимог до інфраструктури.




Рис.1.4. Приклади магнітометричного, ультразвукового сенсора та модуля відеоаналітики, що використовуються в системах «Розумна парковка»

Таблиця 1.3.

Порівняльна характеристика сенсорних технологій для розумного паркування

Тип сенсора	Принцип роботи	Переваги	Недоліки
Магнітометричний	Вимірювання змін магнітного поля	Автономність, простота встановлення	Чутливість до магнітних завад
Ультразвуковий	Вимірювання відстані до об'єкта	Висока точність, непрямий контакт	Вразливість до погодних умов
Відеоаналітика	Комп'ютерний зір, AI-модулі	Широкий спектр аналітики	Висока вартість, потреба у підключенні та живленні

1.3.2. Протоколи передачі даних в IoT-системах паркування (LoRaWAN, NB-IoT, MQTT)

Передача даних є центральним елементом будь-якої IoT-системи, включаючи «розумні парковки». На цьому етапі відбувається зв'язок між сенсорними пристроями, обчислювальними вузлами (наприклад, edge-модулями) та хмарною платформою. Успішна інтеграція цих рівнів залежить від вибору відповідного протоколу зв'язку, який забезпечить потрібний баланс між енергоспоживанням, швидкістю, надійністю та масштабованістю.

У міських умовах, де одночасно функціонують тисячі сенсорів, критично важливими є стабільність передачі повідомлень і здатність адаптуватися до коливань навантаження мережі. Протоколи, які використовуються в таких системах, мають працювати з мінімальними затримками, підтримувати відмовостійкість, а також забезпечувати безпеку при передачі даних.

У таблиці 1.4 наведено порівняння основних протоколів, які використовуються у практиці IoT-систем. Це дозволяє оцінити їхню ефективність залежно від сценарію використання та технічних умов впровадження.

Таблиця 1.4.

Порівняння протоколів передачі даних для IoT-систем паркування

Протокол	Тип передачі	Переваги	Обмеження
MQTT	TCP, publish-subscribe	Низьке енергоспоживання, надійність, гнучкість	Потребує брокера
CoAP	UDP, client-server	Малий розмір повідомлень, швидкість	Менш надійний за TCP
HTTP/2	TCP, client-server	Сумісність з веб-інфраструктурою	Більші накладні витрати
LoRaWAN	LPWAN	Велика зона покриття, автономність	Низька швидкість передачі
NB-IoT	Мобільна мережа	Глибоке покриття, довговічність	Залежність від операторів

1.3.3. Хмарні платформи для IoT (AWS IoT, Azure IoT Hub, Google Cloud IoT)

Хмарна платформа є центральним вузлом IoT-екосистеми: вона приймає телеметрію від сенсорів, управляє життєвим циклом пристроїв, масштабує сховища часових рядів і надає обчислювальні ресурси для машинного навчання. У проєктах «розумної парковки» саме хмара забезпечує збір даних з тисяч розподілених вузлів у режимі реального часу та формує узагальнені прогнози для операторів і водіїв. Вибір платформи визначає не лише вартість, а й майбутню гнучкість та надійність системи.

При попередньому плануванні бюджету розробники використовують спрощену модель розрахунку щомісячних витрат на передавання повідомлень. Вона допомагає

швидко порівняти різні тарифні плани і вибрати оптимальний сценарій використання:

$$C = \sum_{i=1}^n m_i \cdot p_i$$

де m_i — кількість повідомлень певного класу i (у млн/міс.), p_i — ціна за 1 млн повідомлень у цьому класі; n — кількість класів тарифікації. Формулу (1.1) зручно застосовувати при поетапному масштабуванні — вона лінійно описує зростання витрат.

Наприклад, для 10 000 сенсорів, кожен з яких передає 96 повідомлень на добу (15-хвилинний інтервал), маємо 960 000 повідомлень на день або ≈ 29 млн на місяць. За тарифом AWS IoT Core «Ingest» (0,8 USD/млн) витрати складуть ≈ 23 USD, тоді як аналогічний трафік в Azure IoT Hub (0,95 USD/млн) коштуватиме $\approx 27,5$ USD. Навіть така груба оцінка показує різницю у 20 %.

Таблиця 1.5 порівнює три провідні SaaS-рішення за ключовими параметрами: спектром протоколів, функціями управління пристроями, механізмами аналітики і офіційним SLA доступності сервісу.

Таблиця 1.5.

Порівняння IoT-сервісів провідних хмарних платформ

Платформа	Протоколи	Управління пристроями	ML-сервіси	SLA
AWS IoT Core	MQTT, HTTPS, LoRaWAN	Registry, Shadow, Jobs	SageMaker, IoT Analytics	99.9 %
Azure IoT Hub	MQTT, AMQP, HTTPS	Device Twin, DPS	Azure ML, Stream Analytics	99.9 %
GCP IoT Core*	MQTT, HTTP	Registry, Config	Vertex AI, Pub/Sub	99.5 %

Крім базової телеметрії, хмарні сервіси пропонують керовані брокери повідомлень, захищений шлюз для ОТА-оновлень та системи тригерів (Rule Engine), що дає змогу виконувати бізнес-логіку без розгортання додаткових серверів.

Edge-аналітика стає необхідною в умовах великого трафіку та низьких вимог до латентності. У таблиці 1.6 зведено сервіси для розгортання моделей ML безпосередньо на периферії мережі.

Таблиця 1.6.

Хмарні сервіси для інтеграції Edge-аналітики

Платформа Edge	Підтримка контейнерів	Мова/середовище ML	Офлайн-робота
AWS Greengrass	Docker / Lambda	SageMaker Neo	Так
Azure IoT Edge	Docker / Modules	ONNX Runtime	Так
Google Edge ML	TensorFlow Lite	TFLite Model Maker	Обмежена

Оскільки в Україні популярною є модель «гібридної» інфраструктури, практичною рекомендацією є розподіл навантаження: критичні дані паркування — у резервованому регіоні AWS (eu-central-1), а вторинні аналітичні задачі — у локальному дата-центрі Azure Ukraine Cloud.




Рис.1.6 Логічна схема мультихмарного розгортання,

На рисунку показано схему де MQTT-брокер реплікує телеметрію у дві незалежні черги повідомлень, а резервний маршрут спрацьовує при відмові одного з провайдерів.

Такий підхід мінімізує ризики простою, забезпечує відповідність вимогам безпеки та дозволяє масштабуватись без ручного втручання, що критично для міських служб із високою динамікою навантаження.

1.4. Аналіз методів аналізу даних та прогнозування в системах "Розумна парковка"

1.4.1. Статистичні методи аналізу даних про зайнятість

Статистичний аналіз історичних даних про зайнятість паркомісць дозволяє виявити ключові патерни — середнє завантаження, сезонні коливання та аномальні відхилення. Ці патерни визначають подальший вибір алгоритмів прогнозування й допомагають оператору паркінгу ухвалювати рішення щодо тарифної політики та розширення інфраструктури.

Першим кроком є описова статистика: обчислення середнього, медіани, кuartилів та дисперсії для кожної доби чи тижня. Індекс варіації допомагає оцінити, наскільки рівномірно використовується паркувальна зона, що критично для розрахунку динамічних тарифів [23].

Далі аналізують часові залежності через автокореляційну функцію (ACF). Для часової серії x_t автокореляційний коефіцієнт на лагу k визначають як

$$\rho_k = \sum_t (x_t - \mu)(x_{t-k} - \mu) / \sum_t (x_t - \mu)^2$$

де μ — середнє значення вибірки. Піки ACF на лагу 96 (24 год $\times$ 4 кроки) та 672 (7 днів $\times$ 96) вказують на добову й тижневу сезонність, характерну для міських паркувань [24].

Для усунення тренда та сезонності застосовують сезонну різницю: $y_t = x_t - x_{t-s}$, де $s = 96$. Це робить ряд стаціонарним, що є передумовою побудови моделей ARIMA або SARIMA.

Найпростіший базовий прогноз — модель ковзного середнього. Якщо M — довжина вікна, прогноз на момент $t+1$ дорівнює

$$\hat{y}_{t+1} = (1/M) \sum_{i=0}^{M-1} x_{t-i}$$

такий підхід легко реалізувати на edge-рівні, однак він ігнорує сезонну структуру. Тому частіше застосовують $SARIMA(p,d,q)(P,D,Q)_s$ з добовим або тижневим періодом.

Ключові етапи побудови SARIMA-моделі:

- перевірка стаціонарності (тест Дікі—Фуллера);
- підбір порядків p, q за графіками ACF та PACF;
- оцінка параметрів методом максимальної правдоподібності;
- валідація за метриками MAE та RMSE на відкладеній вибірці.

Для прискорення розгортання у промисловому середовищі використовують Auto-ARIMA, який перебирає комбінації параметрів і мінімізує інформаційний критерій AIC. За результатами дослідження у Варшаві модель $SARIMA(1,0,1)(1,1,0)_{96}$ дала $MAE = 4,7\%$ на горизонті 24 год, що на 12% точніше за наївний метод «вчора в той самий час» [25].

Статистичні методи мають перевагу в інтерпретованості та низьких обчислювальних витратах. Вони слугують базовою лінією порівняння для більш складних алгоритмів машинного навчання, розглянутих у наступному підпункті.

1.4.2. Методи машинного навчання для прогнозування доступності паркомісць (регресія, часові ряди, класифікація)

Таблиця 1.7.

Порівняння алгоритмів машинного навчання для прогнозування паркувальної зайнятості

Категорія	Алгоритм	Ключові переваги	Типові обмеження
Класична регресія	Лінійна/Рідж-регресія	Інтерпретованість, швидке навчання	Лінійні залежності,

			погано сезонністю	3
Ensemble	Random Forest	Нелінійні зв'язки, стійкість до шуму	Багато пам'яті, складна інтерпретація	
Boosting	XGBoost / LightGBM	Висока точність, автообробка пропусків	Чутливість до вибору гіперпараметрів	
Deep Learning – Ряди	LSTM / GRU	Запам'ятовують довгі залежності, добова сезонність	Тривале тренування, потребують GPU	
Deep Learning – Гібрид	Temporal Fusion Transformer	Враховує контекстні ознаки, пояснюваність	Нова технологія, мало реалізацій	
Скорингові моделі	Logistic / CatBoost-Classifіer	Прогноз ймовірності зайнятості, робота з категоріями	Потрібен баланс класів, коректна калібровка	

Після базового статистичного аналізу доцільно застосувати алгоритми машинного навчання, здатні уловлювати нелінійні та багато-факторні залежності у даних. Для систем «розумної парковки» актуальними є як регресійні, так і двокласові методи: перші прогнозують числову величину (відсоток зайнятості), другі — ймовірність, що місце буде зайняте у заданий момент.

Формування ознак (feature engineering) включає кодування рік-місяць-день, добових та тижневих циклів через синусоїдальні перетворення $\sin(2\pi t/24)$, $\cos(2\pi t/24)$, а також ковзні середні, лаги та індикатори подій. Практика показує, що додавання погодних параметрів (температура, опади) покращує точність до 3 %-5 % [26].

Для оцінки моделей використовують середню абсолютну похибку та корінь середньоквадратичної помилки:

$$\text{MAE} = (1/n) \sum |y_i - \hat{y}_i|$$

$$\text{RMSE} = \sqrt{[(1/n) \sum (y_i - \hat{y}_i)^2]}$$

де y_i — фактичне значення, $\hat{y}_i$ — прогноз, n — кількість спостережень. RMSE сильніше штрафує великі промахи, тому корисна при довгих горизонтах 24-48 год.

Моделі LSTM і GRU навчаються на послідовностях довжиною 96 кроків (добовий відрізок) і виходять на $\text{MAE} \approx 3,2\%$ на горизонті 1 год у проєктах Нью-Йорка та Барселони [27]. Проте при малих вибірках (< 50 тис. точок) градієнтне бустування (XGBoost) дає схожу точність з меншими витратами на апаратне забезпечення.

Transformer-архітектури, зокрема Temporal Fusion Transformer, поєднують механізм self-attention з рекурентними мережами і здатні опрацьовувати як часові ряди, так і статичні атрибути (тип зони, тариф тощо). У пілотному впровадженні в Гамбурзі точність покращилася на 6 % порівняно з LSTM, а час інференсу залишився в межах 60 мс на CPU [28].

Щоб уникнути перенавчання, застосовують крос-валідацію з розсувним вікном (rolling-window CV) та регуляризацію: L2-штраф у бустингу, dropout 0,2–0,3 у LSTM. Гіперпараметри оптимізують методом Bayesian Optimization, що скорочує час пошуку до 30 % у порівнянні з grid-search.

Отже, вибір методу машинного навчання залежить від доступу до апаратних ресурсів, обсягу даних та вимог до інтерпретованості. Статистичні моделі залишаються базовою лінією, але сучасні DL-архітектури забезпечують вищу точність на складних часових рядах.

Висновки до розділу 1

У першому розділі було здійснено всебічний огляд предметної області, пов'язаної з інтелектуальними системами паркування, що ґрунтуються на технологіях Інтернету речей (IoT), хмарних обчисленнях та методах аналізу даних. Показано, що зростання кількості автомобілів у містах зумовлює потребу у впровадженні нових підходів до управління паркувальними ресурсами. Системи «Розумна парковка» дозволяють автоматизувати процеси моніторингу зайнятості паркомісць у реальному часі та покращити взаємодію з водіями.

Проаналізовано архітектурні підходи до побудови таких систем, включно з сенсорною інфраструктурою, протоколами передачі даних (LoRaWAN, NB-IoT, MQTT) та можливостями хмарних платформ (AWS, Azure, Google Cloud). Визначено переваги використання Edge Computing для попередньої обробки даних безпосередньо на місці збору. Окреслено важливість формування гнучкої багаторівневої архітектури.

Окрема увага приділена методам аналізу та прогнозування зайнятості. Розглянуто статистичні підходи (SARIMA, ковзні середні), а також сучасні алгоритми машинного навчання (LSTM, XGBoost, Transformers), які здатні враховувати складну сезонну та контекстну структуру даних. Сформульовано вимоги до системи прогнозування, зокрема щодо точності, швидкодії та адаптивності до нових умов.

На основі проведеного аналізу було визначено науково-практичну проблему, що полягає у відсутності гнучкої та масштабованої аналітичної системи, яка б інтегрувала IoT-датчики, хмарну інфраструктуру та сучасні методи прогнозування з можливістю масштабування у міських умовах. Це визначає мету роботи та формує перелік задач, що будуть вирішуватись у наступних розділах.

РОЗДІЛ 2

МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ ТА ОБҐРУНТУВАННЯ МЕТОДІВ АНАЛІТИЧНОЇ СИСТЕМИ

2.1. Формалізація задачі прогнозування зайнятості паркувальних місць

2.1.1. Опис вхідних даних (дані з сенсорів, часові мітки, зовнішні фактори)

Одним із ключових елементів ефективної аналітичної системи прогнозування зайнятості паркомісць є якісне визначення структури вхідних даних. Завдяки використанню IoT-сенсорів, які встановлюються безпосередньо на паркувальних зонах або інфраструктурних об'єктах, вдається отримати великий обсяг інформації у режимі реального часу.

Серед основних типів вхідних даних виділяють:

- Статус зайнятості (occupancy) – основна змінна, що сигналізує про наявність або відсутність транспортного засобу на паркомісці.
- Часова мітка (timestamp) – фіксує точний момент, коли був отриманий статус.
- Геолокаційні дані – координати паркомісця або його ідентифікатор у системі.
- Ідентифікатор сенсора – потрібен для кореляції інформації між фізичними пристроями.
- Зовнішні чинники – погода, температура, вологість, атмосферний тиск, події в місті, день тижня, свята.

Наприклад, один запис з сенсора у форматі JSON може виглядати наступним чином:

```
{'sensor_id': 'PKG023', 'timestamp': '2025-04-12T15:32:00', 'occupied': 1, 'temp': 21.5, 'humidity': 45, 'zone': 'A2'}
```

Періодичність збору таких даних становить зазвичай 30–60 секунд. Це дозволяє побудувати детальний часовий ряд для кожного паркомісця або агреговану вибірку по зоні.

Зовнішні фактори мають істотний вплив на патерни використання паркінгів. Наприклад, у дощову погоду активність може знижуватись, а у період масових заходів, навпаки, зростати. Тому до навчального датасету додаються ознаки:

- температура, вологість, опади (з метеостанцій),
- тип дня (будній, вихідний, святковий),
- час доби (ранок, день, вечір, ніч),
- індекс активності району (оцінюється на основі історичних даних або мобільного трафіку).

Для ефективного навчання моделей машинного навчання дані приводяться до табличного формату. У спрощеному вигляді таблиця даних матиме наступну структуру:

Таблиця 2.1.

Приклад структури навчальної вибірки

sensor_id	timestamp	occupancy	temperature	humidity	day_type	hour	zone
PKG023	2025-04-12 15:32:00	1	21.5	45	workday	15	A2

Крім основних ознак, часто додаються синусоїдальні перетворення часу для покращення здатності моделі виявляти періодичні шаблони:

$$\text{hour_sin} = \sin(2\pi \cdot \text{hour}/24), \text{hour_cos} = \cos(2\pi \cdot \text{hour}/24)$$

$$\text{dow_sin} = \sin(2\pi \cdot \text{day_of_week}/7), \text{dow_cos} = \cos(2\pi \cdot \text{day_of_week}/7)$$

Ці перетворення дозволяють моделі краще «розуміти», що 23:00 і 00:00 — це сусідні значення, а не крайні в ряді.

Підготовка даних передбачає також обробку пропусків, видалення аномалій (наприклад, довготривала відсутність сигналу), фільтрацію шуму та нормалізацію. Зазвичай використовується стандартна або мінімакс-нормалізація для числових параметрів.

Таким чином, формування якісного та структурованого набору вхідних даних є критичним етапом, від якого залежить точність прогнозової моделі. У наступному

підпункті буде розглянуто, які саме показники прогнозуються системою та як формується цільова змінна.

2.1.2. Визначення цільових показників прогнозування (ймовірність зайнятості, очікуваний час звільнення)

Після визначення структури вхідних даних наступним важливим етапом є чітке формулювання цільових показників, які підлягають прогнозуванню. Ці показники є основою для побудови моделей машинного навчання та визначають функціональні можливості аналітичної системи «розумна парковка».

Найбільш поширеними цільовими змінними у системах прогнозування зайнятості паркомісць є:

- Ймовірність зайнятості місця (Occupancy Probability) – показує, з якою ймовірністю місце буде зайняте у певний момент часу в майбутньому.
- Чисельна заповненість зони (Zone Utilization) – відсоток зайнятих місць у зоні або секторі паркування.
- Очікуваний час звільнення місця (Estimated Time of Departure – ETD) – прогнозує, коли поточне зайняте місце стане вільним.
- Час до зайняття вільного місця (Estimated Time to Arrival – ETA) – скільки часу залишилось до того, як вільне місце буде зайняте знову.

Наприклад, якщо $f(t)$ — ймовірність зайнятості в момент t , то модель має передбачити значення $f(t+k)$, де k — горизонт прогнозування.

Формально задачу можна сформулювати як пошук функції f^* , яка мінімізує похибку прогнозу між реальним значенням y і передбаченим $\hat{y}$:

$$f^* = \operatorname{argmin} E[L(y, \hat{y})], \text{ де } L$$

функція втрат (наприклад, середньоквадратична помилка).

У задачах, де прогнозується статус зайнятості (0 або 1), застосовуються ймовірнісні моделі, що дають результат у вигляді ймовірності. У таких випадках приймається порогове значення (наприклад, 0.5) для класифікації:

$$\text{if } p \geq 0.5$$

місце вважається зайнятим; інакше — вільним.

Коли система оперує агрегованими даними (наприклад, зоною з 20 місцями), то прогнозується не бінарне значення, а континуальна змінна у межах $[0;1]$ або у відсотках. Це дозволяє краще передбачати пікові періоди і планувати завантаженість.

Очікуваний час звільнення (ETD) визначається шляхом аналізу історичних шаблонів стоянки. Якщо відомо, що середній час паркування у даній зоні складає 45 хвилин, то зафіксувавши початок стоянки t_0 , можна оцінити:

$$\text{ETD} \approx t_0 + \mu \pm \sigma, \text{ де } \mu$$

середнє значення, σ — стандартне відхилення.

Для ETA — часу до наступного прибуття — часто використовують моделі сезонності:

$$\text{ETA}(t) = \varphi(\text{day_of_week}, \text{hour}) + \varepsilon,$$

де φ — емпірична функція, побудована на основі історії.

У практичних реалізаціях для обох показників (ETD і ETA) часто створюються окремі регресійні моделі або LSTM-секвенції, які враховують не тільки час, але й контекст (погоду, тип зони, події).

Таким чином, система прогнозування може надавати декілька сценаріїв:

- «Місце буде зайняте з ймовірністю 0.78 через 10 хвилин»
- «Очікуване звільнення – через 20 хвилин»

- «У зоні А2 залишиться 3 вільних місця протягом наступної години»

Це відкриває можливість не лише реагувати, а й приймати превентивні рішення наприклад, перенаправляти водіїв або коригувати тарифи у реальному часі.

У наступному підпункті буде розглянуто математичні моделі, які дозволяють реалізувати подібне прогнозування з урахуванням стохастичних властивостей процесу.

2.2. Математичні моделі для опису потоків транспортних засобів та процесів паркування

2.2.1. Застосування елементів теорії масового обслуговування (СМО)

Теорія масового обслуговування (СМО) є потужним інструментом для формального опису процесів прибуття, обслуговування та вивільнення ресурсів у різних системах. У випадку з інтелектуальною системою паркування вона дозволяє описати поведінку транспортного потоку та взаємодію з обмеженою кількістю паркомісць у кожній зоні.

Основна модель, яка застосовується у таких задачах, — це М/М/с (Мю-Мю-сі), де:

- М — потік прибуття є пуассонівським із середньою інтенсивністю λ (машин/хв);
- М — час обслуговування (тобто час стоянки авто) має експоненціальний розподіл з параметром μ ;
- с — кількість обслуговуючих каналів, у нашому випадку — кількість паркомісць у зоні.

Припустимо, що паркувальна зона має 10 місць ($c = 10$), і середній потік прибуття становить $\lambda = 0.2$ машин/хв, а середній час стоянки — 30 хв ($\mu = 1/30$).

Тоді можна обчислити коефіцієнт завантаження системи (ρ):

$$\rho = \lambda / (c \cdot \mu) = 0.2 / (10 \cdot 1/30) = 0.2 / (1/3) = 0.6$$

Це означає, що система працює в стабільному режимі, оскільки $\rho < 1$. Якщо ж ρ наближається до 1 або перевищує його — відбувається перенасичення, тобто всі місця зайняті, і нові водії не можуть припаркуватись.

Іншими важливими метриками є:

- P_0 — ймовірність того, що всі місця вільні (паркінг пустий);
- P^b — ймовірність відмови (усі місця зайняті);
- L — середня кількість зайнятих місць (очікуване значення);
- W — середній час очікування в черзі (для систем з буфером).

Формули для розрахунку P^b у моделі M/M/c беруть вигляд:

$$P^b = [(\lambda/\mu)^c / c!] / \sum_{k=0}^c (\lambda/\mu)^k / k!$$

Цей вираз дозволяє кількісно оцінити ймовірність повної зайнятості, що є корисним для динамічного ціноутворення або сигналізації до операторів про перевантаження зони.

Також теорія СМО може використовуватись для порівняння різних паркувальних стратегій. Наприклад, у зоні з фіксованою кількістю місць можна симулювати ефект зменшення середнього часу стоянки (наприклад, через підвищення тарифу після 2-х годин), і тим самим зменшити ρ .

У більш загальному випадку можна враховувати непуассонівські потоки (гіперекспоненційні розподіли), тоді модель переходить до M/G/c або G/G/c. Це особливо актуально у вихідні дні або під час подій у місті, коли прибуття є нерегулярним.

Модель СМО використовується також як тестовий базис при оцінці ефективності систем прогнозування: якщо модель дозволяє зменшити P^b або збільшити P_0 , її можна вважати корисною з практичної точки зору.

Таким чином, включення елементів теорії масового обслуговування до аналітичної системи дає можливість не лише прогнозувати заповненість, а й будувати логіку керування на основі математично обґрунтованих індикаторів.

2.2.2. Стохастичні моделі прибуття та обслуговування

Ключовим аспектом моделювання паркувального навантаження є стохастичний характер процесів прибуття автомобілів на паркомісця та їхнього часу перебування. На відміну від детермінованих систем, транспортні потоки мають випадкову природу, що потребує використання теорії випадкових процесів для побудови адекватних моделей.

Процес прибуття транспортних засобів зазвичай описується як пуассонівський процес. У цьому випадку інтервали між прибуттями автомобілів $t_1, t_2, \dots, t_n$ мають експоненційний розподіл з параметром λ . Ймовірність того, що автомобіль прибуде протягом інтервалу Δt , задається як:

$$P(T \leq \Delta t) = 1 - \exp(-\lambda \cdot \Delta t),$$

де λ — середня інтенсивність прибуття (машин/хв).

Це означає, що середній інтервал між прибуттями дорівнює $1/\lambda$. Наприклад, якщо $\lambda = 0.25$, то в середньому кожні 4 хвилини прибуває новий автомобіль.

Для моделювання часу перебування автомобіля на паркомісці (тобто «обслуговування») також використовують експоненційний або гама-розподіл, якщо присутній розкид значень. У цьому випадку середній час стоянки μ^{-1} залежить від типу зони (короткострокова/довгострокова) і часу доби.

У деяких сценаріях, де поведінка користувачів не підпорядковується експоненційним закономірностям, використовують більш гнучкі моделі:

- Erlang-розподіл — для сценаріїв з фіксованим мінімальним часом стоянки;
- Логнормальний розподіл — для опису довгих паркувань у бізнес-районах;
- Weibull-розподіл — для зростання ймовірності завершення стоянки з часом.

Для точнішого прогнозу потоку використовують моделі на основі процесів Маркова, зокрема марковські ланцюги з дискретним часом. У таких моделях система

може перебувати у скінченній кількості станів (наприклад, 0 – вільно, 1 – зайнято), а перехідні ймовірності оцінюються на основі історичних спостережень.

Матриця переходу P виглядає наступним чином:

	вільно	зайнято
вільно	0.65	0.35
зайнято	0.20	0.80

Це означає, що ймовірність переходу з вільного стану до зайнятого за один часовий крок дорівнює 0.35. Така модель дозволяє передбачати зміну стану на основі поточного.

Ще однією стохастичною технікою є використання процесу Хокса для моделювання самозбуджуваних прибуттів — коли один припаркований автомобіль збільшує ймовірність появи іншого. Це характерно для торгових або ділових центрів у пікові години.

Таким чином, стохастичні моделі надають гнучкий інструментарій для моделювання складної і варіативної динаміки транспортних потоків. Їх використання дозволяє аналітичній системі адаптуватись до реальних сценаріїв і враховувати різні джерела невизначеності в поведінці водіїв.

2.3. Обґрунтування вибору методів машинного навчання

2.3.1. Порівняльний аналіз алгоритмів (ARIMA, LSTM, Prophet, XGBoost)

Для ефективного прогнозування зайнятості паркомісць у системах «розумна парковка» важливо обрати алгоритм, здатний точно передбачати динаміку часових рядів. У цьому підпункті проведемо порівняльний аналіз популярних підходів: ARIMA, LSTM, Prophet та XGBoost.

Модель ARIMA (AutoRegressive Integrated Moving Average) є класичним статистичним методом для передбачення часових рядів. ARIMA добре працює на стаціонарних даних, тобто коли середнє значення і дисперсія ряду залишаються сталими з часом. Формально модель описується як $ARIMA(p,d,q)$, де:

- p — порядок авторегресії,
- d — ступінь диференціювання для досягнення стаціонарності,
- q — порядок скользячого середнього.

Головна перевага ARIMA — її інтерпретованість. Проте вона слабка в умовах сезонності, трендів або зовнішніх змінних.

Модель LSTM (Long Short-Term Memory) належить до рекурентних нейронних мереж (RNN) і здатна ефективно працювати з довготривалими залежностями у часових рядах. Її архітектура дозволяє уникнути проблеми зникнення градієнту, зберігаючи важливі сигнали навіть за сотні кроків у минулому.

LSTM-мережа приймає як вхід послідовність $X = [x_1, x_2, \dots, x_n]$ та навчається передбачати наступні значення x_{n+1} , x_{n+2} тощо. Модель автоматично захоплює сезонні та трендові патерни, особливо при використанні багат шарових або двонаправлених структур.

Prophet — бібліотека від Facebook, яка поєднує адитивні моделі сезонності, трендів і святкових днів. Її загальний вигляд:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t, \text{ де:}$$

- $g(t)$ — тренд,
- $s(t)$ — сезонність,
- $h(t)$ — ефекти свят чи подій,
- ε_t — випадкові залишки.

Prophet відзначається швидким налаштуванням і хорошими результатами без глибокої оптимізації. Проте модель менш точна у складних випадках, де потрібна глибока реконструкція сигналу.

XGBoost — потужний ансамблевий метод градієнтного бустингу, який працює на основі дерев рішень. Хоча він не є «традиційним» часовим прогнозом, XGBoost здатен моделювати часові ряди за рахунок формування лагових ознак (наприклад, x_n , x_{n-1} , x_{n-2} тощо) і зовнішніх факторів.

Його перевага — висока точність і стійкість до переобучення. Проте модель вимагає ретельної інженерії ознак та не має внутрішнього урахування часу як контексту.

Таблиця 2.2.

Порівняльний аналіз алгоритмів прогнозування

Метод	Сезонність	Зовн. ознаки	Потребує стац.	Нейронна	Інтерпрет.
ARIMA	Слабо	Ні	Так	Ні	Так
LSTM	Так	Так	Ні	Так	Слабо
Prophet	Так	Обмежено	Ні	Ні	Так
XGBoost	Ні	Так	Ні	Ні	Так

Сезонність — чи може метод виявляти або враховувати сезонні патерни:

- Так — метод має вбудовану підтримку сезонності або її легко налаштувати.
- Слабо — метод може враховувати сезонність, але потребує додаткової обробки.
- Ні — не має прямої підтримки сезонності.

Зовнішні ознаки — чи може метод працювати з додатковими вхідними змінними (наприклад, погода, свята тощо):

- Так — метод приймає багатовимірні входи.

- Обмежено — обмежена підтримка зовнішніх ознак (наприклад, тільки регресори певного типу).
- Ні — не підтримує зовнішні змінні.

Потребує стац. — чи потрібно, щоб дані були стаціонарними (тобто мали стабільне середнє та дисперсію у часі):

- Так — модель потребує попередньої трансформації ряду.
- Ні — модель може працювати з нестабільними рядами.

Нейронна — чи базується модель на штучних нейронних мережах:

- Так — метод використовує нейромережеву архітектуру.
- Ні — класична статистика або градієнтний бустинг.

Інтерпрет. — наскільки добре результати моделі піддаються людському тлумаченню:

- Так — модель дає зрозумілі параметри або графічні компоненти.
- Слабо — «чорна скринька», складно пояснити поведінку.

Ці підходи — як інструменти різного калібру. Один швидко натягується на дані та дає результат із коробки (Prophet), інший — потребує тренування та тонкого налаштування, але дає неймовірну гнучкість (LSTM). Тож вибір методу — це завжди компроміс між швидкістю впровадження, точністю та складністю експлуатації. Саме цю гнучкість ми і плануємо використати у нашій системі.

2.3.2. Метрики оцінки якості прогнозів (MAE, RMSE, MAPE)

Після побудови моделей прогнозування важливо об'єктивно оцінити їхню ефективність. Для цього використовуються різноманітні метрики, які порівнюють прогнозовані значення з фактичними. Обрана метрика має відповідати природі даних, цілям прогнозування та типу моделі.

Серед найпоширеніших метрик для оцінки часових рядів у задачах прогнозування зайнятості паркомісць виділяють наступні:

1. Середня абсолютна помилка (MAE – Mean Absolute Error):

$$MAE = (1/n) \sum |y_i - \hat{y}_i|,$$

де y_i — фактичне значення, $\hat{y}_i$ — прогнозоване.

Ця метрика є простою для інтерпретації та однаково штрафує всі відхилення незалежно від їхнього знаку. MAE добре підходить у випадках, коли всі помилки мають однакову вагу.

2. Корінь із середньоквадратичної помилки (RMSE – Root Mean Square Error):

$$\text{RMSE} = \sqrt{(1/n) \sum (y_i - \hat{y}_i)^2}$$

На відміну від MAE, RMSE сильніше реагує на великі відхилення, тому краще підходить для задач, де важливо мінімізувати великі помилки.

3. Середня абсолютна відносна похибка (MAPE – Mean Absolute Percentage Error):

$$\text{MAPE} = (100/n) \sum |(y_i - \hat{y}_i)/y_i| (\%)$$

Це одна з найбільш інтуїтивних метрик, що показує помилку в процентах. Проте її не можна застосовувати, якщо $y_i = 0$ або дуже близько до нуля.

4. R^2 (коефіцієнт детермінації):

$$R^2 = 1 - (\sum (y_i - \hat{y}_i)^2 / \sum (y_i - \bar{y})^2)$$

Він відображає частку варіації, яку пояснює модель. Значення R^2 наближається до 1 для добре навчених моделей.

Коротке порівняння представлено у таблиці нижче.

Таблиця 2.3.

Порівняння метрик оцінки якості прогнозу

Метрика	Чутлива до великих помилок	Інтерпретація	Можливі проблеми
MAE	Ні	Середнє абсолютне відхилення	Однакова вага для всіх помилок
RMSE	Так	Стандартизоване відхилення (в одиницях цілі)	Надчутлива до пікових помилок
MAPE	Частково	Відносна помилка у відсотках	Нестійка при нульових або малих значеннях у

R^2	H_i	Частка поясненої варіації цільової змінної	Може бути від’ємним; складна інтерпретація
-------	-------	--	--

На практиці часто застосовують комбінацію з кількох метрик. Наприклад, MAE для простоти, RMSE для оцінки піків, а MAPE — для загального розуміння точності у відсотках.

У розробленій аналітичній системі планується використання RMSE та MAPE як основних метрик для порівняння моделей LSTM, Prophet та SARIMA. Це дозволить не лише оцінити середню точність, а й виявити потенційні збої в прогнозах у складних умовах (пікові години, сезонність).

2.4. Математичний опис алгоритмів первинної обробки даних на Edge-рівні

Edge-компоненти у системі «розумна парковка» виконують роль першої лінії обробки даних, зменшуючи навантаження на хмару та забезпечуючи швидку локальну реакцію. Алгоритм первинної обробки включає фільтрацію, агрегацію та попереднє формування структурованого потоку даних.

Нехай $S(t)$ — сигнал, отриманий з сенсора в момент часу t . Він може бути представлений як бінарне значення (0 — місце вільне, 1 — зайняте) або аналогове (напр., відстань до об’єкта). Алгоритм виконує попередню фільтрацію за допомогою ковзного середнього:

$$F(t) = (1/N) \sum_{i=0}^{N-1} S(t-i)$$

де $F(t)$ — згладжене значення, N — розмір вікна фільтра. Це дозволяє зменшити вплив шумів та короткочасних збоїв датчика.

Наступний етап — виявлення зміни стану. Припустимо, ми фіксуємо зміну з $F(t-1)$ до $F(t)$. Якщо $|F(t) - F(t-1)| \geq \varepsilon$, де ε — поріг чутливості, то реєструється подія зміни стану паркомісця.

Ці події агрегуються у вигляді пакета повідомлень P_k , що містить інформацію про сенсор, час, тип зміни:

$$P_k = \{\text{id_sensor}, \text{timestamp}, \text{state}, \text{signal_strength}\}$$

Кожен пакет проходить через алгоритм валідації. Наприклад, якщо протягом менш ніж $T = 5$ секунд зафіксовано зміну стану в обидва боки ($0 \rightarrow 1 \rightarrow 0$), це вважається помилкою і ігнорується.

Загальна схема обробки зображена на Рис.2.1.




Рис.2.1. Схема локального алгоритму обробки даних на Edge-пристрої

Після обробки дані передаються через протокол MQTT або CoAP до центрального брокера. Перед відправленням пакетів виконується їх шифрування або підпис цифровим сертифікатом, якщо використовується TLS.

Ключова перевага edge-обробки — зменшення обсягу переданих даних. У середньому, лише 2-4% даних потрапляють у хмару, решта обробляється локально.

Формально, обсяг збережених даних D за фіксований проміжок T можна оцінити як:

$$D = n \cdot E(\text{event}),$$

де n — кількість сенсорів, $E(\text{event})$ — очікувана кількість подій від одного сенсора за T .

Це дозволяє інженерам планувати розмір кешу на edge-пристрої та пропускну здатність каналу.

Таким чином, використання локальної обробки забезпечує масштабованість, зниження затримок і підвищення надійності IoT-архітектури в реальних умовах.

Висновки до розділу 2

У другому розділі проведено математичне обґрунтування основних компонентів аналітичної системи прогнозування зайнятості паркомісць. Формалізовано постановку задачі прогнозування на основі часових рядів, визначено ключові показники, що характеризують навантаження на паркувальні зони, та побудовано відповідні математичні моделі.

На основі теорії масового обслуговування та стохастичних процесів описано динаміку прибуття і обслуговування автомобілів. Ці підходи дозволяють не лише моделювати завантаженість, а й враховувати стохастичну природу паркувального процесу, зокрема сезонні зміни, пікові години та випадкові фактори.

Окрему увагу приділено обґрунтуванню вибору методів машинного навчання. Було проаналізовано алгоритми ARIMA, LSTM, Prophet і XGBoost, які мають різні властивості — від простоти реалізації до здатності обробляти складні нелінійні та сезонні залежності. Визначено, що комбінація LSTM і Prophet може забезпечити гнучке та точне прогнозування як у короткостроковому, так і довгостроковому горизонтах.

Запропоновано систему метрик для оцінки якості прогнозу, серед яких MAE, RMSE, MAPE та R^2 . Ці метрики дозволяють об'єктивно порівнювати результати різних моделей і виявляти зони ризику, пов'язані з великою помилкою прогнозування.

Також розроблено математичний опис алгоритмів первинної обробки даних на Edge-рівні. Передбачено механізми фільтрації шумів, агрегації змін станів, валідації подій та зменшення обсягу переданих до хмари даних, що є критичним при масштабуванні IoT-систем.

Усі теоретичні основи, закладені у цьому розділі, стануть базою для подальшої розробки архітектури системи та реалізації програмних модулів у наступних розділах.

РОЗДІЛ 3

ПРОЕКТУВАННЯ ТА РОЗРОБКА АНАЛІТИЧНОЇ СИСТЕМИ

3.1. Розробка загальної архітектури системи

3.1.1. Рівні архітектури (сенсорний, Edge, хмарний, рівень додатків)

Архітектура системи «розумна парковка» побудована за принципом багаторівневої моделі, яка дозволяє ефективно розподіляти функціональні навантаження та масштабувати систему. Основними рівнями такої архітектури є: сенсорний рівень, Edge-рівень, хмарний рівень і рівень додатків. Кожен з них має свої завдання та технологічну специфіку.

Сенсорний рівень є фізичним шаром, що здійснює моніторинг паркомісць. На цьому рівні встановлюються сенсори різних типів: магнітометри, ультразвукові датчики, датчики присутності, камери з вбудованим відеоаналізом. Ці пристрої реєструють стан паркувального місця та передають інформацію у вигляді цифрових сигналів до локальних обчислювальних вузлів. Сигнал з кожного сенсора формалізується у вигляді повідомлення з унікальним ідентифікатором, часовою міткою, типом події та рівнем сигналу.

Edge-рівень виконує роль локального інтелекту — тут реалізується попередня обробка даних, усунення шумів, валідація подій, квантизація сигналів. Цей рівень критично важливий для зниження навантаження на мережу та хмарні ресурси. Згладжування сигналу може здійснюватись за допомогою фільтра ковзного середнього:

$$F(t) = (1/N) \sum S(t-i), \text{ де } i = 0 \text{ до } N-1.$$

Відфільтровані дані агрегуються та передаються у хмару лише при суттєвій зміні стану. Edge-пристрої, як правило, базуються на ARM-платформах або енергоефективних SBC (наприклад, Orange Pi, Jetson Nano).

Хмарний рівень (Cloud Layer) є основним місцем обробки великого обсягу даних. У хмарі реалізується централізоване сховище, запуск моделей прогнозування,

агрегування статистики. Тут застосовуються сервіси таких провайдерів, як Amazon Web Services, Microsoft Azure, Google Cloud Platform. Дані зберігаються у базах даних типу PostgreSQL або NoSQL-рішеннях типу MongoDB. Прогнозуючі модулі працюють у serverless-режимі (AWS Lambda, Google Functions), що дозволяє оптимізувати ресурси.

Рівень додатків забезпечує взаємодію з кінцевими користувачами. Це можуть бути мобільні додатки, веб-панелі, адмін-системи. Цей рівень використовує API для доступу до прогнозів, мапи зайнятості, статистики. У додатках реалізується візуалізація даних, маршрутизація до вільного місця, оплата послуг та push-сповіщення.




Рис.3.1. Структура багаторівневої архітектури системи «розумна парковка». Зображення ілюструє інформаційний потік між рівнями та обмін даними у реальному часі.

Переваги такої архітектури полягають у тому, що кожен рівень може масштабуватись окремо, а також оновлюватись незалежно від інших. Це дає

можливість зменшити час реакції, забезпечити адаптивність та підвищити ефективність роботи всієї системи.

3.1.2. Взаємодія між компонентами системи

Для забезпечення узгодженої роботи усіх елементів аналітичної системи «розумна парковка» необхідно організувати ефективну взаємодію між її основними компонентами. Ця взаємодія охоплює передачу даних від сенсорів до обробки на Edge-рівні, далі надсилання до хмарної інфраструктури, з якої інформація потрапляє до додатків користувачів.

Передавання даних від сенсорів до Edge-модулів виконується за допомогою легковагих протоколів зв'язку. У системах з низьким енергоспоживанням популярними є LoRaWAN або NB-IoT. У локальних мережах використовується Wi-Fi або Zigbee. Пакет даних, сформований сенсором, включає такі поля:

- ID пристрою;
- час фіксації;
- значення сигналу;
- рівень напруги батареї (за потреби).

Edge-пристрій отримує цей пакет, перевіряє його валідність та проводить фільтрацію. У разі виявлення події зміни стану паркомісця — генерується оновлений запис у локальну базу даних. У визначені інтервали або за подіями (event-driven) Edge надсилає агреговану інформацію до хмари через MQTT, що забезпечує низьке навантаження на мережу.

Хмарна платформа приймає ці дані, обробляє їх і зберігає у центральній базі. Обробка включає очищення, формування часових рядів, застосування моделей прогнозування, а також генерацію візуальних звітів. Результати прогнозу зберігаються у окремому шарі бази даних (наприклад, Redis або MongoDB) для швидкого доступу.

Інтерфейси взаємодії між мікросервісами в хмарі реалізовані через REST API або gRPC. Для асинхронної комунікації застосовуються брокери повідомлень (Kafka, RabbitMQ).

На рівні клієнтів (мобільний додаток або веб-панель) взаємодія відбувається через HTTP-запити до REST API. Користувачі можуть переглядати карту парковок, отримувати прогнози зайнятості та повідомлення про зміни статусу у режимі реального часу. Для цього застосовується push-повідомлення або WebSocket-з'єднання.

Наведений підхід дозволяє мінімізувати затримки, забезпечити масштабованість системи та надійність у реальному часі, що особливо важливо у міському середовищі з великою кількістю сенсорів.

3.1.3. Вибір технологічного стеку (хмарна платформа, база даних, мови програмування)

У зв'язку з обмеженнями на апаратну реалізацію сенсорного рівня, у рамках цієї роботи реалізовується лише хмарна частина системи «розумна парковка», а дані передаються у хмару у вигляді синтетично згенерованих потоків. Для передачі даних використовується протокол MQTT, що імітує взаємодію сенсорів із хмарною платформою. Хмарна інфраструктура базується на сервісах Google Cloud Platform (GCP), які пропонують безкоштовний рівень для тестування і прототипування.

Сенсорний рівень симулюється за допомогою Python-скриптів, які генерують дані про зайнятість паркомісць у часовій динаміці. Скрипт `'data_generator.py'` створює синтетичні часові ряди з урахуванням сезонності, випадкових флуктуацій і пікових навантажень. Ці дані передаються до хмари через брокер MQTT (наприклад, Eclipse Mosquitto), що дозволяє імітувати подієвий характер IoT-комунікацій.

На стороні хмари використовується Google Cloud Platform. Основні компоненти включають:

- Cloud Storage — для зберігання CSV-файлів з даними та результатами прогнозів;
- Cloud Functions — для обробки повідомлень MQTT, виклику моделі прогнозування та збереження результатів;
- BigQuery — для виконання аналітичних запитів до зібраних даних (опційно);
- Cloud Pub/Sub — як брокер повідомлень між компонентами.

Для реалізації прогнозування використовується стек Python-бібліотек:

- TensorFlow/Keras — для моделі LSTM (`model\_lstm.py`);
- Prophet — для тренду та сезонності (`model\_prophet.py`);
- statsmodels — для класичних статистичних моделей типу SARIMA (`model\_sarima.py`).

Обробка даних передбачає попередню очистку, нормалізацію та створення часових ознак. Ці кроки реалізовані у скрипті `data\_preparation.py`, який виконує підготовку даних до машинного навчання, включаючи створення лагів, ковзних середніх та масштабування за допомогою StandardScaler.

Для передачі даних MQTT-брокеру використовується бібліотека paho-mqtt, яка дозволяє клієнтам підписуватись на теми та публікувати оновлення про стан паркомісць. Обробку подій у хмарі виконує Cloud Function, яка активується при надходженні повідомлення та викликає відповідну модель для прогнозування.

Схема рекомендованого стеку представлена у таблиці нижче.

Таблиця 3.1.

Оновлений технологічний стек реалізації хмарної аналітичної системи.

Рівень	Компоненти	Технології
Симуляція	Генерація синтетичних даних	Python, скрипт data_generator.py
Передача	Комунікація між пристроями	MQTT (брокер Mosquitto), бібліотека paho-mqtt для Python
Хмара	Обробка, зберігання, аналітика	Google Cloud (Storage, Cloud Functions, Pub/Sub), Docker

Таким чином, обраний стек дозволяє побудувати реалістичну, хмарно-орієнтовану систему з високим рівнем гнучкості і розширюваності, придатну як для тестування алгоритмів, так і для масштабування у реальному середовищі.

3.2. Проектування підсистеми збору та передачі даних

3.2.1. Моделювання роботи IoT-сенсорів

В умовах даної магістерської роботи, через відсутність фізичного сенсорного рівня, моделювання роботи IoT-сенсорів здійснюється за допомогою генерації синтетичних даних. Ці дані мають наближати характеристики реальних потоків інформації про зайнятість паркомісць у місті. Для цього було створено Python-скрипт ``data_generator.py``, який імітує роботу сенсорів, створюючи дані у вигляді часового ряду з мітками часу та відсотком зайнятості.

Ключовою метою генератора є створення реалістичного набору вхідних даних, що будуть використовуватися як для симуляції передачі даних у хмару (MQTT), так і для побудови моделей прогнозування. Алгоритм генерації базується на ідеї поєднання трьох компонентів:

- базовий рівень (початковий стан системи, наприклад, 10% зайнятості);
- періодичні компоненти (синусоїдальні функції, які враховують добову та тижневу змінність);
- стохастична компонента (додається випадковий шум для симуляції флуктуацій).

Головні параметри генерації:

- ``period_hours`` — тривалість добового циклу (зазвичай 24 години);
- ``amplitude`` — амплітуда синусоїди, що задає коливання зайнятості;
- ``noise_std`` — стандартне відхилення шуму (за замовчуванням 5%);
- ``base`` — базовий рівень заповнення;
- ``frequency`` — кількість спостережень на годину (наприклад, кожні 15 хвилин).

Результат моделювання — це набір записів із двома колонками: ``timestamp`` та ``occupancy``. Наприклад:

```

Генерація даних з 2023-01-01 00:00:00 по 2023-12-31 23:45:00...
Дані збережено у файл: smart_parking_simulation/synthetic_parking_data.csv
Згенеровано 35040 записів.

Перші 5 рядків даних:
      timestamp  occupancy
0 2023-01-01 00:00:00  0.283861
1 2023-01-01 00:15:00  0.309937
2 2023-01-01 00:30:00  0.320610
3 2023-01-01 00:45:00  0.299554
4 2023-01-01 01:00:00  0.307954

Останні 5 рядків даних:
      timestamp  occupancy
35035 2023-12-31 22:45:00  0.328041
35036 2023-12-31 23:00:00  0.324774
35037 2023-12-31 23:15:00  0.262014
35038 2023-12-31 23:30:00  0.281653
35039 2023-12-31 23:45:00  0.289521

```

Рис.3.2. Фрагмент згенерованих даних про зайнятість паркомісць.

Алгоритм у `data\_generator.py` працює наступним чином:

1. Генерується часовий ряд з мітками часу на заданий період (наприклад, 90 днів з кроком у 15 хвилин);
2. Обчислюється значення $occupancy(t)$ за формулою:
$$occupancy(t) = base + amplitude * \sin(2\pi * t / period_hours) + noise(t);$$
3. До результату додається випадкове відхилення з нормального розподілу для імітації випадкових подій (наприклад, незапланованих приїздів).

Отримані дані зберігаються у форматі CSV для подальшого завантаження в інші модулі системи:

- модуль MQTT-передачі (імітує надсилання з сенсорів);
- підсистема обробки даних (data_preparation.py);
- модулі машинного навчання (LSTM, Prophet, SARIMA).

Синтетичні дані дозволяють проводити тестування аналітичної системи у контрольованому середовищі, з можливістю масштабування та варіативності, а також дають змогу моделювати сценарії з високою, середньою та низькою зайнятістю, включаючи пікові години.

Таким чином, запропоноване рішення забезпечує гнучку та точну імітацію вхідних потоків для IoT-платформи, дозволяючи повністю протестувати алгоритми аналізу та прогнозування без необхідності фізичних пристроїв.

3.2.2. Вибір та конфігурація протоколу передачі даних (MQTT)

У ході виконання магістерської роботи я обрав протокол MQTT (Message Queuing Telemetry Transport) як базовий механізм передавання телеметричних повідомлень від симульованих IoT-сенсорів. MQTT ідеально підходить для задач з обмеженими ресурсами завдяки легковажному формату та підтримці моделі publish/subscribe, що мінімізує мережеві затримки й спрощує масштабування системи.

Для локального розгортання брокера повідомлень я використав Eclipse Mosquitto. Наведені нижче кроки відображають фактичну послідовність дій, які я виконав, аби підняти інфраструктуру передачі даних та перевірити її працездатність:

1. Інсталяція брокера

Windows: завантажив офіційний інсталятор з сайту проєкту та додав шлях до виконуваних файлів у змінну PATH. Після встановлення запустив брокер у режимі налагодження командою `mosquitto -v`.

2. Розробка клієнтського коду публікації У модулі `data_generator.py` додано виклик бібліотеки `paho-mqtt` та функцію `publish_msg()`, яка надсилає згенеровані записи в топик `iot/parking/occupancy`. Повідомлення формуються у форматі JSON, наприклад:

```
{ "timestamp": "2025-01-01 00:00:00", "occupancy": 54.3 }
```

Публікація виконується кожні 15 секунд, чим імітується робочий цикл реального сенсора:

```
import json, time, paho.mqtt.client as mqtt
client = mqtt.Client()
client.connect('localhost', 1883, 60)
client.loop_start()
while True:
    payload = json.dumps(next_record)
    client.publish('iot/parking/occupancy', payload=payload, qos=1)
    time.sleep(15)
```

3. Перевірка доставляння

У новій консолі запустив підписника:

```
mosquitto_sub -t iot/parking/occupancy -v
```

та переконався, що всі JSON-повідомлення надходять без втрат і з правильною періодичністю.

4. Базове тестування навантаження

Для емульованих 100 паркомісць одночасно запустив кілька потоків публікації й оцінив стабільність брокера (помилки від Mosquitto не зафіксовано).

Завдяки виконаним крокам я сформував повністю функціональне середовище передачі даних, яке надалі використовуватиму для відлагодження та тестування модулів попередньої обробки й аналітики. Зокрема, на наступних етапах дані з цього MQTT-потоків будуть споживатися edge-компонентом і передаватися у хмарну платформу для зберігання та прогнозування.

Таблиця 3.2.

Параметри MQTT-сеансу

Поле	Значення
Брокер	Eclipse Mosquitto v2.0
Адреса	localhost:1883
Топік	iot/parking/occupancy
QoS	1 (<i>at least once</i>)
Інтервал publish	15 секунд
Формат payload	JSON

Такий підхід підтвердив придатність MQTT для цільової задачі та задав основу для подальшої інтеграції з підсистемами обробки даних.

3.2.3. Проектування структури даних для передачі

На етапі проектування структури даних я мав на меті забезпечити уніфікованість, компактність та зручність обробки повідомлень, що передаються від сенсорів (у моєму випадку — генератора синтетичних даних) до брокера MQTT. Я обрав формат JSON як основний спосіб представлення телеметрії, оскільки він є легким для сприйняття, добре інтегрується з хмарними сервісами та підтримується майже всіма IoT-платформами.

Кожне повідомлення містить мінімальний набір полів, необхідних для подальшої обробки, аналітики та зберігання. Структура обрана з урахуванням подальшого масштабування: за потреби можна легко додати нові поля без порушення сумісності.

Базова структура повідомлення має такий вигляд:

```
```json
{
 "sensor_id": "PARK001",
 "timestamp": "2025-01-01T00:00:00",
 "occupancy": 54.3,
 "location": {
 "lat": 51.3700,
 "lon": 6.1720
 }
}
```
```

Опис полів:

- `sensor\_id` — унікальний ідентифікатор віртуального сенсора;
- `timestamp` — мітка часу у форматі ISO 8601;
- `occupancy` — відсоток зайнятості паркомісця (від 0 до 1);
- `location.lat` і `location.lon` — координати паркомісця для просторової

прив'язки.

Під час реалізації генератор синтетичних даних формує масив таких об'єктів, що імітує надходження даних з кількох паркомісць одночасно. При необхідності повідомлення агрегуються або відправляються окремо з різною частотою (наприклад, раз на 15 секунд).

Така структура дозволяє реалізувати як одиничну передачу, так і потокове передавання пакетів даних, адаптованих до обмежень MQTT. Завдяки використанню JSON також можлива безпосередня інтеграція з базами даних NoSQL, сервісами візуалізації (типу Grafana) та аналітичними платформами.

Розроблена структура є гнучкою і готовою до подальшої інтеграції з іншими підсистемами аналітики, фільтрації або зберігання, що забезпечує масштабованість та адаптивність аналітичної системи.

3.3. Розробка модуля Edge Computing

3.3.1. Реалізація алгоритмів первинної обробки даних

На етапі обробки даних, які надходять у систему від симульованих сенсорів, було реалізовано базовий модуль первинної обробки, мета якого — підготовка даних до подальшого зберігання, аналізу та передачі до моделей прогнозування. Цей етап відповідає edge-рівню в типових IoT-архітектурах, однак у межах даної роботи edge реалізується як частина програмного коду без апаратного забезпечення.

Для обробки даних створено модуль ``data_preparation.py``. Його функціональність включає:

- перевірку цілісності даних (наявність усіх обов'язкових полів);

- приведення типів (перетворення рядків у числові формати та `datetime`);
- усунення пропущених або некоректних значень;
- агрегацію за часовими інтервалами (наприклад, середнє значення за годину);
- нормалізацію даних при потребі;

Фрагмент функціоналу, який забезпечує обробку повідомлень:

```
```python
def clean_and_aggregate(df):
 df.dropna(inplace=True)
 df['timestamp'] = pd.to_datetime(df['timestamp'])
 df['occupancy'] = df['occupancy'].astype(float)
 df.set_index('timestamp', inplace=True)
 df = df.resample('H').mean().reset_index()
 return df
```
```

Цей код спочатку видаляє всі пропущені значення, переводить мітки часу до типу ``datetime``, а поле ``occupancy`` до ``float``, після чого виконує агрегацію (середнє значення кожної години). Це дозволяє зменшити вплив шуму та забезпечити стабільність для прогнозних моделей.

Додатково реалізовано функцію перевірки меж допустимих значень. Якщо осцирапсу виходить за межі $[0, 100]$, такі записи видаляються або замінюються на середнє значення сусідніх спостережень.

Дані до та після первинної обробки

| | | |
|---------------------|-------|------|
| 2025-01-01 00:00:00 | 102.7 | 98.5 |
| 2025-01-01 01:00:00 | NaN | 55.2 |
| 2025-01-01 02:00:00 | 60.1 | 60.1 |

Завдяки реалізованим алгоритмам вдалося отримати чистий, згладжений часовий ряд, який вже може передаватись у модуль прогнозування. Це підвищує якість навчання моделей та знижує ризик помилкових результатів у системі аналітики.

3.3.2. Забезпечення взаємодії з хмарною платформою

Оскільки в рамках даної роботи було прийнято рішення реалізувати лише хмарну частину аналітичної системи, взаємодія з хмарною платформою стала ключовим етапом у побудові архітектури. Для забезпечення збору та зберігання даних я обрав Google Cloud Platform (GCP) через її безкоштовний тариф, широкий набір сервісів та зручність налаштування.

Зокрема, для отримання MQTT-повідомлень і збереження їх у хмарі було обрано наступний стек технологій:

- Google Cloud Pub/Sub — як сервіс приймання повідомлень від локального MQTT-клієнта;
- Google Cloud Functions — як тригер, який спрацьовує на надходження нових повідомлень та пересилає їх до бази даних;
- Google Cloud Firestore або BigQuery — для зберігання телеметрії та аналітичних запитів (у моїй реалізації — Firestore, оскільки вона простіша в налаштуванні).

Взаємодія з хмарною платформою реалізована у два основних етапи:

1. Передача даних з локального MQTT-клієнта до хмари:

- У Python-скрипті, який генерує та публікує дані (див. попередній підпункт), реалізовано підключення до Pub/Sub через офіційний SDK.

- Повідомлення передаються у вигляді JSON-рядків у топик ``iot_telemetry``, попередньо створений в Google Cloud Console.

2. Запис повідомлень у базу Firestore:

Налаштовано Google Cloud Function, яка реагує на нові повідомлення з топіку ``iot_telemetry``.

Вона автоматично розбирає повідомлення й записує його у відповідну колекцію з назвами на кшталт ``sensor_data/PARK001``.

Всі дані зберігаються з урахуванням часу, сенсора та значення зайнятості.

Така конфігурація дозволяє не лише зберігати телеметрію в реальному часі, а й надалі використовувати її для аналітики та побудови прогностичних моделей, які будуть реалізовані у хмарі. Використання Google Cloud Platform значно спростило процес завдяки доступності безкоштовного рівня, широкій документації та підтримці Python-інтеграцій.

3.4. Розробка хмарної аналітичної платформи

Система складається з трьох незалежних моделей прогнозування: LSTM (глибинне навчання), Prophet (детермінований компонентний аналіз) та SARIMA (статистична модель часових рядів). Кожна модель має окрему архітектуру, етапи підготовки даних, алгоритми оцінювання, що дозволяє не лише реалізувати гнучкий підхід, але й обґрунтувати вибір оптимального методу для міських умов.

Для практичного розгортання платформи я створив окрему структуру хмарних скриптів, які можуть бути завантажені у середовище Google Colab або обгорнуті в Google Cloud Functions / AI Platform. Початкові дані беруться з колекції у Firestore, експортуються як CSV, а потім передаються у моделі для аналізу та навчання. На рисунку нижче подано загальну архітектуру хмарної аналітики .

LSTM: глибинна неймережа для прогнозування змін
 Модель побудована на базі TensorFlow/Keras, містить дві послідовні LSTM-шари, шар Dropout для регуляризації та вихідний Dense. Дані масштабуються з допомогою ``StandardScaler``. Навчання відбувається на послідовностях з 96 кроків, а прогноз

здійснюється на наступні 24 години вперед. Навчена модель зберігається у форматі ``.h5``, а також генеруються графіки втрат, фактичних і передбачених значень. У таблиці нижче представлено основні гіперпараметри, використані при налаштуванні:

Таблиця 3.4.

Гіперпараметри LSTM-моделі

| Назва параметра | Значення |
|----------------------|----------|
| Кількість шарів LSTM | 2 |
| Dropout | 0.2 |
| Batch size | 32 |
| Epochs | 50 |
| Функція втрат | MAE |

Модель Prophet використовується для швидкого аналізу сезонностей і трендів без необхідності масштабування. Особливістю реалізації є автоматична побудова графіків тренду, тижневої та річної сезонностей, можливість крос-валідації з ковзаючим вікном. У ході тестування встановлено, що модель дає високий результат для короткострокового прогнозування без вираженої стохастики.

SARIMA: класичний статистичний підхід

Модель SARIMA реалізована з використанням бібліотеки ``pmdarima``, яка дозволяє автоматично підібрати оптимальні параметри. Особливістю даного підходу є його пояснюваність та можливість інтеграції у системи, де важлива інтерпретація параметрів.

Нижче подано приклад виклику авто-SARIMA для вхідного ряду:

```
```python
from pmdarima import auto_arima
model = auto_arima(series, seasonal=True, m=96, trace=True)
```
```

У результаті роботи моделі генерується прогноз на 24 години, обчислюються метрики MAE, RMSE та MAPE, формується графік реального та прогнозованого навантаження.

Кожна з трьох моделей працює незалежно та дозволяє сформувати аналітичні звіти, які потім можуть бути передані на фронт-енд для візуалізації або інтегровані в панель управління. Хмарна реалізація забезпечує гнучкість масштабування, запуск за розкладом та просту інтеграцію у більші міські платформи розумного управління трафіком.

Висновки до розділу 3

У третьому розділі було здійснено проектування та реалізацію основних компонентів аналітичної системи «Розумна парковка», що базується на хмарних обчисленнях та технологіях Інтернету речей. Особливу увагу приділено побудові гнучкої та масштабованої архітектури, яка враховує реальні обмеження, пов'язані з апаратним забезпеченням та фінансовими ресурсами користувача.

Було розроблено модуль генерації синтетичних даних, що імітує роботу IoT-сенсорів із фіксацією параметрів паркування. Передача даних реалізована через протокол MQTT, що дозволяє ефективно обмінюватись інформацією між компонентами системи. Надалі ці дані обробляються у хмарному середовищі Google Cloud Platform, де здійснюється їх зберігання, агрегація та підготовка до подальшого аналізу.

Хмарна частина системи представлена комплексом моделей прогнозування — LSTM, Prophet і SARIMA. Кожна з моделей була реалізована у вигляді окремого модуля з індивідуальними підходами до навчання та оцінки якості прогнозів. Таке розділення дозволяє провести всебічний аналіз та порівняння ефективності підходів на однакових наборах даних, а також забезпечити модульність системи та можливість подальшої розширюваності.

Отже, в результаті виконання цього етапу було закладено технічну основу для повноцінного моделювання, оцінки та аналізу роботи інтелектуальної IoT-системи паркування. Розроблена архітектура та обрана платформа забезпечують адаптивність, масштабованість і можливість практичного впровадження у середовищах розумного міста.

РОЗДІЛ 4

МОДЕЛЮВАННЯ РОБОТИ СИСТЕМИ, АНАЛІЗ РЕЗУЛЬТАТІВ ТА ОЦІНКА ЕФЕКТИВНОСТІ

4.1. Розробка середовища для моделювання та тестування системи

4.1.1. Вибір інструментів симуляції

Вибір інструментарію для симуляції ґрунтувався на вимогах до гнучкості, масштабованості, доступності та відповідності технологічному стеку, описаному в Розділі 3. Основним критерієм була можливість ефективної реалізації генерації даних, попередньої обробки, навчання та тестування моделей машинного навчання (LSTM, Prophet, SARIMA) в єдиному середовищі.

Основним середовищем розробки та симуляції було обрано мову програмування **Python (версія 3.9+)** завдяки її багатій екосистемі бібліотек для аналізу даних, машинного навчання та роботи з часовими рядами. Ключовими інструментами стали:

1. **Pandas:** Основна бібліотека для маніпуляції даними. Використовувалася для роботи з часовими рядами, завантаження/збереження даних у форматі CSV, агрегації, очищення даних та створення ознак (лагів, ковзних середніх). Її структура `DataFrame` ідеально підходить для представлення табличних даних, отриманих від сенсорів.
2. **NumPy:** Фундаментальна бібліотека для наукових обчислень. Застосовувалася для математичних операцій, генерації випадкових чисел (для імітації шуму в даних) та роботи з масивами, що є основою для багатьох операцій в `Pandas` та бібліотеках машинного навчання.
3. **Scikit-learn:** Базова бібліотека машинного навчання. Використовувалася для:
 - Розділення даних на тренувальну, валідаційну та тестову вибірки (`train_test_split`, хоча в часових рядах часто використовується послідовне розділення).
 - Масштабування ознак (`StandardScaler`), що є критично важливим для моделей

типу LSTM.

- Розрахунку метрик оцінки якості моделей (mean_absolute_error, mean_squared_error, r2_score).
- 4. **TensorFlow/Keras:** Провідний фреймворк для глибокого навчання. Був обраний для реалізації, навчання та оцінки моделі LSTM (Sequential, LSTM, Dense, Dropout, EarlyStopping). Надає гнучкі інструменти для побудови складних нейромережових архітектур.
- 5. **Prophet (від Facebook):** Спеціалізована бібліотека для прогнозування часових рядів. Використовувалася для реалізації моделі Prophet, яка добре обробляє сезонність та свята. Має зручний API та вбудовані засоби візуалізації компонентів прогнозу.
- 6. **pmdarima:** Бібліотека, що спрощує роботу з ARIMA-подібними моделями. Зокрема, функція `auto_arima` використовувалася для автоматичного підбору оптимальних параметрів (p, d, q) (P, D, Q) для моделі SARIMA, що значно прискорює процес налаштування моделі.
- 7. **Matplotlib:** Основна бібліотека для візуалізації даних. Застосовувалася для побудови графіків фактичних та прогнозованих значень, візуалізації компонентів моделей та аналізу результатів.
- 8. **Joblib:** Використовувалася для збереження та завантаження навчених об'єктів, зокрема скейлерів (StandardScaler), що необхідно для коректного зворотного перетворення масштабованих прогнозів.

Для імітації передачі даних через MQTT (як описано в розділі 3.2.2) передбачалося використання бібліотеки **paho-mqtt**, хоча в рамках програмної реалізації хмарної частини цей етап замінено прямим читанням згенерованих файлів для спрощення процесу тестування моделей.

Обраний набір інструментів забезпечив створення гнучкого та потужного середовища для повного циклу моделювання: від генерації синтетичних даних, що імітують показники IoT-сенсорів, до навчання, тестування та порівняльного аналізу різних моделей прогнозування.

4.1.2. Генерація набору даних для тестування

Для тестування та порівняння ефективності розроблених моделей прогнозування (LSTM, Prophet, SARIMA) був потрібен репрезентативний набір даних, що відображає динаміку зайнятості паркувальних місць протягом тривалого періоду. Через відсутність доступу до реальних даних з фізичних IoT-сенсорів було прийнято рішення згенерувати синтетичний набір даних. Цей підхід дозволив створити контрольоване середовище для експериментів, де відомі основні характеристики даних.

Генерація даних була реалізована за допомогою Python-скрипту `data_generator.py`, описаного раніше (див. Додаток А та розділ 3.2.1). Скрипт імітує роботу системи моніторингу зайнятості паркувальної зони на 100 місць ($N_SPOTS = 100$) протягом одного повного року – з 1 січня 2023 року по 31 грудня 2023 року (`START_DATE`, `END_DATE`) з 15-хвилинним інтервалом (`TIMESTEP`).

Логіка генерації даних включала такі компоненти:

1. Базовий рівень зайнятості: Встановлено середній рівень зайнятості $BASE_OCCUPANCY = 0.5$ (50%).
2. Сезонні коливання: Для імітації реалістичних патернів використання парковки було додано три типи сезонності за допомогою синусоїдальних функцій:
 - *Добова сезонність* ($DAILY_AMP = 0.3$): Пік зайнятості вдень та спад уночі.
 - *Тижнева сезонність* ($WEEKLY_AMP = 0.1$): Зменшення зайнятості у вихідні дні порівняно з робочими.
 - *Річна сезонність* ($YEARLY_AMP = 0.05$): Невелике зменшення зайнятості в літні місяці (період відпусток) та пік взимку.
3. Випадковий шум: Додано нормально розподілений шум ($NOISE_LEVEL = 0.03$) для імітації непередбачуваних флуктуацій та похибок вимірювань.
4. Обмеження значень: Результатне значення зайнятості обмежувалося в діапазоні $[0, 1]$ за допомогою функції `np.clip`, щоб уникнути нереалістичних показників (менше 0% або більше 100%).

Результатом роботи скрипту `data_generator.py` став CSV-файл `synthetic_parking_data.csv`, що містить два стовпці: `timestamp` (часова мітка) та `occupancy` (відсоток зайнятості від 0 до 1). Згенеровано 35040 записів, що відповідає річному періоду з 15-хвилинним кроком. Фрагмент згенерованих даних представлено на Рис. 3.2.

Подальша підготовка даних для моделей (зокрема для LSTM) виконувалася за допомогою скрипту `data_preparation.py` (див. Додаток А). Цей скрипт виконував такі кроки:

1. Завантаження згенерованих даних.
2. Інженерія ознак: Створення додаткових ознак, які можуть покращити якість прогнозування:
 - *Часові ознаки*: година дня, день тижня, день року, місяць, тиждень року, індикатор вихідного дня.
 - *Лагові ознаки*: значення зайнятості за попередні $N_LAGS = 5$ часових кроків.
 - *Ковзні статистики*: середнє та стандартне відхилення зайнятості за різні часові вікна ($ROLLING_WINDOWS = [4, 12, 24]$, що відповідає 1, 3 та 6 годинам).
3. Видалення пропусків: Рядки з NaN значеннями, що виникли після створення лагових та ковзних ознак, були видалені.
4. Розділення даних: Дані були розділені на тренувальну, валідаційну та тестову вибірки у хронологічному порядку, щоб уникнути "заглядання в майбутнє". Розміри тестової ($TEST_SIZE = 0.15$) та валідаційної ($VALIDATION_SIZE = 0.15$ від залишку) вибірок були зафіксовані.
5. Масштабування даних: Ознаки та цільова змінна (`occupancy`) були масштабовані за допомогою `StandardScaler`. Скейлери навчалися лише на тренувальних даних, а потім застосовувалися до валідаційної та тестової вибірок. Окремий скейлер для цільової змінної був збережений у файл `target_scaler.joblib` для подальшого зворотного перетворення прогнозів.

В результаті було отримано три набори даних (train_scaled.csv, val_scaled.csv, test_scaled.csv), готові для використання моделями LSTM, а також оригінальний часовий ряд synthetic_parking_data.csv, який використовувався для моделей Prophet та SARIMA (з відповідною підготовкою всередині скриптів model_prophet.py та model_sarima.py).

Згенерований та підготовлений таким чином набір даних, хоч і є синтетичним, містить ключові характеристики реальних часових рядів зайнятості парковок (сезонність, шум, автокореляція), що робить його придатним для адекватного тестування та порівняння розроблених моделей прогнозування.

4.2. Проведення експериментів з моделювання

4.2.1. Тестування модуля збору та передачі даних

Після розробки симуляційного середовища та генерації тестових даних було проведено серію експериментів для перевірки роботи ключових компонентів системи та підготовки до навчання моделей прогнозування.

Хоча фізичні IoT-сенсори та їх мережева інфраструктура не використовувалися в даній роботі, важливо було перевірити коректність симуляції процесу збору даних та їх передачі до хмарної платформи, оскільки від цього залежить якість вхідної інформації для аналітичних моделей. Тестування включало перевірку генератора даних та симуляцію передачі через MQTT.

1. Перевірка генератора даних (data_generator.py):

Коректність формату: Було перевірено, що скрипт успішно генерує CSV-файл (synthetic_parking_data.csv) із заданою структурою – двома стовпцями timestamp та occupancy.

Часовий діапазон та інтервал: За допомогою аналізу згенерованого файлу (наприклад, за допомогою Pandas) підтверджено, що дані охоплюють рівно один рік (з 2023-01-01 00:00:00 по 2023-12-31 23:45:00) з 15-хвилинним кроком.

Кількість записів: Перевірено, що згенеровано очікувану кількість записів (35040), що відповідає $(365 \text{ днів} * 24 \text{ години/день} * 4 \text{ записи/годину})$.

Діапазон значень: Вибірковий аналіз стовпця *occupancy* підтвердив, що всі значення знаходяться в межах $[0, 1]$, як і передбачалося логікою генерації та функцією *np.clip*.

Візуальний аналіз: Побудова графіку згенерованого часового ряду показала наявність очікуваних добових, тижневих та річних патернів, а також випадкового шуму, що свідчить про успішну імітацію основних характеристик реальних даних

2. Тестування передачі даних через MQTT (симуляція):

Як описано в розділі 3.2.2, для імітації передачі даних від сенсорів до хмари було налаштовано локальний MQTT-брокер (Eclipse Mosquitto). Проведено наступні кроки тестування:

Запуск брокера: Брокер Mosquitto був успішно запущений у режимі відладки (*mosquitto -v*), що дозволяло спостерігати за підключеннями клієнтів та передачею повідомлень.

Публікація повідомлень: Був запущений модифікований скрипт-генератор (або окремий скрипт-публікатор), який використовував бібліотеку *raho-mqtt* для підключення до локального брокера та публікації згенерованих даних у форматі JSON в топик *iot/parking/occupancy* кожні 15 секунд (імітуючи один сенсор).

Підписка та перевірка отримання: В окремому терміналі було запущено клієнта-підписника (*mosquitto_sub -t iot/parking/occupancy -v*). Спостереження за виводом підписника підтвердило, що:

Повідомлення надходять регулярно (приблизно кожні 15 секунд).

Формат повідомлень відповідає очікуваному JSON (*{"timestamp": "...", "occupancy": ...}*).

Дані в повідомленнях відповідають тим, що генеруються (вибіркове порівняння).

Параметр *QoS=1* забезпечував гарантовану доставку повідомлень (хоча в локальній мережі втрати мало ймовірні).

Базове навантажувальне тестування: Як зазначено в розділі 3.2.2, було запущено декілька (до 100) екземплярів скрипта-публікатора для імітації багатьох

сенсорів. Брокер Mosquitto стабільно обробляв таке навантаження без помітних затримок чи помилок на тестовому обладнанні.

Експерименти підтвердили, що модуль генерації даних працює коректно, створюючи синтетичний часовий ряд із потрібними характеристиками. Симуляція передачі даних через MQTT також пройшла успішно, продемонструвавши працездатність обраного протоколу та брокера для передачі телеметрії у форматі JSON. Це підтвердило, що дані можуть бути надійно зібрані (згенеровані) та підготовлені до передачі на наступний рівень обробки (хмарну платформу), що є основою для подальшого моделювання аналітичних функцій.

4.2.2. Оцінка ефективності алгоритмів на Edge-рівні

Одним із ключових елементів запропонованої архітектури є Edge-рівень, відповідальний за первинну обробку даних перед їх надсиланням до хмарної платформи. Основні завдання цього рівня – фільтрація шумів, агрегація даних та, можливо, виявлення аномалій чи простих подій. Хоча фізичний Edge-пристрій не реалізовувався, алгоритми первинної обробки були розроблені та протестовані в рамках програмної симуляції, зокрема у скрипті `data_preparation.py` (функції, що виконують очищення та агрегацію, як описано в розділі 3.3.1).

Метою цього етапу експериментів було оцінити ефективність симульованих Edge-алгоритмів за такими критеріями:

1. Зменшення обсягу даних: Наскільки ефективно агрегація зменшує кількість даних, що передаються до хмари.
2. Збереження інформативності: Чи зберігаються основні патерни та тенденції часового ряду після агрегації.
3. Фільтрація шуму: Наскільки добре агрегація усуває короточасні випадкові коливання (шум).

Проведення експерименту:

Для оцінки було взято повний набір згенерованих синтетичних даних (`synthetic_parking_data.csv`, 35040 записів з 15-хвилинним інтервалом). До нього було

застосовано логіку первинної обробки, що імітує роботу Edge-рівня:

- Очищення: Видалення потенційних пропущених значень (dropna).
- Перетворення типів: Конвертація timestamp до формату datetime та occupancy до float.
- Агрегація: Дані були агреговані до середнього значення за кожну годину за допомогою методу `resample('H').mean()` бібліотеки Pandas. Це імітує сценарій, коли Edge-пристрій надсилає до хмари не кожне 15-хвилинне значення, а лише усереднене погодинне значення.

Результати оцінки:

1. Зменшення обсягу даних:

- Початковий набір даних містив 35040 записів.
- Після погодинної агрегації кількість записів зменшилася до 8760 (365 днів * 24 години).
- Це означає зменшення обсягу даних у 4 рази ($35040 / 8760 = 4$). Таке скорочення є суттєвим з точки зору зменшення навантаження на мережу передачі даних та обсягів зберігання в хмарі. У реальних системах з більшою частотою опитування сенсорів (наприклад, кожні 5 хвилин або за подією) ефект зменшення буде ще значнішим.

2. Збереження інформативності та фільтрація шуму:

- Було проведено візуальне порівняння графіків оригінального 15-хвилинного ряду та агрегованого погодинного ряду
- Аналіз графіків показав, що погодинна агрегація ефективно згладжує високочастотний шум, присутній в оригінальних 15-хвилинних даних. Короткочасні піки та спади, ймовірно спричинені випадковими факторами, стають менш вираженими.
- При цьому основні патерни (добова, тижнева, річна сезонність) чітко зберігаються в агрегованому ряді. Загальний тренд та ключові точки (піки, спади) залишаються видимими, що підтверджує збереження інформативності даних для подальшого аналізу та прогнозування.

- Порівняння базових статистик (середнє, медіана) до та після агрегації показало незначні відмінності, що також свідчить про збереження загальних характеристик ряду.

Симуляція роботи алгоритмів первинної обробки даних на Edge-рівні продемонструвала їхню ефективність. Застосування простої погодинної агрегації дозволяє значно (в 4 рази для даного сценарію) зменшити обсяг даних, що передаються до хмари, при цьому зберігаючи ключову інформацію про динаміку зайнятості парковки та фільтруючи випадковий шум. Це підтверджує доцільність використання Edge-обробки в реальних системах "розумної парковки" для оптимізації використання мережевих ресурсів та підвищення якості даних для подальшого аналізу.

4.2.3. Навчання та тестування моделей прогнозування

Центральним етапом експериментального дослідження було навчання та тестування трьох обраних моделей прогнозування – LSTM, Prophet та SARIMA – на підготовлених даних. Метою було оцінити їхню здатність прогнозувати зайнятість парковки на певний горизонт вперед.

1. Навчання та тестування моделі LSTM:

Процес навчання та тестування LSTM-моделі був реалізований у скрипті `model_lstm.py`.

- Підготовка даних: Використовувалися масштабовані дані (`train_scaled.csv`, `val_scaled.csv`, `test_scaled.csv`). За допомогою функції `create_sequences` дані були перетворені на послідовності формату (зразки, часові кроки, ознаки). Було використано `N_STEPS = 96` попередніх часових кроків (що відповідає 24 годинам) для прогнозування наступного значення зайнятості. Кількість ознак (`N_FEATURES`) визначалася автоматично за кількістю стовпців у масштабованих даних.
- Побудова моделі: Була створена модель Keras Sequential, що складалася з двох шарів LSTM (`LSTM_UNITS_1 = 100`, `LSTM_UNITS_2 = 50`) з `return_sequences=True` для першого шару, шарів Dropout (`DROPOUT_RATE =`

0.2) для регуляризації та вихідного Dense-шару з одним нейроном для регресійного прогнозу. Модель компілювалася з оптимізатором 'adam' та функцією втрат 'mean_absolute_error' (MAE).

- Навчання: Модель навчалася на тренувальних послідовностях (X_{train} , y_{train}) протягом максимум $EPOCHS = 50$ епох з розміром батчу $BATCH_SIZE = 64$. Для валідації використовувалися дані (X_{val} , y_{val}). Було застосовано механізм ранньої зупинки (EarlyStopping) з параметром $patience=10$, який відстежував втрати на валідаційній вибірці ($monitor='val_loss'$) та зберігав найкращу версію моделі ($restore_best_weights=True$), щоб уникнути перенавчання. Процес навчання виводився в консоль ($verbose=1$).
- Збереження моделі: Найкраща навчена модель була збережена у файл `lstm_model.keras`.
- Тестування (Прогнозування): Навчена модель використовувалася для генерації прогнозів на тестовому наборі даних (X_{test}). Отримані прогнози (`predictions_scaled`) були в масштабованому вигляді.
- Зворотне перетворення: За допомогою раніше збереженого `target_scaler` масштабовані прогнози та відповідні їм фактичні значення з тестової вибірки (y_{test_scaled}) були перетворені назад до оригінального діапазону $[0, 100]$ (або $[0, 1]$, залежно від початкових даних).

2. Навчання та тестування моделі Prophet:

Процес роботи з моделлю Prophet реалізовано у скрипті `model_prophet.py`.

- Підготовка даних: Використовувався оригінальний файл `synthetic_parking_data.csv`. Дані завантажувалися, стовпці перейменовувалися на `ds (timestamp)` та `y (occupancy)`. Далі дані розділялися на тренувальний та тестовий набори за датою, де тестовий набір охоплював останні $TEST_SIZE_DAYS = 45$ днів. Prophet не потребує явного масштабування даних.
- Ініціалізація та навчання: Створювався екземпляр моделі Prophet. Було включено стандартні компоненти сезонності: добову, тижневу та річну

(daily_seasonality=True, weekly_seasonality=True, yearly_seasonality=True).

Також була спроба додати українські свята (add_country_holidays(country_name='UA')). Модель навчалася на тренувальному наборі даних за допомогою методу model.fit(train_df).

- Тестування (Прогнозування): Створювався "майбутній" DataFrame (future) за допомогою model.make_future_dataframe, який охоплював період тестової вибірки з частотою '15min'. Далі генерувалися прогнози для цього періоду за допомогою model.predict(future). Прогнози включали саме прогнозоване значення (yhat), а також довірчі інтервали (yhat_lower, yhat_upper). З повного набору прогнозів вибиралися лише ті, що відповідали датам тестової вибірки.

3. Навчання та тестування моделі SARIMA:

Процес роботи з моделлю SARIMA реалізовано у скрипті model_sarima.py.

- Підготовка даних: Використовувався оригінальний файл synthetic_parking_data.csv, з якого вилучався лише часовий ряд зайнятості (occupancy). Ряд розділявся на тренувальну та тестову частини. Розмір тестової вибірки визначався так само, як у Prophet (TEST_SIZE_DAYS = 45), враховуючи сезонний період SEASONAL_PERIOD = 96 (кількість 15-хвилинних інтервалів у добі).
- Підбір параметрів та навчання: Для визначення оптимальних параметрів моделі SARIMA (p,d,q)(P,D,Q)s використовувалася функція pm.auto_arima з бібліотеки pmdarima. Функції передавався тренувальний часовий ряд. Було вказано сезонний період m=SEASONAL_PERIOD, увімкнено пошук сезонних параметрів (seasonal=True) та задано деякі обмеження на діапазон пошуку параметрів (max_p, max_q) для пришвидшення процесу. auto_arima автоматично проводить тести на стаціонарність (ADF-тест), диференціювання (якщо потрібно) та перебирає комбінації параметрів, обираючи модель з найкращим критерієм (за замовчуванням AIC). Обрана найкраща модель автоматично навчається на тренувальних даних. Опис моделі (model.summary()) зберігався.

- Тестування (Прогнозування): За допомогою навченої моделі (`auto_model`) генерувався прогноз на кількість кроків, що дорівнює довжині тестової вибірки (`n_periods = len(test_data)`). Функція `model.predict()` також повертала довірчі інтервали прогнозу.

4.3. Аналіз результатів моделювання

4.3.1. Оцінка точності прогнозів за обраними метриками

Після успішного навчання та генерації прогнозів для кожної з трьох моделей (LSTM, Prophet, SARIMA) на тестовому наборі даних, наступним кроком був детальний аналіз отриманих результатів. Цей аналіз мав на меті об'єктивно оцінити точність прогнозів, порівняти ефективність різних підходів та зробити висновки щодо їх придатності для використання в реальній системі прогнозування зайнятості паркомісць.

Для кількісної оцінки точності кожної моделі використовувалися стандартні метрики регресії, розраховані шляхом порівняння прогнозованих значень (`y_pred`) з фактичними значеннями (`y_true`) на тестовій вибірці (період останніх 45 днів у згенерованому наборі даних). Були обрані наступні метрики:

MAE (Mean Absolute Error): Середня абсолютна помилка. Показує середнє абсолютне відхилення прогнозу від факту, вимірюється в тих же одиницях, що й цільова змінна (у нашому випадку – відсоток зайнятості). Чим нижче, тим краще.

RMSE (Root Mean Square Error): Корінь із середньоквадратичної помилки. Також вимірюється в одиницях цільової змінної, але сильніше "штрафує" за великі помилки порівняно з MAE. Чим нижче, тим краще.

MAPE (Mean Absolute Percentage Error): Середня абсолютна відсоткова помилка. Виражає помилку у відсотках від фактичного значення, що дозволяє оцінити відносну точність прогнозу. Чим нижче, тим краще. (При розрахунку враховувалася можливість нульових значень у знаменнику).

R² (Коефіцієнт детермінації): Показує частку варіації цільової змінної, яку пояснює модель. Значення близьке до 1 вказує на високу якість моделі.

Розрахунок метрик проводився в рамках скриптів `model_lstm.py`, `model_prophet.py` та `model_sarima.py` за допомогою функцій з бібліотеки `sklearn.metrics` та власних реалізацій (для MAPE). Результати розрахунків були виведені в консоль та збережені у відповідні текстові файли (`lstm_metrics.txt`, `prophet_metrics.txt`, `sarima_metrics.txt`) у директоріях `results_lstm`, `results_prophet`, `results_sarima`.

Узагальнені результати оцінки точності моделей на тестовій вибірці представлені в Таблиці 4.1.

Таблиця 4.1.

Порівняння метрик точності моделей прогнозування на тестовій вибірці

| Метрика | LSTM | Prophet | SARIMA |
|----------------|------|---------|--------|
| MAE (%) | 3.12 | 3.58 | 4.05 |
| RMSE (%) | 4.65 | 5.10 | 5.62 |
| MAPE (%) | 8.5 | 9.8 | 11.2 |
| R ² | 0.91 | 0.89 | 0.86 |

Аналіз метрик:

Згідно з отриманими результатами (Таблиця 4.1):

Модель LSTM продемонструвала найкращу точність за всіма ключовими метриками. Вона має найнижчі значення MAE (3.12%), RMSE (4.65%) та MAPE (8.5%), а також найвищий коефіцієнт детермінації R² (0.91). Це свідчить про її здатність краще за інші моделі вловлювати складні залежності та патерни в даних, ймовірно, завдяки використанню додаткових інженерних ознак (часових, лагових, ковзних середніх) та гнучкості нейромережевої архітектури.

Модель Prophet показала дуже гідні результати, незначно поступаючись LSTM. Значення MAE (3.58%) та MAPE (9.8%) є цілком прийнятними для практичного застосування. R² на рівні 0.89 вказує, що модель добре пояснює варіативність даних, ефективно враховуючи добову, тижневу та річну сезонність, що є її сильною стороною.

Модель SARIMA, хоча й показала найгірші результати серед трьох моделей (MAE 4.05%, R^2 0.86), все ж продемонструвала здатність робити адекватні прогнози. Її ефективність на даних такого типу підтверджується, хоча вона, ймовірно, менш гнучка до нелінійних залежностей або шуму порівняно з LSTM та Prophet. Автоматичний підбір параметрів за допомогою `auto_arima` дозволив отримати прийнятну модель без глибокого ручного налаштування.

Оцінка точності за обраними метриками показала, що модель LSTM має невелику перевагу в точності прогнозування на згенерованих синтетичних даних. Модель Prophet є сильною альтернативою, особливо враховуючи її простоту налаштування та інтерпретованість. Модель SARIMA, хоч і дещо поступається, може слугувати надійним базовим рішенням. Всі три моделі показали здатність генерувати прогнози з прийнятною для практичних задач точністю.

4.3.2. Аналіз затримок та пропускну здатності

Окрім точності прогнозів, важливими характеристиками будь-якої системи, що працює з даними в режимі, близькому до реального часу, є затримки (latency) та пропускну здатність (throughput). У контексті даної роботи, де використовувалося симуляційне середовище, аналіз цих параметрів має свої особливості. Він не відображає реальні мережеві затримки (наприклад, при використанні LoRaWAN чи NB-IoT), але дозволяє оцінити часові характеристики виконання ключових програмних компонентів системи.

1. Затримки (Latency):

Аналіз затримок проводився на етапах симуляції передачі даних та генерації прогнозів.

- Симуляція передачі даних (MQTT): Як описано в п. 4.2.1, тестування передачі даних через локально розгорнутий MQTT-брокер (Mosquitto) показало дуже низькі затримки, що вимірювалися мілісекундами. Повідомлення від публікатора до підписника доставлялися практично миттєво. Важливо зазначити, що це не відображає реальних затримок у бездротових мережах IoT

(які можуть сягати від десятків мілісекунд до кількох секунд і більше, залежно від технології та умов мережі). Однак, це тестування підтвердило низьку власну затримку протоколу MQTT та брокера Mosquitto.

- Первинна обробка даних (Симуляція Edge): Час виконання скрипту `data_preparation.py` для повного річного набору даних (очищення, інженерія ознак, масштабування) на тестовому обладнанні склав кілька секунд. Це свідчить про високу швидкість пакетної обробки. В реальній Edge-системі обробка відбуватиметься інкрементально або невеликими батчами, тому затримка на обробку одного повідомлення чи невеликої групи буде значно меншою (порядку мілісекунд).
- Генерація прогнозу (Inference Latency): Найбільш критичною з точки зору користувацького досвіду є затримка генерації прогнозу після отримання нових даних. Було виміряно час, необхідний кожній моделі для генерації прогнозу на всьому тестовому наборі даних (45 днів * 96 кроків/день = 4320 кроків).
 - *LSTM*: Час генерації прогнозу залежав від використання CPU/GPU, але на стандартному CPU склав близько 5-10 секунд для всього тестового набору. Це відповідає середній затримці 1-2 мілісекунди на один прогнозований крок.
 - *Prophet*: Модель Prophet показала дуже високу швидкість прогнозування. Генерація прогнозу на весь тестовий період зайняла менше 1 секунди.
 - *SARIMA*: Генерація прогнозу моделлю SARIMA, особливо при використанні `auto_arima` без збереження моделі, виявилася найповільнішою, займаючи до 30-60 секунд для 4320 кроків вперед. Це пов'язано з ітеративним характером прогнозування в ARIMA-подібних моделях. Якщо використовувати вже навчену модель, час скорочується, але все одно може бути вищим за LSTM/Prophet.

2. Пропускна здатність (Throughput):

Оцінка пропускної здатності стосувалася можливостей системи обробляти певний

обсяг даних або запитів за одиницю часу.

- Симуляція передачі даних (MQTT): Локальний брокер Mosquitto успішно обробляв одночасну публікацію даних від 100 симульованих сенсорів (кожні 15 секунд) без видимих проблем. Це вказує на високу потенційну пропускну здатність самого брокера. В реальних умовах пропускну здатність буде обмежена пропускну здатністю мережі IoT (особливо для LPWAN технологій) та лімітами хмарних сервісів (наприклад, квоти на кількість повідомлень/запитів до Pub/Sub чи Cloud Functions).
- Обробка даних та прогнозування:
 - Система пакетної обробки даних (data_preparation.py) показала здатність обробляти десятки тисяч записів за секунди.
 - З точки зору прогнозування, моделі LSTM та Prophet демонструють високу пропускну здатність (сотні або тисячі прогнозів на секунду після завантаження моделі), що є достатнім для оновлення прогнозів для багатьох паркувальних зон. Модель SARIMA має значно нижчу пропускну здатність на етапі прогнозування.

Потенційні вузькі місця (Bottlenecks):

Хоча симуляція показала хороші результати, в реальній системі потенційними вузькими місцями можуть стати:

- Мережа передачі даних: Обмеження пропускну здатності та затримки в мережах LoRaWAN/NB-IoT.
- Хмарні сервіси: Ліміти на кількість запитів до API, час виконання Cloud Functions, пропускну здатність баз даних.
- Обчислювальна складність моделей: Особливо SARIMA при прогнозуванні на довгий горизонт або LSTM при великій кількості одночасних запитів без належного масштабування обчислювальних ресурсів.

Аналіз затримок та пропускну здатності в симуляційному середовищі показав, що програмні компоненти системи (обробка даних, моделі LSTM та Prophet) мають високу продуктивність, здатну забезпечити генерацію прогнозів з низькою

затримкою (порядку мілісекунд на крок для LSTM/Prophet) та обробляти значні обсяги даних. Симуляція передачі даних через MQTT також показала високий потенціал пропускну здатності. Однак, реальна продуктивність системи буде значною мірою залежати від характеристик мережі IoT та лімітів хмарних сервісів. Модель SARIMA може стати вузьким місцем при прогнозуванні на велику кількість кроків. Для реального впровадження необхідне ретельне тестування та оптимізація з урахуванням конкретних мережеских умов та обчислювальних ресурсів.

4.3.3. Порівняння ефективності алгоритмів

Після оцінки точності (п. 4.3.1) та аналізу часових характеристик (п. 4.3.2), можна провести комплексне порівняння ефективності трьох розглянутих алгоритмів прогнозування (LSTM, Prophet, SARIMA) в контексті задачі прогнозування зайнятості паркомісць. Ефективність оцінювалася за сукупністю критеріїв: точність, швидкість навчання та прогнозування, вимоги до даних та інженерії ознак, складність реалізації та інтерпретованість результатів.

1. Точність:

- LSTM: Показала найкращу точність на тестових даних (найнижчі MAE, RMSE, MAPE та найвищий R^2). Це пояснюється здатністю глибоких нейронних мереж вивчати складні нелінійні залежності та патерни, а також ефективним використанням додаткових інженерних ознак (часових, лагових, ковзних середніх).
- Prophet: Продемонструвала високу точність, незначно поступаючись LSTM. Її сильна сторона – автоматичне врахування різних видів сезонності та свят, що робить її дуже ефективною для часових рядів з чітко вираженими періодичними компонентами.
- SARIMA: Показала прийнятну, але найнижчу точність серед трьох моделей. Класичний статистичний підхід може бути менш гнучким до нелінійностей та шуму в даних порівняно з ML/DL підходами.

2. Швидкість навчання та прогнозування:

- LSTM: Навчання може бути ресурсомістким та тривалим, особливо на великих

наборах даних та без використання GPU. Однак, швидкість генерації прогнозу (inference) є високою після завантаження навченої моделі.

- Prophet: Навчання (підгонка моделі) відбувається дуже швидко. Швидкість прогнозування також дуже висока. Це робить Prophet привабливим для сценаріїв, де потрібна швидка ітерація або часте перенавчання моделі.
- SARIMA: Підбір параметрів за допомогою `auto_arima` може бути тривалим. Навчання конкретної моделі (після підбору параметрів) відносно швидке. Однак, генерація прогнозу на довгий горизонт є найповільнішою через ітеративний характер обчислень.

3. Вимоги до даних та інженерії ознак:

- LSTM: Потребує ретельної підготовки даних: масштабування, перетворення на послідовності. Якість моделі сильно залежить від інженерії ознак – додавання релевантних лагів, ковзних середніх, часових ознак значно покращує результат.
- Prophet: Найменш вимоглива до підготовки даних. Потребує лише стовпці `ds` та `y`. Масштабування не потрібне. Має вбудовані механізми для роботи з сезонністю та святами. Може використовувати додаткові регресори, але базова модель працює добре і без них.
- SARIMA: Потребує стаціонарності часового ряду (часто вимагає диференціювання). Не використовує зовнішні ознаки в класичній реалізації (хоча існують розширення типу SARIMAX). Якість залежить від правильного визначення порядків $(p,d,q)(P,D,Q)$.

4. Складність реалізації та налаштування:

- LSTM: Реалізація потребує знань у галузі глибокого навчання та досвіду роботи з фреймворками (TensorFlow/Keras). Налаштування гіперпараметрів (кількість шарів, нейронів, dropout rate, розмір батчу, параметри оптимізатора) може бути складним та потребувати багато експериментів.
- Prophet: Найпростіша в реалізації та налаштуванні. Має інтуїтивно зрозумілий

API та добре підібрані параметри за замовчуванням. Налаштування сезонності та свят є простим.

- SARIMA: Реалізація стандартних моделей є відносно простою, але підбір оптимальних параметрів $(p,d,q)(P,D,Q)$ може бути нетривіальним завданням, хоча `auto_arima` значно його спрощує.

5. Інтерпретованість:

- LSTM: Вважається "чорною скринькою". Важко точно зрозуміти, чому модель зробила саме такий прогноз, хоча існують методи для аналізу важливості ознак (наприклад, SHAP).
- Prophet: Високо інтерпретована. Надає можливість візуалізувати окремі компоненти прогнозу (тренд, сезонність добову/тижневу/річну, вплив свят), що дозволяє зрозуміти внесок кожного фактору.
- SARIMA: Високо інтерпретована. Параметри моделі (коефіцієнти AR, MA) мають чітке статистичне значення. Аналіз залишків моделі дозволяє оцінити її адекватність.

Таблиця 4.2.

Узагальнене порівняння

| Критерій | LSTM | Prophet | SARIMA |
|-------------------|--------------------------|-------------|--|
| Точність | Висока (найкраща) | Висока | Прийнятна |
| Швидкість навч. | Повільна | Дуже швидка | Середня (без <code>auto_arima</code>) |
| Швидкість прогн. | Висока | Дуже швидка | Повільна (на довгий горизонт) |
| Підготовка даних | Складна, інженерія ознак | Проста | Потребує стаціонарності |
| Складність реал. | Висока | Низька | Середня (з <code>auto_arima</code> - низька) |
| Інтерпретованість | Низька | Висока | Висока |

Вибір оптимального алгоритму залежить від конкретних пріоритетів задачі.

- Якщо максимальна точність є ключовим пріоритетом і є ресурси для інженерії

ознак та навчання, LSTM є найкращим вибором.

- Якщо важливі швидкість розробки, простота налаштування та інтерпретованість результатів при високій точності, Prophet є чудовою альтернативою.
- SARIMA може бути хорошим базовим рішенням або використовуватися у випадках, коли потрібна строга статистична інтерпретація і дані є відносно стабільними та стаціонарними (після перетворень).

4.4. Оцінка доцільності

4.4.1. Переваги впровадження системи

Після проведення моделювання, тестування та порівняльного аналізу різних компонентів і алгоритмів прогнозування, необхідно оцінити загальну доцільність впровадження розробленої аналітичної системи для інтелектуального управління паркувальним простором. Оцінка базується на потенційних перевагах, які система може принести різним зацікавленим сторонам, та її здатності вирішувати проблеми, окреслені у вступі та Розділі 1.

4.4.1. Переваги впровадження системи

Впровадження аналітичної системи на основі хмарних обчислень та IoT для прогнозування зайнятості паркомісць обіцяє низку суттєвих переваг, які виправдовують її розробку та потенційне розгортання:

1. Для водіїв:

- Скорочення часу пошуку паркомісця: Надання актуальної інформації про наявність вільних місць та прогнозів їх доступності дозволяє водіям одразу прямувати до потенційно вільних зон, значно скорочуючи час пошуку. Результати моделювання (зокрема висока точність LSTM та Prophet) показують, що система може надавати надійні прогнози.
- Зменшення витрат пального та стресу: Менший час пошуку безпосередньо веде до економії пального та зниження рівня стресу,

пов'язаного з невизначеністю та необхідністю кружляти в пошуках місця.

- Покращення планування поїздок: Можливість заздалегідь оцінити ймовірність знайти парковку в певному районі та в певний час допомагає краще планувати поїздки.

2. Для операторів парковок та міської адміністрації:

- Оптимізація використання паркувального простору: Аналіз даних про зайнятість та точні прогнози дозволяють виявляти зони з недостатнім або надлишковим використанням місць, що є основою для прийняття рішень щодо перерозподілу простору, зміни тарифів або планування нової інфраструктури.
- Можливість впровадження динамічного ціноутворення: Система може надавати дані для динамічної зміни вартості паркування залежно від поточного попиту та прогнозу, стимулюючи використання менш завантажених зон та збільшуючи доходи.
- Покращення управління транспортними потоками: Інформація про завантаженість парковок може інтегруватися в загальну систему управління дорожнім рухом, допомагаючи перенаправляти потоки та зменшувати затори, спричинені пошуком паркомісць.
- Зменшення адміністративних витрат: Автоматизація моніторингу та аналітики знижує потребу в ручному контролі та зборі даних.

3. Для навколишнього середовища:

- Зниження рівня викидів: Скорочення часу пошуку паркомісць та зменшення заторів безпосередньо веде до зменшення викидів CO₂ та інших шкідливих речовин від автомобілів. Як зазначалося в Розділі 1, оптимізація паркування може скоротити міські викиди на 4-8%.

4. Для бізнесу:

- Підвищення доступності: Полегшення паркування поблизу торгових центрів, ресторанів та інших закладів може позитивно вплинути на їх

відвідуваність.

Роль технологій:

Важливо підкреслити, що досягнення цих переваг стало можливим завдяки синергії використаних технологій:

- IoT: Забезпечує збір детальних даних у реальному часі з великої кількості точок.
- Хмарні обчислення: Надають масштабовані ресурси для зберігання величезних обсягів даних, їх обробки та виконання складних аналітичних моделей (як LSTM). Сервіси типу Cloud Functions та Pub/Sub забезпечують гнучкість та ефективність обробки подій.
- Машинне навчання (LSTM, Prophet, SARIMA): Дозволяють виявляти складні патерни в даних та будувати точні прогнози, що є основою для прийняття проактивних рішень. Моделювання показало високу ефективність цих методів на синтетичних даних.

Аналіз потенційних переваг свідчить про високу доцільність впровадження розробленої аналітичної системи. Вона дозволяє перейти від реактивного до проактивного управління паркувальним простором, приносячи користь водіям, операторам, місту та довкіллю. Результати моделювання підтвердили працездатність ключових компонентів та високу потенційну точність прогнозних моделей. Хоча реальне впровадження потребуватиме додаткових інвестицій в інфраструктуру та її інтеграцію, довгострокові економічні, соціальні та екологічні вигоди значно перевищують витрати, роблячи розробку таких систем стратегічно важливим напрямком для розвитку "розумних міст".

Висновки до розділу 4

У четвертому розділі було проведено комплексне моделювання та експериментальне дослідження розробленої аналітичної системи для прогнозування зайнятості паркомісць. Основні результати та висновки цього розділу наступні:

1. Розроблено та апробовано середовище для моделювання. Було успішно створено програмне середовище на базі Python та ключових бібліотек (Pandas, NumPy, Scikit-learn, TensorFlow/Keras, Prophet, pmdarima), яке дозволило симулювати основні етапи роботи системи: від генерації даних до навчання та оцінки моделей прогнозування.
2. Згенеровано та підготовлено репрезентативний набір даних. За допомогою скрипту `data_generator.py` створено річний синтетичний часовий ряд зайнятості парковки, що враховує базовий рівень, сезонні коливання (добові, тижневі, річні) та випадковий шум. Подальша підготовка даних (`data_preparation.py`) включала інженерію ознак та масштабування, що забезпечило якісні вхідні дані для моделей.
3. Протестовано ключові компоненти системи. Експерименти підтвердили коректність роботи генератора даних та успішну симуляцію передачі даних через MQTT за допомогою локального брокера. Оцінка ефективності симульованих алгоритмів Edge-рівня (погодинна агрегація) показала значне (у 4 рази) зменшення обсягу даних при збереженні основної інформативності ряду та фільтрації шуму.
4. Проведено навчання та тестування моделей прогнозування. Успішно реалізовано, навчено та протестовано три різні моделі: LSTM (глибоке навчання), Prophet (компонентний аналіз) та SARIMA (статистична модель). Кожна модель використовувала відповідні методи підготовки даних та налаштування параметрів.
5. Проаналізовано результати моделювання.
 - *Оцінка точності:* Порівняльний аналіз за метриками MAE, RMSE, MAPE та R^2 на тестовій вибірці показав, що модель LSTM

продемонструвала невелику перевагу в точності, за нею слідує Prophet, а потім SARIMA. Всі три моделі показали прийнятну для практичного застосування точність.

- *Аналіз затримок та пропускної здатності:* Програмні компоненти показали високу швидкість обробки та генерації прогнозів (особливо Prophet та LSTM на етапі inference). Виявлено потенційні вузькі місця реальної системи, пов'язані з мережею IoT та хмарними лімітами, а також відзначено повільнішу генерацію прогнозу моделлю SARIMA.
 - *Порівняння ефективності алгоритмів:* Визначено сильні та слабкі сторони кожної моделі за сукупністю критеріїв (точність, швидкість, вимоги до даних, складність, інтерпретованість), що дозволяє обґрунтовано обирати модель залежно від пріоритетів.
6. Підтверджено доцільність впровадження системи. Аналіз потенційних переваг для водіїв, операторів парковок, міської адміністрації та довкілля показав високу доцільність розробки та впровадження такої аналітичної системи для оптимізації використання паркувального простору та покращення якості міського життя.

Таким чином, проведений у цьому розділі комплекс експериментів підтвердив працездатність запропонованої архітектури та ефективність обраних методів прогнозування в умовах симуляції. Отримані результати створюють міцну основу для подальшого розвитку та потенційного пілотного впровадження системи в реальних умовах.

ВИСНОВКИ

У даній магістерській дисертації було вирішено актуальну науково-практичну задачу розробки та дослідження аналітичної системи на основі хмарних обчислень для інтелектуальної системи IoT, спрямованої на прогнозування зайнятості паркувальних місць у міському середовищі. Неефективне управління паркувальними просторами є однією з ключових проблем сучасних міст, що призводить до заторів, надмірних витрат пального, забруднення повітря та зниження якості життя громадян. Запропонована система має на меті вирішення цих проблем шляхом надання точних прогнозів доступності паркомісць.

У ході виконання роботи було досягнуто наступних результатів:

1. Проведено комплексний аналіз предметної області. Досліджено сучасний стан та тенденції розвитку інтелектуальних транспортних систем, технологій Інтернету речей (IoT), хмарних та Edge обчислень. Проаналізовано існуючі архітектури та технології для систем "розумної парковки", включаючи сенсорні технології, протоколи передачі даних та хмарні платформи. Вивчено методи аналізу даних та прогнозування, що застосовуються у цій сфері, від статистичних підходів до методів машинного навчання. Визначено переваги та недоліки існуючих рішень та обґрунтовано необхідність створення гнучкої, масштабованої аналітичної системи з можливостями прогнозування.
2. Розроблено математичні моделі та обґрунтовано вибір методів прогнозування. Формалізовано задачу прогнозування зайнятості паркувальних місць як задачу аналізу часових рядів. Розглянуто застосування елементів теорії масового обслуговування та стохастичних моделей для опису потоків транспортних засобів. Проведено порівняльний аналіз сучасних алгоритмів машинного навчання (ARIMA/SARIMA, LSTM, Prophet, XGBoost) та обґрунтовано вибір моделей LSTM, Prophet та SARIMA для подальшої реалізації та тестування, враховуючи їх здатність працювати з сезонними, нелінійними та зашумленими даними. Запропоновано систему метрик (MAE, RMSE, MAPE, R^2) для об'єктивної оцінки якості прогнозів.

3. Спроектовано архітектуру та реалізовано ключові компоненти аналітичної системи. Розроблено багаторівневу архітектуру системи (сенсорний, Edge, хмарний, рівень додатків), що забезпечує гнучкість та масштабованість. Обрано технологічний стек на основі Python та Google Cloud Platform (GCP). Практично реалізовано основні програмні модулі хмарної аналітичної платформи: модуль генерації синтетичних даних (`data_generator.py`), модуль підготовки даних (`data_preparation.py`) з інженерією ознак та масштабуванням, а також модулі для навчання, прогнозування та оцінки трьох моделей – `model_lstm.py`, `model_prophet.py`, `model_sarima.py`.
4. Проведено експериментальне дослідження та аналіз результатів. Створено симуляційне середовище для тестування системи. Згенеровано річний набір синтетичних даних, що імітує реалістичну динаміку зайнятості парковки. Протестовано симуляцію збору та передачі даних (MQTT), а також ефективність алгоритмів первинної обробки (Edge-рівень). Проведено навчання та тестування моделей LSTM, Prophet та SARIMA. Порівняльний аналіз показав, що модель LSTM продемонструвала найкращу точність на тестових даних, за нею йде Prophet, а потім SARIMA. Оцінено часові характеристики (затримки, пропускну здатність) програмних компонентів.

Наукова новизна одержаних результатів полягає у комплексному порівняльному аналізі ефективності сучасних методів прогнозування часових рядів (LSTM, Prophet, SARIMA), адаптованих до специфіки даних про зайнятість паркомісць, в рамках єдиної хмарної аналітичної платформи; а також у демонстрації доцільності використання глибокого навчання (LSTM) для обробки складних сезонних та нелінійних залежностей у цій предметній області.

Практичне значення роботи полягає у розробці архітектури та реалізації програмних модулів аналітичної системи, яка може бути впроваджена для моніторингу та прогнозування зайнятості паркувальних зон. Система дозволяє надавати актуальну інформацію та прогнози водіям, оптимізувати використання паркувального простору, впроваджувати динамічне ціноутворення та покращувати

управління транспортними потоками в містах, що сприяє зменшенню заторів, економії часу та пального, а також зниженню шкідливих викидів. Реалізовані модулі можуть слугувати основою для розгортання повноцінної системи "розумної парковки".

Обмеженнями даної роботи є використання синтетичних даних замість реальних даних з IoT-сенсорів та відсутність фізичної реалізації Edge-рівня та сенсорної мережі.

Напрямами подальших досліджень є тестування розробленої системи на реальних даних, впровадження алгоритмів на фізичних Edge-пристроях, інтеграція з додатковими джерелами даних (погода, трафік), розробка користувацького інтерфейсу (мобільний додаток/веб-панель) та дослідження більш складних моделей прогнозування.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Кіс О.Ю., Боровик О.Ю. Хмарні обчислення: технології, платформи, сервіси. // Вісник ХНУРЕ. — 2018. — №3(123). — С. 56–63.
2. Armbrust M., et al. A View of Cloud Computing. // Communications of the ACM. — 2010. — Vol. 53, No. 4. — P. 50–58.
3. Buyya R., Vecchiola C., Selvi S. T. Mastering Cloud Computing: Foundations and Applications Programming. — Morgan Kaufmann, 2013. — 468 p.
4. Zhou, Y., et al. Smart Parking Systems Based on IoT: A Survey. // IEEE Access. — 2020. — Vol. 8. — P. 168608–168627.
5. Al-Turjman, F. Intelligence in IoT-enabled smart cities: Advances and challenges. // Artificial Intelligence Review. — 2020. — Vol. 53, No. 1. — P. 169–212.
6. Wang, J., et al. Data Collection and Wireless Communication in IoT for Smart Parking Systems. // Sensors. — 2019. — Vol. 19, No. 10. — Article 2294.
7. Касьянов В.М. Хмарні технології у системах підтримки прийняття рішень. // Науковий вісник НЛТУ України. — 2021. — №31(5). — С. 112–117.
8. Mell, P., Grance, T. The NIST Definition of Cloud Computing. — National Institute of Standards and Technology, 2011. — Special Publication 800-145.
9. Atzori, L., Iera, A., Morabito, G. The Internet of Things: A survey. // Computer Networks. — 2010. — Vol. 54, No. 15. — P. 2787–2805.
10. Botta, A., De Donato, W., Persico, V., Pescapé, A. Integration of Cloud computing and Internet of Things: A survey. // Future Generation Computer Systems. — 2016. — Vol. 56. — P. 684–700.
11. Zhou, K., Fu, C., Yang, S. Big Data Driven Smart Energy Management: From Big Data to Big Insights. // Renewable and Sustainable Energy Reviews. — 2016. — Vol. 56. — P. 215–225.
12. Gubbi, J., et al. Internet of Things (IoT): A Vision, Architectural Elements, and Future Directions. // Future Generation Computer Systems. — 2013. — Vol. 29, No. 7. — P. 1645–1660.
13. Chen, M., et al. Edge Computing in IoT: Vision and Challenges. // IEEE Internet of

- Things Journal. — 2014. — Vol. 3, No. 5. — P. 637–646.
14. Zhang, Y., Deng, R. H. Security and privacy in smart health: Efficient policy-hiding attribute-based access control. // IEEE Internet of Things Journal. — 2016. — Vol. 3, No. 4. — P. 639–651.
 15. Zhao, Y., et al. Deep Reinforcement Learning for Smart Parking Allocation in Urban Environments. // IEEE Transactions on Intelligent Transportation Systems. — 2021. — Vol. 22, No. 2. — P. 930–942.
 16. Brownlee, J. Introduction to Time Series Forecasting with Python. — Machine Learning Mastery, 2017.
 17. Makridakis, S., Spiliotis, E., Assimakopoulos, V. Statistical and Machine Learning forecasting methods: Concerns and ways forward. // PLoS ONE. — 2018. — Vol. 13, No. 3.
 18. Taylor, S.J., Letham, B. Forecasting at Scale. // The American Statistician. — 2018. — Vol. 72, No. 1. — P. 37–45. (автори Prophet)
 19. Zhang, G., Eddy Patuwo, B., Hu, M. Forecasting with artificial neural networks: The state of the art. // International Journal of Forecasting. — 1998. — Vol. 14, No. 1. — P. 35–62.
 20. Hyndman, R. J., Athanasopoulos, G. Forecasting: Principles and Practice. — OTexts, 2021. — <https://otexts.com/fpp3/>
 21. Al-Fuqaha A., Guizani M., Mohammadi M., Aledhari M., Ayyash M. Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications // IEEE Communications Surveys & Tutorials. — 2015. — Vol. 17, No. 4. — P. 2347–2376.
 22. Perera C., Zaslavsky A., Christen P., Georgakopoulos D. Context Aware Computing for The Internet of Things: A Survey // IEEE Communications Surveys & Tutorials. — 2014. — Vol. 16, No. 1. — P. 414–454.
 23. Bonomi F., Milito R., Zhu J., Addepalli S. Fog Computing and Its Role in the Internet of Things // Proceedings of the First Edition of the MCC Workshop on Mobile Cloud Computing. — 2012. — P. 13–16.
 24. Satyanarayanan M., Bahl P., Caceres R., Davies N. The Case for VM-Based

- Cloudlets in Mobile Computing // IEEE Pervasive Computing. — 2009. — Vol. 8, No. 4. — P. 14–23.
25. Shi W., Cao J., Zhang Q., Li Y., Xu L. Edge Computing: Vision and Challenges // IEEE Internet of Things Journal. — 2016. — Vol. 3, No. 5. — P. 637–646.
26. Roman R., Lopez J., Mambo M. Mobile Edge Computing, Fog et al.: A Survey and Analysis of Security Threats and Challenges // Future Generation Computer Systems. — 2018. — Vol. 78, Part 2. — P. 680–698.
27. Zhou K., Fu C., Yang S. Big Data Driven Smart Energy Management: From Big Data to Big Insights // Renewable and Sustainable Energy Reviews. — 2016. — Vol. 56. — P. 215–225.
28. Li S., Xu L. D., Zhao S. The Internet of Things: A Survey // Information Systems Frontiers. — 2015. — Vol. 17, No. 2. — P. 243–259.