

## МАГІСТЕРСЬКА КВАЛІФІКАЦІЙНА РОБОТА

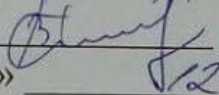
на тему:

«Моделі мережі керування автотранспортом із використанням  
технологій штучного інтелекту»

Виконав: студент 2-го курсу,  
групи ТКС-22м  
спеціальності 172 – Телекомунікації та  
радіотехніка

 Кречук М.Р.

Керівник: к.т.н., доцент каф. ІКСТ

 Воловик А.Ю.

«11» 12 2023 р.


Опонент: д.т.н., професор каф. ІРТС

 Осадчук В.С.

«12» 12 2023 р.

Допущено до захисту

Завідувач кафедри ІКСТ

 д.т.н., проф. Кичак В.М.

«12» 12 2023 р.

Вінницький національний технічний університет  
Факультет інформаційних електронних систем  
Кафедра інфокомунікаційних систем і технологій  
Рівень вищої освіти II-й (магістерський)  
Галузь знань - 17 – Електроніка та телекомунікації  
(шифр і назва)

Спеціальність - 172 – Телекомунікації та радіотехніка  
(шифр і назва)

Освітньо-професійна програма - Телекомунікаційні системи та мережі

**ЗАТВЕРДЖУЮ**

Завідувач кафедри ІКСТ  
д.т.н., професор В.М. Кичак  
“19” 09 2023 року

## **ЗАВДАННЯ НА МАГІСТЕРСЬКУ КВАЛІФІКАЦІЙНУ РОБОТУ СТУДЕНТУ**

Крепчуку Максиму Руслановичу

(прізвище, ім'я, по батькові)

1. Тема роботи Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту

керівник роботи Воловик Андрій Юрійович, канд. техн. наук, доцент  
(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом вищого навчального закладу від “18” 09 2023 року № 247

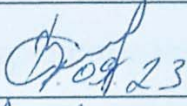
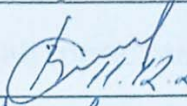

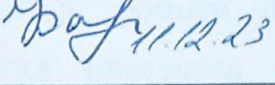


2. Строк подання студентом роботи 08 грудня 2023 року

3. Вихідні дані до роботи середньоквадратична помилка (RMSE) прогнозування інформаційного трафіку при використанні моделі BI-LSTM в середовищі рухомого туману та розміру вибірки 16 – 0,0539; середньоквадратична помилка (RMSE) прогнозування швидкості руху при використанні моделі BI-LSTM в умовах літаючого туману, застосуванні оптимізатора Adam та розміру вибірки 16 – 1,28; ймовірність ідентифікації типу біологічного об'єкта - 99,8%; максимальне середнє підвищення точності - 2,09%.

4. Зміст текстової частини: аналіз автономних транспортних засобів у мережах 5G; методи глибокого навчання в багаторівневих граничних мережах автотранспорту; прогнозування швидкості руху автотранспорту із використанням методів штучного інтелекту; моніторинг інформаційного трафіку безпілотних автомобілів у мобільних мережах; економічна частина; охорона праці та безпека в надзвичайних ситуаціях.

5. Перелік ілюстративного матеріалу (з точним зазначенням обов'язкових креслень) структура мережі LSTM; структура нейронної мережі Bi-LSTM; двошарова структура MEC; структура рухомого туману; структура мережі; загальна архітектура моделі системи; функціональна схема запропонованої мережі.

## 6. Консультанти розділів роботи


Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Спеціальна частина	Воловик А.Ю., доцент кафедри ІКСТ	 10.09.23	 11.12.23
Економічна частина	Кавецький В.В. доцент каф. ЕПВМ	 10.09.23	 11.12.23
Охорона праці та безпека в надзвичайних ситуаціях	Дембіцька С.В. професор кафедри БЖДПБ	 1.09.23	 11.12.23

7. Дата видачі завдання 01 вересня 2023 року

## КАЛЕНДАРНИЙ ПЛАН

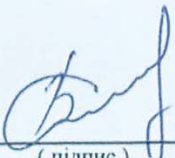
№ з/п	Назва етапів магістерської кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
1.	Розробка технічного завдання	08.09.2023р.	
2.	Аналіз автономних транспортних засобів у мережах 5G	17.09.2023р.	
3.	Методи глибокого навчання в багаторівневих граничних мережах автотранспорту	06.10.2023р.	
4.	Прогнозування швидкості руху автотранспорту із використанням методів штучного інтелекту	27.10.2023р.	
5.	Моніторинг інформаційного трафіку безпілотних автомобілів у мобільних мережах	10.11.2023р.	
6.	Аналіз економічної ефективності розробки	17.11.2023р.	
7.	Охорона праці та безпека життєдіяльності	24.11.2023р.	
8.	Оформлення пояснювальної записки та ілюстративної частини	01.12.2023р.	
9.	Нормоконтроль МКР	04.12.2023р.	
10.	Попередній захист МКР, опонування МКР	08.12.2023р.	
11.	Захист МКР ЕК	11.12.2023р.	

Студент

  
 (підпис)

Крепчук М.Р.

Керівник роботи

  
 (підпис)

Воловик А.Ю.

## АНОТАЦІЯ

УДК 621.391

Крепчук М.Р. Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту – магістерська кваліфікаційна робота зі спеціальності 172 – Телекомунікації та радіотехніка, освітня програма – Телекомунікаційні системи та мережі – Вінниця: ВНТУ 2023 р. 129 – стор., 46 – рис., 26 – табл., 64 – бібл. – українською мовою.

Метою кваліфікаційної роботи є підвищення ефективності функціонування інтелектуальної радіосистеми автономного керованого транспорту шляхом розроблення моделей і методів Штучного інтелекту та туманних обчислень.

Запропоновано застосовувати ефективні методи передачі інформації, зібравши та проаналізувавши навколишні дані для комунікації автономних керованих транспортів між собою. Представлено розв'язання наукової задачі з виявлення та розпізнавання активності біологічних об'єктів на узбіччі дороги. Це рішення може допомогти зменшити кількість аварій, спричинених тваринами або людьми на дорозі. У ньому для забезпечення передачі даних між віддаленими магістральними мережами і головною станцією використано технологію МЕС і комірчасту бездротову технологію LoRa. Запропоновано алгоритм, що використовує рекурентну нейронну мережу для визначення руху людей і тварин по шосе.

Розроблено імітаційну модель мовою програмування Python з реалізацією штучної нейронної мережі для перевірки працездатності запропонованого алгоритму. Результати моделювання показали, що запропоновані рішення дозволяють ідентифікувати тип біологічного об'єкта з імовірністю 99,8%.

Ключові слова: алгоритм довготривалої короткотермінової пам'яті; мобільні периферійні обчислення; штучний інтелект; рекурентна нейронна мережа; програмно-конфігурована мережа.

## ABSTRACT

UDC 621.391

Krepchuk M.R. Models of the vehicle control network using artificial intelligence technologies - Master's thesis in speciality 172 - Telecommunications and Radio Engineering, Educational programme - Telecommunication systems and networks - Vinnytsia: VNTU, 2023. 129 p., 46 figs., 26 tables, 64 bibliography - in Ukrainian.

The aim of the qualification work is to improve the efficiency of the intelligent radio system of autonomous controlled transport by developing models and methods of Artificial Intelligence and fog computing.

It is proposed to apply effective methods of information transmission by collecting and analysing ambient data for communication between autonomous controlled vehicles. A solution to the scientific problem of detecting and recognising the activity of biological objects on the roadside is presented. This solution can help reduce the number of accidents caused by animals or people on the road. It uses MEC technology and LoRa mesh wireless technology to ensure data transmission between remote backbone networks and the headend. An algorithm is proposed that uses a recurrent neural network to determine the movement of people and animals along the highway.

A simulation model in Python programming language with the implementation of an artificial neural network has been developed to test the performance of the proposed algorithm. The simulation results showed that the proposed solutions allow identifying the type of biological object with a probability of 99.8%.

**Keywords:** long-term short-term memory algorithm; mobile edge computing; artificial intelligence; recurrent neural network; software-configurable network.

## ЗМІСТ

ПЕРЕЛІК СКОРОЧЕНЬ.....	5
ВСТУП.....	7
1 АНАЛІЗ АВТОНОМНИХ ТРАНСПОРТНИХ ЗАСОБІВ У МЕРЕЖАХ 5G ...	11
1.1 Мережі зв'язку п'ятого покоління.....	11
1.2 Аналіз розвитку автономних транспортних засобів.....	16
1.3 Перспективи використання технологій МЕС у мережах 5G .....	21
1.4 Перспективи використання туманних обчислень у мережах 5G .....	22
1.5 Перспективи використання туманних обчислень в автономних транспортних засобах .....	28
1.6 Висновки до розділу 1 .....	30
2 МЕТОДИ ГЛИБОКОГО НАВЧАННЯ В БАГАТОРІВНЕВИХ ГРАНИЧНИХ МЕРЕЖАХ АВТОТРАНСПОРТУ .....	31
2.1 Багаторівнева хмарна система .....	31
2.2 Рекурентні нейронні мережі для розв'язання задач послідовного прогнозування інформаційного трафіку.....	36
2.2.1 Мережа довготривалої короткострокової пам'яті (LSTM) .....	38
2.2.2 Двонаправлена LSTM (BI-LSTM) .....	41
2.2.3 Середовище мереж автотранспорту .....	43
2.2.4 Туманне середовище.....	47
2.3 Імітаційна модель .....	51
2.4 Результати моделювання.....	52
2.5 Висновки до розділу 2 .....	56
3 ПРОГНОЗУВАННЯ ШВИДКОСТІ РУХУ АВТОТРАНСПОРТУ ІЗ ВИКОРИСТАННЯМ МЕТОДІВ ШТУЧНОГО ІНТЕЛЕКТУ .....	57
3.1 Обґрунтування інтелектуальних технологій керування автотранспортом... 57	
3.2 Математичні основи методу інтелектуального прогнозування .....	61
3.3 Архітектура методу розвантаження інформаційного трафіку при високій інтенсивності руху .....	64

	3
3.4 Результати моделювання.....	65
3.5 Висновки до розділу 3 .....	72
4 МОНІТОРИНГ ІНФОРМАЦІЙНОГО ТРАФІКУ БЕЗПЛОТНИХ АВТОМОБІЛІВ У МОБІЛЬНИХ МЕРЕЖАХ .....	74
4.1 Обґрунтування вибору технології інтелектуального моніторингу мобільних мереж .....	74
4.2 Мережева архітектура та протоколи Mesh .....	78
4.3 Обчислювальна інфраструктура.....	80
4.4 Алгоритм розпізнавання біологічних об'єктів .....	81
4.5 Навчання штучної нейронної мережі.....	83
4.6 Алгоритм моделювання.....	85
4.7 Висновки до розділу 4 .....	86
5 ЕКОНОМІЧНА ЧАСТИНА.....	87
5.1 Оцінювання наукового ефекту.....	87
5.2 Розрахунок витрат на здійснення науково-дослідної роботи.....	90
5.2.1 Витрати на оплату праці.....	91
5.2.2 Відрахування на соціальні заходи .....	94
5.2.3 Сировина та матеріали.....	95
5.2.4 Розрахунок витрат на комплектуючі.....	96
5.2.5 Спецустаткування для наукових (експериментальних) робіт .....	97
5.2.6 Програмне забезпечення для наукових (експериментальних) робіт .....	98
5.2.7 Амортизація обладнання, програмних засобів та приміщень .....	99
5.2.8 Паливо та енергія для науково-виробничих цілей .....	101
5.2.9 Службові відрядження.....	102
5.2.10 Витрати на роботи, які виконують сторонні підприємства, установи і організації.....	102
5.2.11 Інші витрати.....	102
5.2.12 Накладні (загальновиробничі) витрати.....	103
5.3 Оцінювання важливості та наукової значимості науково-дослідної роботи .....	104

	4
5.4 Висновок до розділу 5.....	105
6 ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ .....	107
6.1 Технічні рішення щодо безпечного виконання роботи.....	107
6.2 Технічні рішення з гігієни праці та виробничої санітарії.....	111
6.2.1 Мікроклімат .....	111
6.2.2 Склад повітря робочої зони.....	112
6.2.3 Виробниче освітлення.....	113
6.2.4 Виробничий шум.....	114
6.2.5 Виробничі випромінювання.....	115
6.3 Безпека в надзвичайних ситуаціях. Дослідження безпеки роботи в умовах дії загрозливих факторів надзвичайних ситуацій.....	116
6.3.1 Дія радіації на живі організми .....	116
6.3.2 Визначення доцільного часу початку евакуації населення з зараженої внаслідок аварії на АЕС місцевості автотранспортом .....	117
6.4 Висновки до розділу 6 .....	119
ВИСНОВКИ.....	120
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	122
ДОДАТКИ.....	130
Додаток А ІЛЮСТРАТИВНА ЧАСТИНА .....	131
Додаток Б Протокол перевірки кваліфікаційної роботи на наявність текстових запозичень .....	136



## ПЕРЕЛІК СКОРОЧЕНЬ

IoT - Інтернет речей;

LSTM - Алгоритм довготривалої короткотермінової пам'яті;

BI-LSTM - Алгоритм двонаправленої довготермінової короткотермінової пам'яті;

eMBB - Поліпшений мобільний широкосмуговий зв'язок;

mMTC - Масовий зв'язок машинного типу;

uRLLC - Наднадійний зв'язок із низькою затримкою;

R&I - Дослідження та інновації;

CAB - Системами автоматизованого водіння;

CSAIL - Лабораторія комп'ютерних наук і штучного інтелекту;

MEC - Мобільні периферійні обчислення;

MCC - Мобільні хмарні обчислення;

V2V - Технологія зв'язку між транспортними засобами;

V2N - Зв'язок між транспортним засобом і мережею;

AI – Штучний інтелект;

QoS - Якість обслуговування;

RSU - Інтелектуальний мультисервісний вузол доступу;

API - Інтерфейс прикладних програм;

WLAN - Бездротова локальна мережа;

DAS - Система допомоги водію;

TSR - Система розпізнавання дорожніх знаків;

DNN – Глибока нейронна мережа;

ML – Машинне навчання;

MLNN - Багатошарова нейронна мережа;

RNN - Рекурентна нейронна мережа;

RMSE - Середньоквадратична помилка;

MAPE - Середня абсолютна відсоткова помилка;

$R^2$  – коефіцієнт детермінації;

EPC - Еволюціонуюче пакетне ядро;

SDN - Програмно-конфігурована мережа;

NFV - Віртуалізація мережевих функцій;

FoG – Туманні обчислення;

LPWAN - Великомасштабна мережа з низьким енергоспоживанням і широким покриттям;

НДР – Науково-дослідна робота.

## ВСТУП

*Актуальність теми.* Ефективний розвиток мереж зв'язку п'ятого і шостого покоління 5G/6G складно уявити без використання методів прогнозування трафіку. Для прогнозування достатньо точного і своєчасного знання про поведінку трафіку і забезпечення швидкого з'єднання, більшої пропускної здатності і швидкого часу відгуку, що називається затримкою.

Зі зростанням кількості інтелектуальних пристроїв, а також популярністю послуг Інтернету речей (IoT), чутливих до затримки та усвідомлення місця розташування, з'явилася технологія туманних обчислень, вона призначена для вирішення проблем, які хмарні обчислення не можуть вирішити самостійно. Оскільки туман знаходиться ближче до користувача, він може поліпшити деякі дуже важливі характеристики QoS, такі як затримка і доступність. Туманні обчислення забезпечують своєчасне надання транспортних послуг у реальному часі локальним користувачам завдяки обробці даних у безпосередній близькості, а не маршрутизації даних у віддалений центр обробки даних у хмарі.

Технологічні переваги мереж 5G, зокрема мережевих технологій SDN/NFV, а також хмарних МЕС і туманних обчислень призводить до необхідності використання методів прогнозування трафіку для виявлення і розпізнавання рухомого біологічного об'єкта, для автономного керованого транспорту на основі інтелектуальних граничних обчислень [1, 2].

Дослідники мають зважати на проблеми, що виникають через величезну кількість пристроїв IoT та їхню взаємодію, різноманітні технології та окремі додатки. Тож для їхнього подолання необхідно розробити та спроектувати структури та моделі, що імітують реальну туманну систему [3].

*Аналіз останніх досліджень.* У галузі мереж зв'язку з ультра малими затримками існують численні дослідження та роботи вітчизняних і зарубіжних учених. Ця область активно розвивається і має великий потенціал для застосування в різних сферах, таких як медицина, автономні автомобілі, віртуальна реальність, інтернет речей та інші. У дослідках і статтях вчених

зазвичай досліджуються методи та технології для зниження затримок у мережах, вдосконалення протоколів передачі даних та покращення якості обслуговування для додатків, які вимагають низьких затримок [4-6].

Деякі з напрямків досліджень і робіт в цій галузі включають. Розробка мереж нового покоління, таких як 5G і майбутні 6G, спрямована на зниження затримок у мережах і забезпечення низької латентності для різних додатків. Дослідження технологій для створення високошвидкісних мереж, які можуть передавати дані з високою швидкістю і низькою затримкою. Розробка розподілених обчислювальних систем, які дозволяють обробку даних ближче до джерела, що також сприяє зниженню затримок у мережах. Дослідження та розробка мереж, які забезпечують низьку латентність для комунікації між автономними автомобілями та інфраструктурою. Розробка мереж для підключення великої кількості IoT-пристроїв з низькою затримкою та високою надійністю. Робота над мережами, які забезпечують плавну передачу даних для VR і AR додатків [7-9].

Учені в усьому світі активно працюють над цими проблемами, і результати їхніх досліджень вносять важливий внесок у розвиток мереж з низькими затримками і покращення якості послуг зв'язку.

Магістерська робота на відміну від відомих методів побудови інфраструктури мереж автономного транспорту пропонує підходи на основі методів Штучного Інтелекту та туманних обчислень, щоб звести до мінімуму мережеві затримки та забезпечити низьке енергоспоживання системи. Усе це загалом і визначає мету, завдання, об'єкт і предмет МКР.

*Мета і завдання роботи.* Метою даної кваліфікаційної роботи є підвищення ефективності функціонування інтелектуальної радіосистеми автономного керованого транспорту шляхом розроблення моделей і методів Штучного інтелекту та туманних обчислень.

Задачами магістерської кваліфікаційної роботи є:

- аналіз розвитку мереж зв'язку та наступних поколінь;

- аналіз принципів побудови та послуг, що надаються користувачам у мережах майбутнього покоління;
- аналіз розвитку автономних транспортних засобів;
- розробка моделі та методів виявлення і розпізнавання біологічних об'єктів у придорожній зоні з використанням технології МЕС для автономних транспортних засобів;
- розробка імітаційної моделі для перевірки працездатності алгоритму розпізнавання, використовуючи рекурентну нейронну мережу для визначення руху людей і тварин по шосе;
- розробка моделі глибокого навчання з використанням алгоритму довготривалої короткотермінової пам'яті (LSTM) та алгоритму двонаправленої довготермінової короткотермінової пам'яті (BI-LSTM) для прогнозування трафіку в автономних транспортних засобах у багаторівневій хмарній архітектурі;
- розробка моделі для прогнозування швидкості руху автотранспорту в зонах з інтенсивним рухом на основі рухомого літаючого туману та стекової двоспрямованої моделі довготривалої короткострокової пам'яті (SBILSTM).

З урахуванням викладеного тема магістерської кваліфікаційної роботи є актуальною.

*Об'єктом дослідження є автономний керований транспорт і його взаємодія з мережами зв'язку.*

*Предметом дослідження є розробка моделей і методів динамічних туманних обчислень для інтелектуальної системи керування.*

*Методи досліджень базуються на використанні: методів машинного та глибокого навчання, математичної статистики, теорії ймовірностей та імітаційного моделювання.*

*Новизна одержаних результатів:*

1. На відміну від відомих методів машинного навчання для прогнозування трафіку в багаторівневій хмарній архітектурі було запропоновано метод прогнозування трафіку в автономних транспортних засобах з використанням

нейронних мереж на основі BI-LSTM і LSTM, що підвищує ефективність прийняття рішень.

2. На відміну від відомих методів глибокого навчання для прогнозування швидкості руху автотранспорту в зонах з інтенсивним рухом було розроблено метод прогнозування швидкості руху автотранспорту в зонах з інтенсивним рухом на основі рухомого літаючого туману та стекової двонаправленої моделі довготривалої короткотермінової пам'яті (SBILSTM), що дає змогу підвищити точність прогнозування швидкості руху.

3. На відміну від відомих методів виявлення і розпізнавання біологічних об'єктів у придорожній зоні для автономних транспортних засобів розроблений метод використовує хмарну структуру МЕС на основі нейронної мережі, що дає змогу підвищити достовірність розпізнавання типів біологічних об'єктів.

*Апробація роботи* та її основні результати роботи проводилися на Всеукраїнській науково-практичній інтернет-конференції «Молодь в науці: дослідження, проблеми, перспективи (МН-2024)» у 2023 році.

# 1 АНАЛІЗ АВТОНОМНИХ ТРАНСПОРТНИХ ЗАСОБІВ У МЕРЕЖАХ 5G

## 1.1 Мережі зв'язку п'ятого покоління

Бездротова технологія 5G покликана забезпечити вищу швидкість передавання даних - до кількох гігабіт на секунду, наднизьку затримку, більшу надійність, величезну ємність мережі, підвищену доступність і стабільніший користувацький досвід для більшої кількості користувачів. Висока продуктивність і підвищена ефективність дозволяють створювати нові можливості для користувачів і об'єднувати нові галузі [7].

5G - це п'яте покоління мобільних мереж, яке є важливим розвитком для сучасних мереж 4G LTE [9]. 5G розроблено для задоволення експоненціального зростання даних і можливостей підключення в сучасному суспільстві, а також Інтернету речей з мільярдами підключених пристроїв. Спочатку 5G працюватиме поруч із наявними мережами 4G, а потім перетвориться на повністю незалежні мережі в пізніших версіях із розширенням зони покриття. Крім забезпечення більш швидкого з'єднання і більшої пропускної спроможності, дуже важливою характеристикою 5G є швидкий час відгуку, званий затримкою.

Переваги технології 5G:

- висока швидкість - 5G набагато швидша, ніж мережі попереднього покоління, з потенційною швидкістю до 20 гігабітів на секунду, що в 100 разів швидше, ніж у мережах 4G і 4G LTE [1]. Покращення, пропоновані 5G, означають, що фільми будуть завантажуватися за секунди, а не за хвилини;

- низька затримка - Затримка - це час, який минає між дією і відповіддю. Наприклад, затримка між натисканням на посилання на веб-сторінці та відображенням цієї веб-сторінки в браузері. Мережі 5G матимуть набагато меншу затримку, ніж 4G LTE. Один з експериментів показав, що вона може становити всього 5 мілісекунд. Така низька затримка зможе підтримувати нові

додатки, як-от IoT і штучний інтелект, забезпечуючи зв'язок у режимі реального часу;

- збільшення потужності - 5G забезпечить у 1000 разів більшу пропускну здатність порівняно з 4G у ширшому частотному спектрі. Він зможе обробляти одночасно додатки з високим попитом і з'єднувати тисячі пристроїв з доступом до Інтернету, від телефонів до датчиків IoT;

- висока пропускну здатність - Велика пропускну здатність означає більшу універсальність і можливість робити більше за менший час. Це підтримує як більш швидке з'єднання, так і більшу кількість пристроїв, а також означає, що в рамках конкретної мережі більше людей можуть підключитися до Інтернету;

- сприяння інноваціям - Якщо 4G був орієнтований насамперед на мобільні телефони, то 5G, маючи низьку затримку і високу пропускну здатність, ідеально підходить для під'єднання цілої низки різних пристроїв або речей, наприклад, дронів і датчиків у продукті або пристрої. У таких галузях, як охорона здоров'я, роздрібна торгівля, виробництво і розваги, буде спостерігатися величезний технологічний прогрес.

Основні характеристики зв'язку 5G, актуальні для сектора виробничої промисловості і не тільки, зводяться до трьох послуг. По-перше, поліпшений мобільний широкопasmовий зв'язок (eMBB) зі збільшеною швидкістю передавання даних вище за 1 Гбіт/с, що досягає 20 Гбіт/с у низхідному каналі та 10 Гбіт/с у висхідному каналі. По-друге, масовий зв'язок машинного типу (mMTC), націлений на велику кількість пристроїв на великих територіях. Гупта та ін. оцінюють його в 1 000 000 з'єднань на км<sup>2</sup>. наводять число 100 вузлів на м<sup>2</sup>, тобто 100 000 000 на км<sup>2</sup>. Така масштабованість у плані кінцевих вузлів є основним аспектом mMTC. Енергоефективна робота (до десяти років автономної роботи) для пристроїв IoT дозволяє підтримувати великі мережі з мінімальним обслуговуванням. По-третє, наднадійний зв'язок із низькою затримкою (uRLLC) [3], націлений на симетричні затримки під час підвищення та пониження швидкості завантаження на 0,5 мс у кожну сторону, що в сумі дає ключовий показник затримки в 1 мс. Надійність сягає понад 99,999 %. URLLC стане



повністю стандартизованим у 3GPP Release 16. Примітно, що за 1 мс сигнали, що йдуть зі швидкістю світла, можуть подолати відстань у 100 км в обидва боки, що вимагає використання хмарних обчислень для управління в замкнутому циклі [1].

- Розширений мобільний широкосмуговий зв'язок (eMBB) - Розширений мобільний широкосмуговий зв'язок означає поліпшення якості мобільного широкосмугового зв'язку, яке, як очікується, забезпечить 5G порівняно з попередніми стандартами й технологіями мобільного зв'язку, збільшивши швидкість передавання даних більш ніж у десять разів. Нові додатки включатимуть у себе стаціонарний бездротовий доступ до Інтернету для будинків, додатки для зовнішнього мовлення без необхідності використання візків для мовлення, а також ширші можливості підключення для людей, які перебувають у дорозі [5].

- Масивний зв'язок машинного типу (mMTC), також відомий як масивний машинний зв'язок (MMC) або масивний зв'язок між машинами, - це тип зв'язку між машинами через дротовий або бездротовий зв'язок, за якого генерація даних, обмін інформацією та управління відбуваються з мінімальним втручанням людини або взагалі без нього. Це підкласифікація зв'язку машинного типу (MTC). mMTC має справу, зокрема, з бездротовим зв'язком і мережею серед величезної кількості (мільярдів) машин і вважається ключовим кроком від

IoT до Інтернету всього. Ринок масових комунікацій машинного типу, за оцінками, зростатиме з темпом зростання 7,5% протягом прогнозованого періоду 2021-2026 рр. Зв'язок машинного типу (MTC) є фундаментальною технологією для реалізації концепції повністю підключеного світу в п'ятому поколінні (5G) IoT. Масове поширення пристроїв MTC є серйозною проблемою для стільникових мереж з погляду експлуатації та управління, включно з масовим доступом і перевантаженням мережі [6]. Зв'язок між машинами (M2M) є важливим структурним елементом IoT і позначається як зв'язок машинного типу (MTC) проектом партнерства третього покоління (3GPP), даючи змогу об'єктам спілкуватися один з одним через будь-яку мережу зв'язку (дротову або

бездротову). МТС з'єднуються один з одним, утворюючи мережу МТС, щоб полегшити інтелектуальне споживання товарів, як-от управління водними ресурсами, інтелектуальний облік, моніторинг довкілля, структур і активів, датчики на тілі, віддалена діагностика, інтелектуальне сільське господарство та системи спостереження.

- Наднадійні комунікації (URLLC): Це критично важливі завдання, включно з управлінням пристроями в реальному часі, промисловими роботами, системами зв'язку та безпеки транспортних засобів, автономним водінням і більш безпечними транспортними мережами. Комунікації з низькою затримкою також відкривають новий світ, у якому можливе віддалене медичне обслуговування, процедури та лікування. Наднадійний зв'язок із низькою затримкою (URLLC), представлений у релізі 15 3GPP відповідно до вимог MCE-R M.2083, є однією з ключових основ нового радіо 5G (NR). Як базова функція, необхідна для підтримки щільних сенсорних мереж кінцевих точок IoT, вона є основним фактором для низки унікальних сценаріїв використання в таких галузях, як виробництво, передача енергії, транспорт і охорона здоров'я. За необхідності підтримки наскрізних затримок до 5 мс бюджет затримки для окремих інтерфейсів може становити всього 1 мс. Це означає, що оптимізація повинна проводитися на кожному етапі процесу передачі даних по висхідному і низхідному каналу. Хоча це не входить у сферу дії специфікацій 3GPP, необхідність скорочення часу відгуку при обробці даних також призводить до появи стратегій високорозподілених граничних обчислень [7].

5G уже на горизонті і, як очікується, матиме величезний вплив на суспільство. 5G дасть змогу розгорнути нові "розумні" міста і галузі, які наразі неможливі при використанні нинішніх технологій [6]. Він також забезпечить нові форми зв'язку і мобільності, які ніколи не були можливі раніше. Вплив 5G на суспільство буде величезним, але у цієї технології є і деякі потенційні недоліки. Потенційні можливості застосування 5G безмежні і включають такі речі, як поліпшення широкосмугового зв'язку, доповнена і віртуальна реальність, автономні транспортні засоби і телемедицина [16]. Очікується, що мережа 5G

матиме значний вплив на наше життя в найближчі роки, і вона вже почала змінювати те, як люди працюють і живуть. Наприклад, найближчими роками очікується вибухове зростання Інтернету речей: під'єднані до мережі пристрої використовуватимуть для відстеження ланцюжків поставок, автоматизації виробничих процесів і підвищення продуктивності в офісах і на заводах. Хоча до повного впровадження 5G ще є деякий час, він уже проклав шлях для нових захопливих технологій, таких як доповнена реальність і віртуальна реальність.

5G дасть змогу використовувати технології IoT для підвищення ефективності бізнес-операцій і ухвалення кращих рішень. Крім того, низька затримка, що забезпечується 5G, дасть змогу компаніям ухвалювати рішення в режимі реального часу і швидше впроваджувати зміни, щоб реагувати на зміни в бізнес-середовищі. Нарешті, 5G буде підтримувати різні офісні додатки, включно з відеоконференціями та віртуальними нарадами, інструментами для спільної роботи та поліпшеними функціями безпеки. Підприємствам необхідно почати думати про те, як вони можуть отримати вигоду з використання цих технологій у своїй повсякденній діяльності, щоб залишатися конкурентоспроможними і підготуватися до появи мережі 5G. 5G може змінити багато аспектів нашого життя, але найбільший вплив, як очікується, буде надано на робоче місце.

Хоча розгортання систем мобільного зв'язку наступного покоління все ще попереду на часовому інтервалі в десять або більше років, багато поточних програм 6G і пов'язані з ними інвестиції відкривають привабливі перспективи для значного прискорення досліджень 6G [12]. Промислові та громадські організації вже почали інвестувати в дослідження та інновації (R&I), щоб відповідати вимогам, які 6G, ймовірно, буде пред'являти, коли почне функціонувати близько 2030 року [15].

До них належать сценарії використання, обіцяні в мережах 5G, але ще не реалізовані, і більш просунуті сценарії використання, які з'являються в контексті систем 6G [18]. Прикладами таких нових сценаріїв є терагерцовий зв'язок, повсюдне покриття (земля, повітря, космос, море), голопортація,

тактильний/дотиковий зв'язок, медична/здорова вертикаль, державна/національна безпека, візуалізація і зондування, послуги громадської безпеки, кіберфізичні системи/виробництво і транспорт.

## 1.2 Аналіз розвитку автономних транспортних засобів

Автономний транспортний засіб - це автомобіль, який здатний відчувати навколишнє середовище і працювати без втручання людини. Пасажир не зобов'язаний контролювати автомобіль у будь-який момент, та й узагалі в ньому немає потреби. Автомобіль може працювати повністю автономно, ніби хтось дійсно керує ним.

Автономний транспортний засіб оснащено різними датчиками для визначення навколишнього простору, такими як радар, лідар, сонар, система глобального позиціонування, комп'ютерний зір, вимірювання відстані та інерціальні вимірювальні прилади. Передові системи управління інтерпретують сенсорну інформацію, щоб визначити відповідний курс для навігації, а також відповідні перешкоди і знаки.

Експерименти із системами автоматизованого водіння (СAB) проводять принаймні з 1920-х років; [10] випробування розпочалися в 1950-х роках. Перший напівавтоматичний автомобіль був розроблений 1977 року японською машинобудівною лабораторією Цукуба. Для його керування були потрібні спеціально розмічені вулиці, які інтерпретувалися двома камерами на автомобілі та аналоговим комп'ютером. Автомобіль розвивав швидкість до 30 км/год (19 миль на годину) за підтримки надземної рейки [2].

Автономний транспортний засіб означає транспортний засіб, здатний долати дороги в районі та розуміти пристрої управління дорожнім рухом без активної роботи водія в будь-якій із систем управління транспортного засобу. Термін "самоврядний транспортний засіб" виключає транспортний засіб, оснащений системами активної безпеки або допомоги водієві, включно із системами для забезпечення електронної допомоги під час руху наосліп,

запобігання зіткненням, екстреного гальмування, допомоги під час паркування, адаптивного круїз-контролю, допомоги під час руху по смузі, попередження про вихід зі смуги руху, про пробки та допомогу в черзі, якщо тільки система сама по собі або у поєднанні з іншими системами не дає змоги транспортному засобу, у якому встановлено систему керування транспортними засобами без активного керування.

Автомобілі без водія потребують різновиду машинного зору для розпізнавання візуальних об'єктів. Автономні транспортні засоби розробляються з використанням глибоких нейронних мереж - типу архітектури глибокого навчання з багатьма обчислювальними етапами та рівнями, в яких нейрони моделюються з середовища, в якому активується мережа. Нейронна мережа спирається на великий обсяг даних, отриманих із реальних сценаріїв водіння, що дає змогу нейронній мережі "навчатися" того, як реалізувати найкращий курс дій [3].

У травні 2018 року дослідники з Массачусетського технологічного інституту оголосили про створення роботизованого автомобіля, здатного орієнтуватися на незапланованих дорогах [4]. Дослідники з Лабораторії комп'ютерних наук і штучного інтелекту (CSAIL) розробили нову систему під назвою MapLite, яка дає змогу саморухомих автомобілям їздити дорогами, якими вони ніколи раніше не їздили, без використання 3D-карт. Система об'єднує GPS-навігацію автомобіля з "розрідженою топографічною картою", такою як OpenStreetMap (тобто, такою, що має тільки 2D-маршрути доріг), і низкою датчиків, що відстежують дорожні умови [5].

Машинне навчання застосовується для більш високих рівнів допомоги водієві, таких як сприйняття і розуміння навколишнього світу. Здебільшого це пов'язано з використанням систем на базі камер для виявлення і класифікації об'єктів, але є також розробки в галузі LiDAR і радарів.

Однією з найбільших проблем автономного водіння є неправильна класифікація об'єктів. Дані, зібрані різними датчиками автомобіля, збираються і потім інтерпретуються системою автомобіля. Але за різниці всього в кілька

пікселів на зображенні, отриманому системою камер, автомобіль може помилково прийняти знак "Стоп" за щось більш нешкідливе, наприклад, за знак обмеження швидкості. Якщо система також прийме пішохода за ліхтарний стовп, то вона не зможе передбачити, що він може зрушити з місця.

Завдяки покращеному та більш узагальненому навчанню моделей машинного навчання, системи можуть покращити сприйняття та ідентифікувати об'єкти з більшою точністю. Навчання системи шляхом надання їй більш різноманітних вхідних даних за ключовими параметрами, на основі яких вона ухвалює свої рішення, допомагає краще перевірити дані і переконатися, що те, на чому вона навчається, є репрезентативним для істинного розподілу в реальному житті. Таким чином, не виникає сильної залежності від одного параметра або набору ключових характеристик, які в іншому разі могли б змусити систему зробити певний висновок.

Нейронні мережі можуть розпізнавати шаблони, тому їх можна використовувати в автомобілях для контролю за водієм. Наприклад, розпізнавання облич може бути використане для ідентифікації водія і перевірки наявності у нього певних прав, наприклад, дозволу на запуск автомобіля, що може допомогти запобігти несанкціонованому використанню і викраденню.

У короткостроковій перспективі автомобілі потребуватимуть певного контролю та уваги з боку людини, призначеної "водієм". Саме тут розпізнавання міміки стане ключем до підвищення безпеки. Системи можуть бути використані для вивчення і виявлення ознак втоми або недостатньої уваги і попередження пасажирів, можливо, навіть для уповільнення або зупинки автомобіля.

Програмне забезпечення для фреймворків глибокого навчання, таке як Caffe і TensorFlow від Google, використовує алгоритми для навчання і включення нейронних мереж. Вони можуть використовуватися під час обробки зображень для вивчення об'єктів та їхньої класифікації, щоб автомобіль міг легко реагувати на навколишнє середовище. Це може бути визначення смуги руху, коли система визначає кути повороту, необхідні для того, щоб уникнути об'єктів або

залишатися в межах смуги руху на шосе, і, отже, точно передбачає шлях попереду.

Нейронні мережі також можуть використовуватися для класифікації об'єктів. За допомогою ML їх можна навчити певних форм різних об'єктів. Наприклад, вони здатні розрізняти автомобілі, пішоходів, велосипедистів, ліхтарні стовпи та тварин.

Зображення також може бути використане для оцінки близькості об'єкта, а також його швидкості та напрямку руху. Для маневрування навколо перешкод автономний автомобіль може використовувати ML для розрахунку вільного простору, наприклад, навколо автомобіля, а потім безпечно об'їхати його або змінити смугу руху для обгону.

Додавання комп'ютерних систем і мережевих можливостей у транспортні засоби робить кібербезпеку автомобілів ще більш актуальною. Машинне навчання може бути використане і тут для підвищення безпеки. Зокрема, його можна використовувати для виявлення атак і аномалій, а потім їх подолання.

Одна із загроз для окремого автомобіля полягає в тому, що зловмисник може отримати доступ до його системи або використати його дані. Моделі машинного навчання повинні виявляти подібні атаки й аномалії, щоб забезпечити автомобіль, його пасажирів і дороги.

Найбільші технологічні компанії та основні виробники автомобілів змагаються в розробці своїх пропозицій автономних транспортних засобів. Кожна з них хоче бути першою на ринку, щоб домінувати в цій галузі. Наразі спостерігається велика активність у розвитку підключеної інфраструктури, появи технології 5G, русі до створення нового законодавства для регулювання галузі та навіть прагненні до мобільності як послуги (MaaS).

Також відбуваються зміни в тому, як використовується машинне навчання. Ось ті майбутні тенденції, які, на нашу думку, визначатимуть ринок автономних транспортних засобів.

Навчання є основним аспектом машинного навчання. Щоб наблизитися до людських можливостей і уникнути ризику аномалій, потрібне багаторазове

навчання системи в різноманітних і не дуже ситуаціях, що виникають на міських дорогах, шосе і автострадах.

У міру того, як виробники автомобілів накопичують дедалі більше дорожніх кілометрів, і дедалі більше об'єктів потребують виявлення і класифікації, створювані набори даних зростають.

Зростання цих наборів даних створює проблему: наявність достатньої обчислювальної продуктивності, на якій можна розгорнути навчені мережі. У зв'язку з цим однією з інновацій є створення високо оптимізованих методів прискорення. У галузі обробки інформації досягнуто великого прогресу, наприклад, у розгортанні навчених мереж безпосередньо на інтегральних мікросхемах. Ці нові мікросхеми дають змогу розгортати складні мережі за низькою ціною і з низьким енергоспоживанням. Подібні кремнієві рішення, оптимізовані за вартістю, що займають мало місця, зможуть просунути ринок вперед і подолати проблеми обчислювальної продуктивності.

Малоймовірно, що ми можемо очікувати появи повномасштабних серійних моделей автономних автомобілів раніше 2025 року. Крім того, ще належить з'ясувати, скільки часу мине, перш ніж кількість автомобілів без водія перевищить кількість автомобілів з ручним керуванням.

Проте, легкові та вантажні автомобілі без водія вже не за горами. Завдяки машинному навчанню, ці автомобілі забезпечать більшу мобільність мільйонам людей з ослабленим зором та інвалідів; дадуть змогу здійснювати доставку до віддалених районів, швидше й економніше доставляти товари людям і з'єднувати спільноти; і, що найголовніше, підвищать безпеку дорожнього руху, знизивши кількість дорожньо-транспортних пригод, травм і смертей.

Нарешті, ключовим фактором є співпраця. Різні компанії мають досвід у своїх галузях, пов'язаних із машинним навчанням. Деякі спеціалізуються на сприйнятті за допомогою камер або обробці даних

LiDAR; інші вкладають кошти в об'єднання вхідних даних датчиків; треті мають досвід у пошуку шляху та плануванні траєкторії та перекладі цих рішень у приємні дії з управління, прискорення та уповільнення. Ці компанії повинні



будуть співпрацювати, щоб допомогти автовиробникам запускати свої автономні транспортні засоби у виробництво.

### 1.3 Перспективи використання технологій MEC у мережах 5G

По суті, Технічне пояснення мети MEC можна викласти як рішення, яке дає змогу користувачам використовувати хмарні обчислювальні ресурси на кордоні мережі (між мережами радіодоступу та опорною мережею) [12]. Прикордонні обчислення є однією з ключових основ для задоволення потреб у зв'язку з низькою затримкою (1 мілісекунда) і можливістю підтримки нових сегментів бізнесу, де телекомунікаційні мережі раніше не існували, в цьому і полягає мета

MEC - керувати завданнями набагато швидше й ефективніше, завдяки більшій близькості між елементами мережі [15].

Платформа MEC зазвичай розгортається на виділеному сервері поверх хмарної інфраструктури, де також можуть бути розгорнуті додатки, що працюють як віртуальні машини або контейнери.

Хост MEC складається з таких частин:

Хост MEC - це об'єкт, що містить платформу MEC та інфраструктуру віртуалізації, яка надає обчислювальні ресурси, ресурси зберігання та мережеві ресурси для запуску додатків MEC.

Платформа MEC - це набір основних функціональних можливостей, необхідних для запуску додатків MEC на певній інфраструктурі віртуалізації, які дають змогу їм надавати і споживати послуги MEC (платформа MEC може також надавати послуги).

Додатки MEC інстанціюються на інфраструктурі віртуалізації вузла MEC на основі конфігурації або запитів, підтверджених керівництвом MEC.

Переваги 5G MEC:

- пропонує клієнтам нові мережеві послуги. Отже, це дає змогу постачальникам послуг збільшити дохід за рахунок використання безлічі варіантів використання;
- додатки працюють у локальному середовищі, що підвищує продуктивність і зручність роботи користувачів завдяки меншим затримкам;
- не змінюючи існуючу архітектуру мережі 5G, постачальники послуг можуть впроваджувати нові послуги для кінцевих споживачів;
- завдяки додаткам OTT ("Over the Top") послуги доступні клієнтам залежно від їхнього місцезнаходження;
- забезпечує безпеку послуг IoT;
- пропонує розподілену інфраструктуру і підвищує надійність додатків і мережевих сервісів;
- знижує потребу в хмарному зберіганні даних і послідовно економить транспортні витрати;
- дає змогу економити пропускну здатність мережі та знижує її перевантаження.

#### 1.4 Перспективи використання туманних обчислень у мережах 5G

Інтернет розвивався з моменту його зародження і зараз виходить за рамки традиційних настільних комп'ютерів. Поширення Інтернету речей призвело до трансформації способів взаємодії світу в Інтернеті. Тепер IoT готовий з'єднати пристрої, людей, середовище, віртуальні об'єкти і машини таким чином, якого світ ще не знав. Розгортання IoT, таких як "розумні міста", "розумні будинки" тощо - речі, що були радше фантастикою, - тепер стають реальністю і, за прогнозами, зачеплять якомога більше аспектів людського життя.

Типові системи IoT складаються з величезної кількості пристроїв, починаючи від датчиків, вбудованих у дороги, і закінчуючи мобільними пристроями, такими як автомобілі та поїзди. При такій великій кількості речей, задіяних у розгортанні IoT, кількість пристроїв, підключених до Інтернету,

зростає семимільними кроками. Наразі кількість кінцевих пристроїв (як правило, смартфонів і ноутбуків) оцінюють приблизно в 3-4 мільярди, і очікують, що за кілька років вона зросте до трильйона. Така кількість пристроїв генеруватиме гігантські обсяги даних, унаслідок чого виникає явище, що отримало назву "цунамі даних". Додатки та мережева інфраструктура повинні будуть відповідним чином адаптуватися до такого величезного збільшення обсягу даних, які їм доведеться опрацьовувати з огляду на обмеження доступної пропускної здатності.

Розвиток техніки завжди був спрямований на створення систем, які можуть функціонувати за мінімального втручання людини. Інтернет речей є ідеальною платформою для розроблення таких застосунків, зокрема тому, що під'єднання кожного пристрою до Інтернету дає кожному пристрою змогу самостійно ухвалювати рішення, тим самим знижуючи необхідність втручання людини. Дослідження таких автономних систем показали, що вони значною мірою залежать від низького часу відгуку застосунку. Системи IoT, такі як інтелектуальні мережі, спільне виявлення об'єктів тощо, вимагають затримки порядку субмілісекунд - вимоги, які Інтернет повинен забезпечити, щоб застосунок працював потрібним чином. Така зміна характеру пристроїв, підключених до Інтернету, і супутнє збільшення обсягу генерованих даних вимагає еволюції і мережевої інфраструктури. Нинішня хмарна модель виконання виявиться неефективною, якщо взагалі здійсненою, для футуристичних додатків, які пропонує розвиток IoT.

Туманне обчислення (Fog computing) - це термін, введений професором Сальваторе Дж. Столфо, який нещодавно був підхоплений компанією Cisco. Fog Computing - це парадигма, яка розширює хмарні обчислення і сервіси до кордонів мережі, даючи змогу додаткам працювати в безпосередній близькості від користувачів, бути дуже географічно розподіленими і підтримувати мобільність користувачів. Завдяки таким характеристикам, Fog скорочує затримки запитів на послуги і покращує QoS, що призводить до чудового користувацького досвіду. Обчислення Fog є необхідністю для нових додатків Інтернету всього (IoE) (як-от

промислова автоматизація, транспорт тощо), які вимагають реального часу/передбачуваної затримки. Завдяки широкому і щільному географічному розподілу, парадигма туману добре підходить для аналізу великих даних у реальному часі. Точки збору даних у туманних обчисленнях щільно розподілені, що додає четверту вісь - георозподіл - до часто згадуваних вимірів великих даних (обсяг, різноманітність, швидкість і достовірність).

Туман надає ті самі послуги, що й хмара (обчислення, зберігання та мережі), і використовує ті самі механізми (віртуалізація, багатокористувацький доступ тощо). Ці загальні атрибути хмари і туману дають змогу розробникам створювати додатки, що використовують взаємодію між туманом і хмарою.

Важливо зазначити, що туман не є заміною існуючої парадигми хмарних обчислень, навпаки, туман є розширенням хмари. Додатки, створені для туману, повинні бути здатні використовувати як гнучкість і потужність хмари, так і можливості туману в реальному часі.

Додатки з жорсткими вимогами до затримок, наприклад, мобільні ігри, відеоконференції тощо. Запуск цих застосунків у хмарі може погіршити якість роботи користувачів через ненадійність QoS, пропонованого хмарою.

Георозподілені додатки, в яких точки збору даних розподілені по великій території, наприклад, моніторинг трубопроводів або мережі датчиків для моніторингу навколишнього середовища.

Швидкі мобільні застосунки за участю високомобільних користувачів (інтелектуальний під'єднаний автомобіль, під'єднаний залізничний транспорт).

Великомасштабні розподілені системи управління, що складаються з величезної кількості датчиків і виконавчих механізмів, які працюють узгоджено для підвищення зручності користувачів. Наприклад, інтелектуальні мережі, підключені залізниці, інтелектуальні системи світлофорів.

Туманні обчислення і мережі 5G - дві концепції, що мають різне походження, але незабаром вони зійдуться, оскільки обіцянки, які дає бачення мереж 5G, роблять необхідним перенесення обробки даних на периферію [11].

Зв'язок у мережах 5G базуватиметься на високочастотних сигналах - у діапазоні міліметрових хвиль, які зможуть виділяти більшу пропускну спроможність для більш швидкого передавання відео та мультимедійного контенту високої якості. Мережі 5G обіцяють забезпечити мілісекундні та субмілісекундні затримки за швидкості передавання даних понад 1 гігабіт на секунду. Ця затримка настільки мала, що виключає можливість того, що радіоінтерфейс є вузьким місцем. Мобільні мережі нового покоління проєктуються таким чином, щоб вони могли обслуговувати комунікації, не обмежуючись людьми (де можна замаскувати затримку) - їх створюють для підтримки надійного та швидкого міжмашинного зв'язку, для ефективного використання якого потрібна низька затримка.

Для того щоб 5G була успішною, вона повинна підтримувати туманні обчислення, інакше радіоінтерфейси з низькою затримкою будуть марні. У типовій мережі 5G мобільні користувачі підключаються до базової станції, яка своєю чергою під'єднана до опорної мережі через дротові канали. Запити до хмарного застосунку проходять через базову станцію і опорну мережу, щоб у підсумку потрапити на хмарні сервери. За такого розгортання, незважаючи на те, що радіоінтерфейси з низькою затримкою забезпечують субмілісекундний зв'язок між мобільним пристроєм і базовою станцією, надсилання запиту з базової станції в хмару призведе до збільшення затримки на порядки.

Необхідно, щоб мережі 5G були не просто інфраструктурою зв'язку. Послуги обчислень і зберігання даних, якщо вони надаватимуться мережею в безпосередній близькості від пристроїв, дають змогу застосункам скористатися перевагами радіозв'язку з низькою затримкою і забезпечити дуже швидкий час відгуку. Це принесе велику користь як споживачам (завдяки своєчасним відповідям), так і провайдеру (завдяки зниженню навантаження на магістральну мережу). Таке перенесення обробки з хмари на периферію формує визначення туманних обчислень, і не буде помилкою сказати, що мережі 5G не зможуть виконати свої обіцянки без туманних обчислень. Туманні обчислення - це не

особливість, як вважає більшість, а необхідна вимога для успішної роботи мереж 5G.

Ключовим елементом мереж 5G, що забезпечує можливість туманних обчислень, є малі стільники (піко і фемтостільники), також відомі як мікростільники. Малі стільники можуть полегшити навантаження на базові станції на даху макростільники, дозволяючи кінцевим точкам підключатися до них. Пристрій може підключатися як до макросоти, так і до мікросоти. Таким чином, архітектура мереж 5G стає ієрархічною: на вершині знаходиться опорна мережа (хмара), потім базові станції макросот, базові станції мікросот і, нарешті, кінцеві пристрої. Таким чином, з точки зору туманних обчислень, базові станції макро- і мікросот утворюють туманні вузли, тобто мережеві вузли, що забезпечують обчислення і зберігання даних. Пакети, що надсилаються пристроями вгору каналом зв'язку, аналізуються на базових станціях мікро- або макросот, перш ніж потрапити в основну мережу.

Ще одним важливим досягненням у галузі зв'язку, яке несе з собою 5G, є ефективний зв'язок між пристроями. Дані, що надсилаються, передаватимуться від пристрою-відправника безпосередньо до пристрою-одержувача, а базова станція оброблятиме тільки керуючу інформацію. Це дає змогу здійснювати обмін даними між пристроями, не навантажуючи базову станцію, у такий спосіб виграючи у туманних систем у масштабованості під час роботи з численними пристроями, що взаємодіють один з одним. Це буде особливо корисно для додатків, які включають в себе безліч підключених точок і безперервний зв'язок між ними, наприклад, розумні будинки.

Архітектура фізичної мережі туманної мережі 5G розширюватиме архітектуру сучасних гетерогенних хмарних мереж радіодоступу. У традиційній архітектурі HCRAN всі завдання обробки додатків виконуються в хмарі всередині опорної мережі, що вимагає передачі даних в опорну мережу від мільярдів кінцевих пристроїв. Така величезна кількість комунікацій може знизити пропускну здатність фронтальної мережі і перевантажити опорну мережу, що згубно позначиться на якості обслуговування кінцевих користувачів.

Інтуїтивно зрозуміле розв'язання цієї проблеми полягає в тому, щоб спустити обчислювальні можливості та можливості зберігання з хмари до кордону, щоб необхідність надсилати всі дані, що генеруються кінцевими пристроями, до хмари відпала, а це позбавить фронтальну та опорну мережі від величезного сплеску трафіку.

Рівень пристроїв - Рівень пристроїв включає в себе всі кінцеві пристрої, підключені до туманної мережі. До пристроїв належать пристрої IoT, такі як датчики, шлюзи тощо, а також мобільні пристрої, такі як смартфони, планшети тощо. Ці пристрої можуть обмінюватися даними безпосередньо з мережею або здійснювати одноранговий зв'язок між собою. Будучи джерелом усіх даних, що надходять у мережу, і основними виконавцями завдань, ці пристрої являють собою найнижчий рівень туманних пристроїв. Рівень пристрою забезпечує обчислення або за допомогою вбудованого кодування (для пристроїв низького класу, таких як датчики), або як програмне забезпечення, що працює в операційній системі пристрою.

Туманний рівень - Туманний рівень складається з проміжних мережевих пристроїв, розташованих між кінцевими пристроями на рівні пристроїв і хмарним рівнем. Першою точкою розвантаження в цьому шарі є віддалена радіоголовка (RRH) і малі стільники, які з'єднані оптоволоконним фронтальним каналом з основною мережею. Обробка вхідних даних тут значно знизить навантаження на фронтальну частину (Fronthaul). Макросоти також утворюють точку розвантаження обробки даних, які відправляють оброблені дані в опорну мережу через транзитні канали. І Fronthaul, і Backhaul реалізуються за допомогою каналів Ethernet, а проміжні пристрої, як-от маршрутизатори та комутатори на шляху від радіоголовок до ядра, також є потенційними місцями, де завдання обчислень і зберігання даних можуть бути розвантажені.

Хмарний рівень - цей рівень утворює вершину ієрархічної архітектури, а хмарні віртуальні машини є точками розвантаження обчислень. Теоретично нескінченна масштабованість і висококласна інфраструктура хмари дають змогу обробляти дані, які потребують інтенсивних обчислень і великого обсягу пам'яті,

що неможливо зробити на граничних пристроях. На додаток до обробки на рівні додатків, хмарний рівень містить блоки базової смуги, які обробляють дані, що надходять від RRH і малих стільників через фронтальні канали, і направляють оброблені дані на сервери додатків.

### 1.5 Перспективи використання туманних обчислень в автономних транспортних засобах

Туманні обчислення - це архітектура розподілених обчислень, яка являє собою проміжний рівень пристроїв між хмарою і кінцевими пристроями. По суті, це розширює обчислювальні ресурси та ресурси зберігання, що зазвичай надаються хмарою, ближче до межі мережі. Туманні обчислення значно перегукуються зі спорідненими технологіями, такими як мобільні периферійні обчислення (MEC) і мобільні хмарні обчислення (MCC), і ці терміни іноді використовуються як взаємозамінні [16].

Також може бути включено машинне навчання, яке допомагає зрозуміти, які дані необхідно відправити в хмару. Це дає змогу розв'язати проблему затримки під час надсилання даних у хмару, що дуже важливо для самокерованих автомобілів.

Автомобільні туманні обчислення розроблені з урахуванням двох ключових категорій: рухомі та припарковані автомобілі. У кожному розділі розуміння комунікаційних та обчислювальних компонентів роботи саморухомих автомобілів є дуже важливим. Загалом, комунікація зосереджена на створенні ефективних методів передачі інформації іншим прилеглим автомобілям. Саме тут і відбувається обчислення. Мета - зібрати і проаналізувати навколишні дані (наприклад, кількість машин, швидкість, наявність пішоходів тощо) і відповісти методом, який найкраще підходить для поточної обстановки.

Попереднє опрацювання даних - Найбільшою перевагою туманних обчислень є можливість опрацьовувати дані з локальних інтелектуальних пристроїв, у даному випадку з нашого автомобіля. Однак для того, щоб наш



самокерований автомобіль знав про своє оточення, а також спілкувався з іншими самокерованими автомобілями, потрібна велика обчислювальна потужність і зворотний зв'язок у реальному часі.

Існують дві найпоширеніші форми зв'язку: технологія зв'язку між транспортними засобами (V2V) - це інтелектуальна технологія, яка дозволяє обмінюватися даними від одного транспортного засобу до іншого [21]. Зв'язок для технології V2V заснований на виділеному зв'язку малого радіусу дії (DSRC) [30]. Це не зовсім нова технологія, вона існує вже кілька десятиліть, але системи V2V матимуть найбільший вплив на безпеку транспортних засобів, коли вони стануть широко доступними, наприклад, для запобігання дорожньо-транспортним пригодам. Зв'язок V2V дає змогу автомобілям отримувати інформацію про швидкість і положення інших автомобілів, що знаходяться поруч, використовуючи протокол бездротового зв'язку, аналогічний Wi-Fi [22]. Ці дані потім використовуються для попередження водіїв про потенційні небезпеки, допомагаючи зменшити кількість аварій і заторів на дорогах. V2V може виявляти небезпечні дорожні умови, проблеми рельєфу та погодні загрози в радіусі 300 метрів. Система V2V здатна зробити водіння більш передбачуваним і безпечним для всіх учасників дорожнього руху.

Зв'язок між транспортним засобом і мережею (V2N) - Оскільки транспортні засоби дедалі менше залежать від ручного керування, можлива реалізація більш безпечних, ефективних і стійких поїздок, і все це завдяки технологіям V2N. Передача інформації між транспортними засобами та системою управління спрямована на передачу інформації між транспортними засобами та мережею. Цей процес можливий завдяки мережевій інфраструктурі з високою пропускну здатністю, низькою затримкою та високою надійністю. Автомобілі можуть отримувати ширококомвні попередження про затори на дорогах або аварії, прокладаючи шлях до автономного водіння - майбутнього мобільності.

V2V визначається кількістю присутніх компонентів (тобто кількістю автомобілів), а також середньою швидкістю цих автомобілів.

## 1.6 Висновки до розділу 1

Аналіз розвитку мереж зв'язку п'ятого покоління показує, що мережа може забезпечити дуже високу швидкість передавання даних, наднизьку затримку, більшу надійність, величезну ємність мережі та високу пропускну спроможність, що призводить до швидкого з'єднання, а також більшій кількості пристроїв і більшій кількості людей, які можуть підключитися до інтернету.

Проаналізовано: можливості використання методів туманних обчислення в мережах 5G для вирішення завдань автономного керованого транспорту; методи машинного навчання при визначенні даних необхідних для відправки в хмару, для зменшення затримки при відправці даних в хмару; визначено коло завдань в яких можна ефективно застосувати машинне та глибоке навчання для прогнозування трафіку в мережах зв'язку п'ятого та наступних поколінь. До цих завдань належать прогнозування втрат пакетів, затримки та пропускну спроможності в мережах зв'язку п'ятого покоління для Інтернету Речей і Тактильного Інтернету.

Для комунікації автономних керованих транспортів між собою, потрібно застосувати ефективні методи передачі інформації, для цього дуже важливо зібрати і проаналізувати навколишні дані. У зв'язку з цим, потрібна велика обчислювальна потужність і зворотний зв'язок у реальному часі. Необхідно дослідити можливість і ефективність використання автомобільних туманних обчислень.

## 2 МЕТОДИ ГЛИБОКОГО НАВЧАННЯ В БАГАТОРІВНЕВИХ ГРАНИЧНИХ МЕРЕЖАХ АВТОТРАНСПОРТУ

### 2.1 Багаторівнева хмарна система

Автономні транспортні засоби є одним з найбільш важливих нових варіантів використання перспективних технологій для мереж п'ятого покоління (5G) і наступного покоління в численних додатках. Наразі використання БА експоненціально зростає в усьому світі, завдяки швидкому зростанню обізнаності та використанню методів штучного інтелекту (AI) в різних галузях. Прогнозування потоків даних необхідне для БА, щоб поліпшити передачу даних і зменшити затримки за рахунок ефективнішого використання відповідних можливостей, моніторингу, управління і контролю дорожньої системи. У даному розділі дисертаційної роботи пропонується підхід глибокого навчання з двонаправленою моделлю довготривалої короткострокової пам'яті (BI-LSTM) для прогнозування інтенсивності руху транспортних засобів з багаторівневими сервісами хмарних обчислень. З точки зору точності прогнозування проводиться порівняння між BI-LSTM і односпрямованою LSTM залежно від кількості використовуваних пакетів. Точність прогнозування розраховується за допомогою середньоквадратичної помилки (RMSE), середньої абсолютної відсоткової помилки (MAPE), коефіцієнта детермінації (R2) і часу обробки.

Багаторівнева мережева структура відрізняється від будь-якої іншої структури, оскільки вона охоплює, контролює, управляє локальними хмарними структурами і пропонує кращі можливості, ніж постачальники хмарних послуг.

Багаторівнева архітектура забезпечує стабільну і повторювану архітектуру на декількох платформах: вона є основною у виробництві, а також ядром нинішньої і майбутньої публічної хмари. Зі зростанням використання IoT у різних сферах життя, включно з обміном даними в реальному часі між користувачами та машинами, тактильний інтернет дав змогу системі IoT миттєво та швидко взаємодіяти в промисловому та комерційному секторах.

Тактильний інтернет - це інтернет, що забезпечує віддалений доступ до точних і віртуальних операцій у режимі реального часу, що поєднує в собі кілька переваг: практично повну відсутність затримок, надійність і дуже високий захист. Реалізація тактильного інтернету містить у собі додатки з різних галузей: робототехніка, електроніка, віртуальна реальність, доповнена реальність, штучний інтелект тощо. [6, 7].

Очікується, що технології бездротового зв'язку наступного покоління, включно з мережами 5G і вище, стануть важливим фактором успіху автономних транспортних засобів у найближчі роки. Вони дадуть змогу впровадити нові послуги та сценарії застосування в майбутньому інтелектуальному транспорті, завдяки можливості швидкого і надійного обміну даними між різними суб'єктами. Розвиток комунікаційних технологій для інтелектуальних транспортних систем у поєднанні з передовою обробкою даних і штучним інтелектом (AI) означає, що такі важливі функції, як забезпечення великомасштабних мереж, вибір технологій для гетерогенного бездротового доступу, а також інтелектуальні та безпечні інтегровані послуги, користуються великим попитом [8].

Повністю функціональна та ефективна мережа 5G немислима за відсутності AI. Поєднання ML та AI на кордоні мережі може бути досягнуто шляхом розподілу мереж 5G, що забезпечує синхронне підключення декількох пристроїв IoT та генерує велику кількість даних, які можуть бути оброблені за допомогою ML та AI, що дозволяють таким мережам бути предиктивними та проактивними, що необхідно для ефективності мережі п'ятого покоління. Додавши ML до технології 5G, інтелектуальні канали можуть приймати власні рішення. Мобільні пристрої можуть створювати гнучкі, динамічні колекції відповідно до зчитаних даних, що підвищує ефективність, латентність і надійність мережевих додатків.

Як тільки ML і AI будуть об'єднані з 5G периферійні обчислення для множинного доступу (MEC), мобільні оператори зможуть забезпечити їх [9,10]:

Значний ступінь комп'ютеризації завдяки розподіленій структурі ML та AI на кордоні мережі; Управління трафіком у мережах доступу на основі додатків;

Динамічне нарізування мережі, що охоплює різні сценарії з різними умовами якості обслуговування (QoS) [11].

Автономні транспортні засоби з підтримкою багаторівневих хмарних обчислень зростають в усьому світі по експоненті, оскільки репутація методів штучного інтелекту та їхнє використання в численних додатках різко зросло. Прогнозування транспортних потоків необхідне для того, щоб автономні транспортні засоби визначали маршрут руху та ухвалювали адаптивні рішення щодо об'єктів, які їх оточують. Зв'язок між транспортними засобами (V2V) дає змогу автомобілям спілкуватися один з одним, передаючи повідомлення, що містять дані про швидкість автомобіля або попередження про зміну місця розташування. Коли система транспортних засобів обмінюється даними за допомогою зв'язку V2R (vehicle-to-roadside), придорожній пристрій бере на себе керування рухом транспортних засобів і відправляє широкомовне повідомлення всім автомобілям, які перебувають поблизу [12].

Специфічні проблеми, пов'язані з маршрутизацією у VANETs, - топологія мережі, демографічна ситуація, різна щільність трафіку в інший час і швидкі зміни транспортних засобів, що прибувають і вибувають, у мережах автотранспорту [26]. У мережах мереж мереж автотранспорту широкомовні пакети передаються залежно від географічної області, визначеної пакетом. Транспортні засоби посилають короткі пакети зі своїми ідентифікаторами та поточним географічним положенням [29].

Таким чином, може бути розроблена кооперативна система запобігання зіткненням, яка допоможе уникнути зіткнень шляхом надання попереджень. Безпека мереж автотранспорту критично важлива, оскільки їхнє існування пов'язане з невідкладними ситуаціями. Важливо, щоб зловмисник не зміг змінити життєво важливу інформацію [13]. На рисунку 2.1, показано багаторівневу хмарну систему, яка складається з декількох рівнів. Перший рівень - це фізичне обладнання, яке включає в себе бортові пристрої (OBU), які можуть бути підключені до розподілених RSU. RSU - це інтелектуальний мультисервісний вузол доступу, який використовується замість невеликих

мережевих вузлів при розширенні традиційних мереж і створенні нових мереж з великою кількістю віддалених об'єктів [23]. Другий рівень містить гетерогенні, хмарні, граничні сервери, розкидані вздовж кордону RAN [24]. Система складається з двох серверів MEC: міні-хмари і мікрохмарного граничного сервера. Кожен RSU пов'язаний з мобільними базовими станціями і граничним сервером мікрохмари. Граничний сервер мікрохмари працює з обмеженими обчислювальними та енергетичними можливостями. Кожен набір серверів мікрохмари пов'язаний із граничним сервером мініхмари з потужними обчислювальними та енергетичними ресурсами.

Рівень 3 - це SDN, розподілена по основній мережі. Цей рівень складається з двох основних підрівнів: рівня управління і даних. На підрівні даних знаходяться розподілені віртуальні комутатори OpenFlow, які обслуговують відповідну версію протоколу OpenFlow. Другий підрівень (рівень площини управління) включає розподілені SDN для управління і контролю всієї мережі [54]. Інтерфейс прикладних програм (API) управляє SDN і основними мережевими інтерфейсами до рівня 1 і сервера додатків.

Пропонована система має два прямі інтерфейси на рівні-1. Первинним інтерфейсом є транспортний засіб, а наступним інтерфейсом - каркасна мережа транспортного засобу. Це може бути досягнуто через відповідну мережу IEEE 802.11, різні стандарти зв'язку для бездротової локальної мережі (WLAN) зв'язку на різних частотах, більш відомої як Wi-Fi [64]; рівень-2 - розподілені граничні сервери пов'язані через швидку бездротову мережу (Wi-fi). Кожен RSU пов'язаний із сервером MEC для забезпечення обчислювальної потужності на кордоні мережі доступу [28]. Це знижує трафік на провідну мережу, зменшуючи її перевантаження або втрату пакетів.

Концепції глибокого навчання нещодавно привернули увагу багатьох дослідників завдяки своїй здатності вирішувати проблеми розпізнавання, розуміння природної мови, скорочення розмірності, ідентифікації об'єктів, моделювання руху, прогнозування трафіку тощо. Глибоке навчання використовує концепції багат шарових нейронних мереж для виведення

глибинних властивостей даних від найнижчого до найвищого рівня. Вони знаходять у даних велику кількість структур, які дають змогу їх уявити та зробити логічні висновки. Розробка автономного транспорту, який може зробити транспортні мережі набагато економічнішими та знизити ризик для життя людей. Ця концепція також має додаткову перевагу - економію часу. В останні десятиліття велика увага приділяється безпечному автоматизованому водінню. Інформація має вчасно надходити від систем допомоги водієві (DAS), автономних транспортних засобів і систем розпізнавання дорожніх знаків (TSR) [8, 14].

Прогнозування мережевого трафіку є важливим інструментом для бездротових мереж 5G та інших мереж, що дає змогу керувати перевантаженням і ресурсами мережі, а також забезпечувати безпеку, надійність і зв'язок обраних мереж. Використання статистичних часових рядів або підходів машинного навчання дозволяє прогнозувати майбутні потоки мережевого трафіку на основі попередніх даних. Ефективне прогнозування може поліпшити якість обслуговування (QoS) і знизити експлуатаційні витрати для постачальників мережевих послуг. Наявна література показує, що моделі глибоких навчань більш ефективно вивчають моделі мережевого трафіку і більш точно передбачають майбутній трафік, ніж традиційні моделі [9, 10, 15].

У роботі [14] розглядається прогнозування мережевого трафіку з використанням глибоких нейронних мереж (DNN, аббр. від англ. Deep Neural Network). Досліджується те, як DNN можуть заздалегідь передбачити приблизну швидкість мережевої взаємодії. У роботі [15] було виконано прогнозування затримки IoT за допомогою багато параметричного методу DNN. У [16, 17] вивчалось довгострокове і короткострокове прогнозування трафіку бездротової мережі за допомогою LSTM з підтримкою глибокого навчання. У [18] авторами представлено рішення на основі глибокого навчання для мереж 5G та інтернету транспортних засобів (IoV, аббр. від англ. Internet of Vehicles). У статті [19] розглядаються останні дослідження бездротових мереж наступного покоління і роль методів машинного навчання (ML, аббр. від англ. Machine Learning) у цих

майбутніх бездротових системах. Прогнозування трафіку за часовими рядами з використанням глибокого навчання і LSTM-мережі для граничних обчислень з підтримкою IoT виконано в роботі [20]. У роботі [21] представлено дослідження проблеми прогнозування трафіку IoT за допомогою Машинного навчання, глибокого навчання, статистичних методів прогнозування на основі часових рядів, таких як LSTM, ARIMA, VARMA і нейронних мереж прямого розповсюдження (FFNNs, аббр. від англ. Feed Forward Neural Networks). У статті [22] було представлено великий огляд сучасних ML підходів до прогнозування стільникового трафіку в мережах 5G. У роботі [22] проведено дослідження прогнозування маршруту транспортного засобу на основі ML з використанням V2V-взаємодії та бортових датчиків. Представлено метод прогнозування маршруту з використанням алгоритму випадкового лісу та архітектури кодер-декодер LSTM. Проаналізовані релевантні роботи дали змогу зробити деякі попередні висновки щодо способу розв'язання задачі прогнозування трафіку в бездротовому комунікаційному середовищі автономних транспортних засобів із багаторівневою хмарною архітектурою підтримки обчислень із використанням методів штучного інтелекту.

Вбачається, що гіпотетично перспективним є підхід глибокого навчання на основі моделей рекурентних нейронних мереж типу LSTM та їхніх можливих модифікацій, адаптованих під предметну область.

## 2.2 Рекурентні нейронні мережі для розв'язання задач послідовного прогнозування інформаційного трафіку

Прогнозування поведінки трафіку за допомогою глибокого навчання має велике значення, оскільки воно здатне навчатися на великих обсягах даних і визначати моделі краще, ніж інші підходи. Прогнозування потенційного трафіку дає змогу поліпшити QoS до виникнення збоїв.

Навчання за допомогою глибоких нейронних мереж (DNN) може бути використане як метод прогнозової аналітики, оскільки воно використовує



історичну інформацію для поліпшення процесу прийняття рішень, що призводить до підвищення точності. Крім того, прогнозування можливості появи великої кількості потоків даних у незвичний час, які, найімовірніше, можна класифікувати як атаки на основі потоків даних, дає змогу підвищити безпеку мережі. Ба більше, прогнозування таких великих потоків даних може також усунути ризик, який може порушити роботу системи IoT.

Прогнозування мережевого трафіку дає змогу користувачам швидко вживати заходів щодо відстеження перевантаженості трафіку і поліпшення роботи мережі.

Крім того, прогнозування трафіку на тривалі періоди дає змогу використовувати детальні моделі трафіку для оцінювання майбутніх потреб у пропускній спроможності, що забезпечує більш точне планування та ухвалення більш ефективних рішень. Прогнозування на короткі періоди (від мілісекунд (мс) до хвилин) підходить для динамічних ресурсів. Швидке прогнозування трафіку є потужним методом для досягнення більшої ефективності. Їхні методи необхідні для підвищення точності прогнозування мережевого трафіку, щоб запобігти погіршенню здатності системи до забезпечення якості обслуговування та подолати труднощі 5G.

Спостережувана технологія повинна прогнозувати, щоб запобігти слабким спільним рішенням; тому необхідні різні прогнози трафіку.

Численні стратегії ML були розроблені для підвищення точності прогнозів трафіку. Серед найкращих підходів - DNN, який заснований на системі ANN. Цей метод був проконтрольований і протестований для прогнозування майбутніх даних про трафік. Глибоке навчання - це особливий вид багат шарової нейронної мережі (MLNN). Глибоке навчання залежить від MLNN і відповідних алгоритмів, які обробляють великі набори даних. Інші способи краще, ніж звичайні NN, обробляють дані з попередніх випадків. RNN належить до найбільш поширених і широко використовуваних мережевих циклів у попередній інформації. Кожна мережа в циклі отримує вхідні дані та інформацію

від попередньої мережі, виконує певний процес, генерує вихід і передає дані майбутній мережі.

Звичайна рекурентна нейронна мережа (RNN), абр. від англ. Recurrent Neural Network) - це мережа, що використовує петлю зворотного зв'язку для створення пам'яті та вкрай погано справляється з умовами, коли будь-що має бути "збережено" надовго. Затримки в навчанні стають ще серйознішими, коли немає зв'язку між останньою необхідною порцією даних і критичною метою. Вплив прихованого стану або входу  $t$ -кроку на наступні стани мережі реакції швидко зменшується. Пропоновані сьогодні рішення з глибоким навчанням в основному пов'язані з гнучкістю і складністю безперервної мережі "будівельних блоків". Було показано, що замість одного числа, на яке впливають усі наступні умови, можна створити особливого роду клітинку, в якій тим чи іншим способом імітувати "довгу пам'ять", операції запису і читання в цій "клітинці пам'яті" тощо. Така клітина матиме не одну групу ваг, подібно до звичайного нейрона, а різні, в такому разі навчання буде дуже важким, але практично витрати зазвичай відбуваються. Для одних випадків потрібна тільки нова інформація, а для інших - більш ранні дані. Звичайні нейронні мережі відстають у навчанні, тому що затримка між раніше необхідною інформацією і необхідним ключем збільшується експоненціально.

### 2.2.1 Мережа довготривалої короткострокової пам'яті (LSTM)

Однією з найпопулярніших і часто використовуваних модельних структур у штучному інтелекті є LSTM. Мережа LSTM - це тип рекурентної нейронної мережі (RNN, абр. від англ. Recurrent Neural Network), які найбільше підходять для довгострокового зберігання даних і зазвичай використовуються в галузі глибокого навчання. Оскільки великі обсяги даних можуть вплинути на продуктивність моделі, вона є природним вибором для побудови, навчання та розгортання мережі. Перевага LSTM у тому, що вона допомагає забезпечити менший вплив на незалежні зв'язки. Крім того, мережа повинна бути навчена

визначати, який фрагмент інформації підходить для мережі, і мати точне уявлення про те, що потрібно зберігати. У разі глибокого навчання, LSTM застосовується багаторазово.

LSTM став найефективнішим рішенням майже всіх проблем прогнозування послідовностей завдяки останнім досягненням у галузі науки про дані. Комірка LSTM отримує або відкидає дані залежно від їхньої ваги. Згодом ці дані відшкодовуються залежно від їхньої ваги. Операція навчання RNN адаптує ваги з'єднань, які керують прихованим станом і входом. Але ці мережі навчаються в міру надходження сигналів, вихідного сигналу або видалення інформації через послідовні кроки поширення помилки. Блок LSTM, на відміну від стандартного рекурентного блоку, зберігає комірку пам'яті.

Стандартна структура комірок LSTM показана на рисунку 2.1. Осередок у LSTM має три основні вузли, звані гейтами (gate), які керують його станом: вхідний (input gate), забування (forget gate) і вихідний (output gate), а фактичний осередок зворотного зв'язку - це прихований стан.

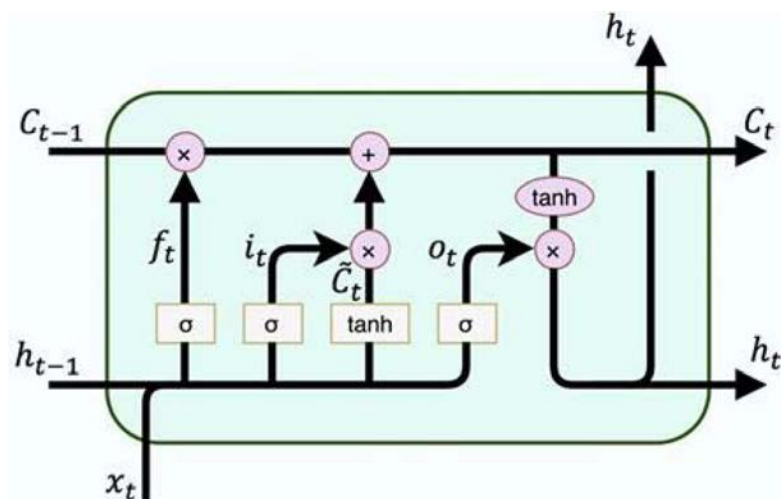


Рисунок 2.1 - Структура мережі LSTM

Гейти LSTM являють собою сигмоїдальну передавальну функцію (1), тобто їхній вихід еквівалентний 0 або 1.

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (2.1)$$

Слід оцінити гейт забування, як відсотковий внесок входу; вхідний гейт вибирає поточну інформацію для зберігання в комірці пам'яті. Поточний вектор значень-кандидатів можна використати для стану шару активації гіперболічного тангенса (tanh-шар - один із типів шарів, які використовують у нейронних мережах, що містить свої власні вагові матриці). Вхідний гейт підключається до tanh-шару для отримання зміни стану. Вихід функції активації tanh відповідає значенню між -1 і 1 для визначення його значущості.

Оцінка використовує функцію  $\tanh(x)$  таким чином:

$$\tanh \tanh (x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.2)$$

Інші зв'язки збільшують зв'язність моделі (про них ми поговоримо нижче).

Припустимо, що ми задаємо, що  $x_t$  і  $h_t$  - це вектори вхідного і прихованого стану за часом  $t$ . У цьому разі  $W_i$  і  $W_h$  являють собою вагові матриці, які застосовуються до вхідного шляху і зворотного зв'язку, відповідно, а  $b$  - вектор зміщення.

З огляду на наступний вхід  $x_t$  для прихованого стану  $f$  з попереднього кроку  $h_{t-1}$  і поточний стан комірki  $C_{t-1}$ , ми обчислюємо математичні форми для вхідних воріт  $i_t$ , воріт забуття  $f_t$  та вихідних воріт  $o_t$  в LSTM:

$$i_t = \sigma(w_i x_t + g_i h_{t-1} + b_i) \quad (2.3)$$

$$f_t = \sigma(w_f x_t + g_f h_{t-1} + b_f) \quad (2.4)$$

$$o_t = \sigma(w_o x_t + g_o h_{t-1} + b_o) \quad (2.5)$$

де  $i_t, f_t, o_t$  визначаються як функція вагових матриць  $w_i, g_i, w_f, g_f, w_o, g_o$  і векторів зміщення  $b_i, b_f, b_o$ .

Компактні форми для рівнянь стану клітини-кандидата, стану клітини і вектора прихованого стану (вихідного вектора) такі:

$$C'_t = \tanh(w_c x_t + g_c h_{t-1} + b_c) \quad (2.6)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot C'_t \quad (2.7)$$

$$h_t = o_t \odot \tanh(C'_t) \quad (2.8)$$

Стан клітини-кандидата  $\tilde{C}_t$  визначають як функцію вагових матриць  $w_c$  і  $g_c$ . Оператор  $\odot$  позначає добуток Хадамарда (добуток за елементами).

### 2.2.2 Двонаправлена LSTM (BI-LSTM)

Двонаправлені LSTM засновані на блоці LSTM, де два LSTM подаються на вхідний сигнал. Одна подається на вхідний ряд (шлях прямого поширення).

На другому етапі зворотна форма вхідного ряду подається на модель LSTM (шлях зворотного поширення). Мережа LSTM аналізує тільки вплив минулої серії на поточну та ігнорує пізнішу інформацію, тому оптимальна продуктивність не досягається. На відміну від цього BI LSTM пов'язує вихід блоку LSTM двонаправлено. Вона вловлює двонаправлені залежності сигналів, що підвищує загальну продуктивність моделі. BI-LSTM - це послідовна обчислювальна модель, що складається з двох LSTM. Кожна нейронна мережа має низку інформації у зворотному шляху (від вхідної до попередньої) і прямому шляху (від останньої до вхідної). У двонаправленій мережі вхідні дані надходять у двох напрямках, що відрізняє BI-LSTM від звичайної LSTM. У звичайній LSTM вхідний потік може йти в одному напрямку: або назад, або вперед. У

двонаправленій LSTM можна змусити вхідні дані надходити в обох напрямках, щоб отримати інформацію з майбутнього і минулого.

Bi-LSTM ефективно збільшують кількість інформації, доступної мережі, покращуючи зміст, доступний алгоритму. Прямий і зворотний напрямки Bi-LSTM одночасно передаються на вихідний модуль. Таким чином, можуть бути отримані минулі та майбутні дані, як показано на рисунку 2.2. У кожен момент часу  $t$  вхід подається на прямий і зворотний шляхи мережі LSTM.

Вихід Bi-LSTM може бути представлений таким чином:

$$\vec{h}_t = H(W_1 x_t + W_2 \vec{h}_{t-1} + \vec{b}) \quad (2.9)$$

$$h^{\leftarrow}_t = H(W_3 x_t + W_5 h^{\leftarrow}_{t-1} + b^{\leftarrow}) \quad (2.10)$$

$$y_t = W_4 \vec{h}_t + W_6 h^{\leftarrow}_t + b_y \quad (2.11)$$

На рисунку 2.2 можна бачити потік інформації у зворотному і прямому шарах.




Рисунок 2.2 - Структура нейронної мережі Bi-LSTM

BI-LSTM зазвичай використовують там, де потрібна послідовність завдань. Цей тип мережі може використовуватися в класифікації текстів, розпізнаванні мови і прогностичних моделях.

### 2.2.3 Середовище мереж автотранспорту

Транспортні засоби потенційно можуть взаємодіяти з іншими учасниками цих мереж і придорожною інфраструктурою (RSU) для доступу до інформаційних послуг, починаючи від безпеки та закінчуючи підтримкою водіїв, підключенням до Інтернету для отримання конкретної інформації та мультимедійних засобів (VoIP, обмін миттєвими повідомленнями тощо) [17].

МЕС включають в себе переміщення обчислень, пов'язаних з трафіком і послугами, з централізованої хмари на кордон мережі і ближче до клієнтів.

Границя мережі аналізує, обробляє і зберігає дані замість того, щоб відправляти їх у хмару для обробки. Найбільш значною перевагою прикордонних обчислень є значне скорочення затримок під час аналітичної обробки [19]. Обчислення виконуються на кінцевих пристроях, тому інформації не потрібно долати кілометри мереж, щоб потрапити до центру обробки даних.

Переваги прикордонних обчислень з множинним доступом очевидні в багатьох місцях і додатках. Найбільш очевидним є те, що вона дає змогу мережевим операторам і постачальникам послуг скоротити затримки під час надання послуг для поліпшення загального обслуговування клієнтів, а також впроваджувати нові послуги з високою пропускною спроможністю без згаданих вище затримок.

Якщо припустити, що хмарна служба обміну повідомленнями може бути спроектована як система черг, то середня затримка, викликана доставкою повідомлення в хмару, укладається в таке рівняння:

$$w \propto \frac{\rho}{1-\rho} \cdot \frac{1}{\mu} \quad (2.12)$$

де  $\mu$  - продуктивність сервера (швидкість передачі, що відноситься до кількості повідомлень/одиницю часу).  $\rho$  - це щільність трафіку; ми також можемо визначити це як відношення між швидкістю вхідних повідомлень і продуктивністю  $\rho = a/\mu$ , а - це швидкість вхідних повідомлень за одиницю часу. Ми розглядаємо її як функцію інтенсивності дорожнього руху.

Якщо припустити, що область зв'язку вузла являє собою контур радіуса  $R$ , то вхідний трафік можна розрахувати як

$$a = 2R\eta v \quad (2.13)$$

де  $R$  - дальність зв'язку (m),  $\eta$  - щільність транспортних засобів, оснащених мережевими вузлами ( $1/m^2$ ),  $v$  - швидкість транспортних засобів (m/s).

Якщо система не має втрат, то це відповідає завантаженню сервера. Якщо ми задамо значення затримки  $w$ , як показано в (2.12), використання залежить від значення продуктивності  $\mu$ . Виходячи зі згаданого вище взаємозв'язку, ми можемо бути впевнені, що для досягнення високого рівня зручності використання нам необхідно збільшити продуктивність. Ми повинні вибрати високий трафік і високі значення продуктивності, щоб отримати значні переваги. Ці умови відповідають умовам зірково-структурованої мережі.

Впровадження МЕС не є дуже ресурсоефективним рішенням.

Використання МЕС забезпечує відносно невелике покриття території з відносно невеликою кількістю користувачів, що означає відносно невеликий трафік і витрати на обладнання та персонал. Використання високопродуктивного обладнання не є життєздатним рішенням, оскільки використання низькопродуктивного сервера негативно позначається на якості обслуговування. Ця проблема виникає через відносно невеликий трафік (кількість користувачів) і нестабільний трафік.

Тому, коли ми використовуємо рішення МЕС для поліпшення якості послуг, ми повинні запропонувати рішення для поліпшення якості використовуваного обладнання. Ключовим моментом є пропозиція багаторівневої архітектури для



оптимізації використання обладнання для рішень МЕС, як показано на рисунку 2.3.




Рисунок 2.3 - Двошарова структура МЕС

У цій структурі є два шари; перший шар складається з системи МЕС, що містить мікрокомірки або малі комірки. Є ізотропна базова станція, де кожна комірка оснащена необхідними обчислювальними ресурсами (хмара).

Стільники обслуговуватимуть користувачів навколо та поруч з антенами. Другий шар МЕС сота має антену з формуванням променя. Ця сота може допомогти будь-якому абоненту в сотах першого рівня завдяки технології формування променя.

Формування променя покращує використання пропускної спроможності бездротової мережі та дальність дії, а також підвищує якість потокового відео, голосу та інших застосунків, чутливих до пропускної спроможності, затримок і джиттера. Коли ресурси першого рівня зайняті, осередок у другому шарі обслуговує запити абонентів. Якщо ресурси першого шару зайняті, осередок другого шару обслуговує запити абонентів.

Нехай трафік являє собою пуасонівський потік, а експоненціальний розподіл описує час обслуговування. Модель черги загалом сумісна з методом М/М/1/к з обмеженим буфером. Тоді ймовірність того, що вхідна інформація не потрапить у систему (ймовірність втрати) визначається виразом:

$$p = \frac{1-\rho}{1-\rho^{n+2}} \rho^{n+1} \quad (2.14)$$

Наступне рівняння дає змогу розрахувати середній розмір черги за  $i=1$ :

$$\bar{L} = \frac{\rho(1-(n+1)\rho^n + k\rho^{n+1})}{(1-\rho)(1-\rho^{n+1})} \quad (2.15)$$

Середній час відгуку першого шару представлено таким чином:

$$T = (\bar{L} + 1)\bar{t} \quad (2.16)$$

Порівнюючи систему з обмеженим розміром черги з конструкцією з необмеженим розміром черги, ми обчислюємо затримку системи М/М/1:

$$\bar{T}_m = \frac{\bar{t}}{1-\rho} \quad (2.17)$$

Для методу М/М/1, навантаження на сервер достатнє для забезпечення трафіку; для методу М/М/1/к, навантаження на сервер можна обчислити в такий спосіб:

$$u_i = 1 - P_0 \quad (2.18)$$

$$P_0 = \left\{ \frac{1}{n+1} \quad \rho_i = 1 \frac{1-\rho_i}{1-\rho_i^{n+1}} \quad \rho_i \neq 1 \right. \quad (2.19)$$

де  $P_0$  - імовірність того, що сервер не працює в цей час.

Пропонується модель реалізації для МЕС з урахуванням вищенаведеного припущення про модель черги. Щоб збільшити використання методу МЕС (мікро- або мініхмари), слід вибрати режим підвищеного використання хмари; однак це призведе до погіршення QoS. Пропонується використовувати кілька рівнів, включно з хмарами, призначеними для обслуговування надлишкового трафіку, що надходить із сусідніх рівнів. Такий метод працює за такою схемою: комунікації з регіоном мереж автотранспорту надходять у хмару першого рівня, що описується системою черг M/M/1/k (перший рівень).

Припускається, що продуктивність хмари  $\mu_1$  визначається часом обслуговування  $t_1$ . І вибираємо значення  $t$  на основі часу доставки  $T_0$  та вимог до навантаження сервера.

#### 2.2.4 Туманне середовище

Fog призначений насамперед для додатків і сервісів, які погано працюють в архітектурі хмарних обчислень або не можуть у ній працювати.

У сфері IoT зростаючий розвиток не може бути повністю підтриманий тільки хмарними рішеннями. При оцінці IoT доводиться стикатися з очищенням і попередньою обробкою даних перед відправкою їх у Хмару. Fog плідно взаємодіє з Хмарою, особливо в адмініструванні даних і аналітиці, породжуючи новий клас додатків. Архітектура обчислень Fog - це свого роду "прошарок" на кордоні між Хмарою і пристроями IoT з датчиками і мобільними пристроями користувачів.

Потенційна структура такої системи може бути представлена на рис. 2.4. Система складається з декількох шарів. Ці шари можуть мати різні або ідентичні додатки. Наприклад, базова станція з ізотропною антеною і мікрохмарою покладається на транспортний засіб для обслуговування вхідних туманних запитів, які мають бути виконані якомога швидше.

Аналогічно, наступний хмарний шар допомагає запитам, які не були виконані першою хмарию і очікують обслуговування. Хмара 3-го рівня, реалізована на третій базовій станції зі спрямованою антеною, задовольняє вимоги щодо перевантаження трафіку обох нижніх хмар.




Рисунок 2.4 - Структура рухомого туману

При моделюванні результуючого трафіку ми повинні запропонувати модель туману. Ми припускаємо, що туман - це потік пристроїв, що рухаються в одному напрямку (рис. 2.4). У загальному випадку кожен пристрій може рухатися своїм шляхом, але цей випадок нереальний. Крім того, ми припускаємо, що зона покриття базової станції - це сфера радіуса  $R$ . Ми пропонуємо один конкретний напрямок для всіх пристроїв, що знаходяться в досліджуваній області.

Ця перспектива включає в себе будь-яку кількість шарів. Шари можуть бути реалізовані у вигляді стаціонарних базових станцій на дорозі або мобільних базових станцій на транспортному засобі або дроні.

Кілька систем, які з'єднують основну хмару протягом часу  $\Delta t$ , це

$$n_1(\tau) = \frac{S}{2} v \tau \eta = 2\pi R^2 v \tau \eta, \quad (2.20)$$

де  $S$  - площа сфери,  $v$  - швидкість туману (m/s),  $\tau$  - інтервал (секунди),  $\eta$  - кількість пристроїв на одиницю об'єму (щільність туману),  $R$  - радіус сфери (метри).

$$n_i(\tau) = p_{i-1} n_{i-1}(\tau), \quad (2.21)$$

де  $p_{i-1}$  - імовірність втрати рівня  $i^l$ . Будь-яка система може перебувати в  $i^{\text{th}}$  хмарі у випадковий момент часу  $\gamma$  із середнім значенням

$$\bar{\gamma} = \frac{4R}{3v}. \quad (2.22)$$

Функція розподілу ймовірностей для  $\gamma$  описується як у (2.23)

$$f(\gamma) = \frac{1}{2} \left( \frac{v}{R} \right)^2 \gamma, \quad 0 \leq \gamma \leq \frac{2R}{v} \quad (2.23)$$

$$F(\gamma) = \frac{1}{4} \left( \frac{v\gamma}{R} \right)^2 \quad 0 \leq \gamma \leq \frac{2R}{v} \quad (2.24)$$

Імовірність того, що система не працює на базовій станції дорівнює ймовірності того, що час утримання в зоні не буде більшим, ніж затримка  $T_m$

$$p(\gamma \leq T_m) = F(T_m) = \frac{1}{4} \left( \frac{vT_m}{R} \right)^2, \quad 0 \leq T_m \leq \frac{2R}{v} \quad (2.25)$$

Красиво звучить уявлення цього методу як системи черг, у якій зацікавлені запити з кількома пріоритетами залишають чергу, перш ніж будуть обслужені, якщо час затримки перевищує час перебування в зоні дії базової станції. Однак, точного рівняння для цього методу не існує. Отже, ми можемо запропонувати

використовувати метод черги M/M/1/prio, за якого середня затримка має бути меншою, ніж  $T_m$  Ми можемо обчислити  $T_m$  з (20), використовуючи формулу

$$T_m = \frac{2R}{v} \sqrt{p_0}, \quad (2.26)$$

коли  $p_0$  - імовірність того, що час в області обслуговування менший за  $T_m$ , ми припускаємо, що  $p_0$  - імовірність програшу на цьому рівні.

Ми застосовуємо метод M/M/1/prio для демонстрації затримки на кожному шарі:

$$\bar{W}_i = \frac{\sum_{j=1}^M \rho_j \bar{t}_j}{(1-R_{i-1})(1-R_i)}, \quad i = 1, \dots, M \quad (2.27)$$

$$R_i = \sum_{j=1}^i \rho_j, \quad R_{i-1} = \sum_{j=1}^{i-1} \rho_j \quad (2.28)$$

де  $M$  - номер пріоритету;  $\rho_j$  - інтенсивність  $j$ -го пріоритетного трафіку,  $t_j$  - середній час обслуговування  $j$ -го пріоритетного запиту.

Під час визначення плану за допомогою багаторівневого МЕС, заснованого на цьому методі, ми повинні вибрати параметри шляху; таким чином, вони можуть задовольняти такій умові

$$\bar{W}_i + \bar{t}_i < T_m \quad (2.29)$$

Дисбаланс полягає в тому, що середня затримка менша за час у зоні дії базової станції з імовірністю  $1-p_0$ . Якщо  $p_0$  невелика, то (2.29) означає, що, як правило, запити  $i$ -го пріоритету обслуговуються в зоні дії базової станції.

Використовуючи (2.26), (2.27) і (2.29), ми можемо зробити оцінку необхідної продуктивності  $t_j$  для кожного пріоритету і кількості хмар (шарів).

### 2.3 Імітаційна модель

Структура модельованої мережі являє собою певну реалізацію методу черг.

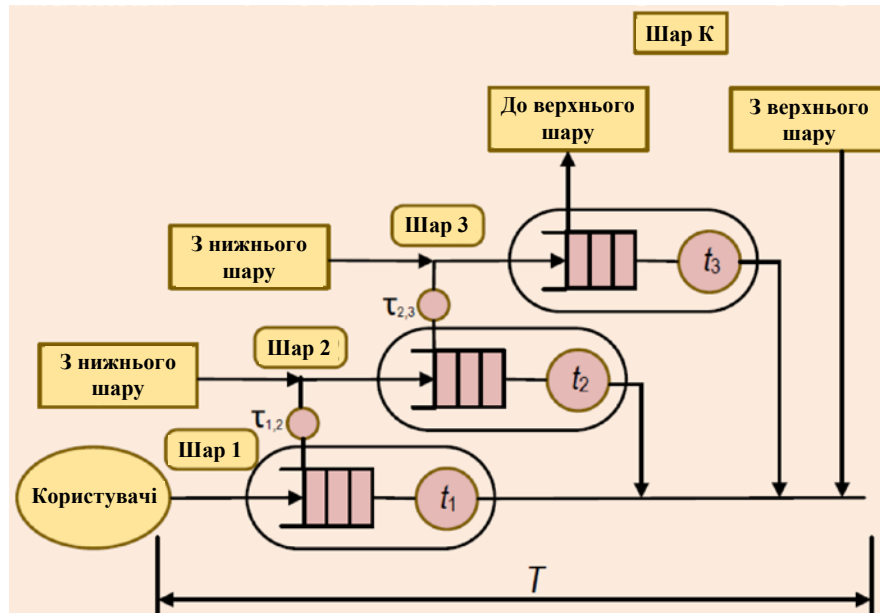


Рисунок 2.5 - Структура мережі

Кожен шар моделі складається з одного сервера і однієї черги, і кожна черга має два виходи і тільки один вхід. Вхід черги приймає вхідну інформацію від цього шару. Виходом є верхня частина черги, підключена до сервера. Якщо деякі запити не були задоволені на даному рівні (втрачені рекомендації), вони виходять з черги і продовжують надходити на наступний рівень через цей вихід. Існують різні причини, через які запити не були обслужені від одного середовища до іншого. Для середовища мереж автотранспорту використовували таку структуру моделі: кожен шар описує стаціонарну комірку базової станції та втрачені запити через надмірний трафік у першому випадку; у другому випадку втрати спричинені надто великою затримкою, що перевищує  $T_m$ .

Зазвичай у цих двох випадках можна використовувати кілька пріоритетних запитів. Проте, передбачалося, що всі пакети (повідомлення) в середовищі мереж автотранспорту однорідні, і через це використовувалися не пріоритетні черги.

## 2.4 Результати моделювання

Здійснюється прогнозування трафіку на основі підходу глибокого навчання з використанням BILSTM і LSTM мереж для автономних транспортних засобів з багаторівневими хмарними обчисленнями. Точність прогнозування вимірювалася за допомогою RMSE, MAPE, R<sup>2</sup> і часу обробки, з використанням функції втрат MSE і швидкості навчання 0,1. Було проведено порівняння між BILSTM і односпрямованою LSTM з використанням RMSE, MAPE, R<sup>2</sup> і часу обробки при різних розмірах для середовища мереж автотранспорту. Набори даних для навчання були отримані з багаторівневих хмарних обчислень з підтримкою автономного транспорту. Завдання було виконано за допомогою MATLAB, оскільки набір даних було зібрано й оброблено, його було розділено на 70 і 30 % для навчання, а також 30 % для тестування.

Для розрахунку точності прогнозування застосовували математичні форми для RMSE, MAPE і R<sup>2</sup>, як описано в рівняннях (2.30), (2.31) і (2.32):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.30)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{x_t} \right| \quad (2.31)$$

$$R^2 = 1 - \frac{SS_{Regression}}{SS_{Total}} = 1 - \frac{\sum_i (y_i - \hat{y}_i)}{\sum_i (y_i - \underline{y}_i)} \quad (2.32)$$

де N - загальне число спостережень,  $y_i$  - фактичне значення,  $\hat{y}_i$  - передбачене значення,  $\underline{y}_i$  - середнє значення всіх значень.  $SS_{Total}$  - сума загальних квадратичних помилок, а  $SS_{Regression}$  - сума квадратичних помилок регресії.

У таблиці 2.1 показано точність прогнозування швидкості трафіку в разі використання середовища мереж автотранспорту за трьох різних частин



навчальної вибірки (BatchSizes) з погляду використання двох різних BI-LSTM і LSTM-моделей з урахуванням функції втрат MSE як міри продуктивності та швидкості навчання 0,1. Щоб дослідити модель прогнозування, яка забезпечує парадигмальну точність і максимальне середнє покращення, масштабувалася точність прогнозування за допомогою середньоквадратичної помилки (RMSE, абр. від англ. Root Mean Square Error), середньої абсолютної відсоткової помилки (MAPE, абр. від англ. Mean Absolute Percentage Error) і коефіцієнта детермінації  $R^2$ .

Таблиця 2.1 - Точність прогнозування трафіку в середовищі мереж автотранспорту

Розмір вибірки	BI-LSTM				LSTM			
	RMSE	MAPE%	$R^2$	Тривалість оброблення	RMSE	MAPE%	$R^2$	Тривалість оброблення
8	0.0241	2.9902	0.9959	44.5000	0.0547	5.1858	0.9862	27.7969
16	0.0350	4.3937	0.9958	39.8750	0.0954	10.3052	0.9732	28.6563
64	0.0943	10.8848	0.9721	25.1094	0.1379	15.3204	0.9436	36.1719

Як видно з результатів у таблиці 2.1, за використання BatchSizes = 8 точність прогнозування перевершує конкурентів і має найкращі показники для BI-LSTM і LSTM мереж.

Відповідно, максимальне середнє поліпшення в обох випадках становить 7.9 і 10.135 %. Однак це займає найбільше часу обробки для BI-LSTM і найшвидше для LSTM. Точність прогнозування за BatchSizes = 16 приблизно така сама, як і за BatchSizes = 8. У цьому випадку максимальне середнє поліпшення становить 6.5 і 5.12 % відповідно для BI-LSTM і LSTM. Однак, точність прогнозування при використанні BatchSizes = 64 є досить низькою порівняно з іншими, хоча має найшвидший час опрацювання для BI-LSTM, але найтриваліший для LSTM. Крім того, коефіцієнт детермінації  $R^2$  приблизно однаковий в обох випадках і близький до 1, що вказує на хорошу відповідність. З іншого боку, точність прогнозування за допомогою BI-LSTM вища, ніж у

LSTM у всіх випадках, а максимальне середнє поліпшення BI-LSTM порівняно з LSTM у всіх випадках: 2.2, 5.9 і 4.4 %, відповідно.

На рисунках 2.6 показано результати прогнозування для різних частин вибірки Batch Size у BI-LSTM та LSTM-моделях: криві (зліва) являють собою ймовірність помилки прогнозування швидкості трафіку, а гістограми (праворуч) - ймовірність втрати з плином часу (у секундах).

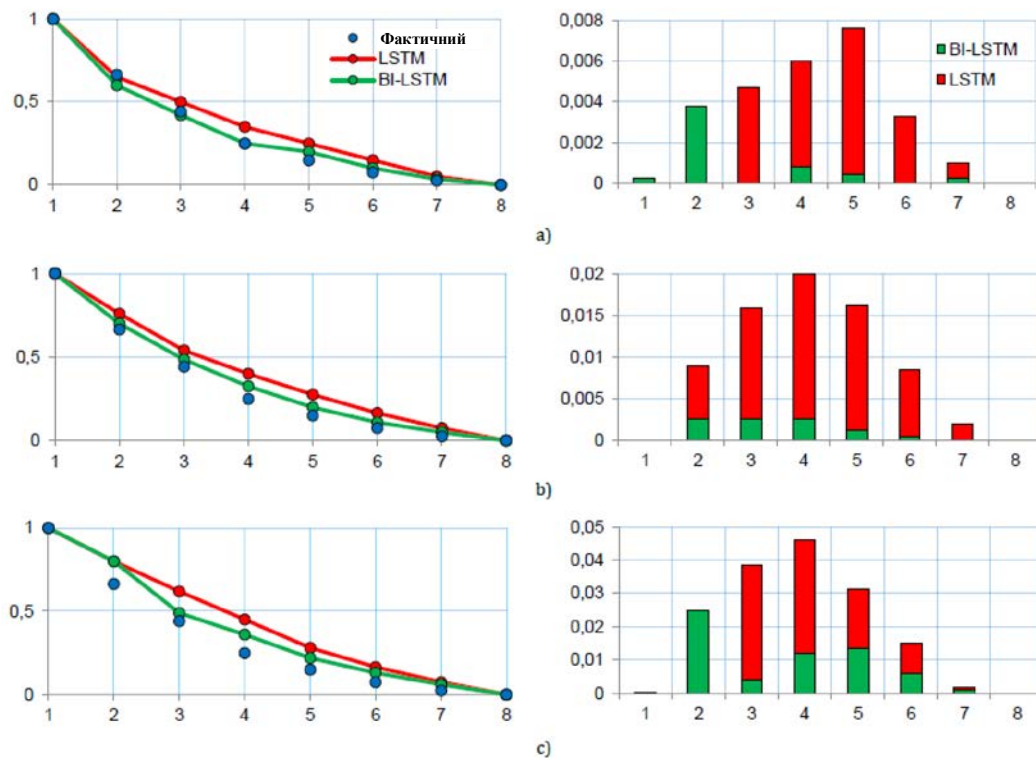


Рисунок 2.6 - Прогнозування вихідних патернів у разі використання BatchSize, що дорівнює: а) 8, б) 16 і с) 64

У таблиці 2.2 показано точність прогнозування швидкості трафіку в разі використання середовища рухомого туману за трьох різних частин навчальної вибірки (BatchSizes) з погляду використання двох різних BI-LSTM і LSTM-моделей з урахуванням функції втрат MSE як міри продуктивності та швидкості навчання 0,1. Щоб дослідити модель прогнозування, яка забезпечує парадигмальну точність і максимальне середнє поліпшення, масштабувалася точність прогнозування за допомогою RMSE MAPE і  $R^2$ .

Таблиця 2.2. Точність прогнозування трафіку в середовищі рухомого туману

Розмір вибірки	BI-LSTM				LSTM			
	RMSE	MAPE%	R <sup>2</sup>	Тривалість оброблення	RMSE	MAPE%	R <sup>2</sup>	Тривалість оброблення
8	0.0039	0.3615	0.9999	25.5313	0.0186	1.4719	0.9972	29.5156
16	0.0539	4.1281	0.9772	36.4375	0.0768	6.6099	0.9669	27.2188
64	0.0874	7.5498	0.9593	45.7031	0.1127	9.9158	0.9529	44.6406

Як видно з результатів у таблиці 2.2, за використання BatchSizes = 8 точність прогнозування перевершує конкурентів і має найкращі показники для BI-LSTM і LSTM мереж.

Відповідно, максимальне середнє поліпшення в обох випадках становить 7,2% і 8,4%. Крім того, для BI-LSTM потрібен найшвидший час обробки. Точність прогнозування за BatchSizes = 16 приблизно така сама, як і за BatchSizes = 8. У цьому випадку максимальне середнє поліпшення становить 3,8% і 5,14% відповідно для BI-LSTM і LSTM. Однак, точність прогнозування при використанні BatchSizes = 64 є досить низькою порівняно з іншими, хоча має найшвидший час опрацювання для BI-LSTM, але найтриваліший для LSTM. Крім того, коефіцієнт детермінації R<sup>2</sup> приблизно однаковий в обох випадках і близький до 1, що вказує на хорошу відповідність. З іншого боку, точність прогнозування за допомогою BI-LSTM вища, ніж у LSTM у всіх випадках, а максимальне середнє поліпшення BI-LSTM порівняно з LSTM у всіх випадках: 1,11%, 2,5% і 2,4%, відповідно.

Результати моделювання точності прогнозування показують, що BI-LSTM-провісник перевершує LSTM-провісник у всіх випадках. При використанні 8 частин вибірки точність прогнозування перевершує конкурентів з найкращими показниками для BI-LSTM і LSTM мереж. Для 64 частин вибірки точність прогнозування низька порівняно з іншими.

Коефіцієнт детермінації (R<sup>2</sup>) приблизно однаковий в обох випадках і близький до 1, що означає, що мережа добре підігнана.

У середовищі мереж автотранспорту, за використання 64 частин вибірки, модель BI-LSTM має найшвидший час опрацювання і найповільніший час опрацювання за використання 8 частин вибірки. У середовищі туману, модель BI-LSTM має найшвидший час обробки за умови використання 8 частин вибірки, а модель LSTM має найшвидший час обробки за умови використання 16 частин вибірки, але найповільніший час обробки за умови використання 64 частин вибірки.

## 2.5 Висновки до розділу 2

Запропоновано методи глибокого навчання з використанням BI-LSTM і LSTM для прогнозування трафіку в автономних транспортних засобах із багаторівневими хмарними обчисленнями.

Виконано прогнозування у двох середовищах: у середовищі мереж автотранспорту та в середовищі туману.

Точність прогнозування трафіку вимірювалася за допомогою RMSE, MAPE,  $R^2$  і часу обробки, з використанням функції втрат MSE і швидкості навчання 0,1.

Проведено порівняння між BI-LSTM і односпрямованою LSTM з використанням RMSE, MAPE,  $R^2$  і часом обробки за різних частин вибірки у двох середовищах: у середовищі мереж автотранспорту і в середовищі туману.

Набори даних для навчання були отримані з багаторівневих хмарних обчислень з підтримкою БА.

Дослідження виконано з використанням MATLAB. Через те, що набір даних було зібрано й оброблено, його було розділено на 70%, 30% для навчання і 30% для тестування.

### 3 ПРОГНОЗУВАННЯ ШВИДКОСТІ РУХУ АВТОТРАНСПОРТУ ІЗ ВИКОРИСТАННЯМ МЕТОДІВ ШТУЧНОГО ІНТЕЛЕКТУ

#### 3.1 Обґрунтування інтелектуальних технологій керування автотранспортом

Останнім часом автономні транспортні засоби завоювали популярність, оскільки вони дуже впливають на суспільство, підвищуючи безпеку і комфорт, знижуючи витрату пального, зменшуючи кількість заторів і аварій, заощаджуючи витрати і підвищуючи надійність. Проте, досі існують деякі функціональні недоліки автономних транспортних засобів, які необхідно усунути, перш ніж вони зможуть бути повністю розгорнуті на основних автомагістралях. Прогнозування транспортного потоку важливе для автономного транспорту, щоб визначити свій маршрут і приймати адаптивні рішення щодо навколишнього середовища. Глибоке навчання - це потужний метод для розроблення адаптивних і прогнозувальних систем, який також успішно використовується в автомобільних мережах. У цьому розділі ми пропонуємо підхід глибокого навчання з використанням стекової двонаправленої моделі довготривалої короткострокової пам'яті (SBILSTM) для прогнозування руху транспортних засобів у місцях з інтенсивним рухом на основі літаючих туманних обчислень. З погляду точності прогнозування проводиться порівняння між запропонованою моделлю SBILSTM і звичайними моделями BILSTM і LSTM. Точність прогнозування розраховується за допомогою середньоквадратичної помилки (RMSE), середньої абсолютної відсоткової помилки (MAPE), коефіцієнта детермінації (R-квадрат) і часу обробки.

Результати показують, що точність прогнозування за допомогою запропонованої SBILSTM перевершує традиційні моделі BILSTM і LSTM.

З появою 5G і наступних технологій галузь переходить від під'єднаних автомобілів до автономного водіння й автономного транспортного засобу, що дає змогу надавати нові послуги.

Фундаментальними проблемами є обробка і зберігання великих обсягів даних, що генеруються постійно зростаючою кількістю датчиків у БА, а також забезпечення реального часу і надійності мережі, водночас ключові позиції займають Fog і edge computing. У рамках розвитку концепції автономних транспортних засобів та їхньої інфраструктури необхідно вирішити проблему додаткових зовнішніх обчислювальних потужностей, необхідних для розподілу обчислень цифрових моделей доріг. Це відбувається при великому скупченні автомобілів і, в принципі, всіх рухомих керованих об'єктів.

З огляду на технологічні переваги мереж 5G, описані вище, особливо метод розвантаження і Fog computing, є можливість реалізувати наше завдання. Коли потрібна додаткова енергія, збирається мережа літаючих дронів, які повинні знаходитися на відповідній ділянці дороги з високим трафіком [28].

Ми можемо визначити кількість дронів, необхідних для даної ділянки, і місце розташування обчислювального літаючого туману для забезпечення необхідної обчислювальної потужності.

Наразі БА стали новою галуззю вивчення штучного інтелекту (AI), і очікується, що їхня популярність зростатиме. Ми все ще перебуваємо на ранніх стадіях розвитку самокерованих автомобілів, але технологія швидко вдосконалюється. Очікується, що технологія саморуху матиме значний вплив на автомобільну промисловість. Вона забезпечує безпечне водіння за рахунок автоматичного керування транспортними засобами. Це знижує аварійність на дорогах та економічні витрати, а також є більш безпечною альтернативою водіям-людям.

Автомобіль без водія здатний безпечно і ефективно їздити без допомоги людини-водія - це БА. Серед багатьох потенційних переваг автономного водіння - підвищення безпеки, ефективності та комфорту.

Наприклад, БА можуть допомогти знизити кількість дорожньо-транспортних пригод, заторів і шкідливих викидів. Хоча технологія все ще вдосконалюється, кілька компаній вже проводять випробування автономних автомобілів на дорогах загального користування. У міру розвитку технологій ми

можемо очікувати, що найближчими роками на дорогах з'являтиметься дедалі більша кількість автомобілів.

З розвитком транспортних засобів зростає і потреба в машинному навчанні (ML). Щоб бути повністю автономними, БА повинні виконувати безліч завдань. До них відносяться виявлення і об'їзд перешкод, дотримання правил дорожнього руху і прийняття рішень залежно від мінливих умов. Кожне з цих завдань являє собою унікальний виклик, який має бути подоланий системою ML. Щоб розробити БА, здатний виконувати всі ці завдання, інженери повинні спочатку створити систему, яка зможе взаємодіяти з різними системами ML і розуміти їх. Це непросте завдання, оскільки кожна система призначена для виконання конкретного завдання і може використовувати різні формати даних і стандарти.

Однак це необхідно для розробки повністю БА. Така велика кількість завдань, які ML повинен об'єднати, являє собою унікальний виклик.

ML - це гілка штучного інтелекту (AI), яка аналізує й інтерпретує шаблони та структури даних для забезпечення навчання, міркувань і прийняття рішень без участі людини. У машинному навчанні користувачі можуть постачати комп'ютерний алгоритм великою кількістю даних і дозволяти йому ухвалювати рішення на основі даних. Алгоритм може використовувати коригування для поліпшення майбутніх рішень. Машинне навчання (ML) - одна з найважливіших і найпопулярніших галузей, що розвиваються (AI) сьогодні. Останнім часом машинне навчання стало важливою галуззю досліджень, що розвивається, для інженерії дорожнього руху, особливо для прогнозування дорожнього руху. Дорожні затори мають прямий або непрямий вплив на економіку. Щодня через затори на дорогах витрачається дорогоцінний час і паливо. Оскільки затори на дорогах є серйозною проблемою для всіх верств суспільства, необхідне дрібномасштабне прогнозування дорожнього руху, щоб люди могли жити без розчарування і напруги. У забезпеченні економічного зростання країни головним пріоритетом має бути зниження завантаженості доріг. Це можливо лише за умови швидкого руху транспорту. Тому для оцінки або прогнозування дорожнього руху нам необхідні прогнози руху.

Останнім часом багато дослідників доклали великих зусиль і зосередилися на прогнозуванні трафіку бездротових мереж в автономних транспортних засобах на основі обчислень літаючого туману. Ця робота присвячена прогнозуванню трафіку в автономних транспортних засобах у жвавих районах за допомогою обчислень на основі літаючого туману з використанням підходу глибокого навчання на основі SBILSTM. Тому в цьому розділі представлено попередні роботи, що мають відношення до нашої галузі.

Abdellah та ін. [27] запропонували односпрямований алгоритм глибокого навчання на основі LSTM для прогнозування мережевого трафіку V2X залежно від пакетів, що відправляються за секунду. У [28] обговорювалися як ML, так і статистичні методи для прогнозування мережевого трафіку. Дослідження показує, що більшість наявних рішень неефективні в реальних додатках через особливості обробки мережевих даних у сучасних мережевих технологіях, таких як теорія мереж, проблема перенавчання та "земляна правда". У [29] дослідники розробляють застосунок для Android, який задовольняє потребу користувачів бачити трафік у реальному часі, використовуючи IoT, машинне навчання та розширені API на основі GPS. API збирають дані за допомогою краудсорсингу і накопичують місце розташування користувача в реальному часі на серверах за допомогою мікросервісів.

Застосунок для Android заснований на механізмі збору даних про трафік у режимі реального часу з використанням передових хмарних API, IoT, машинного навчання і хмарних обчислень.

У [30] дослідники зосередилися на повному вивченні експериментальних характеристик і оцінок архітектури глибокого навчання нейронної мережі для виявлення семи категоріальних атак, виявлених у наборі даних трафіку Distributed Smart Space Orchestration System. У [31] було розроблено нову систему прогнозування трафіку в щільно розгорнутих мережах IoT на основі штучного інтелекту (AI). Це полегшує управління трафіком і дає змогу уникнути перевантаженості мережі. Розроблений алгоритм AI являє собою модель глибокого навчання на основі згорткової нейронної мережі, яка є легким



алгоритмом, який може бути реалізований розподіленим обчислювальним вузлом на кордоні, таким як вузол Fog, з обмеженими обчислювальними потужностями.

У [32] основною метою було вивчення прогалин у ролі ML у сервісах і системах обчислень Fog. У роботі представлено участь ML у трьох аспектах Fog computing: Управління ресурсами, Точність і Безпека. Результат показує, що ML чинить значний вплив на поліпшення додатків і послуг Fog computing. У роботі [33] досліджено роль ML у Fog Computing і представлено участь ML у трьох аспектах Fog Computing: поліпшення парадигми, безпека і конфіденційність, а також прикладні рішення. Найпоширенішими методами ML є статистичні алгоритми або алгоритми контрольованого навчання. У [34, 35] досліджувалося довгострокове та короткострокове прогнозування трафіку бездротової мережі за допомогою LSTM-мережі з підтримкою глибокого навчання.

### 3.2 Математичні основи методу інтелектуального прогнозування

Стекова BILSTM є надійним методом для розв'язання складних задач прогнозування послідовності. Архітектура стекової LSTM - це модель BILSTM, що складається з декількох шарів. Вищий шар BILSTM посиляє нижчому шару BILSTM послідовність значень, а не одне значення.

Один вихідний сигнал на кожен крок вхідного часу, на відміну від одного вихідного сигналу на всі кроки вхідного часу.

Архітектура мереж LSTM була спочатку розроблена Хохрайтером і Шмідхубером. Більш формально, задано вектор вхідної послідовності  $x = (x_1, x_2, \dots, x_n)$  і, де  $n$  позначає довжину вхідного речення. Основною структурою LSTM є використання трьох керуючих воріт для управління вектором активації комірок пам'яті  $s$ . Перші ворота забування визначають, яка частина стану комірки  $s_{t-1}$  у попередній момент часу зберігається до поточного стану комірки; другі вхідні ворота визначають, якою мірою вхід  $x_t$  мережі зберігається до поточного стану комірки; треті вихідні ворота визначають, яку частину стану комірки передають

у поточне вихідне значення мережі LSTM. Три гейти являють собою повністю підключений шар, вхід якого - вектор, а вихід - дійсне число в  $[0, 1]$ .

Основна архітектура осередку LSTM показана на рисунку 3.1, а її представлення має такий вигляд:

$$it = \sigma(Wi xt + Ui ht-1 + bi), \quad (3.1)$$

$$ft = \sigma(Wf xt + Uf ht-1 + bf) \quad (3.2)$$

$$ot = \sigma(Wo xt + Uo ht-1 + bo) \quad (3.3)$$

$$ct = ft * ct-1 + it * \tanh(Wc xt + Uc ht-1 + bc) \quad (3.4)$$

$$h_t = ot * \tanh(ct), \quad (3.5)$$

де  $\sigma$  - логістична сигмоїдна функція,  $x_t$  позначає вектор  $t$ -го слова речення,  $h_t$  означає прихований стан, терміни  $W$  і  $b$  являють собою вагові матриці, відповідно (наприклад,  $W_f$  представляє вагову матрицю забутих воріт), і вектори зсуву (наприклад,  $b_i$  представляє вектор зсуву вхідних воріт) для трьох воріт.

Щоб подолати недолік одного осередку LSTM, який може вловлювати тільки попередній контекст, але не може використовувати майбутній контекст, Шустер і Палівал винайшли двонаправлені рекурентні нейронні мережі (BRNN), які об'єднують два окремі приховані шари LSTM з протилежними напрямками до одного виходу. Завдяки такій структурі вихідний шар може використовувати пов'язану інформацію як із попереднього, так і з майбутнього контексту.

$$\vec{h}_t = H(W_1 x_t + W_2 \vec{h}_{t-1} + \vec{b}) \quad (3.6)$$

$$h_t^{\leftarrow} = H(W_3 x_t + W_5 h_{t-1}^{\leftarrow} + b^{\leftarrow}) \quad (3.7)$$

$$y_t = W_4 \vec{h}_t + W_6 h_t^{\leftarrow} + b_y \quad (3.8)$$

де  $y = y_1, y_2, \dots, y_t, \dots, y_n$  - вихідна послідовність першого прихованого шару.

Деякі попередні роботи показали, що шляхом об'єднання декількох BILSTM у нейронні мережі можна додатково поліпшити продуктивність класифікації та регресії. Ба більше, існує низка теоретичних доказів того, що глибока ієрархічна модель є більш ефективною в поданні деяких функцій, ніж неглибока. Ми визначили стекову мережу BILSTM, де вихід  $y_t$  з нижнього шару стає входом верхнього шару. Структура стекової BILSTM показана на рисунку 3.1:




Рисунок 3.1 - Структура стекової BILSTM(SBILSTM)

### 3.3 Архітектура методу розвантаження інформаційного трафіку при високій інтенсивності руху

Загальна архітектура методу розвантаження трафіку в місцях з високою інтенсивністю руху заснована на обчисленнях "рухомого літаючого туману"

У наведених вище розділах визначено технологічні тенденції в обчисленнях Fog, доволі докладно описано можливості цих технологій, а в окремому розділі описано проблему, розв'язання якої є метою цієї дисертації.

Поставлене завдання полягає у визначенні кількості літаючих туманів, а також розташування цих обчислювальних літаючих туманів для забезпечення необхідної обчислювальної потужності.

За великого скупчення автомобілів і, в принципі, всіх рухомих керованих об'єктів (наприклад, велосипедів, пішоходів тощо), необхідно забезпечити додаткову обчислювальну потужність зовні (щодо самих об'єктів) для розподілу обчислень цифрової моделі дороги.

Для цього, коли потрібна додаткова пропускна здатність, створюється мережа літаючих дронів, які розміщуються у відповідних місцях на дорозі, де спостерігається висока інтенсивність руху. у даному розділі ми пропонуємо використовувати обчислення на основі літаючого туману для забезпечення необхідної обчислювальної потужності.

На рисунку 3.2 показано загальну архітектуру, що включає елементи фізичного світу (автомобілі, дороги, безпілотники тощо). Як уже було показано на практиці, за всіх доступних сьогодні обчислювальних можливостей і технологій, БА необхідно забезпечити додаткову зовнішню обчислювальну потужність (відносно самих об'єктів) для розподілу обчислень цифрової моделі дороги за наявності великого скупчення автомобілів або керованих об'єктів, що рухаються.

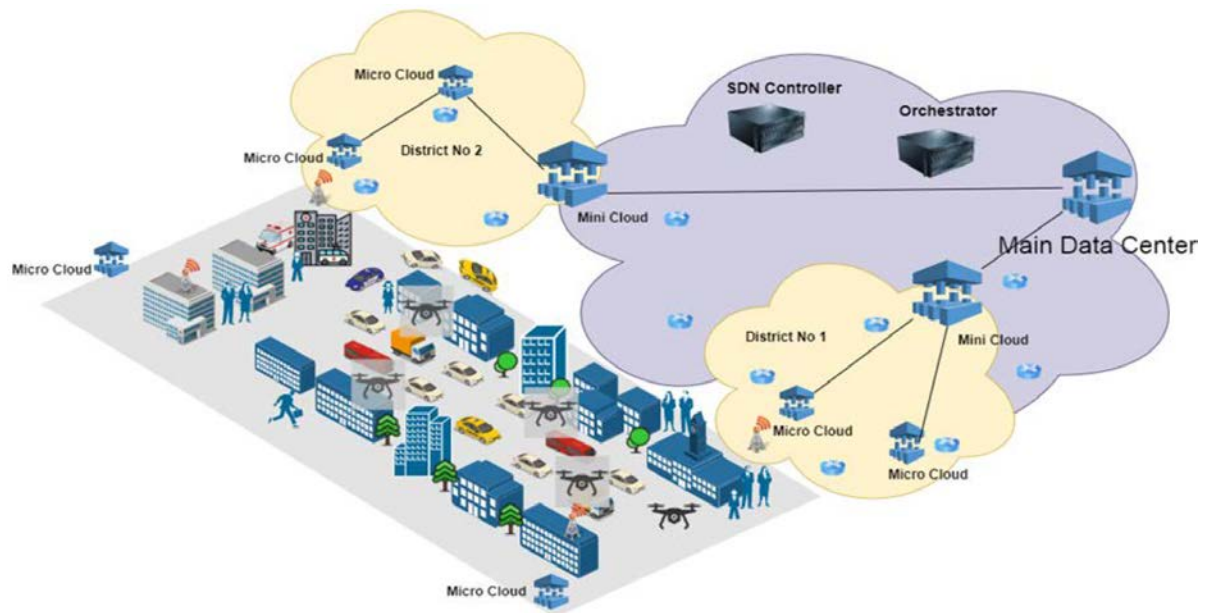


Рисунок 3.2 - Загальна архітектура моделі системи

На рисунку вище показано елементи, які присутні і можуть взаємодіяти один з одним. Щоб з'ясувати, скільки обчислювальної потужності потрібно для цих елементів, ми запропонували вирішення проблеми, відправивши групу дронів у район, де спостерігається перевантаження для цих елементів.

Ми зібрали дані для кількох можливих випадків і записали їх у скрипт Python, одним із яких був випадок, коли конкретна ділянка дороги була обрана на певний період. Результати програмування цих даних дозволили нам визначити кількість і розташування безпілотників, необхідних для цієї дороги.

### 3.4 Результати моделювання

У цьому підрозділі ми виконуємо прогнозування трафіку за допомогою підходу глибокого навчання з використанням запропонованої SBILSTM і традиційних BILSTM і LSTM мереж для БА в зонах з високим трафіком на основі літаючих туманних обчислювальних середовищ. Точність прогнозування оцінювали за допомогою RMSE, MAPE,  $R^2$  і часу обробки, з MSE як функцією

втрат і швидкістю навчання 0,1. Було проведено порівняння між SBILSTM і традиційними моделями на основі RMSE, MAPE,  $R^2$  і часу обробки.

Ми змоделювали систему автономного транспорту за допомогою програми Python для створення навчального набору даних глибокого навчання. Ми також використовували програму MATLAB для моделювання прогнозування трафіку за допомогою моделі глибокого навчання. Після збору та обробки набір даних для прогнозування було подано в модель глибокого навчання, а потім розділено на 70% для навчання і 30% для тестування.

Для розрахунку точності прогнозування використовувалися математичні форми для RMSE, MAPE і  $R^2$ , як описано в рівняннях (3.9), (3.10) і (3.11).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.9)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{x_t} \right| \quad (3.10)$$

$$R - squared = 1 - \frac{SS_{Regression}}{SS_{Total}} = 1 - \frac{\sum_i (y_i - \hat{y}_i)}{\sum_i (y_i - \underline{y}_i)} \quad (3.11)$$

де  $N$  - загальна кількість спостережень,  $y_i$  - фактичне значення,  $SS_{Total}$  - сума загальних квадратичних помилок,  $SS_{Regression}$  - сума квадратичних помилок регресії.

Таблиця 3.1 - Точність прогнозування швидкості руху в умовах літаючого туману

Оптомізатор Adam; Розмір вибірки 16				
RNNs	RMSE	MAPE	R-squared	Тривалість оброблення
Stacked BILSTM	1.26	10.87	0.99	285.09
BI-LSTM	1.28	11.04	0.98	70.28
LSTM	1.54	13.13	0.98	179

У таблиці 3.1 показано точність прогнозування для трафіку туману під час використання глибокого навчання, коли використовуються три різні моделі: стекова BILSTM, BILSTM і LSTM, з використанням методу оптимізації Адама, частин вибірки 16, функції втрат MSE і швидкості навчання 0,1. Точність прогнозування оцінювали за допомогою RMSE, MAPE і R2.

З наведеної вище таблиці видно, що модель, передбачена за допомогою стекової BILSTM моделі, перевершує своїх конкурентів і має найкращі показники. В обох випадках максимальне середнє поліпшення становить 2,26%.

Однак у моделі SBILSTM найтриваліший час обробки. Точність прогнозування моделі BILSTM приблизно така сама, як і в моделі SBILSTM. У цьому випадку максимальне середнє поліпшення становить 2,09%, і вона також має найшвидший час обробки порівняно з іншими моделями. Однак точність прогнозування моделі LSTM невисока порівняно з іншими моделями, хоча час опрацювання в неї швидший, ніж у моделі BILSTM. Ба більше, коефіцієнт детермінації ( $R^2$ ) близький до 1, що вказує на хорошу відповідність, і в усіх випадках він приблизно однаковий.

На рисунках 3.3 – 3.5 є передбачені моделі, в яких є дві криві: одна показує прогнозування в часі, а інша - втрати при навчанні в часі. Як видно з малюнків, моделі прогнозування запропонованої стекової BILSTM та BILSTM приблизно однакові та зменшуються з часом. Однак модель прогнозування з LSTM

збільшується до значення 9 с, а потім випадковим чином зменшується. Крім того, втрати з часом на другій кривій показують, що модель LSTM має найвищі втрати, порівняно з іншими моделями, за 9 с, а в разі використання стекової BILSTM та BILSTM - за 44 с та 49 с, відповідно.

Гістограми на рисунках 3.6 – 3.8 показують залежність між швидкістю трафіку та значеннями MSE. Ми зазначаємо, що за використання стекової BILSTM і BILSTM моделі рівень трафіку становить 14% і 15%, відповідно, за значень MSE від 0 до 0,12, а за використання моделі LSTM найвищий рівень трафіку становить 29%, за значень MSE від 0 до 0,071.

На рисунку 3.9 показано залежність між втратами під час навчання та кількістю ітерацій під час навчання, причому всі втрати зменшуються в міру збільшення кількості ітерацій.




Рисунок 3.3 - Прогнозований вихідний сигнал із використанням запропонованої стекової моделі BILSTM



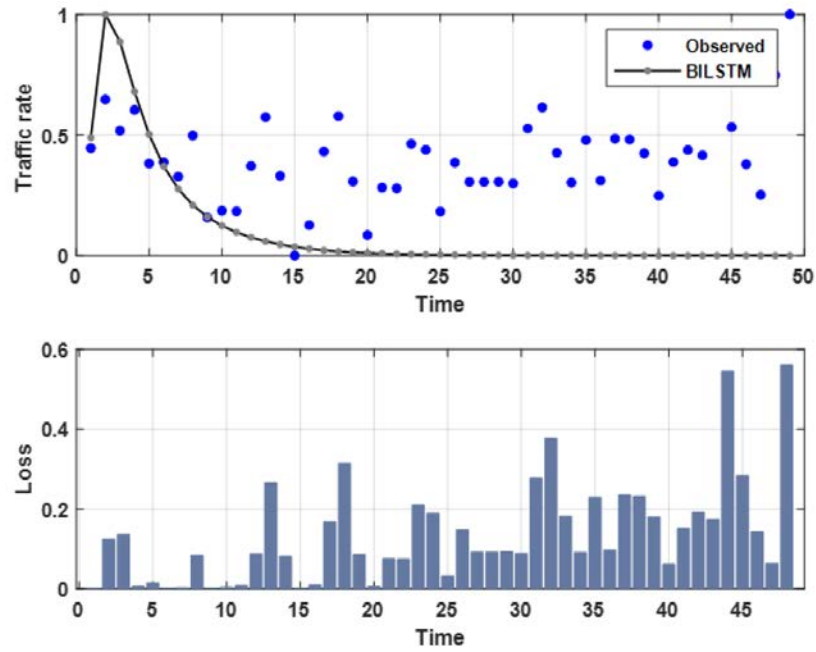


Рисунок 3.4 - Зпрогнозований результат із використанням моделі BILSTM




Рисунок 3.5 - Зпрогнозований результат за допомогою моделі LSTM




Рисунок 3.6 - Гістограма втрат під час навчання при використанні запропонованої моделі




Рисунок 3.7 - Гістограма втрат під час навчання при використанні моделі BILSTM




Рисунок 3.8 – Гістограма втрат під час навчання при використанні моделі LSTM

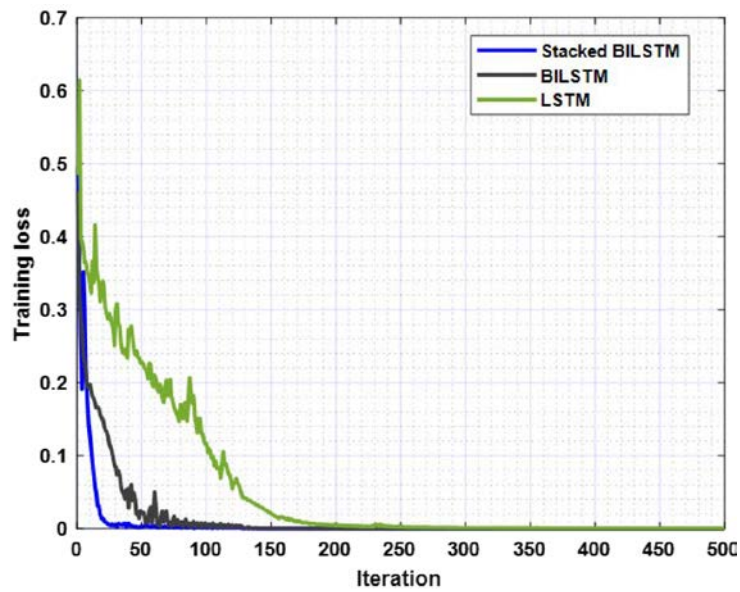


Рисунок 3.9 – Залежність втрат при навчанні від кількості ітерацій

### 3.5 Висновки до розділу 3

Для прогнозування руху транспортних засобів у зонах з інтенсивним рухом на основі обчислювального середовища туману було запропоновано підхід глибокого навчання з використанням стекової двоспрямованої моделі довготривалої короткострокової пам'яті (SBILSTM); проведено порівняння між запропонованою SBILSTM та традиційними BILSTM і LSTM для точності прогнозування; моделі глибокого навчання було навчено з використанням методу оптимізації Адама, частин вибірки 16, функції втрат MSE та швидкості навчання 0,1; оцінювали точність прогнозування за допомогою середньоквадратичної помилки (RMSE), середньої абсолютної відсоткової помилки (MAPE), коефіцієнта детермінації (R-квадрат) і часу обробки.

Остаточні результати моделювання показали таке: запропонована модель SBILSTM перевершує своїх конкурентів і має найкращу продуктивність; за умови використання звичайної моделі BILSTM точність прогнозування вища, ніж у моделі LSTM; точність прогнозування за умови використання традиційної моделі LSTM низька порівняно з іншими; коефіцієнт детермінації ( $R^2$ ) приблизно однаковий у всіх випадках і близький до 1, що означає, що мережа налаштована правильно; " традиційна BILSTM має найкоротший час процесу, в той час як запропонована SBILSTM має найдовший час процесу.

Модель глибокого навчання на основі стекової BILSTM моделі пропонується для прогнозування руху автономних транспортних засобів у перевантажених районах на основі обчислювального середовища літаючого туману. Модель глибокого навчання ґрунтується на гіпотезі, що глибока ієрархічна модель може представляти деякі функції експоненціально ефективніше, ніж традиційні моделі.

Укладання прихованих шарів BILSTM поглиблює модель, більш точно підтверджуючи її статус глибокого навчання. Успіх цього підходу під час розв'язання багатьох складних завдань прогнозування зазвичай пов'язують із глибиною нейронної мережі. Предиктор SBILSTM перевершує своїх

конкурентів і має найкращі показники. Точність прогнозування за допомогою традиційної моделі LSTM низька порівняно з іншими. Традиційний BILSTM має найменший час обробки, а запропонований SBILSTM - найбільший. R-квадрат для всіх предикторів приблизно дорівнює і близький до 1, що означає, що мережа добре підігнана.

## 4 МОНІТОРИНГ ІНФОРМАЦІЙНОГО ТРАФІКУ БЕЗПЛОТНИХ АВТОМОБІЛІВ У МОБІЛЬНИХ МЕРЕЖАХ

### 4.1 Обґрунтування вибору технології інтелектуального моніторингу мобільних мереж

Обговорюється можливість застосування бортових платформ з метою підтримки наземних мереж для використання ресурсів автономних транспортних засобів як частини критичних до затримок додатків. Бортові платформи можуть підвищити безпеку поїздок транспортних засобів, доставляючи на них своєчасну інформацію про навколишнє оточення навіть у віддалених районах земної кулі. Обговорюються вимоги та потенційні рішення для підтримки інфраструктури автономних транспортних засобів як частини інтелектуальної транспортної системи. Пропонується використовувати вздовж дороги енергоефективні сенсори, які можуть об'єднуватися один з одним у Mesh-мережі. Крім того, пропонується новий підхід до виявлення активності біологічних об'єктів на узбіччі дороги, заснований на технологіях штучного інтелекту.

Технології 5G призначені не тільки для збільшення пропускної здатності бездротової мережі до 20 Гбіт/с, а й для значного збільшення обсягу переданих даних [36]. Мережа 5G/IMT-2020 підтримує такі важливі функції, як ультрамалі затримки (швидше реагування) [37], широкосмугові канали (прискорення передавання даних) і одночасне підключення декількох пристроїв (наприклад, датчиків або інтелектуальних пристроїв).

Програмно-конфігуровані мережі (Software-Defined Network) дають змогу розділити рівні управління і даних [38]. SDN забезпечує набагато ефективніший розподіл ресурсів і підтримує роботу мережевих додатків із заданою якістю обслуговування. Не випадково в даний час загальноприйнятим є концептуальне рішення про заміну еволюціонуючого пакетного ядра EPC (Evolved Packet Core) на програмно конфігуруємі мережі, в тому числі й мультиконтролерні [6].

Віртуалізація мережевих функцій (Network Function Virtualization, NFV) - це технологія віртуалізації фізичних мережевих елементів телекомунікаційної мережі, коли мережеві функції виконуються програмними модулями, що працюють на стандартних серверах і віртуальних машинах. Ці програмні модулі можуть взаємодіяти один з одним для надання послуг зв'язку, в яких раніше використовувалися апаратні платформи. Концепція NFV бере початок з SDN, але ці технології є незалежними, хоча вони доповнюють одна одну [42]: SDN вимагає нових інтерфейсів, модулів управління та застосунків, а NFV передбачає переміщення мережевих застосунків із виділеного обладнання у віртуальні контейнери на готовому комерційному обладнанні [39].

Автономні транспортні засоби можуть використовувати переваги технології 5G для досягнення ультрамалої затримки під час передачі даних. Щоб домогтися ультрамалої затримки для автономного транспортного засобу, об'єкт управління мережею повинен вчасно ухвалювати рішення про послуги, запити на які надходять від транспортних засобів.

З розвитком технологій і появою штучного інтелекту, автономні транспортні засоби стали центром уваги в багатьох галузях.

Прогнози показують, що найближчими роками автономні транспортні засоби з'являтимуться на дорогах дедалі частіше [40]. Вони поєднують у собі безліч технологій, що працюють без участі людини, допомагають розв'язати дорожню кризу, скоротити кількість аварій, що трапляються з вини людей, зменшити забруднення довкілля, спричинене звичайними автомобілями, і знизити споживання енергії [41].

Концепція граничних обчислень (Mobile Edge Computing, MEC) полягає в тому, щоб розмістити хмарні ресурси якомога ближче до користувачів або навіть безпосередньо в терміналах користувачів. Технологія MEC дає змогу використовувати послуги хмарних обчислень і середовище інформаційних технологій на кордоні базової мережі, що забезпечує швидкий відгук на послуги автономних транспортних засобів і підвищує ефективність використання ресурсів [42]. Дорожні карти також можуть зберігатися і оброблятися на

мережевих серверах МЕС. Сервер МЕС може керувати обчислювальними службами для великої кількості автономних транспортних засобів. Тому останніми роками дослідження в галузі автономних транспортних засобів із мережевою підтримкою стають дедалі актуальнішими.

У [43] розглянуто досягнення в розвитку мереж МЕС, а також основні проблеми, що виникають під час організації мережевої архітектури з МЕС. Також крім трьох рівнів мережевої архітектури (рівень кінцевого користувача, рівень кордону мережі радіодоступу з серверами МЕС, пов'язаними з базовими станціями, і рівень віддаленого хмарного сервера) запропоновано додатковий рівень між серверами МЕС та віддаленою хмарою, що дає змогу кінцевим користувачам взаємодіяти із серверами МЕС, віддаленою хмарою та один з одним.

З моменту появи автомобілів на швидкісних дорогах між містами виникла проблема зіткнень із тваринами, які можуть раптово з'являтися на проїжджій частині. З огляду на тенденції в розвитку автомобільного транспорту, а саме широке впровадження автономних транспортних засобів, варто поглянути на проблему аварій за участю тварин більш широко. Якщо за кермом перебуває людина, то вона може помітити зміни в навколишньому оточенні (тінь, кущі, попередження зустрічних водіїв тощо), що дасть їй змогу заздалегідь зменшити швидкість та бути готовою до неочікуваної ситуації, в тому числі до зіткнення з твариною. Однак навіть з урахуванням можливостей людини нещасні випадки з тваринами не рідкість. Тому в рамках розроблення концепції автономних транспортних засобів та їхньої інфраструктури необхідно розглянути проблему аварій з біологічними об'єктами та розробити відповідні рішення, які дадуть змогу врятувати життя людей і тварин, а також зберегти майно (автомобілі, елементи дорожньої інфраструктури тощо). Саме в цьому і полягає наукове завдання, що розв'язується в цьому розділі дисертаційної роботи, а саме: розробка системи виявлення та розпізнавання рухомих біологічних об'єктів для автономних транспортних засобів на основі інтелектуальних граничних обчислень.



З огляду на розглянуті вище технологічні переваги мереж 5G, зокрема мережевих технологій SDN/NFV, а також хмарних MEC і туманних FoG обчислень, з'являється можливість реалізувати цю задачу в рамках встановлених вимог до швидкості прийняття рішення з урахуванням прогнозування активності біологічних об'єктів. Крім того, необхідно передбачити можливість подальшого розроблення відповідних програмних модулів для задач прогнозування руху біологічних об'єктів.

Поставлена проблема виявлення біологічних об'єктів у придорожній зоні містить у собі безліч складних системних завдань, розв'язання яких, своєю чергою, дасть змогу вийти на новий рівень безпеки руху, особливо в рамках концепції автономних транспортних засобів.

Узагальнена архітектура включає елементи фізичного світу (автомобіль, дорога, тварини тощо) [44]. Це рішення може входити до складу інформаційної системи, що містить аналітичні цифрові моделі інфраструктури (дорожньої та придорожньої) і автономного транспорту. Як уже з'ясувалося на практиці, сам автономний транспортний засіб з усіма доступними сьогодні обчислювальними можливостями і технологіями машинного зору не може врахувати деякі поєднання зовнішніх явищ і забезпечити абсолютну безпеку як для пасажирів, так і для всього іншого оточення. Тому пропонується розробляти і враховувати дані з цифрових моделей доріг та інфраструктури, в яких автономний транспорт є частково самостійною структурою. Взаємодія різних елементів системи один з одним має забезпечуватися мережевою та обчислювальною інфраструктурою мереж зв'язку 5G (а в подальшому - шостого покоління та мереж 2030) [45].

Одним із принципів, закладених у вимогах до розроблюваного рішення, є здійсненність в умовах віддаленості доріг від населених пунктів. Як уже було зазначено вище, для виконання цієї вимоги запропоновано використовувати нове покоління технології LoRa, що дає змогу передавати дані з віддалених датчиків, розташованих уздовж дороги в кілька рядів. Після спрацьовування датчика його дані передаються до хмари MEC, що розташована на найближчій базовій станції, тож усю придорожню смугу можна поділити на "зони". Після передавання даних

до найближчої хмари відбувається їх первинне опрацювання, що дає змогу створити необхідну структуру даних для аналітичного модуля розпізнавання об'єктів, реалізованого з використанням технології машинного навчання [46]. Після цього певні повідомлення транслюються в ширококомовному режимі на найближчі базові станції, які передають відповідні повідомлення автономним транспортним засобам. Своєю чергою, ці транспортні засоби, завчасно отримавши інформацію про можливість зустрічі з біологічними об'єктами, визначають їхні швидкісні та часові параметри й прогнозують подальшу модель їхнього руху. У такий спосіб знижується ймовірність нещасних випадків, які могли б статися, якби автономний транспортний засіб покладався тільки на бортову сенсорну систему та бортову систему відеоаналітики з машинним зором. Також можна зазначити, що пропоноване рішення завдяки використанню мережевих технологій має істотно більші можливості, ніж індивідуальний набір датчиків та інтелектуальних систем окремого автомобіля або навіть групи автомобілів. У пропонованому рішенні автомобіль знатиме про об'єкти ще до того, як лідар або радар зможе помітити, проаналізувати і відреагувати на дорожню ситуацію.

#### 4.2 Мережева архітектура та протоколи Mesh

LoRa - це стандарт великомасштабної мережі з низьким енергоспоживанням і широким покриттям (LPWAN). Широка зона покриття і великомасштабна мережа необхідні для пристроїв інтернету речей, оскільки при використанні локальних технологій (наприклад, Wi-Fi) охоплення мережі буде обмежене кількома десятками і сотнями метрів навколо точок доступу, в той час як мережі інтернету речей повинні покривати набагато більші території. Для передавання даних на далекі відстані зазвичай потрібен передавач великої потужності, однак для пристроїв інтернету речей важливим є низьке енергоспоживання, оскільки принаймні частина з них працює від загальноновживаних батарейок. Тут є дилема між максимізацією відстані передавання даних і мінімізацією споживання енергії

приймачем-передавачем, яку можна розв'язати за допомогою зменшення пропускної здатності каналу зв'язку. Для передачі радіосигналу на задану відстань ми можемо або збільшити потужність сигналу, або зменшити смугу пропускання каналу. Другий варіант рішення і пропонується в технології LoRa.

Принцип роботи комірчастої мережі LoRaWAN показано на рис. 4.1.

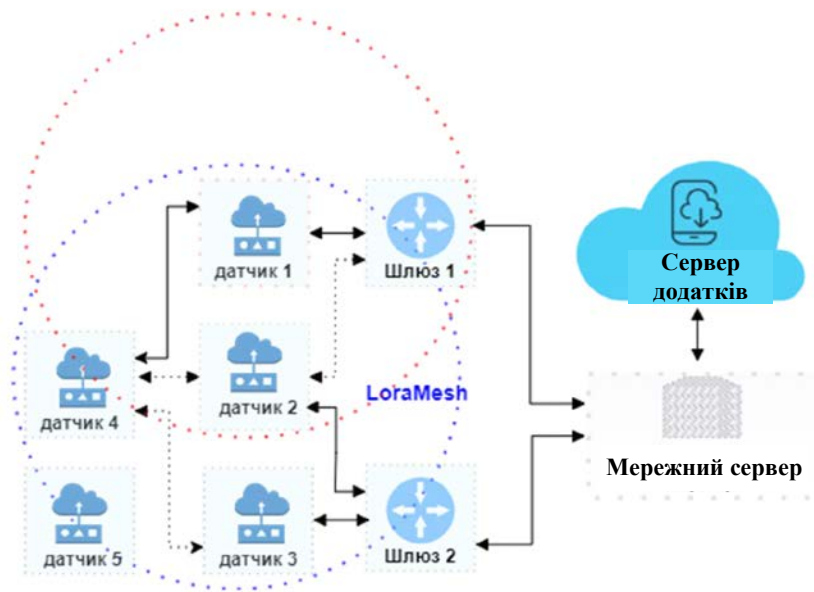


Рисунок 4.1 – Топологія мережі LoRaWAN

Датчики (1, 2, 3) є проміжними ланками між датчиком 4 і мережевим сервером.

Коли один із них виходить із ладу, датчик 5 відіграє роль проміжної ланки, і з'єднання між сервером і датчиком 4 відновлюється. Шлюзи (1, 2) слугують точкою входу і виходу між мережевим сервером і датчиками, інформацію передає сервер додатків під час запиту.

Мережа LoRaWAN Mesh пропонує надійний спосіб передачі даних [47].

Технологія дозволяє створювати великі гнучкі мережі, які споживають мало енергії. Це робить мережу LoRaWAN одним з найкращих способів одночасного збору даних з великої кількості віддалених датчиків.

### 4.3 Обчислювальна інфраструктура

У рамках розглянутої архітектури виділено низку елементів, що реалізують певні обчислювальні та мережеві функції. На рис. 4.2 показано функціональну схему рішення для обчислювальної інфраструктури.

На рис. 4.2 показано такі елементи:

- датчики з модулем LoRaWAN MESH для збирання та подальшого передавання даних через MESH-мережу (LoRa-MESH (GW)) на базову станцію (LoRa-WAN MESH BS) та на віртуальний сервер;

- базові станції LoRaWAN MESH BS для агрегації трафіку LoRa та подальшого передавання даних у придорожні хмари (мікрохмари в структурі MEC);

- мікрохмари, у рамках яких розгорнуто застосунок серверної аналітики.

До складу цього додатка входять такі основні модулі:

1. алгоритм виявлення тварин на узбіччі дороги. Цей алгоритм реалізовано на основі архітектури рекурентних нейронних мереж, попередньо навчених виявленню відповідних біологічних об'єктів;

2. цифрова модель узбіччя. Цей модуль являє собою програмний комплекс, який реалізує придорожні математичні моделі та аналітичні моделі вищого порядку (наприклад, систему прогнозування), а також зберігає дані й обробляє їх для подальшої передачі [48];

3. цифрова модель частини дороги. Цей модуль являє собою програмний пакет, що реалізує математичні моделі частини дорожньої інфраструктури, керованої з хмари. Це програмне забезпечення надає, зберігає, обробляє дані про всю дорожню ситуацію та управління динамічними елементами дороги (наприклад, залізничним переїздом тощо).

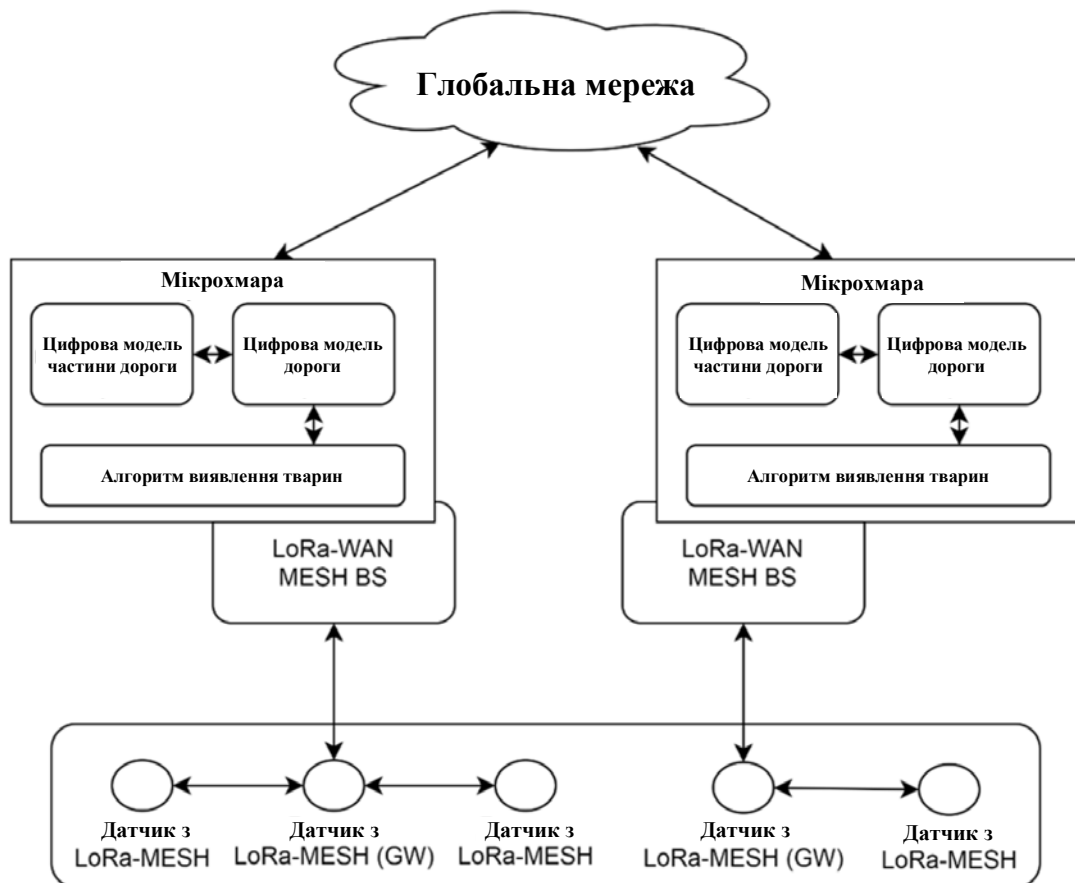


Рисунок 4.2 – Функціональна схема запропонованої мережі

На основі цих даних формуються певні прогностичні аналітичні дані для розвитку відповідної ділянки дороги, інформуються будь-які автономні транспортні засоби, що прибувають, шляхом передачі запитуваних даних бортовою системою транспортного засобу.

#### 4.4 Алгоритм розпізнавання біологічних об'єктів

Пропонується новий алгоритм, що допомагає розпізнавати біологічні об'єкти, які перебувають поруч із дорогою і намагаються її перетнути. Цей алгоритм має розпізнавати такі ситуації: поруч із проїжджою частиною перебувають одна людина, група людей або велика тварина (наприклад, олень, лось тощо).

На рис. 4.3. показано карту датчиків у двох сусідніх зонах (2 сусідні зони на трасі довжиною кожної з них 4 метри).

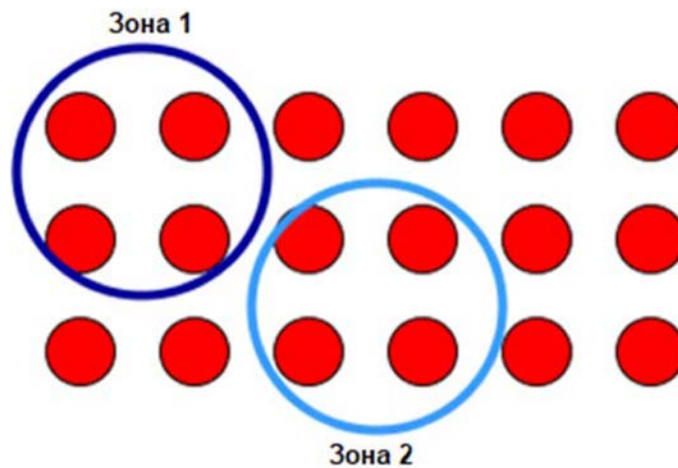


Рисунок 4.3 – Карта датчиків у зонах

Обробка даних відбувається таким чином. Нехай число активних датчиків в одній зоні (4 метри) становить  $N$ , де  $M := [x, y] = [3, 4] = 12$  (кількість датчиків в одній зоні). Позначимо  $T$  - час спрацьовування (Дельта між датчиками із сусідніх зон). Тоді різниця між часом спрацьовування датчиків із сусідніх зон.

$$TS = TS_{1_1} - TS_{1_2}; \quad (4.1)$$

де  $TS_{1_1}$  - час спрацьовування першого датчика в першій зоні,  $TS_{1_2}$  - час спрацьовування першого датчика в другій зоні.

Сума сил натискання датчиків біологічним об'єктом в одній зоні:

$$F = \sum_{n=0}^N F_n, N \in M. \quad (4.2)$$

де  $F_n$  - сила натискання  $n$  датчиків в одній зоні.

З фізичного погляду  $F_0$  означає, що жодного датчика не натиснуто.

Середній час натискання датчиків в одній зоні:

$$\Delta T_{avg} = \frac{\sum_{n=0}^N \Delta t_n}{N}, N \in M \quad (4.3)$$

де  $\Delta t_n$  - дельта часу натискання  $n$  датчиків Відстань між першим датчиком, що спрацював у першій зоні, і останнім датчиком, що спрацював у другій зоні:

$$S = \sqrt{(N_{12} - N_{11})^2 + (N_{22} - N_{21})^2} \quad (4.4)$$

де,  $N_{12}$ - перший датчик, що спрацював, у другій зоні.  $N_{11}$ - перший датчик, що спрацював, у першій зоні.  $N_{22}$  - другий датчик, що спрацював у другій зоні.

$N_{21}$  - другий датчик, що спрацював у першій зоні.

#### 4.5 Навчання штучної нейронної мережі

Сьогодні штучна нейронна мережа широко використовується для розв'язання різноманітних завдань у різних аспектах нашого життя. Наприклад, галузі розпізнавання мови, комп'ютерного зору (комплексна інтегрована відеоаналітика графічних об'єктів), останнім часом - складні інженерні системи та їхні модулі (наприклад, нафтопереробні автомобільні заводи тощо). Настільки складні завдання аналізу великих обсягів інформації розв'язують за допомогою розроблення інструментів, що належать до класу штучного інтелекту. Одним із методів прогнозування моделей на основі великих обсягів даних, що найбільш активно розвиваються, є технологія штучних нейронних мереж.

На даний момент існує велика кількість різноманітних нейронних мереж. Класифікація - це одне з типових завдань, які вони вирішують. Одним із найпоширеніших методів класифікації є метод, що ґрунтується на описі об'єктів за допомогою знаків: Кожен об'єкт характеризується набором числових або нечислових знаків [49]. Однак для деяких типів даних відкриті знаки не дають точності класифікації [50], наприклад, колір точок зображення або цифровий аудіосигнал.

Причина в тому, що ці дані містять приховані особливості. Глибоке навчання - це набір алгоритмів машинного навчання, які намагаються моделювати високорівневі абстракції даних або, кажучи іншими словами, витягувати приховані особливості з даних. Тому, враховуючи особливості об'єкта (трафіку) і його атрибути (числові ряди), було обрано нейронну мережу з глибоким навчанням [51].

Для розв'язання задачі розпізнавання біологічного об'єкта з урахуванням специфіки даних, що надходять для досліджуваної задачі, а також вимог, що ставляться до досліджуваної та розроблюваної системи, було обрано рекурентну нейронну мережу.

Оскільки обрана архітектура нейронної мережі реалізує принцип навчання з учителем, потрібно скласти навчальні набори даних з розміченими даними, а потім зберегти стан навченої мережі. Для навчання нейронної мережі вхідний набір даних було перетворено на тренувальний набір даних шляхом додавання нового стовпця даних, кожна комірка якого мала ідентифікатор статистичної вибірки. Відповідно, для навчання розпізнавання більшого трафіку цей навчальний набір даних необхідно розширити, позначивши відповідну статистичну вибірку міткою біологічного об'єкта, наприклад: олені, люди або група людей.

Мережева модель містить чотири повнозв'язні рівні рекурентної нейронної мережі, кожен з яких містить 12 прихованих вузлів.

Гіперпараметри (параметри алгоритмів, значення яких встановлюють перед запуском процесу навчання) навчання:

1. оптимізатор: Adam;
2. кількість епох (кількість повних проходів по навчальному набору даних): 60;
3. кількість вибірок на ітерацію: 1024;
4. швидкість навчання: 0,0025. (має невелике позитивне значення, часто в діапазоні від 0,0 до 1,0).



#### 4.6 Алгоритм моделювання

Для перевірки працездатності запропонованого методу виявлення біологічного об'єкта на узбіччі дороги відповідно до вищевикладеного було розроблено генератор даних. Як імітацію було розроблено імітаційну модель на мові програмування Python з реалізованою штучною рекурентною нейронною мережею. Після створення набору даних розроблена нейронна мережа була активована, а після успішного навчання її стан був збережений (отримана архітектура, ваги та інші параметри).

За допомогою генератора модельних даних з подальшим опрацюванням було сформовано тренувальний набір даних, який надійшов на вхід нейронної мережі, конфігурація якої описана вище.

Під час навчання відстежували параметр "точність" (функція, зворотна функції помилок під час розпізнавання активності біологічного об'єкта) і параметр "помилки" (перехресна ентропія, що визначає близький до істинного передбачуваний розподіл). Розроблена нейронна мережа пройшла навчання, після чого відбулася перевірка її роботи на тестових датасетах. Виявилось, що в навченому стані розроблена нейронна мережа може визначити тип біологічного об'єкта з імовірністю 99,8%. Матриця помилок показує, що мережа припустилася помилки тричі (три чорні прямокутники з одиницями). Також варто зазначити, що обрана архітектура стала ефективним рішенням поставленого завдання. За меншої кількості нейронів у вкладених шарах штучна нейронна мережа працює нестабільно, вона не досягає належного рівня якості виявлення об'єкта і припускається значної кількості помилок. За більшого значення кількості вкладених нейронів мережа також працює нестабільно і виникає ефект так званого "перенавчання" мережі, що було отримано в рамках дослідження архітектури нейронної мережі та її навчання на тестових даних.

#### 4.7 Висновки до розділу 4

1. Представлено розв'язання наукової задачі з виявлення та розпізнавання активності біологічних об'єктів на узбіччі дороги. Це рішення може допомогти зменшити кількість аварій, спричинених тваринами або людьми на дорозі. У ньому для забезпечення передавання даних між віддаленими магістральними мережами та головною станцією використано технологію МЕС і комірчасту бездротову технологію LoRa.

2. Запропоновано алгоритм, використання рекурентної нейронної мережі для визначення руху людей і тварин по шосе.

3. Розроблено імітаційну модель мовою програмування Python з реалізацією штучної нейронної мережі для перевірки працездатності запропонованого алгоритму. Результати моделювання показали, що запропоновані рішення дозволяють ідентифікувати тип біологічного об'єкта з імовірністю 99,8%.

Запропоновано використовувати технологію організації хмарних структур МЕС. Ця технологія забезпечить виконання критерію продуктивності системи, звівши до мінімуму мережеві затримки; запропоновано використовувати мережу загальнодоступних датчиків із комунікаційними модулями LoRa Mesh. Використання цієї радіотехнології дасть змогу відповідати критерію віддаленості окремих ділянок доріг від базових станцій, а також забезпечить низьке енергоспоживання системи; запропоновано використовувати нейронні мережі в рамках задачі опрацювання інформації, що надходить, і з урахуванням необхідності високої достовірності аналітичних даних для розпізнавання типів біологічних об'єктів.

## 5 ЕКОНОМІЧНА ЧАСТИНА

Виконання науково-дослідної роботи завжди передбачає отримання певних результатів і вимагає відповідних витрат. Результати виконаної роботи завжди дають нам нові знання, які в подальшому можуть бути використані для удосконалення та/або розробки (побудови) нових, більш продуктивних зразків техніки, процесів та програмного забезпечення.

Дослідження на тему «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту» може бути віднесено до фундаментальних і пошукових наукових досліджень і спрямоване на вирішення наукових проблем, пов'язаних з практичним застосуванням. Основою таких досліджень є науковий ефект, який виражається в отриманні наукових результатів, які збільшують обсяг знань про природу, техніку та суспільство, які розвивають теоретичну базу в тому чи іншому науковому напрямку, що дозволяє виявити нові закономірності, які можуть використовуватися на практиці.

Для цього випадку виконаємо такі етапи робіт:

- 1) здійснимо проведення наукового аудиту досліджень, тобто встановлення їх наукового рівня та значимості;
- 2) проведемо планування витрат на проведення наукових досліджень;
- 3) здійснимо розрахунок рівня важливості наукового дослідження та перспективності, визначимо ефективність наукових досліджень.

### 5.1 Оцінювання наукового ефекту

Основними ознаками наукового ефекту науково-дослідної роботи є новизна роботи, рівень її теоретичного опрацювання, перспективність, рівень розповсюдження результатів, можливість реалізації. Науковий ефект НДР на тему «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту» можна охарактеризувати двома показниками: ступенем наукової новизни та рівнем теоретичного опрацювання.

Значення показників ступеня новизни і рівня теоретичного опрацювання науково-дослідної роботи в балах наведені в табл. 5.1 та 5.2.

Таблиця 5.1 – Показники ступеня новизни науково-дослідної роботи виставлені експертами

Ступінь новизни	Характеристика ступеня новизни	Значення ступеня новизни, бали		
		Експерти (ПБ, посада)		
		1	2	3
Принципово нова	Робота якісно нова за постановкою задачі і ґрунтується на застосуванні оригінальних методів дослідження. Результати дослідження відкривають новий напрям в даній галузі науки і техніки. Отримані принципово нові факти, закономірності; розроблена нова теорія. Створено принципово новий пристрій, спосіб, метод	0	0	0
Нова	Отримана нова інформація, яка суттєво зменшує невизначеність наявних значень (по-новому або вперше пояснені відомі факти, закономірності, впроваджені нові поняття, розкрита структура змісту). Проведено суттєве вдосконалення, доповнення і уточнення раніше досягнутих результатів	40	0	55
Відносно нова	Робота має елементи новизни в постановці задачі і методах дослідження. Результати дослідження систематизують і узагальнюють наявну інформацію, визначають шляхи подальших досліджень; вперше знайдено зв'язок (або знайдено новий зв'язок) між явищами. В принципі відомі положення розповсюджені на велику кількість об'єктів, в результаті чого знайдено ефективне рішення. Розроблені більш прості способи для досягнення відомих результатів. Проведена часткова раціональна модифікація (з ознаками новизни)	0	40	0
Традиційна	Робота виконана за традиційною методикою. Результати дослідження мають інформаційний характер. Підтверджені або поставлені під сумнів відомі факти та твердження, які потребують перевірки. Знайдено новий варіант рішення, який не дає суттєвих переваг в порівнянні з існуючим	0	0	0
Не нова	Отримано результат, який раніше зафіксований в інформаційному полі, та не був відомий авторам	0	0	0
<b>Середнє значення балів експертів</b>		45,0		

Згідно отриманого середнього значення балів експертів ступінь новизни характеризується як нова, тобто отримана нова інформація, яка суттєво зменшує невизначеність наявних знань (по-новому або вперше пояснені відомі факти, закономірності, впроваджені нові поняття, розкрита структура змісту) та проведено суттєве вдосконалення, доповнення і уточнення раніше досягнутих результатів.

Таблиця 5.2 – Показники рівня теоретичного опрацювання науково-дослідної роботи виставлені експертами

Характеристика рівня теоретичного опрацювання	Значення показника рівня теоретичного опрацювання, бали		
	Експерт (ПІБ, посада)		
	1	2	3
Відкриття закону, розробка теорії	0	0	0
Глибоке опрацювання проблеми: багатоаспектний аналіз зв'язків, взаємозалежності між фактами з наявністю пояснень, наукової систематизації з побудовою евристичної моделі або комплексного прогнозу	65	60	0
Розробка способу (алгоритму, програми), пристрою, отримання нової речовини	0	0	57
Елементарний аналіз зв'язків між фактами та наявною гіпотезою, класифікація, практичні рекомендації для окремого випадку тощо	0	0	0
Опис окремих елементарних фактів, викладення досвіду, результатів спостережень, вимірювань тощо	0	0	0
<b>Середнє значення балів експертів</b>	60,7		

Згідно отриманого середнього значення балів експертів рівень теоретичного опрацювання науково-дослідної роботи характеризується як глибоке опрацювання проблеми: багатоаспектний аналіз зв'язків, взаємозалежності між фактами з наявністю пояснень, наукової систематизації з побудовою евристичної моделі або комплексного прогнозу.

Показник, який характеризує рівень наукового ефекту, визначаємо за формулою [55]:

$$E_{\text{нау}} = 0,6 \cdot k_{\text{нов}} + 0,4 \cdot k_{\text{теор}}, \quad (5.1)$$

де  $k_{\text{нов}}, k_{\text{теор}}$  - показники ступеня новизни та рівня теоретичного опрацювання науково-дослідної роботи,  $k_{\text{нов}} = 45,0, k_{\text{теор}} = 60,7$  балів;

$0,6$  та  $0,4$  – питома вага (значимість) показників ступеня новизни та рівня теоретичного опрацювання науково-дослідної роботи.

$$E_{\text{нау}} = 0,6 \cdot k_{\text{нов}} + 0,4 \cdot k_{\text{теор}} = 0,6 \cdot 45,0 + 0,4 \cdot 60,67 = 51,27 \text{ балів.}$$

Визначення характеристики показника  $E_{\text{нау}}$  проводиться на основі висновків експертів виходячи з граничних значень, які наведені в табл. 5.3.

Таблиця 5.3 – Граничні значення показника наукового ефекту

Досягнутий рівень показника	Кількість балів
Високий	70...100
Середній	50...69
Достатній	15...49
Низький (помилкові дослідження)	1...14

Відповідно до визначеного рівня наукового ефекту проведеної науково-дослідної роботи на тему «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту», даний рівень становить 51,27 балів і відповідає статусу - середній рівень. Тобто у даному випадку можна вести мову про потенційну фактичну ефективність науково-дослідної роботи.

## 5.2 Розрахунок витрат на здійснення науково-дослідної роботи

Витрати, пов'язані з проведенням науково-дослідної роботи на тему «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту», під час планування, обліку і калькулювання собівартості науково-дослідної роботи групуємо за відповідними статтями.

### 5.2.1 Витрати на оплату праці

До статті «Витрати на оплату праці» належать витрати на виплату основної та додаткової заробітної плати керівникам відділів, лабораторій, секторів і груп, науковим, інженерно-технічним працівникам, конструкторам, технологам, креслярам, копіювальникам, лаборантам, робітникам, студентам, аспірантам та іншим працівникам, безпосередньо зайнятим виконанням конкретної теми, обчисленої за посадовими окладами, відрядними розцінками, тарифними ставками згідно з чинними в організаціях системами оплати праці.

#### Основна заробітна плата дослідників

Витрати на основну заробітну плату дослідників ( $Z_o$ ) розраховуємо у відповідності до посадових окладів працівників, за формулою [55]:

$$Z_o = \sum_{i=1}^k \frac{M_{ni} \cdot t_i}{T_p}, \quad (5.2)$$

де  $k$  – кількість посад дослідників залучених до процесу досліджень;

$M_{ni}$  – місячний посадовий оклад конкретного дослідника, грн;

$t_i$  – число днів роботи конкретного дослідника, дн.;

$T_p$  – середнє число робочих днів в місяці,  $T_p=22$  дні.

$$Z_o = 16320,00 \cdot 22 / 22 = 16320,00 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці.

Таблиця 5.4 – Витрати на заробітну плату дослідників

Найменування посади	Місячний посадовий оклад, грн	Оплата за робочий день, грн	Число днів роботи	Витрати на заробітну плату, грн
Керівник проекту	16320,00	741,82	22	16320,00
Науковий співробітник (фахівець дослідження проблем штучного інтелекту)	15600,00	709,09	17	12054,55
Інженер-розробник телекомунікаційних систем	15300,00	695,45	22	15300,00
Всього				43674,55

### Основна заробітна плата робітників

Витрати на основну заробітну плату робітників ( $Z_p$ ) за відповідними найменуваннями робіт НДР на тему «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту» розраховуємо за формулою:

$$Z_p = \sum_{i=1}^n C_i \cdot t_i, \quad (4.3)$$

де  $C_i$  – погодинна тарифна ставка робітника відповідного розряду, за виконану відповідну роботу, грн/год;

$t_i$  – час роботи робітника при виконанні визначеної роботи, год.

Погодинну тарифну ставку робітника відповідного розряду  $C_i$  можна визначити за формулою:

$$C_i = \frac{M_M \cdot K_i \cdot K_c}{T_p \cdot t_{зм}}, \quad (5.4)$$

де  $M_M$  – розмір прожиткового мінімуму працездатної особи, або мінімальної місячної заробітної плати (в залежності від діючого законодавства), прийmemo  $M_M=6700,00$  грн;



$K_i$  – коефіцієнт міжкваліфікаційного співвідношення для встановлення тарифної ставки робітнику відповідного розряду (табл. Б.2, додаток Б) [55];

$K_c$  – мінімальний коефіцієнт співвідношень місячних тарифних ставок робітників першого розряду з нормальними умовами праці виробничих об'єднань і підприємств до законодавчо встановленого розміру мінімальної заробітної плати.

$T_p$  – середнє число робочих днів в місяці, приблизно  $T_p = 22$  дн;

$t_{зм}$  – тривалість зміни, год.

$$C_1 = 6700,00 \cdot 1,10 \cdot 1,35 / (22 \cdot 8) = 56,53 \text{ грн.}$$

$$З_{р1} = 56,53 \cdot 4,50 = 254,39 \text{ грн.}$$

Таблиця 5.5 – Величина витрат на основну заробітну плату робітників

Найменування робіт	Тривалість роботи, год	Розряд роботи	Тарифний коефіцієнт	Погодинна тарифна ставка, грн	Величина оплати на робітника грн
Підготовка робочого місяця наукового співробітника	4,50	2	1,10	56,53	254,39
Підготовка робочого місяця інженера-розробника телекомунікаційних систем	5,50	2	1,10	56,53	310,92
Введення програмних блоків моделювання поведінки апаратури мереж із вбудованим ШІ	6,80	3	1,35	69,38	471,78
Інсталяція програмного забезпечення математичного моделювання мереж	10,00	4	1,50	77,09	770,88
Введення програмних блоків моделювання поведінки мереж із вбудованим ШІ	3,50	5	1,70	87,37	305,78

продовження таблиці 5.5 – Величина витрат на основну заробітну плату робітників

Найменування робіт	Тривалість роботи, год	Розряд роботи	Тарифний коефіцієнт	Погодинна тарифна ставка, грн	Величина оплати на робітника грн
Налагодження програмних блоків математичної моделі дослідження	4,00	5	1,70	87,37	349,47
Формування (введення) бази даних дослідження моделі мережі	15,25	3	1,35	69,38	1058,03
Тестування взаємодії моделей НВЧ приймача, передавача, антенного обладнання мереж	3,20	3	1,35	69,38	222,01
Контроль результатів дослідження	4,80	4	1,50	77,09	370,02
Всього					4113,29

Додаткова заробітна плата дослідників та робітників

Додаткову заробітну плату розраховуємо як 10 ... 12% від суми основної заробітної плати дослідників та робітників за формулою:

$$Z_{\text{дод}} = (Z_o + Z_p) \cdot \frac{H_{\text{дод}}}{100\%}, \quad (5.5)$$

де  $H_{\text{дод}}$  – норма нарахування додаткової заробітної плати. Прийmemo 11%.

$$Z_{\text{дод}} = (43674,55 + 4113,29) \cdot 11 / 100\% = 5256,66 \text{ грн.}$$

### 5.2.2 Відрахування на соціальні заходи

Нарахування на заробітну плату дослідників та робітників розраховуємо як 22% від суми основної та додаткової заробітної плати дослідників і робітників за формулою:

$$Z_n = (Z_o + Z_p + Z_{\text{одд}}) \cdot \frac{H_{zn}}{100\%} \quad (5.6)$$

де  $H_{zn}$  – норма нарахування на заробітну плату. Приймаємо 22%.

$$Z_n = (43674,55 + 4113,29 + 5256,66) \cdot 22 / 100\% = 11669,79 \text{ грн.}$$

### 5.2.3 Сировина та матеріали

До статті «Сировина та матеріали» належать витрати на сировину, основні та допоміжні матеріали, інструменти, пристрої та інші засоби і предмети праці, які придбані у сторонніх підприємств, установ і організацій та витрачені на проведення досліджень за темою «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту».

Витрати на матеріали на даному етапі проведення досліджень в основному пов'язані з використанням моделей елементів та моделювання роботи і досліджень за допомогою комп'ютерної техніки та створення експериментальних математичних моделей або програмного забезпечення, тому дані витрати формуються на основі витратних матеріалів характерних для офісних робіт.

Витрати на матеріали ( $M$ ), у вартісному вираженні розраховуються окремо по кожному виду матеріалів за формулою:

$$M = \sum_{j=1}^n H_j \cdot C_j \cdot K_j - \sum_{j=1}^n B_j \cdot C_{\text{в}j}, \quad (5.7)$$

де  $H_j$  – норма витрат матеріалу  $j$ -го найменування, кг;

$n$  – кількість видів матеріалів;

$C_j$  – вартість матеріалу  $j$ -го найменування, грн/кг;

$K_j$  – коефіцієнт транспортних витрат, ( $K_j = 1,1 \dots 1,15$ );

$B_j$  – маса відходів  $j$ -го найменування, кг;

$C_{ej}$  – вартість відходів  $j$ -го найменування, грн/кг.

$$M_1 = 3,0 \cdot 175,00 \cdot 1,03 - 0 \cdot 0 = 540,75 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці.

Таблиця 5.6 – Витрати на матеріали

Найменування матеріалу, марка, тип, сорт	Ціна за 1 кг, грн	Норма витрат, кг	Величина відходів, кг	Ціна відходів, грн/кг	Вартість витраченого матеріалу, грн
Папір офісний А4 MAESTRO standart+ (500)	175,00	3,0	0	0	540,75
Папір для записів А5 Marshal DEX 250	95,00	3,0	0	0	293,55
Органайзер офісний SKIPER 2500	176,00	4,0	0	0	725,12
Канцелярське приладдя BOSS UAS	152,00	4,0	0	0	626,24
Картридж для принтера HP Laser jet 1566	1640,00	2,0	0	0	3378,40
Диск оптичний CD-R Optic MAX	24,00	4,0	0	0	98,88
Flesh-пам'ять 64 GB Startrack	170,00	1,0	0	0	175,10
Всього					5838,04

#### 5.2.4 Розрахунок витрат на комплектуючі

Витрати на комплектуючі ( $K_e$ ), які використовують при проведенні НДР на тему «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту», розраховуємо, згідно з їхньою номенклатурою, за формулою:

$$K_e = \sum_{j=1}^n H_j \cdot C_j \cdot K_j \quad (5.8)$$

де  $H_j$  – кількість комплектуючих  $j$ -го виду, шт.;

$C_j$  – покупна ціна комплектуючих  $j$ -го виду, грн;

$K_j$  – коефіцієнт транспортних витрат, ( $K_j = 1,1 \dots 1,15$ ).

$$K_e = 1 \cdot 2940,00 \cdot 1,03 = 3263,40 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці.

Таблиця 5.7 – Витрати на комплектуючі

Найменування комплектуючих	Кількість, шт.	Ціна за штуку, грн	Сума, грн
Роутер з підтримкою технології МІМО	1	2940,00	3263,40
Всього			3263,40

### 5.2.5 Спецустаткування для наукових (експериментальних) робіт

До статті «Спецустаткування для наукових (експериментальних) робіт» належать витрати на виготовлення та придбання спецустаткування необхідного для проведення досліджень, також витрати на їх проектування, виготовлення, транспортування, монтаж та встановлення.

Балансову вартість спецустаткування розраховуємо за формулою:

$$B_{\text{спец}} = \sum_{i=1}^k C_i \cdot C_{\text{пр.і}} \cdot K_i, \quad (5.9)$$

де  $C_i$  – ціна придбання одиниці спецустаткування даного виду, марки, грн;

$C_{np.i}$  – кількість одиниць устаткування відповідного найменування, які придбані для проведення досліджень, шт.;

$K_i$  – коефіцієнт, що враховує доставку, монтаж, налагодження устаткування тощо, ( $K_i = 1, 10 \dots 1, 12$ );

$k$  – кількість найменувань устаткування.

$$B_{спец} = 8320,00 \cdot 1 \cdot 1,03 = 17094,00 \text{ грн.}$$

Отримані результати зведемо до таблиці:

Таблиця 5.8 – Витрати на придбання спецустаткування по кожному виду

Найменування устаткування	Кількість, шт	Ціна за одиницю, грн	Вартість, грн
Модель імітатора передавача	1	2860,00	2945,80
Модель імітатора приймача	1	3140,00	3234,20
Всього			6277,10

### 5.2.6 Програмне забезпечення для наукових (експериментальних) робіт

До статті «Програмне забезпечення для наукових (експериментальних) робіт» належать витрати на розробку та придбання спеціальних програмних засобів і програмного забезпечення, (програм, алгоритмів, баз даних) необхідних для проведення досліджень, також витрати на їх проектування, формування та встановлення.

Балансову вартість програмного забезпечення розраховуємо за формулою:

$$B_{прог} = \sum_{i=1}^k C_{инрг} \cdot C_{прог.i} \cdot K_i, \quad (5.10)$$

де  $C_{инрг}$  – ціна придбання одиниці програмного засобу даного виду, грн;

$C_{\text{прг.і}}$  – кількість одиниць програмного забезпечення відповідного найменування, які придбані для проведення досліджень, шт.;

$K_i$  – коефіцієнт, що враховує інсталяцію, налагодження програмного засобу тощо, ( $K_i = 1, 10 \dots 1, 12$ );

$k$  – кількість найменувань програмних засобів.

$$B_{\text{прг}} = 9485,00 \cdot 1 \cdot 1,01 = 9579,85 \text{ грн.}$$

Отримані результати зведемо до таблиці:

Таблиця 5.9 – Витрати на придбання програмних засобів по кожному виду

Найменування програмного засобу	Кількість, шт	Ціна за одиницю, грн	Вартість, грн
Прикладне програмне забезпечення проектування PCAD 2000 Schematic	1	9485,00	9579,85
Комп'ютерні радіомережі моделі	1	6820,00	6888,20
Всього			16468,05

### 5.2.7 Амортизація обладнання, програмних засобів та приміщень

В спрощеному вигляді амортизаційні відрахування по кожному виду обладнання, приміщень та програмному забезпеченню тощо, розраховуємо з використанням прямолінійного методу амортизації за формулою:

$$A_{\text{обл}} = \frac{Ц_{\text{б}}}{T_{\text{г}}} \cdot \frac{t_{\text{вик}}}{12}, \quad (5.11)$$

де  $Ц_{\text{б}}$  – балансова вартість обладнання, програмних засобів, приміщень тощо, які використовувались для проведення досліджень, грн;

$t_{вик}$  – термін використання обладнання, програмних засобів, приміщень під час досліджень, місяців;

$T_в$  – строк корисного використання обладнання, програмних засобів, приміщень тощо, років.

$$A_{обл} = (110260,00 \cdot 1) / (5 \cdot 12) = 1837,67 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці.

Таблиця 5.10 – Амортизаційні відрахування по кожному виду обладнання

Найменування обладнання	Балансова вартість, грн	Строк корисного використання, років	Термін використання обладнання, місяців	Амортизаційні відрахування, грн
Комп'ютерне обладнання для вирішення проблем моделювання процесів в системах 6G EOM HP Z6 G4 WKS Tower i9/ Xeon Silver 4108 (6QP06EA)	110260,00	5	1	1837,67
Оргтехніка	7360,00	5	1	122,67
ОС Windows	4350,00	2	1	181,25
Пакет Matlab 2020	5360,00	2	1	223,33
Пакет Microwave Office	7560,00	2	1	315,00
Пакет Visual System Simulator	7100,00	2	1	295,83
Приміщення лабораторії досліджень	390000,00	25	1	1300,00
Пристрої передачі даних	8790,00	5	1	146,50
Робоче місце інженера-розробника телекомунікаційних систем	8420,00	7	1	100,24
Робоче місце наукового співробітника	8600,00	7	1	102,38
Всього				4624,87



### 5.2.8 Паливо та енергія для науково-виробничих цілей

Витрати на силову електроенергію ( $B_e$ ) розраховуємо за формулою:

$$B_e = \sum_{i=1}^n \frac{W_{yi} \cdot t_i \cdot C_e \cdot K_{vni}}{\eta_i}, \quad (5.12)$$

де  $W_{yi}$  – встановлена потужність обладнання на визначеному етапі розробки, кВт;

$t_i$  – тривалість роботи обладнання на етапі дослідження, год;

$C_e$  – вартість 1 кВт-години електроенергії, грн; (вартість електроенергії визначається за даними енергопостачальної компанії), прийmemo  $C_e = 7,50$  грн;

$K_{vni}$  – коефіцієнт, що враховує використання потужності,  $K_{vni} < 1$ ;

$\eta_i$  – коефіцієнт корисної дії обладнання,  $\eta_i < 1$ .

$$B_e = 0,10 \cdot 160,0 \cdot 7,50 \cdot 0,95 / 0,97 = 120,00 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці.

Таблиця 5.11 – Витрати на електроенергію

Найменування обладнання	Встановлена потужність, кВт	Тривалість роботи, год	Сума, грн
Пристрої передачі даних	0,10	160,0	120,00
Оргтехніка	0,50	2,5	9,38
Комп'ютерне обладнання для вирішення проблем моделювання процесів в системах 6G EOM HP Z6 G4 WKS Tower i9/ Xeon Silver 4108 (6QP06EA)	0,40	160,0	480,00
Робоче місце інженера-розробника телекомунікаційних систем	0,11	160,0	132,00
Робоче місце старшого наукового співробітника	0,11	160,0	132,00
Всього			873,38

### 5.2.9 Службові відрядження

До статті «Службові відрядження» дослідної роботи на тему «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту» належать витрати на відрядження штатних працівників, працівників організацій, які працюють за договорами цивільно-правового характеру, аспірантів, зайнятих розробленням досліджень, відрядження, пов'язані з проведенням випробувань машин та приладів, а також витрати на відрядження на наукові з'їзди, конференції, наради, пов'язані з виконанням конкретних досліджень.

Витрати за статтею «Службові відрядження» відсутні.

### 5.2.10 Витрати на роботи, які виконують сторонні підприємства, установи і організації

Витрати за статтею «Витрати на роботи, які виконують сторонні підприємства, установи і організації» відсутні.

### 5.2.11 Інші витрати

До статті «Інші витрати» належать витрати, які не знайшли відображення у зазначених статтях витрат і можуть бути віднесені безпосередньо на собівартість досліджень за прямими ознаками.

Витрати за статтею «Інші витрати» розраховуємо як 50...100% від суми основної заробітної плати дослідників та робітників за формулою:

$$I_{\text{с}} = (Z_{\text{o}} + Z_{\text{p}}) \cdot \frac{H_{\text{іс}}}{100\%}, \quad (5.15)$$

де  $H_{\text{іс}}$  – норма нарахування за статтею «Інші витрати», приймемо  $H_{\text{іс}} = 50\%$ .

$$I_6 = (43674,55 + 4113,29) \cdot 50 / 100\% = 23893,92 \text{ грн.}$$

### 5.2.12 Накладні (загальновиробничі) витрати

До статті «Накладні (загальновиробничі) витрати» належать: витрати, пов'язані з управлінням організацією; витрати на винахідництво та раціоналізацію; витрати на підготовку (перепідготовку) та навчання кадрів; витрати, пов'язані з набором робочої сили; витрати на оплату послуг банків; витрати, пов'язані з освоєнням виробництва продукції; витрати на науково-технічну інформацію та рекламу та ін.

Витрати за статтею «Накладні (загальновиробничі) витрати» розраховуємо як 100...150% від суми основної заробітної плати дослідників та робітників за формулою:

$$B_{нзв} = (Z_o + Z_p) \cdot \frac{H_{нзв}}{100\%}, \quad (5.16)$$

де  $H_{нзв}$  – норма нарахування за статтею «Накладні (загальновиробничі) витрати», прийmemo  $H_{нзв} = 100\%$ .

$$B_{нзв} = (43674,55 + 4113,29) \cdot 100 / 100\% = 47787,84 \text{ грн.}$$

Витрати на проведення науково-дослідної роботи на тему «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту» розраховуємо як суму всіх попередніх статей витрат за формулою:

$$B_{заг} = Z_o + Z_p + Z_{доп} + Z_n + M + K_в + B_{спец} + B_{прз} + A_{обл} + B_e + B_{св} + B_{сп} + I_6 + B_{нзв}. \quad (5.17)$$

$$B_{заг} = 43674,55 + 4113,29 + 5256,66 + 11669,79 + 5838,04 + 3263,40 + 6277,10 + 16468,05 + 4624,87 + 873,38 + 0,00 + 0,00 + 23893,92 + 47787,84 = 198740,88 \text{ грн.}$$

Загальні витрати  $ZB$  на завершення науково-дослідної (науково-технічної) роботи та оформлення її результатів розраховується за формулою:

$$ZB = \frac{B_{заг}}{\eta}, \quad (5.18)$$

де  $\eta$  - коефіцієнт, який характеризує етап (стадію) виконання науково-дослідної роботи, прийmemo  $\eta=0,9$ .

$$ZB = 198740,88 / 0,9 = 220823,20 \text{ грн.}$$

### 5.3 Оцінювання важливості та наукової значимості науково-дослідної роботи

Оцінювання та доведення ефективності виконання науково-дослідної роботи фундаментального чи пошукового характеру є достатньо складним процесом і часто базується на експертних оцінках, тому має вірогідний характер.

Для обґрунтування доцільності виконання науково-дослідної роботи на тему «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту» використовується спеціальний комплексний показник, що враховує важливість, результативність роботи, можливість впровадження її результатів у виробництво, величину витрат на роботу.

Комплексний показник  $K_p$  рівня науково-дослідної роботи може бути розрахований за формулою:

$$K_p = \frac{I^n \cdot T_c \cdot R}{B \cdot t}, \quad (5.19)$$

де  $I$  – коефіцієнт важливості роботи. Приймемо  $I=4$ ;

$n$  – коефіцієнт використання результатів роботи;  $n=0$ , коли результати роботи не будуть використовуватись;  $n=1$ , коли результати роботи будуть використовуватись частково;  $n=2$ , коли результати роботи будуть використовуватись в дослідно-конструкторських розробках;  $n=3$ , коли результати можуть використовуватись навіть без проведення дослідно-конструкторських розробок. Прийmemo  $n=3$ ;

$T_C$  – коефіцієнт складності роботи. Прийmemo  $T_C = 2$ ;

$R$  – коефіцієнт результативності роботи; якщо результати роботи плануються вище відомих, то  $R = 4$ ; якщо результати роботи відповідають відомому рівню, то  $R = 3$ ; якщо нижче відомих результатів, то  $R = 1$ . Прийmemo  $R = 4$ ;

$B$  – вартість науково-дослідної роботи, тис. грн. Прийmemo  $B = 220823,20$  грн;

$t$  – час проведення дослідження. Прийmemo  $t = 0,08$  років, (1 міс.).

Визначення показників  $I$ ,  $n$ ,  $T_C$ ,  $R$ ,  $B$ ,  $t$  здійснюється експертним шляхом або на основі нормативів [55].

$$K_p = \frac{I^n \cdot T_C \cdot R}{B \cdot t} = 4^3 \cdot 2 \cdot 4 / 220,8 \cdot 0,08 = 27,82.$$

Якщо  $K_p > 1$ , то науково-дослідну роботу на тему «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту» можна вважати ефективною з високим науковим, технічним і економічним рівнем.

#### 5.4 Висновок до розділу 5

Витрати на проведення науково-дослідної роботи на тему «Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту» складають 220823,20 грн. Відповідно до проведеного аналізу та розрахунків рівень наукового ефекту проведеної науково-дослідної роботи на тему «Моделі

мережі керування автотранспортом із використанням технологій штучного інтелекту» є середній, а дослідження актуальними, рівень доцільності виконання науково-дослідної роботи  $K_p > 1$ , що свідчить про потенційну ефективність з високим науковим, технічним і економічним рівнем.

## 6 ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ

Державна політика з питань охорони праці в Україні регулюється законодавчими та нормативно-правовими актами, зокрема Законом України «Про охорону праці» від 14 жовтня 1992 р.

Цей Закон визначає основні положення щодо реалізації конституційного права громадян про охорону їх життя і здоров'я в процесі трудової діяльності, регулює за участі відповідних державних органів відносини між власником підприємства, установи й організації або уповноваженим ним органом і працівником з питань безпеки, гігієни праці та виробничого середовища і встановлює єдиний порядок організації охорони праці в Україні.

Під час розробки моделі мережі керування автотранспортом із використанням технологій штучного інтелекту на працівника могли мати вплив такі небезпечні та шкідливі виробничі фактори:

1. Фізичні: підвищена запиленість та загазованість повітря робочої зони; підвищена чи понижена температура повітря робочої зони; підвищений рівень шуму на робочому місці; підвищений рівень електромагнітного випромінювання; підвищена чи понижена іонізація повітря; пряма і відбита блискість; підвищення яскравість; недостатня освітленість робочої зони.

2. Психофізіологічні: статичне перевантаження; розумове перевантаження; емоційні перевантаження.

Відповідно до наведених факторів здійснюємо планування щодо безпечного виконання роботи.

### 6.1 Технічні рішення щодо безпечного виконання роботи

Під робочим місцем розробника моделі мережі керування автотранспортом із використанням технологій штучного інтелекту мається на увазі зона його трудової діяльності, оснащення необхідними засобами праці.

Загальною вимогою раціональної організації робочих місць є створення працівникам максимальної зручності для здійснення їх діяльності, вивільнення від нераціональних переміщень та рухів, зниження на цій основі витрат праці на виконувану роботу. Економія часу і сил працівника - головні критерії раціональності організації робочих місць.

Робоче місце і взаємне розташування усіх її елементів має відповідати антропометричним, фізичним і неординарним психологічним вимогам [57]. Важливе значення має також характеру роботи. Зокрема, з організацією робочого місця проектувальника мають бути дотримані такі основні умови:

- оптимальне розміщення устаткування, що до складу робочого місця;
- достатній робочий простір, що дозволяє здійснювати всі необхідні рухи, і переміщення;
- необхідне природне, і штучне висвітлення до виконання поставлених завдань;
- рівень акустичного шуму, який не перевищує допустимого значення;
- достатня вентиляція робочого місця;

Головними елементами робочого місця розробника є письмовий стіл і крісло. Основним робочим положенням є положення сидячи. Робоче місце для виконання робіт у положенні сидячи організується відповідно до вимог [57].

Необхідно передбачити при проектуванні можливість різного розміщення документів: збоку від ПК, між монітором і клавіатурою і т.п. Крім того, у випадках, коли ПК має низьку якість зображення, наприклад, помітні миготіння, відстань від очей до екрана роблять більшою (близько 700 мм), ніж відстань від ока до документа (300...450 мм). В загальному випадку, при високій якості зображення на ПК відстань від очей користувача до екрана, документа і клавіатури може бути рівним.

Велике значення надається характеристикам робочого крісла [58]. При проектуванні крісла виходять з того, що при будь-якому робочому положенні дослідника його поза повинна бути фізіологічно правильно обгрунтованою, тобто положення частин тіла повинно бути оптимальним. Для задоволення вимог



фізіології, що впливають з аналізу положення тіла людини в положенні сидячи, конструкція робочого сидіння повинна відповідати таким основним вимогам:

- допускати можливість зміни положення тіла, тобто забезпечити вільне переміщення корпусу і кінцівок тіла один щодо одного;
- допускати регулювання висоти в залежності від росту працюючої людини (в межах від 400 до 550 мм);
- мати злегка увігнуту поверхню, мати невеликий нахил, тому поверхню сидіння рекомендується робити м'якою, передній край закругленим, а кут нахилу спинки робочого крісла - регульованим.

Приміщення, де здійснювалася розробка моделі мережі керування автотранспортом із використанням технологій штучного інтелекту за небезпекою ураження електричним струмом можна віднести до 1 класу, тобто це приміщення без підвищеної небезпеки (сухе, мало заповишене, з нормальною температурою повітря, ізольованими підлогами і малим числом заземлених приладів) [59].

На робочому місці з усього обладнання металевим є лише корпус системного блоку комп'ютера, в якого крім робочої ізоляції передбачений елемент для заземлення та провід з заземлюючий жилою для приєднання до джерела живлення.

Електротехнічне устаткування: апаратури, кабелі й керівництва, розподільні пристрої всіх видів і напруг по своїх номінальних параметрах задовольняє умовам роботи як при нормальних режимах, так і при коротких замиканнях, перенапругах, перевантаженнях.

Для забезпечення безпеки устанавлюються наступні технічні рішення:

- Забезпечено недоступність струмопровідних частин (застосована схована провідка, кабель прокладений у спеціальних ринвах).
- Забезпечено ізолювання струмопровідних частин з використанням ізоляції, опір якої не нижче 1кОм/В, передбачені постійний контроль і профілактика ізоляції.

– Напруга освітлювальної мережі приймається 220 В із заземленою нейтраллю.

У випадку виникнення аварійної ситуації працівник зобов'язаний:

– у всіх випадках виявлення пошкодження проводів електричного живлення, несправності заземлення та інших пошкодженнях електрообладнання, виникненні запаху гарі, диму - негайно вимкнути електричне живлення і повідомити про аварійну ситуацію свого безпосереднього керівника й чергового електрика;

– при попаданні людини під електричну напругу негайно звільнити її від дії струму шляхом вимкнення електричного живлення, до прибуття лікаря надати потерпілому долікарську медичну допомогу;

– при будь-яких випадках порушень роботи технічного обладнання або програмного забезпечення негайно викликати представника технічної служби з питань експлуатації обчислювальної техніки;

– у випадку виникнення різі в очах, різкого погіршення зору, виникнення головного болю, больових відчуттів у пальцях та кистях рук, посилення серцебиття - негайно припинити роботу з використанням ПК, повідомити про те, що сталося, свого безпосереднього керівника й звернутися до медичної установи;

– при загорянні обладнання негайно відключити його від електромережі;

про загорання повідомити свого безпосереднього керівника, оперативного чергового, пожежну службу; ужити заходів щодо ліквідації вогню за допомогою вуглекислотного або порошкового вогнегасника.

## 6.2 Технічні рішення з гігієни праці та виробничої санітарії

### 6.2.1 Мікроклімат

Робота, яка виконується розробником моделі мережі керування автотранспортом із використанням технологій штучного інтелекту за енерговитратами відноситься до категорії I а (енерговитрати до 139 Дж/с) [60]. Допустимі параметри мікроклімату для цієї категорії наведені в табл. 6.1 (відповідно до ДСН 3.3.6.042-99 [61]).

Таблиця 6.1 – Параметри мікроклімату

Період року	Допустимі		
	t, °C	W, %	V, м/с
Теплий	22-28	55	0,1-0,2
Холодний	21-25	75	0,1

Для забезпечення необхідних за нормативами параметрів мікроклімату в приміщенні передбачено система опалення, система кондиціонування та систематичне вологе прибирання.

Вимірювання параметрів мікроклімату проводиться на робочому місці і в робочій зоні на початку, в середині та в кінці робочої зміни. Вимірювання здійснюються не менше 2-х разів на рік (теплий та холодний періоди року) у порядку поточного санітарного нагляду, а також при прийманні до експлуатації нового технологічного устаткування, внесенні технічних змін в конструкцію діючого устаткування, організації нових робочих місць тощо.

### 6.2.2 Склад повітря робочої зони

У сучасній техніці застосовується безліч речовин, які можуть потрапляти в повітря і становити небезпеку здоров'ю людей. Для визначення небезпечності досліджується вплив цих речовин на організм людини і встановлюють безпечні для людини концентрації та дози, які можуть потрапити різними шляхами в організм людини.

Для створення здорових і безпечних умов праці потрібно мати гігієнічне нормування шкідливих речовин, надійні способи визначення їх концентрацій у повітрі і сучасне технічне та організаційне забезпечення їх знешкодження.

В приміщенні, де здійснюється розробка моделі мережі керування автотранспортом із використанням технологій штучного інтелекту можливими шкідливими речовинами у повітрі є пил та озон. Джерелами цих речовин є офісна техніка. Пил потрапляє у приміщення ззовні. ГДК шкідливих речовин, які знаходяться в досліджуваному приміщенні, наведені в таблиці 6.2.

Таблиця 6.2 – ГДК шкідливих речовин у повітрі

Назва речовини	ГДК, мг/м <sup>3</sup>		Клас небезпечності
	Максимально разова	Середньо добова	
Пил нетоксичний	0,5	0,15	4
Озон	0,16	0,03	4

Параметри іонного складу повітря на робочому місці, що обладнане ПК, повинні відповідати допустимим нормам (табл. 6.3).

Таблиця 6.3 – Рівні іонізації повітря приміщень при роботі на ПК

Рівні	Кількість іонів в 1 см <sup>3</sup>	
	n+	n-
Мінімально необхідні	400	600
Оптимальні	1500-3000	3000-5000
Максимально необхідні	50000	50000

Для забезпечення комфортних умов використовуються як організаційні методи (раціональна організація проведення робіт залежно від пори року і доби, чергування праці і відпочинку), так і технічні засоби (вентиляція, кондиціонування повітря, опалювальна система).

### 6.2.3 Виробниче освітлення

Серед чинників зовнішнього середовища, що впливають на організм людини в процесі праці, світло посідає одне з перших місць. Адже відомо, що майже 90 % усієї інформації про довкілля людина одержує через органи зору. Підчас здійснення будь-якої трудової діяльності втомлюваність очей, в основному, залежить від напруженості процесів, що супроводжують зорове сприйняття. До таких процесів належать адаптація, акомодация та конвергенція.

Світло впливає не лише на функцію органів зору, а й на діяльність організму в цілому. У разі поганого освітлення людина швидко втомлюється, працює менш продуктивно, зростає потенційна небезпека помилкових дій і нещасних випадків.

Норми освітленості при штучному освітленні та КПО (для III пояса світлового клімату) при природному та сумісному освітленні, які необхідно забезпечити під час виконання розробки моделі мережі керування автотранспортом із використанням технологій штучного інтелекту зазначені у таблиці 6.4 (відповідно ДБН В.2.5-28-2018 [62]):

Таблиця 6.4 - Норми освітленості в приміщенні

Характеристика зорової роботи	Найменший розмір розрізнення об'єкта	Розряд зорової роботи	Підрияд зорової роботи	Контраст об'єкта розрізнення з фоном	Характеристика фона	Освітленість, лк		КПО, $e_n$ , %			
						Штучне освітлення		Природне освітлення		Сумісне освітлення	
						Комбіноване	Загальне	Верхнє або верхнє і бокове	Бокове	Верхнє або верхнє і бокове	Бокове
Дуже високої точності	Від 0,15 до 0,3	II		великий	світлий	1000	300	7	2,5	4,2	1,5

Для забезпечення достатнього освітлення передбачені такі заходи:

- 1) Систематичне очищення скла від бруду – не рідше двох разів на рік.
- 2) Система природного освітлення доповнюється загальним штучним освітленням, що створюється за допомогою люмінесцентних ламп.

#### 6.2.4 Виробничий шум

Для робочих місць в приміщеннях із ПК характерна наявність механічних шумів (виникають внаслідок коливання деталей машин та їхнім взаємним переміщенням), аеродинамічних шумів (виникають в пружних конструкціях у газі або рідині) та шумів електричних машин.

Деякі ПК є потенційними джерелами цілого ряду звукових коливань як чутного, так і ультразвукового діапазону. Найчастіше рівні акустичного випромінювання, що виходить від ПК, охоплюють діапазон частот від 6,3 до 40 кГц.

Санітарні норми виробничого шуму, ультразвуку та інфразвуку відображені в ДСН 3.3.6.037-99 [63]. Для умов виконання роботи допустимі рівні звукового тиску повинні наведені в таблиці 6.5.

Таблиця 6.5 – Допустимі рівні звукового тиску і рівні звуку для постійного широкополосного шуму

Характер робіт	Допустимі рівні звукового тиску (дБ) в стандартизованих октавних смугах зі середньгеометричними частинами (Гц)									Допустимий рівень звуку, дБА
	32	63	125	250	500	1000	2000	4000	8000	
Виробничі приміщення	86	71	61	54	49	45	42	40	38	50

Для забезпечення допустимих параметрів шуму доцільно використовувати комп'ютери з пасивним охолодженням та встановити пластикові вікна, які мають достатню звукоізоляцію.

#### 6.2.5 Виробничі випромінювання

Під час розробки моделі мережі керування автотранспортом із використанням технологій штучного інтелекту існує ризик виникнення підвищеного рівня електромагнітного поля. Несприятливу дію на організм людини мають електромагнітні випромінювання радіочастотного діапазону, джерелами яких є телевізійні і радіомовні станції, пристрої стільникового радіозв'язку, апарати високочастотного нагрівання і навіть побутова апаратура.

Електромагнітні поля чинять термічний і морфологічний вплив на організм людини, викликаючи в ньому функціональні зміни.

Допустимі значення параметрів неіонізуючих електромагнітних випромінювань від монітора комп'ютера представлені в табл. 6.6.

Таблиця 6.6 - Допустимі значення параметрів неіонізуючих електромагнітних випромінювань

Найменування параметра	Допустимі значення
Напруженість електричної складової електромагнітного поля на відстані 50см від поверхні відеомонітора	10В / м
Напруженість магнітної складової електромагнітного поля на відстані 50см від поверхні відеомонітора	0,3 А / м
Напруженість електростатичного поля не повинна перевищувати:	20кВ / м
для дорослих користувачів	
для дітей дошкільних установ і що вчаться середніх спеціальних і вищих навчальних закладів	15кВ / м

Для зниження дії цих видів випромінювання рекомендується застосовувати монітори із зниженим рівнем випромінювання (MPR-II, TCO-92, TCO-99, TCO-03), а також дотримувати регламентовані режими праці і відпочинку.

6.3 Безпека в надзвичайних ситуаціях. Дослідження безпеки роботи в умовах дії загрозливих факторів надзвичайних ситуацій

#### 6.3.1 Дія радіації на живі організми

Так як 70% маси тіла складається з води, то під впливом радіації розпочинається утворення вільних радикалів гідроксогрупи і гідрогени, що в свою чергу утворюють пероксид гідрогену. Утворені радикали окислюють і відновлюють молекули органічних сполук. Цими речовинами є білки, ліпіди, нуклеопротейди, ферменти та інші.

Заключним результатом початкової дії іонізуючих випромінювань є порушення структури тканини і клітин.



Після припинення процесу опромінення живого організму біохімічні зміни не припиняються тому, що утворені радикали та іони продовжують свою активну дію ще протягом деякого періоду часу. Виникає період вторинної дії іонізуючих випромінювань [64].

### 6.3.2 Визначення доцільного часу початку евакуації населення з зараженої внаслідок аварії на АЕС місцевості автотранспортом

Визначити доцільний час початку евакуації населення з зараженої внаслідок аварії на АЕС місцевості автотранспортом ( $K_{\text{осл}} = 2$ ) з швидкістю  $V = 30$  км/год на відстань  $L = 65$  км, якщо вимірний рівень радіації через  $t = 4,1$  год зараження складає  $P_t = 8,2$  р/год. Допустима доза опромінення  $D_{\text{доп}} = 8$  р.

Доцільний час початку евакуації населення визначимо з формули

$$D_{\text{доп}} = \frac{2P_1(\sqrt{t_k} - \sqrt{t_n})}{K_{\text{осл}}} \text{ [р]}, \quad (6.1)$$

де  $t_n, t_k$  – час початку та кінця опромінення, відповідно, год;

$K_{\text{осл}}$  – коефіцієнт ослаблення радіації.

Тривалість руху під час евакуації визначимо за формулою

$$t_p = L / V \text{ [год]}. \quad (6.2)$$

Рівень радіації через 1 год після аварії знайдемо з формули

$$P_t = P_1 t^{-0,5} \text{ [р/год]}, \quad (6.3)$$

звідки

$$P_1 = P_t / t^{-0,5} = P_t t^{0,5} \text{ [р/год]}. \quad (6.4)$$

Час кінця опромінення визначимо за формулою

$$t_{\kappa} = t_p + t_n \text{ [ГОД]}. \quad (6.5)$$

Прирівнявши можливу дозу опромінення до допустимої отримаємо

$$\sqrt{t_p + t_n} - \sqrt{t_n} = \frac{D_{\text{доп}} K_{\text{осл}}}{2P_1} = a \text{ [ГОД]}. \quad (6.6)$$

Піднесемо до квадрату обидві частини рівняння (6.6)

$$t_p + t_n - 2\sqrt{t_n}\sqrt{t_p + t_n} + t_n = a^2, \quad (6.7)$$

або

$$2\sqrt{t_n}\sqrt{t_p + t_n} = t_p + 2t_n - a^2. \quad (6.8)$$

Знову піднесемо до квадрату обидві частини рівняння (6.8)

$$4t_n t_p + 4t_n^2 = (t_p - a^2)^2 + 4t_n(t_p - a^2) + 4t_n^2, \quad (6.9)$$

звідки

$$t_n = \frac{(t_p - a^2)^2}{4a^2} \text{ [ГОД]}. \quad (5.10)$$

Після підстановки відомих значень у формули (6.2, 6.4, 6.6, 6.10), отримаємо:

$$t_p = 65 / 30 = 2,17 \text{ (ГОД)};$$

$$P_I = 8,2 \cdot 4,1^{0,5} = 16,6 \text{ (р/год)};$$

$$a = \frac{8 \cdot 2}{2 \cdot 16,6} = 0,48 \text{ (год)};$$

$$t_n = \frac{(2,17 - 0,48)^2}{4 \cdot 0,48^2} = 4,08 \text{ (год)}.$$

#### 6.4 Висновки до розділу 6

Визначено, що доцільний час початку евакуації населення з зараженої внаслідок аварії на АЕС місцевості автотранспортом складає 4,08 год.

## ВИСНОВКИ

1) Аналіз розвитку мереж зв'язку п'ятого покоління показує, що, мережа може забезпечити дуже високу швидкість передавання даних, наднизьку затримку, більшу надійність, величезну ємність мережі та високу пропускну здатність, що призводить до швидкого з'єднання, а також більшу кількість пристроїв і більше людей можуть під'єднатися до інтернету.

2. Проаналізовано можливості використання методів: туманних обчислень у мережах 5G для розв'язання задач автономного керованого транспорту; ов машинного навчання для визначення даних необхідних для відправки у хмару, що зменшить затримку під час відправки даних у хмару. Визначено коло завдань у яких можна ефективно застосувати машинне та глибоке навчання прогнозування трафіку в мережах зв'язку п'ятого та наступних поколінь. До цих завдань належить прогнозування втрат пакетів, затримки та пропускну спроможності в мережах зв'язку п'ятого покоління для Інтернету Речей та Тактильного Інтернету.

3. Запропоновано застосовувати ефективні методи передачі інформації, зібравши та проаналізувавши навколишні дані для комунікації автономних керованих транспортів між собою.

4) Досліджено можливість і ефективність використання автомобільних туманних обчислень, оскільки потрібна велика обчислювальна потужність і зворотний зв'язок у реальному часі для комунікації автономних керованих транспортів між собою.

5. Представлено розв'язання наукової задачі з виявлення та розпізнавання активності біологічних об'єктів на узбіччі дороги. Це рішення може допомогти зменшити кількість аварій, спричинених тваринами або людьми на дорозі. У ньому для забезпечення передачі даних між віддаленими магістральними мережами і головною станцією використано технологію MEC і комірчасту бездротову технологію LoRa.

6. Запропоновано алгоритм, що використовує рекурентну нейронну мережу для визначення руху людей і тварин по шосе.

7. Розроблено імітаційну модель мовою програмування Python з реалізацією штучної нейронної мережі для перевірки працездатності запропонованого алгоритму. Результати моделювання показали, що запропоновані рішення дозволяють ідентифікувати тип біологічного об'єкта з імовірністю 99,8%.

8. Розроблено метод глибокого навчання з використанням BI-LSTM і LSTM для прогнозування трафіку в автономних транспортних засобах з багаторівневими хмарними обчисленнями.

9. Розроблено модель глибокого навчання на основі стекової двонаправленої моделі довготривалої короткострокової пам'яті SBILSTM для прогнозування руху автономного транспорту в перевантажених районах на основі обчислювального середовища літаючого туману.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Raphael Kiesel, Johannes van Roessel, Robert H. Schmitt, Quantification of economic potential of 5G for latency critical applications in production, *Procedia Manufacturing*, Volume 52, 2020, Pages 113-120, ISSN 2351-9789, <https://doi.org/10.1016/j.promfg.2020.11.021>.
2. Abdellah A.R., Alshahrani A., Muthanna A., Koucheryavy A. Performance Estimation in V2X Networks Using Deep Learning Based M-Estimator Loss Functions in the Presence of Outliers // *Symmetry*. 2021. Vol. 13. Iss. 11. P. 2207. DOI:10.3390/sym13112207.
3. Chochliouros I.P., Spiliopoulou A.S., Lazaridis P., Dardamanis A., Zaharis Z., Kostopoulos A. Dynamic Network Slicing: Challenges and Opportunities // *Proceedings of the International Conference on Artificial Intelligence Applications and Innovations (AIAI 2020, Neos Marmaras, Greece, 5–7 June 2020)*. IFIP WG 12.5 International Workshops. IFIP Advances in Information and Communication Technology. Vol. 585. Cham: Springer, 2020. DOI:10.1007/978-3-030-49190-1\_5
4. Miglani A., Kumar N. Deep learning models for traffic flow prediction in autonomous vehicles: A review, solutions, and challenges // *Vehicular Communications*. 2019. Vol. 20. P. 100184. DOI:10.1016/j.vehcom.2019.100184
5. Gillani M., Niaz H.A., Farooq M.U., Ullah A. Data collection protocols for VANETs: a survey // *Complex & Intelligent Systems*. 2022. Vol. 8. Iss. 3. PP. 2593-2622. DOI:10.1007/s40747-021-00629-x
6. Grigorescu S, Trasnea B, Cocias T, Macesanu G. A survey of deep learning techniques for autonomous driving // *Journal of Field Robotics*. 2020. Vol. 37. Iss. 3. PP. 362–386. DOI:10.1002/rob.21918
7. Pfülb B., Hardegen C., Gepperth A., Rieger S. A Study of Deep Learning for Network Traffic Data Forecasting // *Proceedings of the 28th International Conference on Artificial Neural Networks and Machine Learning (ICANN 2019, Munich, Germany, 17–19 September 2019)*. Lecture Notes in Computer Science. Vol. 11730. Cham: Springer, 2019. PP. 497-512. DOI:10.1007/978-3-030-30490-4\_40

8. Ateeq M., Ishmanov F., Afzal M.K., Naeem M. Predicting Delay in IoT Using Deep Learning: A Multiparametric Approach // IEEE Access. 2019. Vol. 7. PP. 62022–62032. DOI:10.1109/ACCESS.2019.2915958

9. Abdellah A.R., Koucheryavy A. Deep Learning with Long Short-Term Memory for IoT Traffic Prediction // Proceedings of the 20th International Conference on Next Generation Networks and Systems, NEW2AN 2020, and 13th Conference on Internet of Things, Smart Spaces, ruSMART 2020 (St. Petersburg, Russia, 26–28 August 2020. Lecture Notes in Computer Science. Vol. 12525. Cham: Springer, 2020. PP. 267–280. DOI:10.1007/978-3-030-65726-0\_24

10. Almutairi M.S. Deep Learning-Based Solutions for 5G Network and 5G-Enabled Internet of Vehicles: Advances, Meta-Data Analysis, and Future Direction // Mathematical Problems in Engineering. 2022. Vol. 2022. P. 6855435. DOI:10.1155/2022/6855435

11. Kaur J., Khan M.A., Iftikhar M., Imran M., Haq Q.E.U. Machine Learning Techniques for 5G and Beyond // IEEE Access. 2021. Vol. 9. PP. 23472–23488. DOI:10.1109/ACCESS.2021.3051557

12. Khedkar S.P., Canessane R.A., Najafi M.L. Prediction of Traffic Generated by IoT Devices Using Statistical Learning Time Series Algorithms // Wireless Communications and Mobile Computing. 2021. Vol. 2021. P. 5366222. DOI:10.1155/2021/5366222

13. Selvamanju E., Shalini V.B. Machine Learning Based Mobile Data Traffic Prediction in 5G Cellular Networks // Proceedings of the 5th International Conference on Electronics, Communication and Aerospace Technology (ICECA, Coimbatore, India, 02–04 December 2021). IEEE, 2021. PP. 1318–1324. DOI:10.1109/ICECA52323.2021.9675887

14. Choi D., Yim J., Baek M., Lee S. Machine Learning Based Vehicle Trajectory Prediction Using V2V Communications and On-Board Sensors // Electronics. 2021. Vol. 10. Iss. 4. P. 420. DOI:10.3390/electronics10040420

15. Rasouli A., Tsotsos J.K. Autonomous Vehicles That Interact With Pedestrians: A Survey of Theory and Practice // IEEE Transactions on Intelligent

Transportation Systems. 2020. Vol. 21. Iss. 3. PP. 900–918.  
DOI:10.1109/TITS.2019.2901817

16. Badicu A., Suciuc G., Balanescu M., Dobre M., Birdici A., Orza O., Pasat A. PMs concentration forecasting using ARIMA algorithm // Proceedings of the 91-st Vehicular Technology Conference (VTC2020-Spring, Antwerp, Belgium, 25–28 May 2020). IEEE, 2020. DOI:10.1109/VTC2020-Spring48590.2020.9129390

17. Shang Q., Tan D., Gao S., Feng L. A Hybrid Method for Traffic Incident Duration Prediction Using BOA Optimized Random Forest Combined with Neighborhood Components Analysis // Journal of Advanced Transportation. 2019. Vol. 2019. P. 4202735. DOI:10.1155/2019/4202735

18. Lohrasbinasab I., Shahraki A., Taherkordi A., Delia Jurcut A. From statistical to machine learning-based network traffic prediction. Trans. Emerg. Telecommun. Technol. (2021), Article e4394

19. Singh, D.P.; Sharma, D. Traffic Prediction Using Machine Learning and IoT. In Integration of Cloud Computing with Internet of Things; Wiley: Hoboken, NJ, USA, 2021; pp. 111–129. [CrossRef]

20. Dukka K. R.; H. B.; Janmenjoy N.; Pandi V.; Bighnaraj N.; Pradeep K. S.; Deep neural network based anomaly detection in Internet of Things network traffic tracking for the applications of future smart cities in Special Issue: “Deep Network Based Industrial Internet of Things Applications” and “Integration of Satellite-Aerial-Terrestrial Networks” July 2021, Article e4121

21. Ateya, A.A., Soliman, N.F., Alkanhel, R. et al. Lightweight Deep Learning-Based Model for Traffic Prediction in Fog-Enabled Dense Deployed IoT Networks. J. Electr. Eng. Technol. (2022). <https://doi.org/10.1007/s42835-022-01314-w>

22. Abdulkareem, Karrar & Mohammed, Mazin & Gunasekaran, Saraswathy & Al-Mhiqani, Mohammed & Mutlag, Ammar & Mostafa, Salama & Ali, Nabeel & Ibrahim, Dheyaa. (2019). A Review of Fog Computing and Machine Learning: Concepts, Applications, Challenges, and Open Issues. IEEE Access. 7. 1-1. DOI:10.1109/ACCESS.2019.2947542.



23. Samann, F. E. F., Abdulazeez, A. M., & Askar, S. (2021). Fog Computing Based on Machine Learning: A Review. *International Journal of Interactive Mobile Technologies (IJIM)*, 15(12), pp. 21–46. <https://doi.org/10.3991/ijim.v15i12.21313>.

24. Ali R. Abdellah, Andrey Koucheryavy. "Deep Learning with Long Short-Term Memory for IoT Traffic Prediction," Galinina O., Andreev S., Balandin S., Koucheryavy Y. (eds) *Internet of Things, Smart Spaces, and Next Generation Networks and Systems (NEW2AN /SMART)*, Lecture Notes in Computer Science, Springer, Cham., Vol 12525, pp. 267–280, 2020. [https://doi.org/10.1007/978-3-030-65726-0\\_24](https://doi.org/10.1007/978-3-030-65726-0_24).

25. Ali R. Abdellah, Andrey Koucheryavy. "VANET Traffic Prediction Using LSTM with Deep Neural Network Learning," Galinina O., Andreev S., Balandin S., Koucheryavy Y. (eds) *Internet of Things, Smart Spaces, and Next Generation Networks and Systems. (NEW2AN/ruSMART)*. Lecture Notes in Computer Science, Springer, Cham. Vol 12525. pp. 281–294, 2020, [https://doi.org/10.1007/978-3-030-65726-0\\_25](https://doi.org/10.1007/978-3-030-65726-0_25).

26. Qiao, L.; Li, Y.; Chen, D.; Serikawa, S.; Guizani, M.; Lv, Z. A survey on 5G/6G, AI, and Robotics. *Comput. Electr. Eng.* 2021, 95, 107372.

27. Dogra, A.; Jha, R.K.; Jain, S. A survey on beyond 5G network with the advent of 6G: Architecture and emerging technologies. *IEEE Access* 2020, 9, 67512–67547.

28. Long, Q.; Chen, Y.; Zhang, H.; Lei, X. Software defined 5G and 6G networks: A survey. *Mob. Netw. Appl.* 2019, 1–21.

29. Navarro-Ortiz, J.; Romero-Diaz, P.; Sendra, S.; Ameigeiras, P.; Ramos-Munoz, J.J.; Lopez-Soler, J.M. A survey on 5G usage scenarios and traffic models. *IEEE Commun. Surv. Tutor.* 2020, 22, 905–929.

30. Siriwardhana, Y.; Porambage, P.; Liyanage, M.; Ylianttila, M. A Survey on Mobile Augmented Reality with 5G Mobile Edge Computing: Architectures, Applications, and Technical Aspects. *IEEE Commun. Surv. Tutor.* 2021, 23, 1160–1192.

31. De Alwis, C.; Kalla, A.; Pham, Q.V.; Kumar, P.; Dev, K.; Hwang, W.J.; Liyanage, M. Survey on 6G frontiers: Trends, applications, requirements, technologies and future research. *IEEE Open J. Commun. Soc.* 2021, 2, 836–886.
32. Mahmoud, H.H.H.; Amer, A.A.; Ismail, T. 6G: A comprehensive survey on technologies, applications, challenges, and research problems. *Trans. Emerg. Telecommun. Technol.* 2021, 32, e4233.
33. Jeong, J.; Shen, Y.; Oh, T.; Céspedes, S.; Benamar, N.; Wetterwald, M.; Härrilä, J. A comprehensive survey on vehicular networks for smart roads: A focus on IP-based approaches. *Veh. Commun.* 2021, 29, 100334.
34. Ismael, H.R.; Ameen, S.Y.; Kak, S.F.; Yasin, H.M.; Ibrahim, I.M.; Ahmed, A.M.; Rashid, Z.N.; Omar, N.; Salih, A.A.; Ahmed, D.M. Reliable communications for vehicular networks. *Asian J. Res. Comput. Sci.* 2021, 10, 33–49.
35. Zeadally, S.; Guerrero, J.; Contreras, J. A tutorial survey on vehicle-to-vehicle communications. *Telecommun. Syst.* 2020, 73, 469–489.
36. Al-Heety, O.S.; Zakaria, Z.; Ismail, M.; Shakir, M.M.; Alani, S.; Alsariera, H. A comprehensive survey: Benefits, services, recent works, challenges, security, and use cases for SDN-VANET. *IEEE Access* 2020, 8, 91028–91047.
37. Arena, F.; Pau, G.; Severino, A. A review on IEEE 802.11 p for intelligent transportation systems. *J. Sens. Actuator Netw.* 2020, 9, 22.
38. Balador, A.; Cinque, E.; Pratesi, M.; Valentini, F.; Bai, C.; Gómez, A.A.; Mohammadi, M. Survey on decentralized congestion control methods for vehicular communication. *Veh. Commun.* 2021, 33, 100394.
39. Ji, B.; Zhang, X.; Mumtaz, S.; Han, C.; Li, C.; Wen, H.; Wang, D. Survey on the internet of vehicles: Network architectures and applications. *IEEE Commun. Stand. Mag.* 2020, 4, 34–41.
40. Bhatia, J.; Dave, R.; Bhayani, H.; Tanwar, S.; Nayyar, A. SDN-based real-time urban traffic analysis in VANET environment. *Comput. Commun.* 2020, 149, 162–175.

41. Yu, H.; Liu, R.; Li, Z.; Ren, Y.; Jiang, H. An RSU Deployment Strategy based on Traffic Demand in Vehicular Ad Hoc Networks (VANETs). *IEEE Internet Things J.* 2021.
42. Sharma, S.; Kaul, A. VANETs Cloud: Architecture, Applications, Challenges, and Issues. *Arch. Comput. Methods Eng.* 2021, 28, 2081–2102.
43. Ahmed, A.A.; Alzahrani, A.A. A comprehensive survey on handover management for vehicular ad hoc network based on 5G mobile networks technology. *Trans. Emerg. Telecommun. Technol.* 2019, 30, e3546.
44. Tayyab, M.; Gelabert, X.; Jäntti, R. A survey on handover management: From LTE to NR. *IEEE Access* 2019, 7, 118907–118930.
45. Duo, R.; Wu, C.; Yoshinaga, T.; Zhang, J.; Ji, Y. SDN-based handover scheme in cellular/IEEE 802.11 p hybrid vehicular networks. *Sensors* 2020, 20, 1082.
46. Pham, Q.V.; Fang, F.; Ha, V.N.; Piran, M.J.; Le, M.; Le, L.B.; Hwang, W.J.; Ding, Z. A survey of multi-access edge computing in 5G and beyond: Fundamentals, technology integration, and state-of-the-art. *IEEE Access* 2020, 8, 116974–117017.
47. Filali, A.; Abouaomar, A.; Cherkaoui, S.; Kobbane, A.; Guizani, M. Multi-access edge computing: A survey. *IEEE Access* 2020, 8, 197017–197046.
48. Liu, L.; Chen, C.; Pei, Q.; Maharjan, S.; Zhang, Y. Vehicular edge computing and networking: A survey. *Mob. Netw. Appl.* 2020, 26, 1145–1168.
49. Boukerche, A.; Soto, V. Computation offloading and retrieval for vehicular edge computing: Algorithms, models, and classification. *ACM Comput. Surv. (CSUR)* 2020, 53, 1–35.
50. Sharma, A.; Vanjani, P.; Paliwal, N.; Basnayaka, C.M.W.; Jayakody, D.N.K.; Wang, H.C.; Muthuchidambaranathan, P. Communication and networking technologies for UAVs: A survey. *J. Netw. Comput. Appl.* 2020, 168, 102739.
51. Hussain, R.; Lee, J.; Zeadally, S. Trust in VANET: A survey of current solutions and future research opportunities. *IEEE Trans. Intell. Transp. Syst.* 2020, 22, 2553–2571.
52. Gyawali, S.; Xu, S.; Qian, Y.; Hu, R.Q. Challenges and solutions for cellular based v2x communications. *IEEE Commun. Surv. Tutor.* 2020, 23, 222–255.

53. Souza, V.B.; Pereira, M.H.; Lelis, L.H.; Masip-Bruin, X. Enhancing resource availability in vehicular fog computing through smart inter-domain handover. In Proceedings of the GLOBECOM 2020-2020 IEEE Global Communications Conference, Taipei, Taiwan, 7–11 December 2020; IEEE: Manhattan, NY, USA, 2020; pp. 1–6.

54. Muthanna, A.; Shamilova, R.; Ateya, A.A.; Paramonov, A.; Hammoudeh, M. A mobile edge computing/software-defined networking-enabled architecture for vehicular networks. *Internet Technol. Lett.* 2020, 3, e109.

55. Методичні вказівки до виконання економічної частини магістерських кваліфікаційних робіт / Уклад. : В. О. Козловський, О. Й. Лесько, В. В. Кавецький. – Вінниця : ВНТУ, 2021. – 42 с.

56. ДСТУ OHSAS 18002:2015. Системи управління гігієною та безпекою праці. Основні принципи виконання вимог OHSAS 18001:2007 (OHSAS 18002:2008, IDT). К. : ГП «УкрНИУЦ», 2016. 21

57. ДСТУ 8604:2015 Дизайн і ергономіка. Робоче місце для виконання робіт у положенні сидячи. Загальні ергономічні вимоги. URL: [http://online.budstandart.com/ua/catalog/doc-page?id\\_doc=71028](http://online.budstandart.com/ua/catalog/doc-page?id_doc=71028).

58. НПАОП 0.00-7.15-18 Вимоги щодо безпеки та захисту здоров'я працівників під час роботи з екранними пристроями. URL: [http://sop.zp.ua/norm\\_praor\\_0\\_00-7\\_15-18\\_01\\_ua.php](http://sop.zp.ua/norm_praor_0_00-7_15-18_01_ua.php).

59. Правила улаштування електроустановок - [Електронний ресурс] - Режим доступу: <http://www.energiy.com.ua/PUE.html>

60. Гігієнічна класифікація праці (за показниками шкідливості і небезпеки факторів виробничого середовища від 12.08.1986 № 4137-86. - [Електронний ресурс] - Режим доступу: <http://zakon4.rada.gov.ua/laws/show/v4137400-86>

61. ДСН 3.3.6.042-99 Санітарні норми мікроклімату виробничих приміщень. - [Електронний ресурс] - Режим доступу: <http://mozdocs.kiev.ua/view.php?id=1972>

62. ДБН В.2.5-28-2018 Природне і штучне освітлення - [Електронний ресурс] - Режим доступу: <http://document.ua/prirodne-i-shtuchne-osvitlennja-nor8425.html>

63. ДСН 3.3.6.037-99 Санітарні норми виробничого шуму, ультразвуку та інфразвуку. - [Електронний ресурс] - Режим доступу: <http://document.ua/sanitarni-normi-virobnichogo-shumu-ultrazvuku-ta-infrazvuku-nor4878.html>

64. Сакевич В. Ф. Основи розробки питань цивільної оборони в дипломних проєктах / В. Ф. Сакевич. – Вінниця : ВДТУ, 2001. – 109 с.

## ДОДАТКИ

Додаток А  
(обов'язковий)

ІЛЮСТРАТИВНА ЧАСТИНА  
МОДЕЛІ МЕРЕЖІ КЕРУВАННЯ АВТОТРАНСПОРТОМ ІЗ  
ВИКОРИСТАННЯМ ТЕХНОЛОГІЙ ШТУЧНОГО ІНТЕЛЕКТУ  
назва магістерської кваліфікаційної роботи

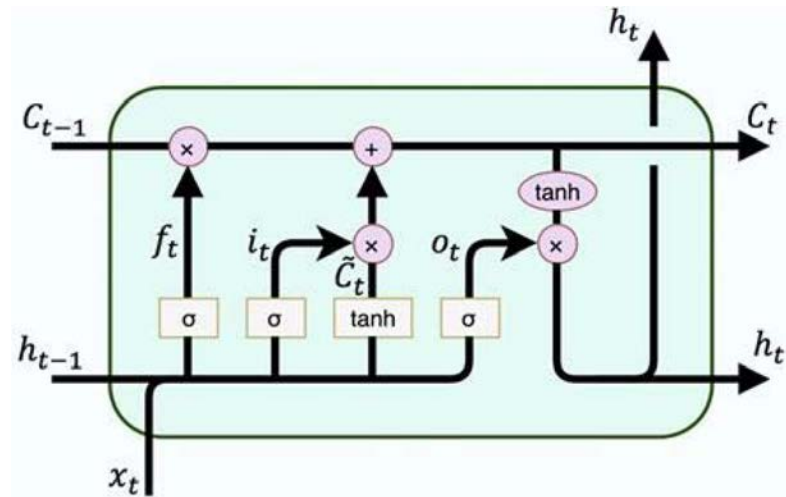


Рисунок 1 - Структура мережі LSTM

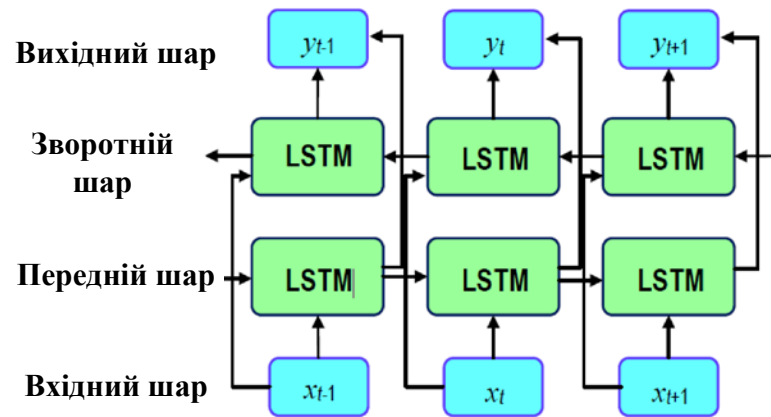


Рисунок 2 - Структура нейронної мережі Bi-LSTM






Рисунок 3 - Двошарова структура МЕС




Рисунок 4 - Структура рухомого туману




Рисунок 5 - Структура мережі

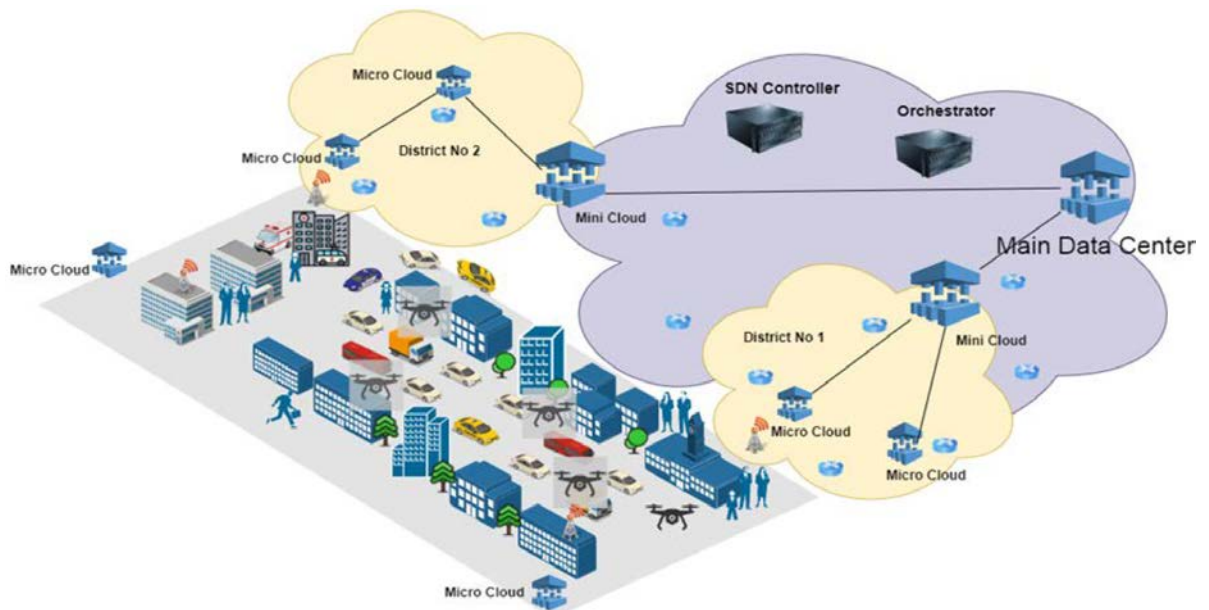


Рисунок 6 - Загальна архітектура моделі системи

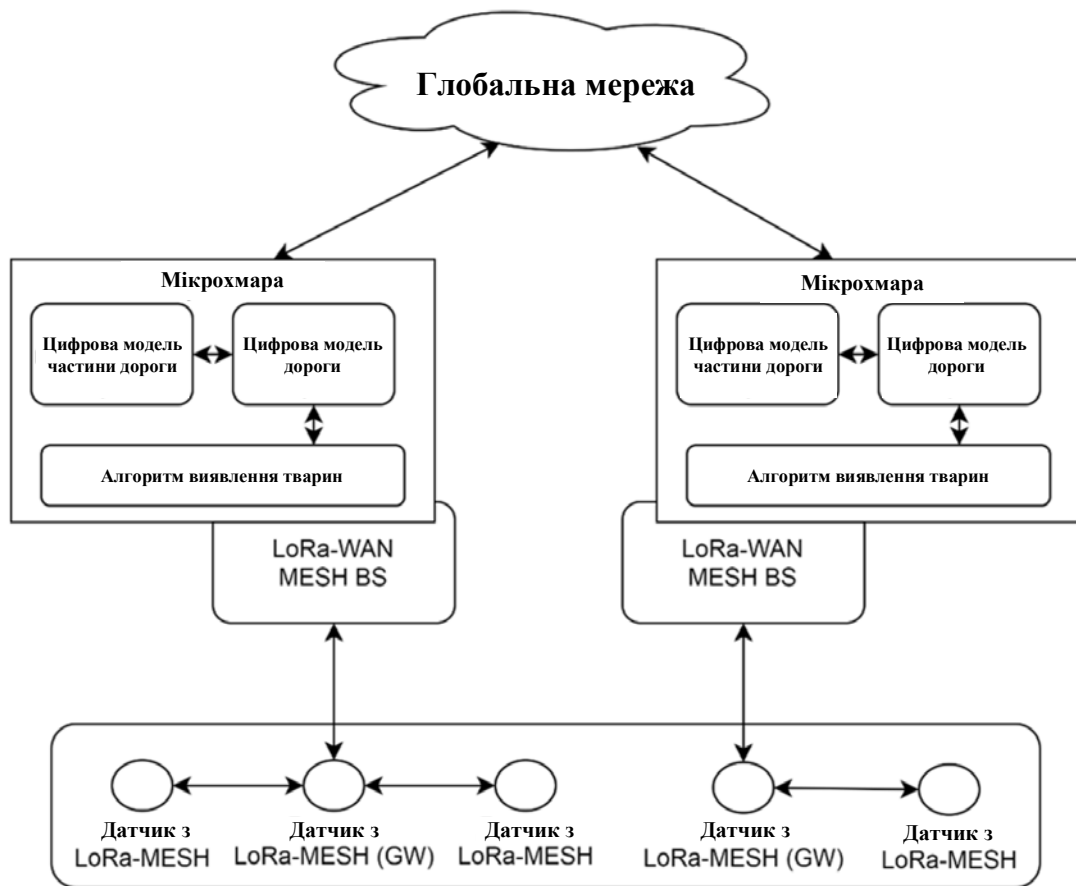


Рисунок 7 – Функціональна схема запропонованої мережі

Додаток Б  
(обов'язковий)

Протокол перевірки кваліфікаційної роботи на наявність текстових запозичень

ПРОТОКОЛ  
ПЕРЕВІРКИ КВАЛІФІКАЦІЙНОЇ РОБОТИ  
НА НАЯВНІСТЬ ТЕКСТОВИХ ЗАПОЗИЧЕНЬ

Назва роботи: Моделі мережі керування автотранспортом із використанням технологій штучного інтелекту

Тип роботи: Магістерська кваліфікаційна робота  
(БДР, МКР)

Підрозділ кафедра інфокомунікаційних систем і технологій, факультет інформаційних електронних систем  
(кафедра, факультет)

Показники звіту подібності Unichesk

Оригінальність 98,76 % Схожість 1,24 %

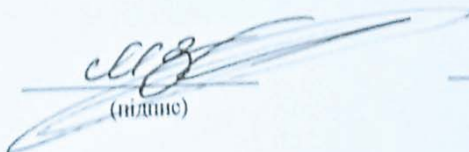
Аналіз звіту подібності (відмітити потрібне):

1. Запозичення, виявлені у роботі, оформлені коректно і не містять ознак плагіату.

2. Виявлені у роботі запозичення не мають ознак плагіату, але їх надмірна кількість викликає сумніви щодо цінності роботи і відсутності самостійності її виконання автором. Роботу направити на розгляд експертної комісії кафедри.

3. Виявлені у роботі запозичення є недобросовісними і мають ознаки плагіату та/або в ній містяться навмисні спотворення тексту, що вказують на спроби приховування недобросовісних запозичень.

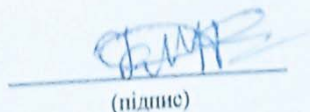
Особа відповідальна за перевірку

  
(підпис)

Васильківський М.В.  
(прізвище, ініціали)

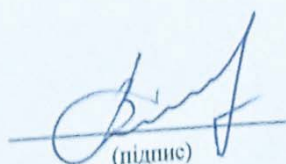
Ознайомлені з повним звітом, який був згенерований системою Unichesk щодо роботи.

Автор роботи

  
(підпис)

Крепчук М.Р.  
(прізвище, ініціали)

Керівник роботи

  
(підпис)

Воловик А.І.У.  
(прізвище, ініціали)