



Я, як студент ХНУРЕ, розумію і підтримую політику закладу із академічної доброчесності. Я не надавав і не одержував недозволену допомогу під час підготовки кваліфікаційної роботи. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело.

19.01.2024



Маслов О. А.

# ХАРКІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ РАДІОЕЛЕКТРОНІКИ

Факультет \_\_\_\_\_ АКТ \_\_\_\_\_  
Кафедра \_\_\_\_\_ КІТАР \_\_\_\_\_  
Рівень вищої освіти \_\_\_\_\_ другий (магістерський) \_\_\_\_\_  
Спеціальність \_\_\_\_\_ 151 Автоматизація та комп'ютерно-інтегровані технології \_\_\_\_\_  
Тип програми \_\_\_\_\_ Освітньо-професійна \_\_\_\_\_  
Освітня програма \_\_\_\_\_ Комп'ютеризовані та робототехнічні системи \_\_\_\_\_  
(шифр і назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри КІТАР \_\_\_\_\_  
(підпис)

« \_\_\_\_ » \_\_\_\_\_ 20\_\_ р.

## ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові \_\_\_\_\_ Маслову Олександрю Анатолійовичу \_\_\_\_\_  
(прізвище, ім'я, по батькові)

1. Тема роботи \_\_\_\_\_ Розроблення інтелектуальної системи керування потоком автотранспорту в динамічних умовах \_\_\_\_\_

Затверджена наказом по університету від \_\_\_\_\_ 03.11.2023 р. № 1288Ст \_\_\_\_\_

2. Термін подання студентом роботи до екзаменаційної комісії \_\_\_\_\_

3. Вихідні дані до роботи \_\_\_\_\_

Для обчислення та демонстрації результатів використовується система моделювання SUMO;

Використовується архітектура у форматі ARC-IT;

Для ідентифікації використовуються моделі YOLOv3.

4. Перелік питань, що потрібно опрацювати в роботі Вступ; Аналіз існуючих технологій проектованої системи; Аналіз принципів розробки інтелектуальної транспортної системи; Нейромережеві підходи до аналізу та регулювання дорожнього руху; Реалізація методу керування потоком автотранспорту з використанням нейромережі; Висновки; Додатки

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій

Графічний демонстраційний матеріал в форматі PowerPoint (\*.ppt) формату \_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

#### 6. Консультанти розділів роботи

Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата

#### КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Аналіз технічного завдання	12.10 – 18.10.23	виконано
2	Аналіз принципів розробки інтелектуальної транспортної системи	20.10 – 09.11.23	виконано
3	Нейромережеві підходи до аналізу та регулювання дорожнього руху	23.11 – 01.12.23	виконано
4	Реалізація методу керування потоком автотранспорту з використанням нейромережі	02.12 – 03.12.23	виконано
5	Експериментальні дослідження	04.12 – 31.12.23	виконано
6	Подання роботи на перевірку Інтернет-сервісом Unichesk	19.01.2024	виконано
7	Оформлення пояснювальної записки	20.01.2024	виконано
8	Подання роботи на рецензію	21.01.2024	виконано
9	Подання роботи на підпис зав. кафедри	22.01.2024	виконано
11	Подання кваліфікаційної роботи в ЕК	23.01.2024	виконано

Дата видачі завдання \_\_\_\_\_ 10.10.2023 р. \_\_\_\_\_

Студент \_\_\_\_\_  
(підпис)

\_\_\_\_\_ Маслов О. А. \_\_\_\_\_

Керівник роботи \_\_\_\_\_  
(підпис)

\_\_\_\_\_ доц. Демська Н. П. \_\_\_\_\_  
(посада, прізвище, ініціали)

## РЕФЕРАТ

Пояснювальна записка: 75 с., 1 табл., 25 рис., 4 дод., 33 джерела.

ІНТЕЛЕКТУАЛЬНА ТРАНСПОРТНА СИСТЕМА, НЕЙРОННА МЕРЕЖА, ДОРОЖНІЙ РУХ, СИМУЛЯТОР МІСЬКОГО ТРАФІКУ, ТРАНСПОРТНИЙ ПОТІК.

Об'єкт дослідження – автоматизація процесу керування потоком автотранспорту.

Предмет дослідження – інтелектуальна система.

Мета роботи – розробка системи, яка допоможе скоротити час очікування при переїзді перехресть та передбачення руху транспортних потоків з урахуванням маршрутизації та перспективного навантаження.

Для досягнення мети було розглянуто структури та концепції інтелектуальної транспортної мережі, а також проаналізовано лінійні та нелінійні алгоритми для аналізу та прогнозування руху транспорту.

Отримані результати використовувались для реалізації управління транспортними потоками за допомогою основних агентів, таких як світлофори, інформаційні канали та системи інформування.

Модель була проілюстрована, а отримані результати були проаналізовані для досягнення встановленої мети.

## ABSTRACT

Explanatory note: 75 pp., 1 table, 25 figures, 4 appendices, 33 sources.

INTELLIGENT TRANSPORT SYSTEM, NEURAL NETWORK,  
TRAFFIC, CITY TRAFFIC SIMULATOR, TRANSPORT FLOW.

The object of research is the automation of the process of managing the traffic flow.

The subject of research is an intelligent system.

The goal of the work is the development of a system that will help reduce the waiting time when crossing an intersection and predict the movement of traffic flows taking into account routing and prospective load.

To achieve the goal, the structures and concepts of the intelligent transport network were considered, as well as linear and non-linear algorithms for traffic analysis and forecasting were analyzed.

The obtained results were used to implement the management of traffic flows with the help of basic agents, such as traffic lights, information channels and information systems.

The model was illustrated and the obtained results were analyzed to achieve the set goal.

## ЗМІСТ

Перелік скорочень .....	7
Вступ.....	8
1 Аналіз існуючих технологій проєктованої системи .....	9
1.1 Розгляд існуючих підходів до керування потоком автотранспорту .....	9
1.2 Аналіз алгоритмів роботи сучасних систем інтелектуального керування транспортними потоками.....	10
1.3 Переваги та недоліки розглянутих систем і алгоритмів в контексті рішення задачі керування потоком в динамічних умовах .....	12
1.4 Висновки до розділу .....	15
2 Аналіз принципів розробки інтелектуальної транспортної системи.....	17
2.1 Основні складові для аналізу та моделювання .....	19
2.2 Засоби для моделювання та симуляції структури інтелектуальних транспортних систем. ....	24
2.3 Висновки до розділу .....	26
3 Нейромеревеві підходи до аналізу та регулювання дорожнього руху .....	27
3.1 Системи моделювання транспортних потоків .....	27
3.2 Ступінь деталізації трафіку.....	28
3.3 Прогнозування заторів.....	31
3.4 Прогнозування трафіку.....	32
3.5 Системи обробки транспортних потоків .....	33
3.6 Порівняння моделей розглянутих нейромереж .....	44
3.7 Висновки до розділу .....	47
4 Реалізація методу керування потоком автотранспорту з використанням нейромережі.....	48
4.1 Опис пропонованого підходу до керування транспортним потоком.....	48

4.2 Впровадження методу контролю транспортних потоків через регулювання світлофорів .....	51
4.3 Система регулювання транспортним потоком на основі передбачення та перенаправлення потоків. ....	62
4.4 Моделювання транспортного потоку та симуляція алгоритму передбачення .....	64
4.5 Висновки до розділу .....	66
5 Охорона праці .....	68
Висновки .....	70
Перелік джерел посилання .....	72
Додаток А Псевдокоди алгоритмів .....	76
Додаток Б Код програми .....	79
Додаток В Апробація результатів наукових досліджень .....	90
Додаток Г Демонстраційний матеріал .....	93

## ПЕРЕЛІК СКОРОЧЕНЬ

- ІТС – інтелектуальна транспортна система;
- МН – машинне навчання;
- ANN (Artificial Neural Network) – штучна нейронна мережа;
- ARIMA (Autoregressive Integrated Moving Average) – авторегресійне інтегроване ковзне середнє;
- CANN (Cascade Artificial Neural Network) – каскадна штучна нейронна мережа;
- CNN (Convolutional Neural Network) – згорткова нейронна мережа;
- DBN (Deep Belief Network) – мережа глибокої довіри;
- DNN (Deep Neural Nets) – глибока нейронна мережа;
- DQN (Deep Q-Network) – глибока Q мережа;
- GRU (Gated Recurrent Unit) – закрита рекурентна одиниця;
- LSTM (Long Short-Term Memory) – довготривала короткочасна пам'ять;
- RL (reinforcement learning) – навчання з підсиленням;
- RNN (Recurrent Neural Networks) – рекурентна нейронна мережа;
- SAE (Sparse Autoencoder) – розріджений автоенкодер;
- SUMO (Simulation of Urban Mobility) – симулятор міського трафіку;
- WNN (Wavelet Neural Network) – хвильова нейронна мережа.

## ВСТУП

У сучасному світі, автотранспорт відіграє найважливішу роль у забезпеченні мобільності населення і розвитку економіки. Зростання обсягів автотранспорту та зростаюча комплексність дорожньої інфраструктури роблять проблеми керування транспортними потоками більш актуальними та складними. У багатьох містах світу нерегулярні затори та перевантажені дороги стали не тільки дійсною загрозою для життя та безпеки учасників дорожнього руху, але й джерелом значних втрат для економіки та довкілля.

Спроби поліпшити управління транспортними потоками включають в себе різні технічні та інженерні рішення, включаючи побудову нових доріг, оптимізацію світлофорів та впровадження систем електронного збору дорожнього руху. Однак такі традиційні підходи не завжди здатні ефективно вирішити складні проблеми управління потоками в режимі реального часу, оскільки вони нерідко не враховують динаміку змін умов на дорозі та індивідуальні поведінки водіїв.

У зв'язку з цим виникає необхідність розроблення інноваційних та інтелектуальних систем керування автотранспортними потоками, які могли б пристосовуватися до змін обстановки, надавати оптимальні рішення та підвищувати загальну продуктивність системи управління транспортом. В цьому контексті важливим стає застосування сучасних технологій інтелектуального аналізу даних, машинного навчання та адаптивного керування для створення інтегрованих систем керування автотранспортними потоками. Ця робота має стратегічне значення, оскільки її результати можуть сприяти покращенню керування транспортними потоками, зменшенню заторів, покращенню безпеки руху та оптимізації використання існуючої дорожньої інфраструктури.

Кваліфікаційна робота виконана згідно [1-2]. Результати роботи опубліковані в [3].

# 1 АНАЛІЗ ІСНУЮЧИХ ТЕХНОЛОГІЙ ПРОЄКТОВАНОЇ СИСТЕМИ

## 1.1 Розгляд існуючих підходів до керування потоком автотранспорту

Аналіз різних підходів та технологій, які використовуються для керування автотранспортними потоками, є ключовим завданням для виконання роботи. Основні підходи та технології, які застосовуються в цій області, наступні.

### 1.1.1 Синхронізація світлофорів

Традиційний метод управління дорожнім рухом, який полягає в установці світлофорів на перехрестях та їх синхронізації для оптимізації руху. Використовуються алгоритми, які забезпечують зелене світло для головного напрямку руху з урахуванням потоків автотранспорту та інших факторів [4].

### 1.1.2 Системи електронного збору дорожнього руху

Системи, які використовуються для автоматичного збору даних про дорожній рух, включаючи інформацію про швидкість, густину потоку, інтенсивність та інше. Зібрані дані використовуються для аналізу та вивчення динаміки дорожнього руху [4].

### 1.1.3 Системи «розумного» паркування

Технології, які надають інформацію про доступність паркувальних місць в режимі реального часу. Це допомагає водіям знаходити вільні паркувальні місця та зменшує час пошуку паркувального місця, що може поліпшити рух на дорогах [4].

### 1.1.4 Системи керування великими даними

Використання аналітики великих даних для прогнозування потоків

автотранспорту та оптимізації дорожньої інфраструктури. Враховує велику кількість даних, включаючи дані про дорожній рух, метеорологічні умови, події та інше [4].

#### 1.1.5 Інтерактивні додатки та системи навігації

Мобільні додатки та системи навігації, які надають водіям інформацію про стан дорожнього руху, оптимальні маршрути та інше. Використовують дані GPS та великих даних для надання інформації в режимі реального часу.

#### 1.1.6 Автоматизовані системи контролю за рухом

Використання камер відеоспостереження та сенсорів для автоматичного виявлення порушень дорожнього руху та нагляду за безпекою. Системи для автоматичного надання штрафів і вдосконалення безпеки на дорозі.

#### 1.1.7 Інтегровані системи керування транспортними потоками

Комплексні платформи, які об'єднують кілька технологій для керування автотранспортними потоками, включаючи синхронізацію світлофорів, збір даних, аналітику та системи навігації. Такі системи надають можливість більш ефективного та інтегрованого керування дорожнім рухом [5].

### 1.2 Аналіз алгоритмів роботи сучасних систем інтелектуального керування транспортними потоками

Сучасні системи інтелектуального керування транспортними потоками використовують різні алгоритми та підходи для оптимізації руху на дорогах.

### 1.2.1 Алгоритми машинного навчання для передбачення та оптимізації потоків

Використання машинного навчання у сучасних системах керування дорожнім рухом включає в себе створення моделей для передбачення руху транспортних засобів та оптимізації рухових потоків. Для цього використовуються алгоритми, такі як лінійна регресія, дерева рішень, методи глибокого навчання (нейронні мережі) та методи часового ряду. Нейронні мережі можуть вивчати складні нелінійні зв'язки між факторами, які впливають на дорожній рух, і надавати прогнози в режимі реального часу.

### 1.2.2 Адаптивне керування світлофорами

Ця система використовує датчики і камери для збору даних про потік автотранспорту на перехрестях та вулицях. Алгоритми аналізують ці дані та приймають рішення про зміну режиму роботи світлофорів в реальному часі. Наприклад, якщо на одному з напрямків є великий затор, система може виділити цьому напрямку більше часу зеленого сигналу для поліпшення потоку [6].

### 1.2.3 Оптимізація маршрутів на основі реального часу

Ця система використовує дані GPS від транспортних засобів для визначення їхнього розташування та швидкості руху. Алгоритми обчислюють найкоротший або найшвидший маршрут для кожного транспортного засобу в режимі реального часу і надають водіям інструкції для оптимального переміщення через місто [6].

### 1.2.4 Системи управління мультимодальним транспортом

Ці системи інтегрують різні види транспорту (автомобілі, автобуси, метро, велосипеди, пішоходи) в єдину систему, що дозволяє подорожуючим здійснювати пересідання та вибирати оптимальні маршрути з використанням різних видів транспорту [6].

### 1.2.5 Системи аналізу дорожньої інфраструктури

Вони використовують алгоритми для оцінки стану доріг, перехрестя та інших дорожніх об'єктів. Це допомагає ідентифікувати місця, де можуть виникнути затори або аварії, і планувати необхідні ремонти та модернізації.

### 1.2.6 Системи керування паркуванням

Алгоритми визначають доступні парковочні місця та надають водіям інформацію про їх розташування. Це допомагає водіям знайти парковку швидше та зменшує час пошуку місця [7].

### 1.2.7 Системи попередження про аварії

Ці системи використовують алгоритми для виявлення небезпечних ситуацій на дорозі, таких як різка зупинка транспортного засобу перед вами або наближення до перехрестя з червоним світлофором. Вони можуть надсилати попередження водіям через системи автоматичної нотифікації або інші засоби [6].

## 1.3 Переваги та недоліки розглянутих систем і алгоритмів в контексті рішення задачі керування потоком в динамічних умовах

### 1.3.1 Алгоритми машинного навчання для передбачення та оптимізації потоків

#### Переваги:

– покращення прогнозування – за допомогою машинного навчання можливо зробити більш точні прогнози руху автотранспорту, що дозволяє забезпечити краще планування рухових потоків;

– адаптація до змін – алгоритми машинного навчання можуть адаптуватися до змін у дорожніх умовах, подій та різних чинників, що впливають на рух.

#### Недоліки:

- потреба в великій кількості даних – машинне навчання вимагає значних обсягів даних для навчання моделей, що може бути проблематичним для нових, або менше навантажених доріг;

- складність в налаштуванні – вибір правильних моделей та параметрів може бути складним завданням [8].

### 1.3.2 Адаптивне керування світлофорами

Переваги:

- оптимізація в реальному часі – дозволяє реагувати на зміни потоків в реальному часі та підвищує ефективність світлофорного регулювання;

- зменшення заторів – шляхом реагування на поточну ситуацію може бути досягнуто зменшення заторів.

Недоліки:

- споживання ресурсів – постійна робота датчиків та камер для збору даних може вимагати значних ресурсів та енергії;

- потреба в інфраструктурних вкладеннях – вимагає встановлення відповідної інфраструктури та обладнання.

### 1.3.3 Оптимізація маршрутів на основі реального часу

Переваги:

- маршрутизація в режимі реального часу – допомагає водіям уникати заторів та зменшує час подорожі;

- економія пального – допомагає зменшити споживання пального та викиди CO<sub>2</sub>.

Недоліки:

- залежність від даних GPS – точність оптимізації залежить від якості даних GPS, і помилки можуть вплинути на точність маршруту;

- потреба в розумних транспортних засобах – не всі автотранспортні засоби обладнані GPS або сумісні з системами маршрутизації [8].

#### 1.3.4 Системи управління мультимодальним транспортом

##### Переваги:

- забезпечення різноманітних варіантів – дозволяють подорожуючим вибирати найкращий спосіб пересування в залежності від ситуації;
- зменшення навантаження на автотранспорт – сприяють зменшенню навантаження на дороги та зменшенню заторів.

##### Недоліки:

- потреба в інтеграції – вимагають інтеграції різних систем та видів транспорту, що може бути складним завданням;
- необхідність інформаційної підтримки – вимагають доступу до інформації про розклади та розташування транспорту.

#### 1.3.5 Системи аналізу дорожньої інфраструктури

##### Переваги:

- забезпечення раннього виявлення проблем – дозволяють вчасно реагувати на проблеми в дорожній інфраструктурі та зменшити ризики аварій;
- планування покращень – допомагають визначити необхідність і планувати ремонтні та модернізаційні роботи.

##### Недоліки:

- високі витрати на обладнання – встановлення та обслуговування системи може бути дорогим;
- потреба в постійному моніторингу – вимагають постійного моніторингу та обслуговування для підтримки ефективності [9].

#### 1.3.6 Системи керування паркуванням

##### Переваги:

- швидший пошук парковки – допомагають водіям знаходити парковочні місця швидше, що зменшує затори;
- можливість ефективного використання парковочних площ –

дозволяють оптимізувати використання парковочних площ та зменшити забруднення.

Недоліки:

- необхідність обладнання – вимагають встановлення сенсорів та систем моніторингу на парковочних місцях;
- обмеженість використання в певних місцях – можуть бути недоступні, або менш ефективні в деяких районах.

### 1.3.7 Системи попередження про аварії

Переваги:

- зменшення аварій – допомагають запобігати аваріям та зменшити травматизм на дорозі;
- збільшення безпеки – підвищують загальну безпеку дорожнього руху.

Недоліки:

- можливі помилки і ложні спрацювання – системи можуть виявити небезпеку там, де її немає, або навпаки;
- залежність від технічного обладнання – вимагають сучасного технічного обладнання та інфраструктури [9].

## 1.4 Висновки до розділу

Дослідження щодо розроблення інтелектуальної системи керування потоком автотранспорту в динамічних умовах може включати в себе ключові аспекти і методи. Можна дослідити аналіз та передбачення поведінки транспортного потоку, розробити алгоритми адаптивного керування світлофорами, інтегрувати дані з різних джерел, оптимізувати маршрути та системи попередження про аварії.

Для досягнення цих цілей можна використати методи машинного навчання для аналізу і передбачення руху транспорту, оптимізаційні методи для керування рухом, аналіз даних для виявлення патернів у русі, а також

розробити алгоритми передбачення, керування світлофорами, оптимізації маршрутів і систем безпеки.

Технологічно можна використати різні засоби, включаючи датчики, камери, GPS, IoT-технології та аналіз великих даних, для збору і обробки інформації, необхідної для цього дослідження. Ці аспекти і методи допоможуть розробити інтелектуальну систему керування для ефективного керування транспортними потоками в різних дорожніх умовах.

## 2 АНАЛІЗ ПРИНЦИПІВ РОЗРОБКИ ІНТЕЛЕКТУАЛЬНОЇ ТРАНСПОРТНОЇ СИСТЕМИ

Інтелектуальні транспортні системи (Intelligent transportation system) – це назва для транспортної системи, в якій транспортні засоби взаємодіють між собою та з оточуючим середовищем для створення більш комфортних умов для водіння. Інтелектуальна інфраструктура призначена для підвищення безпеки та пропускної здатності дорожніх систем. ІТС – це складні та сучасні системи, спрямовані на покращення водійського досвіду. У цих системах взаємодіють транспортні засоби, водії, пасажери, дорожні оператори та менеджери, спілкуючись один з одним та з оточуючим середовищем, і часто пов'язані з складними магістральними інфраструктурними системами [10].

Національна архітектура ІТС встановлює загальні принципи для планування, визначення та інтеграції інтелектуальних транспортних систем. Це результат спільного внеску різноманітної групи фахівців з ІТС, включаючи практиків транспорту, системних інженерів, розробників систем, технологічних спеціалістів, консультантів і інших. На рисунку 2.1 зображено узагальнену архітектуру інтелектуальної транспортної системи [10].

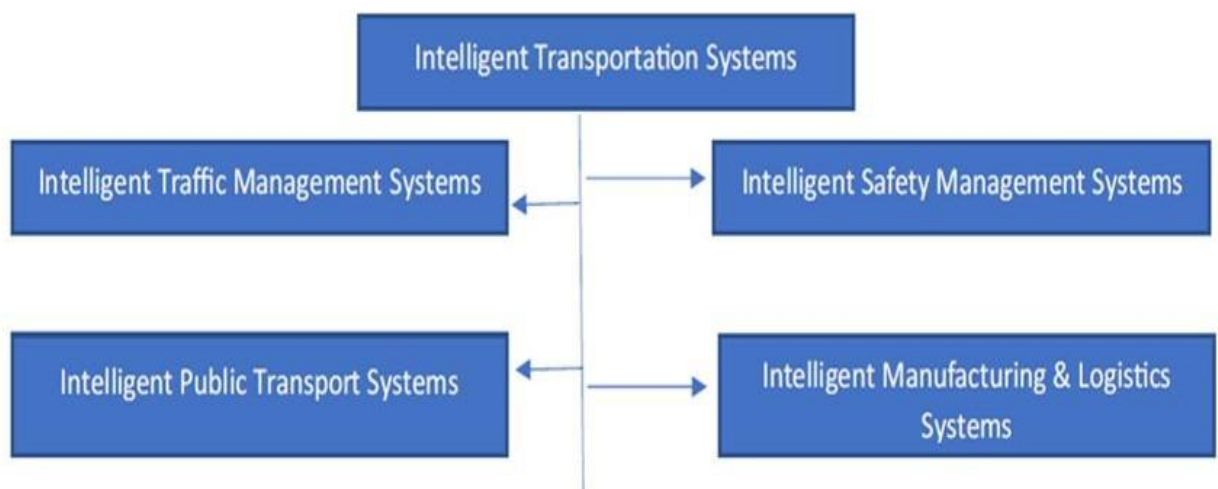


Рисунок 2.1 – Узагальнена архітектура інтелектуальної транспортної системи [10]

Хоча інтелектуальні транспортні системи (ІТС) часто розглядаються в контексті дорожнього руху, об'єднане використання транспортних засобів пасажирами та вантажним транспортом означає, що ІТС також включає інтерфейс з іншими видами транспорту, такими як залізничний, водний та повітряний транспорт.

Системи ІТС не існують у вакуумі. Вони часто залежать від основних інфраструктурних систем для телекомунікацій, інфраструктурних мереж та Інтернету.

Інтелектуальні транспортні системи не обов'язково обмежені лише транспортними засобами та дорогами. Повітряний транспорт, морський транспорт та залізничні транспортні системи можуть ставати все більш інтелектуальними. Вони вже використовують передові системи та електроніку як частину своєї роботи та інфраструктури. Наприклад, морські навігаційні системи для судів використовують електроніку та радіо для визначення місцезнаходження, уникнення перешкод та запобігання зіткненням [10].

Метою управління та контролю дорожнього руху є забезпечення безпечного руху користувачів транспортних засобів. Початковим інструментом управління дорожнім рухом стала розділена проїжджа частина з встановленим правилом щодо напрямку руху ліворуч або праворуч від розділової лінії. Першим інструментом інтелектуальних транспортних систем (ІТС) став світлофор із правилами зупинки на червоне світло. Проте, з розвитком комп'ютеризації, мереж, систем детекції та інших технологій, набір інструментів для управління транспортом значно розширився та продовжує розвиватися, особливо в контексті прямої взаємодії з учасниками дорожнього руху через ІТС [5].

Стандарти управління та контролю трафіку представлені в різних функціональних областях, таких як:

- управління та контроль трафіку через архітектуру;
- ідентифікація та виявлення учасників дорожнього руху;

- регулювання світлофорами;
- контроль доступу до зони;
- контроль швидкості руху;
- моделювання трафіку;
- управління пригодами на дорозі;
- управління дорожніми роботами;
- управління якістю повітря;
- інформація про дорожню мережу та поради;
- оптимізація дорожньої мережі;
- спеціальне керування маршрутами користувачів;
- забезпечення дотримання правил дорожнього руху.

## 2.1 Основні складові для аналізу та моделювання

### 2.1.1 Система світлофорів

Світлофори становлять ключовий елемент системи дорожнього руху, і час очікування перед зміною сигналу може значно впливати на загальний час подорожі. Ефективне функціонування світлофорів може сприяти загальній ефективності руху [11].

Загальні проблеми включають необхідність очікування на переїзді, коли інших транспортних засобів з іншого боку немає, однаковий час очікування для доріг з високою або низькою щільністю руху, фіксований графік роботи світлофора, який не враховує змін в потоці руху, або потребу очікування багатьох циклів світлофора при великій інтенсивності руху. Очевидно, що інтелектуальні світлофори, які працюють в системі інтелектуального транспорту, можуть вирішити ці проблеми. Запропонована система світлофорів бере до уваги кількість транспортних засобів і графік роботи. Передбачається, що кількість транспортних засобів, що очікують перетину на кожному переході, відома наперед. Для транспортних засобів, які підключені до мережі та обладнані напів-автономною системою, це

завдання легше виконати, оскільки їхнє місцезнаходження відоме глобальній системі позиціонування (GPS) або локальному алгоритму картографування. Рисунок 2.2 демонструє статистичні докази переваг використання інтелектуальних світлофорів [11].

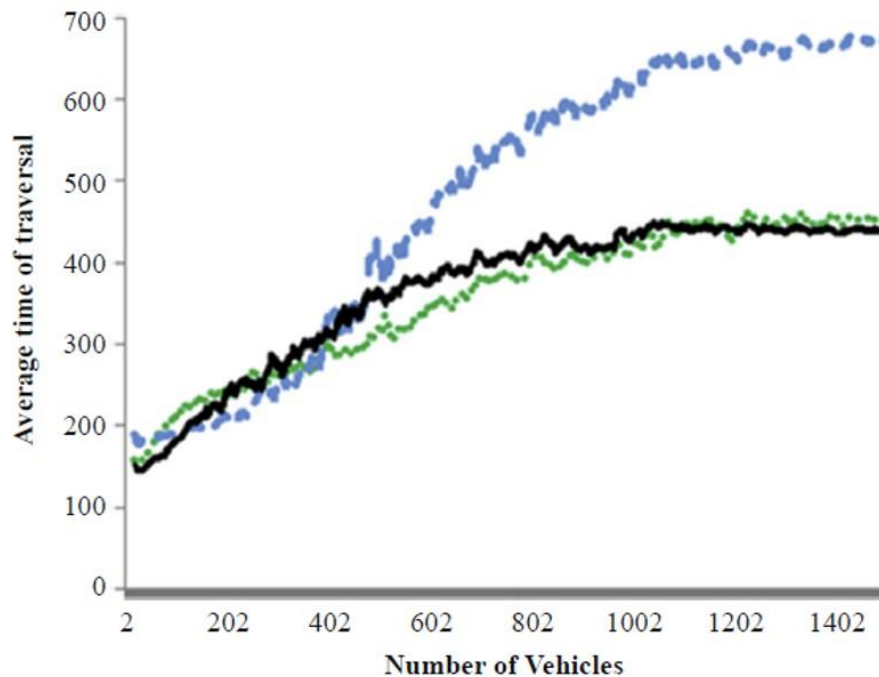


Рисунок 2.2 – Діаграма переваг системи управління світлофором [11]

Спостереження за всіма кривими вказує на тенденцію збільшення середнього часу проходження при зростанні кількості транспортних засобів, до того моменту, коли цей час стає постійним. Збільшення спостерігалось через підвищену інтенсивність руху. При досягненні насиченої інтенсивності руху будь-яке подальше збільшення кількості транспортних засобів не мало впливу. Крива із фіксованим часом роботи світлофора виявилася значно менш ефективною в порівнянні з двома іншими підходами, які вказали на майже однакову тенденцію. Незважаючи на це, запропонована система, насправді, випереджає систему з циклічними змінами на перехресті, оцінювана за середнім часом проходження [11].

### 2.1.2 Регулювання швидкісних режимів на різних смугах

Встановлення різних обмежень швидкості для різних смуг руху є концепцією важливого значення, особливо в умовах різноманітності транспортних засобів на дорозі, де рух варіюється від повільних до швидких транспортних засобів. Очевидно, що рух транспортних засобів з низькою швидкістю на всіх смугах призведе до сповільнення руху на загальній ділянці, що не є оптимальним для транспортних засобів з великою швидкістю. Так само, як і в разі фіксованого часу роботи світлофора, використання статичних обмежень швидкості для окремих смуг руху може стати сумнівним. Таким чином, оптимальність динамічного регулювання обмежень швидкості на різних смугах руху стає необхідністю [12].

### 2.1.3 Оптимізація маршрутів

Ефективне планування маршруту відіграє ключову роль у розподілі трафіку між дорожніми мережами, сприяючи швидкому та оптимальному подоланню відстані для кожного транспортного засобу в умовах взаємодії з іншими учасниками руху. Часто транспортні засоби обирають популярні маршрути для швидкого досягнення пункту призначення, що може викликати затори та зниження швидкості для всіх. Неврахування інших учасників дорожнього руху при плануванні маршруту може призвести до неефективних результатів. Ключовим вирішенням є розумне розподілення трафіку, використовуючи всю інфраструктуру для оптимізації колективних подорожей. Здійснюється використання алгоритму Uniform Cost Search для планування маршрутів кожного транспортного засобу з метою мінімізації часу подорожі. До розрахунку використовується штраф на кожній ділянці шляху, залежний від інтенсивності руху. Передбачення щільності руху здійснюється на основі історичних даних, адаптуючи маршрут до змінюючихся тенденцій. Постійна адаптація до сценарію дорожнього руху за допомогою перепланування маршруту дозволяє транспортним засобам спільно складати ефективний план подорожі, враховуючи мінливі умови [11].

$$\rho(Ra, t) = \begin{cases} \rho_{\text{current}}(Ra), & t \leq \beta \\ \rho_{\text{historic}}(Ra, t), & t > \beta \end{cases} \quad (2.1)$$

де  $\rho_{\text{current}}(Ra)$  – визначає поточну щільність трафіку;  
 $\rho_{\text{historic}}(Ra, t)$  – прогнозованою щільністю руху;  
 $\beta$  – час, до якого поточна щільність руху є достовірною.

Загальну суму, що обчислюється для вузла  $c1$  при розширенні з вузла  $c2$ , який з'єднаний дорогою  $Ra$ , можна виразити рівняннями:

$$t(c1) = t(c2) + \frac{|Ra|}{s_i}, \quad (2.2)$$

$$f(c1) = f(c2) + \alpha \rho(Ra, t(C1)), \quad (2.3)$$

де  $\alpha$  – постійна штрафу;  
 $t(c1)$  – час прибуття до  $c1$ ;  
 $Ra$  – довжина дороги.

На рисунку 2.3 показано графік використання системи маршрутизації залежно від параметра альфа.

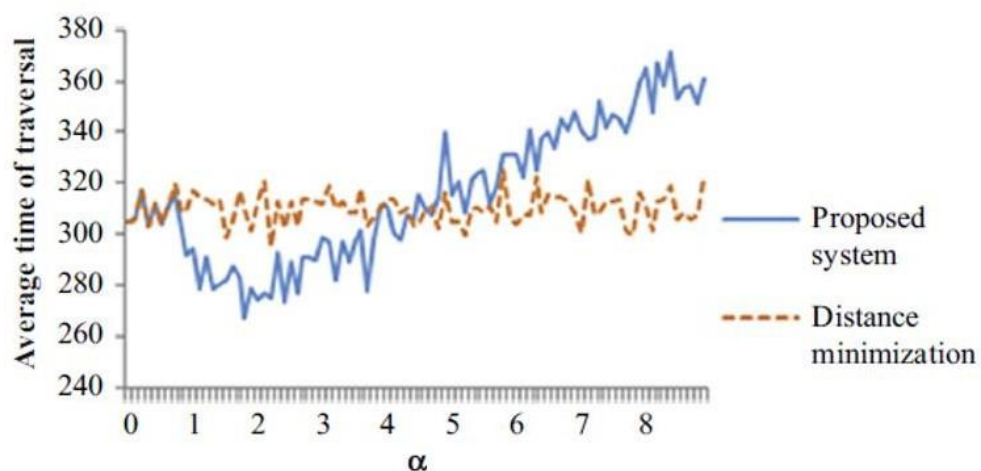


Рисунок 2.3 – Графік використання системи маршрутизації залежно від параметра альфа

#### 2.1.4 Уникнення заторів

Управління міським рухом для уникнення заторів – важлива задача, оскільки велика кількість транспортних засобів на дорогах часто викликає серйозні труднощі. Затори, характеризуються зниженням середньої швидкості руху транспортних засобів та збільшенням часу подорожі. Непередбачуваність може виникати з-за великої кількості транспорту або несподіваного зменшення пропускної здатності, такого як аварії чи перекриття доріг [12].

Завдяки росту автономності та систем управління транспортом, транспортні засоби можуть уникати потенційних заторів. Інтелектуальні агенти на дорожній інфраструктурі можуть моніторити та вимірювати щільність руху на різних дорогах, а інтелектуальні пристрої в транспортних засобах можуть збирати дані для планування маршруту, обходячи ділянки з потенційними заторами.

Існують два підходи до маршрутизації: централізовані та децентралізовані. Децентралізовані методи розглядають кожен транспортний засіб окремо під час планування, шукаючи оптимальний маршрут. Ці методи можуть враховувати рух інших транспортних засобів, прогнозувати його або використовувати історичні дані. Однак ці методи мають свої обмеження, такі як складність моделювання великої кількості транспорту та невизначеності при плануванні.

Класифікація та впровадження систем, які забезпечують динамічне управління міським рухом, важливі для покращення продуктивності та зручності подорожей у містах [12].

2.2 Засоби для моделювання та симуляції структури інтелектуальних транспортних систем.

Існує низка проектів, які базуються на вже визнаних стандартах ІТС і призначені для реалізації, демонстрації та моделювання ІТС. До цих проектів входять такі ініціативи, як FRAME, HARTS, ARC-IT та SUMO.

### 2.2.1 FRAME

FRAME (ФРЕЙМ) розроблена для використання у низхідному підході до планування та розгортання інтегрованих ІТС. Загальна концепція і можливості можуть бути представлені у формальній (еталонній) моделі. Архітектура FRAME не враховує прийняття рішень чи вибір тими, хто реалізує або регулює ІТС, оскільки вона не передбачає створення еталонної моделі.

Загальну концепцію та структуру системи слід описувати технологічно незалежним способом, щоб вимоги вищого рівня залишалися сталими при розвитку технології. Важливою особливістю архітектури FRAME є те, що вона розроблена як підмножина, тому її можна використовувати частково. Архітектура FRAME служить не лише моделлю інтегрованої ІТС, але і структурою, на основі якої можна систематично та узагальнено створювати конкретні моделі інтегрованої ІТС [28].

### 2.2.2 HARTS

HARTS (Довідник з гармонізованої архітектури для технічних стандартів) представляє собою ініціативу, створену Цільовою групою з гармонізації 7 (HTG7) в рамках спільної угоди між ЄС та США у 2011 році. Метою було підтримувати «глобальні відкриті стандарти там, де це можливо, для забезпечення сумісності систем співробітництва та уникнення надлишкових стандартів».

Одним із ключових результатів HARTS є концепція пакетів послуг ІТС, що представляють собою набір орієнтованих на обслуговування перспектив систем інтелектуальних транспортних систем.

ARC-IT (Довідник з архітектури для спільного та інтелектуального транспортування) виступає національною еталонною архітектурою ІТС у США. Вона служить загальною основою для планування, визначення та інтеграції інтелектуальних транспортних систем. ARC-IT надає рамки для планування та проектування ІТС, але не визначає конкретних реалізацій, дозволяючи інженерам та планувальникам працювати з різними завданнями, використовуючи загальну мову як основу для надання ІТС [15].

### 2.2.3 ARC-IT

Довідник архітектури для кооперативного та інтелектуального транспорту (ARC-IT) визначає загальну структуру для організації, визначення та інтеграції інтелектуальних транспортних систем. Цей продукт відображає внесок широкого кола фахівців з інтелектуальних транспортних систем, включаючи спеціалістів з транспорту, системних інженерів, розробників систем, технологічних експертів, консультантів та інших [15].

### 2.2.4 SUMO

"Simulation of Urban Mobility" – це відкритий мікроскопічний моделювальний інструмент для руху, який дозволяє відтворити рух окремих транспортних засобів у заданій дорожній мережі. Ця симуляція забезпечує можливість дослідження різних аспектів управління трафіком. Кожен транспортний засіб в моделі має чітко визначений маршрут і рухається по мережі самостійно. Хоча симуляції за замовчуванням детерміновані, існують різні варіанти введення випадковості, що дозволяє розглядати більший спектр сценаріїв.

### 2.3 Висновки до розділу

Цей розділ присвячений вивченню концепції інтелектуальної транспортної системи, аналізу архітектури та ключових компонентів, огляду регулювання та стандартизації, а також розгляду перспектив розвитку сучасної транспортної системи, використовуючи інструменти великих даних та штучного інтелекту.

Здійснено дослідження сучасної архітектури, вибравши конкретні напрями для подальшого аналізу та реалізації окремих компонентів системи управління транспортом. Також виявлені основні труднощі при створенні системи управління транспортом.

Було розглянуто основні підходи до побудови інтелектуальних транспортних систем. Визначено перелік сервісів для розробки системи управління та моделювання інтелектуальних транспортних систем.

## 3 НЕЙРОМЕРЕЖЕВІ ПІДХОДИ ДО АНАЛІЗУ ТА РЕГУЛЮВАННЯ ДОРОЖНЬОГО РУХУ

Існує декілька критеріїв для класифікації моделей транспортних потоків, таких як рівень деталізації, операціоналізація та представлення процесів. У цьому контексті ми розглянемо різні класи моделей транспортних потоків, які визначаються за рівнем деталізації, а саме (суб-) мікроскопічний, мезоскопічний та макроскопічний підходи до моделювання.

### 3.1 Системи моделювання транспортних потоків

Зокрема дослідження руху на дорогах, може бути поліпшено шляхом проведення польових досліджень та експериментів з реальним транспортним потоком. Однак, окрім наукових викликів, пов'язаних із відтворенням таких експериментів, велику роль відіграють вартість і безпека. У зв'язку із складністю транспортних систем, аналітичні підходи можуть не завжди дати очікувані результати. Таким чином, моделі транспортних потоків (симуляції), призначені для опису поведінки складних систем транспортних потоків, стали ключовим інструментом для аналізу та експериментування.

Залежно від конкретного типу моделі, область їх застосування в транспортних потоках є дуже різноманітною. Наприклад, це може включати в себе:

- оцінку альтернативних методів (динамічного) керування дорожнім рухом;
- проектування та тестування нових транспортних засобів, таких як геометричні конструкції;
- моделювання операційних потоків, що є складовою частиною інших інструментів, наприклад, управління та оптимізація трафіку на основі моделей, а також динамічне призначення трафіку.

Моделі трафіку можна класифікувати за наступними

характеристиками:

- тип шкали незалежних змінних (безперервна, дискретна, напівдискретна);
- рівень деталізації (субмікроскопічний, мікроскопічний, мезоскопічний, макроскопічний);
- представлення процесів (детерміноване, стохастичне);
- вибір операціоналізації (аналітична, імітаційна);
- масштаб застосування (мережевий, ділянковий, зв'язковий та перетинний).

### 3.2 Ступінь деталізації трафіку

Моделі трафіку можна розподілити залежно від рівня деталізації, яким вони відображають системи транспортного руху. Ця класифікація виникає з розгляду окремих об'єктів трафіку та рівня деталізації цих об'єктів у відповідних моделях потоків. Їх класифікація є наступною:

- субмікроскопічні імітаційні моделі: це моделі, які надають високодетальний опис функціонування окремих складових транспортних засобів та їх взаємодії з оточуючим середовищем;
- мікроскопічні імітаційні моделі: вони також надають високодетальний опис, фокусуючись на виокремлених та відстежуваних окремих об'єктах у системі;
- мезоскопічні моделі: ці моделі мають середню деталізацію, охоплюючи середні рівні деталізації для представлення трафіку;
- макроскопічні моделі: це моделі, які працюють на низькому рівні деталізації, надаючи загальний та об'єднаний огляд системи трафіку.

Мікроскопічна імітаційна модель деталізовано описує просторово-часову поведінку елементів системи, таких як транспортні засоби та водії, а також їх взаємодію з високим ступенем деталізації. Наприклад, для кожного транспортного засобу у потоці зміни смуги руху ретельно описуються через

докладний ланцюг рішень водіїв. Подібно до інших мікроскопічних імітаційних моделей, субмікроскопічні імітаційні моделі враховують характеристики окремих транспортних засобів у потоці. Проте, окрім детального опису поведінки водіння, вони також ретельно моделюють поведінку керування транспортним засобом відповідно до навколишніх умов. Це включає у себе функціонування конкретних елементів (вузлів) автомобіля.

Мезоскопічна модель фокусується на поведінці людей, відмовляючись від відслідковування окремих транспортних засобів. У цьому підході трафік розглядається як групи об'єктів та їх взаємодії на низькому рівні деталізації. Наприклад, маневр зі зміни смуги руху для окремого транспортного засобу розглядається як миттєва подія, що базується на факторах, таких як відносна щільність смуг руху і різниця в швидкості.

Макроскопічні моделі транспортних потоків розглядають рух на рівні агрегації, уявляючи його як єдиний потік, не розглядаючи окремих складових частин. Наприклад, вони використовують агреговані характеристики, такі як швидкість потоку, щільність та загальна швидкість, для представлення загальної карти трафіку. Деталі маневрів окремих транспортних засобів, таких як зміна смуги руху, зазвичай не враховуються. Макроскопічна модель може припускати, що транспортний потік рівномірно розподіляється по смугах проїжджої частини, використовуючи для цього апроксимацію. Класифікація макроскопічних моделей течії може базуватися на кількості диференціальних рівнянь у приватних похідних, які часто є основою таких моделей. Модель може бути безперервною, описуючи зміни стану системи безперервно від часу відповідно до безперервних дій, або дискретною, припускаючи, що зміни стану відбуваються уривчасто в дискретні моменти часу. Поза часом інші незалежні змінні можуть бути описані як безперервні або дискретні (наприклад, положення, швидкість, бажана швидкість) [11].

Макроскопічні моделі транспортних потоків описують рух як єдиний потік без розгляду окремих транспортних засобів. Наприклад, вони

використовують загальні параметри, такі як швидкість потоку, щільність та загальна швидкість, для агрегованого вигляду на трафік. Окремі маневри транспортних засобів, такі як зміна смуги руху, зазвичай не враховуються. Макроскопічна модель може припускати, що транспортний потік рівномірно розподіляється по смугах проїжджої частини, використовуючи для цього апроксимацію. Класифікація макроскопічних моделей течії може базуватися на кількості диференціальних рівнянь у приватних похідних, що зазвичай визначають структуру моделі. Модель може бути безперервною, що описує зміни стану системи неперервно від часу відповідно до безперервних дій, або дискретною, припускаючи, що зміни відбуваються лише в дискретні моменти часу. Поза часом інші незалежні змінні можуть бути виражені як безперервні чи дискретні (наприклад, положення, швидкість, бажана швидкість).

Щодо критерію операціоналізації, моделі можуть бути використані як аналітичні рішення систем рівнянь або як імітаційні моделі.

Масштаб застосування визначає область застосування моделі, яка може включати динаміку об'єктів на конкретній ділянці дороги, усій транспортній мережі, коридорі, місті тощо.

З точки зору використання моделей, мікроскопічні моделі ідеально підходять для автономного моделювання, такого як перевірка геометрії проїжджої частини. В той час як для модельних оцінок, прогнозів та управління транспортним потоком відсутність закритого аналітичного рішення представляє виклик, що важко вирішити.

Макроскопічні моделі, придатні для великомасштабних мережевих застосувань, ставлять за мету дослідження макроскопічних характеристик потоку. Хоча калібрування їх вважається простішим (порівняно з мікроскопічними та мезоскопічними моделями), вони зазвичай занадто узагальнені, щоб адекватно враховувати мікроскопічні деталі та події, такі як зміни геометрії проїжджої частини. Проте, завдяки закритим аналітичним рішенням, вони ефективно використовуються для оцінки, прогнозування та управління транспортним потоком [11].

### 3.3 Прогнозування заторів

Процес прогнозування транспортних заторів включає два ключових етапи: збір даних і розробку прогнозної моделі. Кожен крок в цій методології має важливе значення і може впливати на результати, якщо виконаний неправильно. Загальні компоненти дослідження прогнозування заторів представлено на рисунку 3.1.

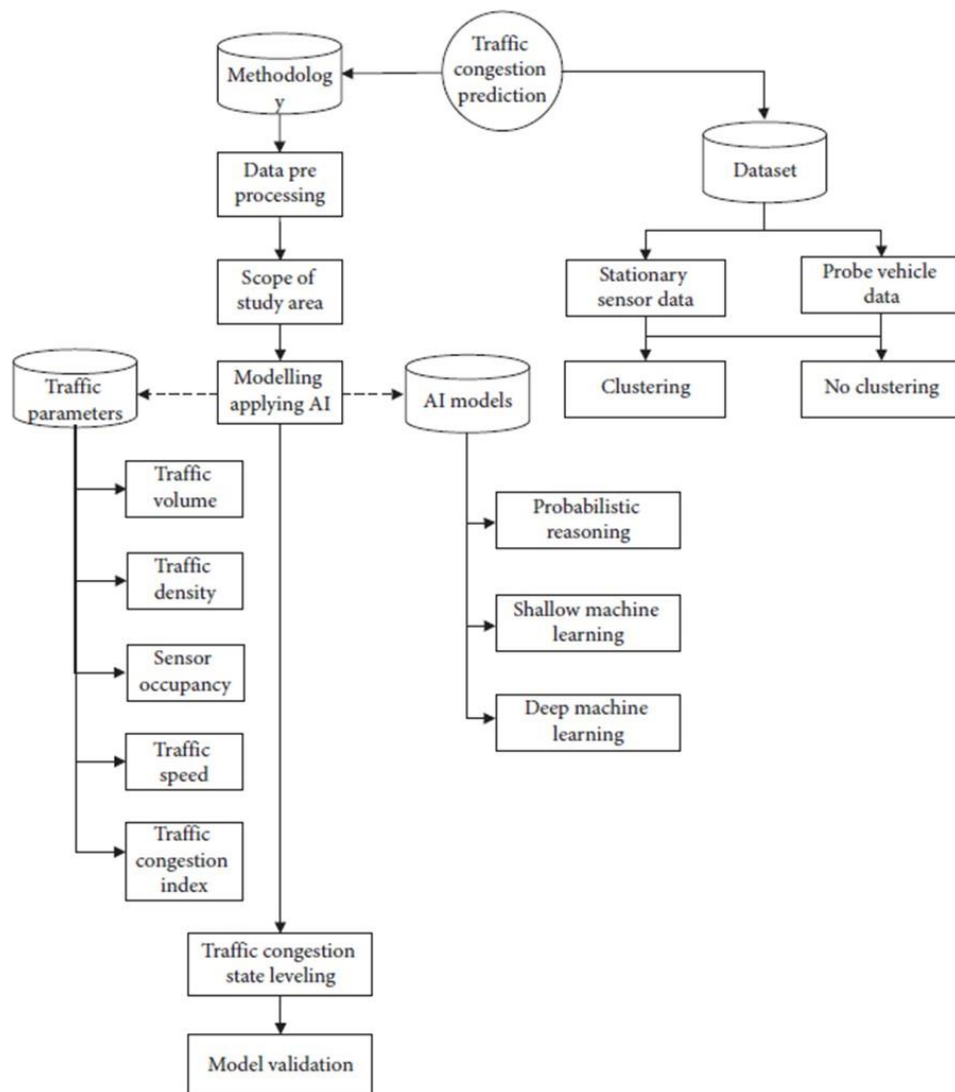


Рисунок 3.1 – Загальна система прогнозування заторів [12]

Після проведення процесу збору даних, обробка даних виявляється ключовою на етапі підготовки наборів даних для подальшого використання в навчальних і тестових задачах. Характер обробки даних може значно

відрізнитися в залежності від конкретного дослідження. Після створення моделі, її ефективність перевіряється за допомогою порівняння з іншими базовими моделями, а також аргументованими аналізами її реальних результатів [13].

### 3.4 Прогнозування трафіку

Прогнозування трафіку – це передбачення обсягу та щільності транспортного потоку з метою ефективного управління рухом транспортних засобів, зменшення заторів та визначення оптимальних маршрутів з найменшими витратами часу чи енергії.

Це важливо для двох ключових категорій організацій, відзначаючи важливість прогнозування, навіть не враховуючи поїздки на вихідні:

Національні або місцеві органи влади. У останні десять-двадцять років багато міст впроваджували інтелектуальні транспортні системи (ІТС) для планування міської транспортної мережі та керування дорожнім рухом. Ці системи використовують актуальні дані та прогнози для підвищення ефективності та безпеки транспорту, а також для інформування користувачів про поточні дорожні умови та корекції інфраструктури, такої як вуличне освітлення [11].

Логістичні компанії. У логістичній галузі точні прогнози дорожніх умов та руху необхідні для точного планування операцій та розробки оптимальних маршрутів. Це має вирішальне значення для ефективності та успішної роботи цих компаній.

Рисунок 3.2 відображає різноманітні напрямки використання прогнозування транспортних потоків.

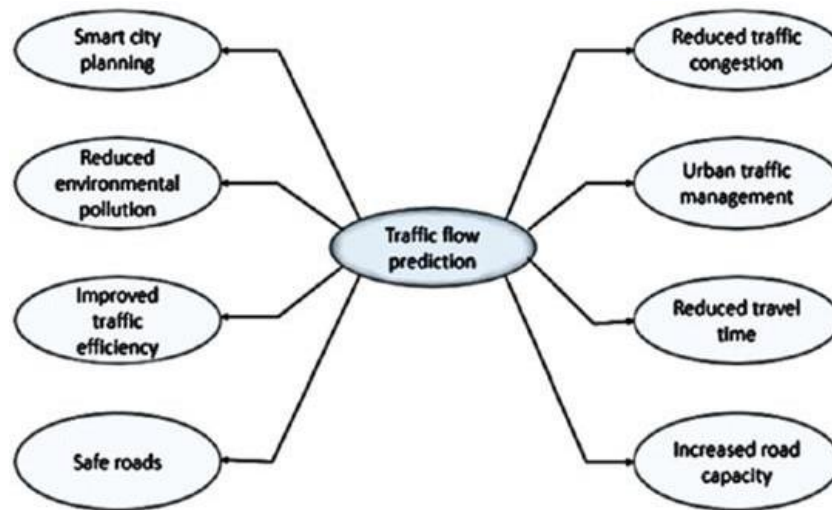


Рисунок 3.2 – Переваги системи передбачення транспортних потоків [11]

### 3.5 Системи обробки транспортних потоків

#### 3.5.1 Методологія машинного навчання

Машинне навчання (МН) дозволяє розробляти прогностичні моделі, що опрацьовують обширні обсяги різноманітних даних із різних джерел. Методологія машинного навчання охоплює весь цикл розробки та впровадження моделей машинного навчання, включаючи кілька ключових етапів.

Перший етап – визначення завдання та збір даних. На першому етапі необхідно чітко визначити завдання, яке ми хочемо вирішити, і зібрати необхідні дані. Це включає в себе розуміння бізнес-проблеми, формулювання цілей та визначення обмежень проекту. Здебільшого це етап експлораторного аналізу, де важливо збирати релевантні дані та чистити їх для подальшого використання.

Другий етап включає в себе вибір моделей. Після збору даних виникає завдання вибору найважливіших ознак та підготовки їх для моделювання. Цей етап включає в себе відсіювання аномалій, заповнення пропущених значень, шкалювання даних та інші операції, які забезпечують правильне функціонування моделей [14].

Третій етап – вибір та навчання моделей. Після підготовки даних обираються моделі, які найкраще відповідають поставленій задачі. Це може бути широкий спектр від класичних алгоритмів машинного навчання до глибоких нейронних мереж. Моделі навчаються на тренувальних даних, і їхні параметри налаштовуються для максимізації точності.

Четвертий етап – тестування та оцінка. Отримані моделі тестуються на нових даних для оцінки їхньої точності та загальної ефективності. Важливо враховувати різні метрики, такі як точність, чутливість, специфічність та інші, залежно від конкретного випадку використання.

Останній етап – впровадження та моніторинг. Останній етап включає в себе впровадження моделей в реальне середовище. Це може включати в себе створення API для взаємодії з моделлю, інтеграцію з існуючими системами та моніторинг їхньої продуктивності. Також може виникнути необхідність періодичної оптимізації моделей відповідно до змін у вихідних даних або умовах роботи [15].

На рисунку 3.3 зображено дерево алгоритмів машинного навчання.



Рисунок 3.3 – Дерево алгоритмів машинного навчання

### 3.5.2 Алгоритми кластеризації

Алгоритми кластеризації – це методи, що групують схожі об'єкти в кластери або групи на основі певних критеріїв чи властивостей. Ці алгоритми використовуються в різних галузях, таких як аналіз даних, машинне навчання, обробка зображень та інші. Вони спрощують аналіз великих обсягів даних, допомагаючи виявляти приховані закономірності та групувати подібні об'єкти. Деякі з популярних алгоритмів кластеризації включають:

- к-середніх (K-Means). Розділяє дані на K кластерів, де кожен кластер представлений своїм центром (середнім значенням);
- ієрархічна кластеризація. Побудова ієрархії кластерів, де кожен об'єкт починає як окремий кластер, а потім об'єднується чи розщеплюється до досягнення певного критерію;
- DBSCAN (Density-Based Spatial Clustering of Applications with Noise). Орієнтований на області, які мають високу щільність, розділяє об'єкти на кластери в залежності від щільності даних;
- агломеративна кластеризація. Розглядає кожен об'єкт як окремий кластер і поступово об'єднує близькі кластери до досягнення потрібного числа кластерів;
- гібридні алгоритми. Використовують комбінації різних методів кластеризації для покращення ефективності.

Ці алгоритми забезпечують можливість виявлення структури в неупорядкованих даних, розподілених за певним чином. Вибір конкретного алгоритму залежить від характеристик даних та вимог конкретної задачі [16].

### 3.5.3 Метод статистичного аналізу

Методи статистичного аналізу дозволяють виявляти закономірності трафіку на різних часових шкалах, таких як протягом дня, різні дні тижня, або сезонні коливання. Проте ці методи, в силу своєї обмеженої точності, менше ефективні у роботі з великою кількістю багатовимірних даних.

Зокрема, моделі авторегресійного інтегрованого ковзного середнього

(ARIMA) активно використовуються для прогнозування трафіку з 1970-х років. Ці моделі, які є класичним статистичним підходом, відзначаються простотою в реалізації та демонструють високу точність порівняно з іншими статистичними методами. ARIMA спостерігає за даними, зібраними з регулярних інтервалів часу, припускаючи, що минулі залежності повторяться у майбутньому.

Тим не менше, транспортний потік представляє собою складну структуру з численними змінними, які не можуть ефективно оброблятися одномірними моделями ARIMA [16].

#### 3.5.4 Підхід до глибокого навчання

Методи глибокого навчання виявили вражаючу ефективність в прогнозуванні дорожнього руху, набагато перевершуючи методи машинного навчання та статистичні підходи, і постійно досягаючи точності близько 90% та вище. В основі цих алгоритмів лежать нейронні мережі.

Нейронні мережі, або штучні нейронні мережі (ANN) складаються з взаємопов'язаних вузлів (нейронів), розташованих у два або більше шарів і здатних до функціонування аналогічно до людського мозку. Різноманіття типів нейронних мереж дозволяє їм вирішувати різні завдання. Зокрема, згорткові нейронні мережі виявилися надзвичайно ефективними в розпізнаванні та аналізі зображень, і можуть успішно застосовуватися, наприклад, для виявлення пробок на дорогах за допомогою відеозаписів з камер спостереження. Середня точність класифікації в таких випадках досягає 89,5% [17].

У зв'язку з прогнозуванням трафіку, використання рекурентних нейронних мереж (RNN) виявилось особливо вдалим, оскільки ці моделі спеціально розроблені для обробки даних, що представляють собою тимчасові ряди або спостереження, зібрані визначеними інтервалами часу. Наприклад, в контексті моделей дорожнього руху це може включати в себе аналіз динаміки руху на дорогах протягом конкретного періоду часу.

Під час застосування рекурентних нейронних мереж виявлено високі показники точності у прогнозуванні розвитку навантажень. Проте, слабкістю RNN є проблема градієнта, яка впливає на ефективність моделі через втрату інформації з попередніх шарів, призводячи до їх "короткочасної пам'яті".

Для вирішення цієї проблеми широко використовують розширені варіанти RNN, такі як довготривала короткочасна пам'ять (LSTM) та вентилярована рекурентна одиниця (GRU). Ці моделі спеціально спроектовані для подолання проблеми градієнта, забезпечуючи більш точний прогноз транспортних потоків та полегшуючи процес їх навчання. Відповідне дерево моделей можна спостерігати на рисунку 3.4 [17].

Нині ведеться багато досліджень, де висувається ідея використання різних видів нейронних мереж для прогнозування трафіку, таких як графові нейронні мережі, нечіткі нейронні мережі, байєсівські нейронні мережі та інші. Також експериментують із гібридними підходами, які комбінують два чи більше алгоритмів. Але на сьогодні немає загальноприйнятого методу, який був би ефективним у всіх випадках і забезпечував найточніші передбачення.

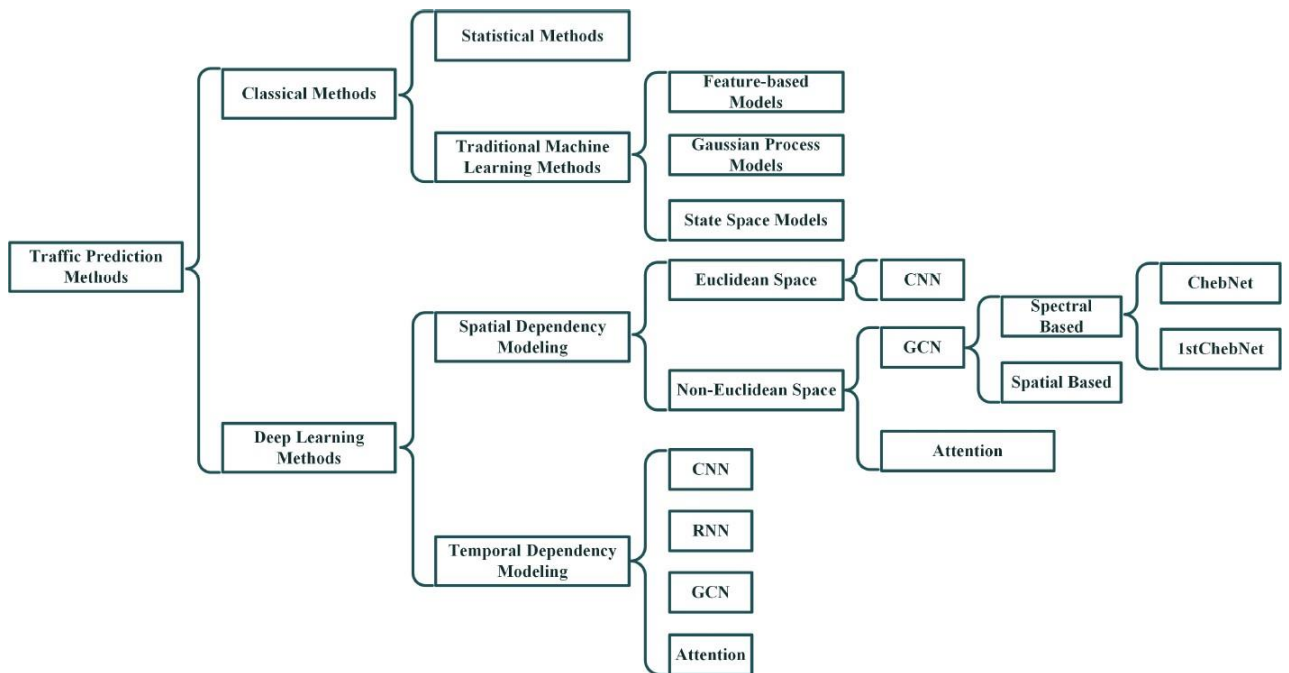


Рисунок 3.4 – Основні методи прогнозування транспортних потоків [17]

### 3.5.6 Застосування методів нелінійного аналізу та прогнозування трафіку

У контексті прогнозування транспортних заторів, значною мірою важливість прогностичних моделей обумовлюється наявністю надійно зібраних даних, таких як дані про швидкість руху, погоду, інформація про події та аварії. Традиційні підходи, які часто використовують параметричні методи, такі як модель ARIMA, недостатньо ефективні у зазначених умовах через стохастичний та нелінійний характер транспортного потоку [18].

Зокрема, моделі ARIMA, хоч і є широко визнаними в короткостроковому прогнозуванні транспортних потоків, не завжди відповідають вимогам у зв'язку зі змінною та непередбачуваною природою транспортного руху. У результаті пошуку більш ефективних підходів, деякі дослідники віддають перевагу непараметричним моделям, і саме тут нейронні мережі стають цікавим інструментом для прогнозування транспортних потоків [19].

Наприклад, неглибокі нейронні мережі зворотного поширення (BPNN) демонстрували перспективні результати, але їхні обмеження виявились докладніше при аналізі великого обсягу даних. Таким чином, з'явлення глибокого навчання, яке використовує багаторівневі структури для ефективного виявлення ознак великого обсягу необроблених даних, виявилось обіцяючим рішенням [20-21].

Глибоке навчання, яке включає різні архітектури, такі як CNN, RNN, LSTM, RBM, DBN та SAE, призначене для розв'язання проблеми нелінійності транспортних потоків. Наприклад, CNN ефективно адаптується до просторових залежностей трафіку, тоді як RNN, і особливо архітектура LSTM, успішно враховує довгострокові та короткострокові тимчасові залежності [22].

Незважаючи на обіцяючі результати глибокого навчання, такі моделі також мають свої обмеження. Для їх ефективного навчання вимагається значна кількість історичних даних, і це може призвести до перепідгонки

моделі при різких змінах транспортного потоку на невеликому часовому інтервалі.

Останнім часом вчені виявляють інтерес до гібридних та неконтрольованих підходів, оскільки вони можуть стати більш ефективними в умовах невизначеності та відсутності повних даних. Огляди моделей, зокрема заснованих на машинному навчанні та статистичних підходах, акцентують увагу на перспективах прогнозування транспортних потоків та дорожнього руху [22].

### 3.5.7 WNN (хвильова нейронна мережа)

Хвильова нейронна мережа (WNN) представляє собою клас нейронних мереж, який використовує хвильові функції як активаційні функції для передачі сигналів через мережу. Цей тип мережі взятий із концепції хвильового аналізу та оптимізований для вирішення задач обробки сигналів та прогнозування часових рядів.

Хвильові функції, такі як вейвлет-функції, є ключовим елементом в хвильових нейронних мережах. Вони дозволяють мережі ефективно адаптуватися до різних частотних компонент сигналів, що робить WNN особливо ефективними для аналізу та розпізнавання широкого спектру сигналів, таких як зображення, аудіо чи часові ряди.

Однією з переваг хвильових нейронних мереж є їхній високий рівень адаптивності до змін у вхідних сигналах та здатність ефективно виявляти складні взаємозв'язки у даних. Ці мережі знайшли застосування у багатьох областях, включаючи обробку сигналів, медичні дослідження, фінансовий аналіз та прогнозування.

Існує декілька варіацій хвильових нейронних мереж, які можуть використовувати різні типи хвильових функцій залежно від конкретних завдань та характеристик даних. Використання хвильових функцій дозволяє WNN ефективно моделювати та аналізувати структуру сигналів у вхідних даних [14].

### 3.5.8 DNN (глибока нейронна мережа)

Глибокі нейронні мережі (DNN) представляють собою потужні моделі машинного навчання, які використовуються для розв'язання складних завдань в різних областях, таких як обробка зображень, розпізнавання мови, аналіз тексту, генерація контенту, рекомендації та багато інших.

Основні характеристики глибоких нейронних мереж включають у себе:

- багатошарова структура. DNN складається з багатошарової архітектури, яка включає в себе вхідний шар, приховані шари та вихідний шар. Кожен шар містить набір штучних нейронів, інтерпретуючи вхід та передаючи його далі для вирішення задачі;

- зворотне поширення (Backpropagation). Для навчання глибоких нейронних мереж використовується алгоритм зворотного поширення. Цей метод оновлює ваги мережі, зменшуючи помилку між прогнозованими та фактичними результатами;

- функції активації. Глибокі нейронні мережі використовують нелінійні функції активації, такі як ReLU (Rectified Linear Unit) або сигмоїдальні функції, для надання моделі здатності виявляти та вивчати складні нелінійні залежності в даних;

- автоматичне вивчення ознак. Однією з ключових переваг DNN є їхня здатність автоматичного вивчення корисних ознак з вхідних даних. Мережа може вирізняти різні рівні абстракції, розпізнаючи важливі особливості від сирих вхідних даних;

- великі обсяги даних. Глибокі нейронні мережі зазвичай потребують великі обсяги даних для навчання, але вони показують вражаючі результати, коли їх використовують у великих і виразних наборах даних [23].

Глибокі нейронні мережі зараз є однією з основних технологій у сфері штучного інтелекту та машинного навчання. Вони використовуються для вирішення завдань, які раніше вважались вкрай складними, і надають вражаючі результати у багатьох областях, реалізуючи значні технологічні прориви [14].

### 3.5.9 CNN (згорткова нейронна мережа)

Згорткові нейронні мережі (CNN) представляють собою потужний клас алгоритмів глибокого навчання, спеціально розроблених для аналізу та обробки великих обсягів візуальних даних, таких як зображення та відео. Вони виявилися особливо ефективними у завданнях розпізнавання образів, сегментації зображень, визначення об'єктів та інших схожих задач.

Основні характеристики згорткових нейронних мереж включають у себе:

- згорткові шари (Convolutional Layers). Основна ідея полягає в тому, щоб використовувати фільтри, які скользять (згортаються) по вхідних даних, виконуючи операції згортки. Це дозволяє моделі автоматично вивчати просторові особливості, такі як краї та текстури;

- шари об'єднання (Pooling Layers). Після кожного згорткового шару зазвичай слідує шар об'єднання, який служить для зменшення розмірності отриманих карт ознак, а також для виділення найважливіших особливостей;

- активаційні функції. Згорткові нейронні мережі використовують нелінійні активаційні функції, такі як ReLU (Rectified Linear Unit), для внесення нелінійності та здатності моделі виявляти складні залежності;

- повні зв'язки (Fully Connected Layers). Зазвичай в кінці архітектури згорткової нейронної мережі розмірність зменшується, і вона піддається обробці повністю зв'язаним шарам для остаточного прийняття рішення.

Згорткові нейронні мережі демонструють вражаючу здатність до автоматичного вивчення ієрархічних та локальних особливостей вхідних даних. Їх застосовують у широкому спектрі областей, включаючи комп'ютерне зору, обробку природної мови та аналіз даних, де важливо враховувати просторові взаємозв'язки та локальні особливості [14].

### 3.5.10 SAE (автоенкодера)

Сховані автоенкодери (Stacked Autoencoder – SAE) представляють собою клас глибоких нейронних мереж, спроектованих для вирішення

завдань зменшення розмірності та виділення ключових ознак з вхідних даних. Цей тип автоенкодера є частиною сімейства, яке включає штучні нейронні мережі і спрямоване на оптимізацію представлення даних шляхом їх зменшення через кодування та подальше декодування.

Основні риси SAE:

- багат шарова структура. SAE складається з набору з'єднаних послідовних автоенкодерів, кожен з яких є окремим шаром. Кількість шарів може змінюватися відповідно до завдання та складності даних;

- пошарове навчання: SAE навчається пошарово, розпочинаючи з найнижчого шару. Кожен автоенкодер, або шар, використовується для зменшення розмірності даних та виділення важливих ознак;

- завдання енкодування та декодування. Кожен автоенкодер має дві основні фази – енкодування та декодування. Енкодер призначений для перетворення вхідних даних в меншу розмірність (код), а декодер відновлює вихідні дані з цього коду;

- зменшення розмірності та виділення ознак. Основна мета SAE - зменшення розмірності даних, при цьому зберігаючи корисну інформацію. Це призводить до отримання нового представлення даних, яке містить в собі ключові ознаки та забезпечує високу репрезентативність;

- переваги глибокого представлення. Комбінація кількох автоенкодерів у SAE дозволяє отримати глибокі представлення даних, які можуть бути використані для подальших завдань машинного навчання чи аналізу.

SAE знаходять застосування в різних областях, таких як обробка зображень, розпізнавання обличь, рекомендаційні системи та інші, де важливо отримати компактне та високоякісне представлення великих обсягів даних, забезпечуючи ефективність та точність [14].

На рисунку 3.5 зображено базову архітектуру енкодера.




Рисунок 3.5 – Приклад архітектури енкодера [14]

### 3.5.11 RNN (рекурентні нейронні мережі)

Рекурентні нейронні мережі (RNN) є класом штучних нейронних мереж, розроблених для обробки послідовних даних та врахування контексту часу. Вони виявили велику ефективність у задачах, пов'язаних з обробкою текстів, прогнозуванням часових рядів та іншими доменами, де важливий часовий контекст. Основною особливістю RNN є їхня здатність до збереження попередньої інформації та використання її при обробці нових вхідних даних, що робить їх ефективними для моделювання послідовних залежностей у вхідних даних. Також існують розширені варіанти RNN, такі як довготривала короткочасна пам'ять (LSTM) та вентилярована рекурентна одиниця (GRU), які вирішують проблему градієнтного зникнення та покращують здатність моделі зберігати та використовувати довгострокові залежності в даних [14].

### 3.5.12 Гібридні мережі

Гібридні нейронні мережі – це моделі, які комбінують різні архітектури та підходи з метою покращення ефективності та універсальності у вирішенні конкретних завдань. Ці мережі об'єднують у собі переваги різних типів нейронних мереж для отримання кращих результатів в конкретних сценаріях.

Наприклад, можливий гібрид – поєднання CNN та RNN. Такий підхід може бути корисним для обробки послідовних даних, таких як відеопотік, де CNN визначає просторові особливості кадра, а RNN враховує часові залежності між кадрами.

Ще однією формою гібридних мереж є поєднання глибокого навчання з класичними методами машинного навчання, такими як методи оптимізації чи статистичні підходи. Це може забезпечити компроміс між точністю та обчислювальною ефективністю [23].

Гібридні нейронні мережі можуть також включати компоненти, які не є нейронними, наприклад, базовані на правилах системи. Це може покращити здатність моделі адаптуватися до конкретних умов та доповнювати недоліки, які можуть бути притаманні чистим нейронним мережам.

Застосування гібридних мереж може бути особливо ефективним у випадках, коли одна типова архітектура мережі не вирішує всіх аспектів складного завдання. Гібриди нейронних мереж дозволяють інтегрувати різноманітні підходи та досягати кращих результатів у різноманітних вирішеннях [14].

### 3.6 Порівняння моделей розглянутих нейромереж

#### 3.6.1 Штучна нейронна мережа (ANN)

Переваги:

- здатність до навчання на основі даних;
- адаптивність до складних завдань;
- здатність до паралельної обробки;
- універсальність у застосуванні;
- автоматизація функцій.

Недоліки:

- потреба у великій кількості даних;
- чорна скринька;
- схильність до перенавчання;
- вимоги до обчислювальних ресурсів;
- питання етики та прозорості;
- залежність від початкового навчання.

### 3.6.2 Хвильова нейронна мережа (WNN)

#### Переваги:

- висока швидкість навчання;
- відмінна здатність до роботи з часовими рядами;
- ефективність у роботі з нечіткими та непевними даними;
- висока стійкість до шуму в даних;
- здатність враховувати нелінійні зв'язки.

#### Недоліки:

- обмежена у вирішенні завдань, що вимагають точності;
- велика витратність з питань обчислювальних ресурсів;
- складність в налаштуванні параметрів;
- залежність від якості вхідних даних;
- важкість інтерпретації результатів.

### 3.6.3 Рекурентні нейронні мережі (RNN)

#### Переваги:

- здатність працювати з послідовностями даних та розпізнавати шаблони в часових рядах;
- ефективність у вирішенні завдань, пов'язаних із зв'язками в часі, таких як мовний аналіз та прогнозування часових рядів;
- здатність враховувати попередні контексти та залежності, що робить їх ефективними для аналізу послідовностей даних;
- використовуються в обробці природної мови, генерації тексту та інших завдань, пов'язаних із послідовностями.

#### Недоліки:

- проблема зникаючого градієнта: у складних моделях RNN може виникати проблема втрати інформації про контекст через тривалі послідовності;

- обмежена здатність запам'ятовувати довгострокові залежності через проблему зникання градієнта;
- висока витратність обчислювальних ресурсів та обмежена паралельність в навчанні;
- важкість в налаштуванні та підтримці моделей на різних типах задач;
- залежність від якості та обсягу вхідних даних.

#### 3.6.4 Сховані автоенкодери (SAE)

Переваги:

- зменшення розмірності та вилучення ознак;
- глибоке представлення;
- ефективне узагальнення та перенавчання;
- пошарове навчання.

Недоліки:

- зменшення розмірності та вилучення ознак;
- глибоке представлення;
- ефективне узагальнення та перенавчання;
- пошарове навчання.

#### 3.6.5 Гібридні мережі

Переваги:

- комбінація сильних сторін різних моделей;
- універсальність та гнучкість;
- покращена точність прогнозувань;
- ефективність у вирішенні складних завдань.

Недоліки:

- складність розробки та впровадження;
- великі витрати обчислювальних ресурсів;

- підвищена ймовірність перенавчання;
- необхідність оптимізації вагових коефіцієнтів.

### 3.7 Висновки до розділу

У цьому розділі ми коротко оглянули основні стратегії аналізу даних, які є важливими для розробки інтелектуальної транспортної системи. Ми провели систематизацію різних досліджень у галузі використання нелінійних методів аналізу, які базуються на нейронних мережах, з метою їх використання як інструменту для передбачення транспортних потоків [11].

Щодо створення моделі керування транспортним потоком, було запропоновано наступне.

Використання різноманітних методів нелінійного аналізу, включаючи LSTM, DQN, RF, SVR та інші, враховуючи динамічну природу транспортної системи та її різноманітні стани, надає можливості для включення методів машинного навчання в програмування та динамічну адаптацію світлофора система. У цьому сценарії пропонується використовувати алгоритм Q-навчання та мережу DQN. Для аналізу трафіку та моделювання потоку трафіку рекомендується використовувати алгоритми LSTM, RF і SVR, а також досліджувати інші потенційні моделі, що охоплюють гібридні та теоретичні конструкції. Використання модуля для аналізу та прогнозування трафіку за допомогою методів машинного навчання для вивчення основних моделей руху, визначення дорожніх обмежень і планування маршрутів на основі динамічної перспективи маршруту дає змогу використовувати цей аналіз для стратегічного планування руху та ефективного перенаправлення руху [13].

## 4 РЕАЛІЗАЦІЯ МЕТОДУ КЕРУВАННЯ ПОТОКОМ АВТОТРАНСПОРТУ З ВИКОРИСТАННЯМ НЕЙРОМЕРЕЖІ

### 4.1 Опис запропонованого підходу до керування транспортним потоком

Запропонований підхід охоплює комплексну систему, що ґрунтується на наукових дослідженнях в області оптимального управління світлофорами, передбачення заторів, керування рухом на перехрестях, інтелектуальних систем розрахунку маршрутів, систем розподілу потоків та аналізу альтернативних архітектур для генерації та планування руху на маршрутах за допомогою графів [24].

Для обчислення та демонстрації результатів використовується система моделювання SUMO.

Загалом архітектура проекту використовує реальні дані про транспортні потоки. Однак через відсутність таких даних у відкритому доступі, пропонується використовувати дані симуляції дорожнього руху з певними налаштуваннями.

Реалізація управління дорожнім рухом включає такі модулі:

- керування світлофорами за допомогою алгоритмів машинного навчання;
- збір даних про трафік за допомогою вимірювань, датчиків та відео;
- моделювання та генерація прогнозів трафіку за допомогою нейронних мереж з урахуванням обмежуючих факторів (погода, ремонтні роботи, аварії, великі події тощо);
- сповіщення в реальному часі про альтернативні маршрути з урахуванням GPS-позиції транспортного засобу, з використанням традиційних алгоритмів розрахунку маршрутів (Дейкстри, A\*, Максимального потоку тощо);
- проектування альтернативних потоків на основі історичного аналізу попиту з використанням алгоритму Maximum Flow, з урахуванням заторів та

пропускної здатності на конкретних лініях, використовуючи нейронні мережі та симуляцію трафіку альтернативних напрямків руху [25].

На рисунку 4.1 наведено приблизну архітектуру системи, де окремі компоненти реалізуються за допомогою програмних модулів.

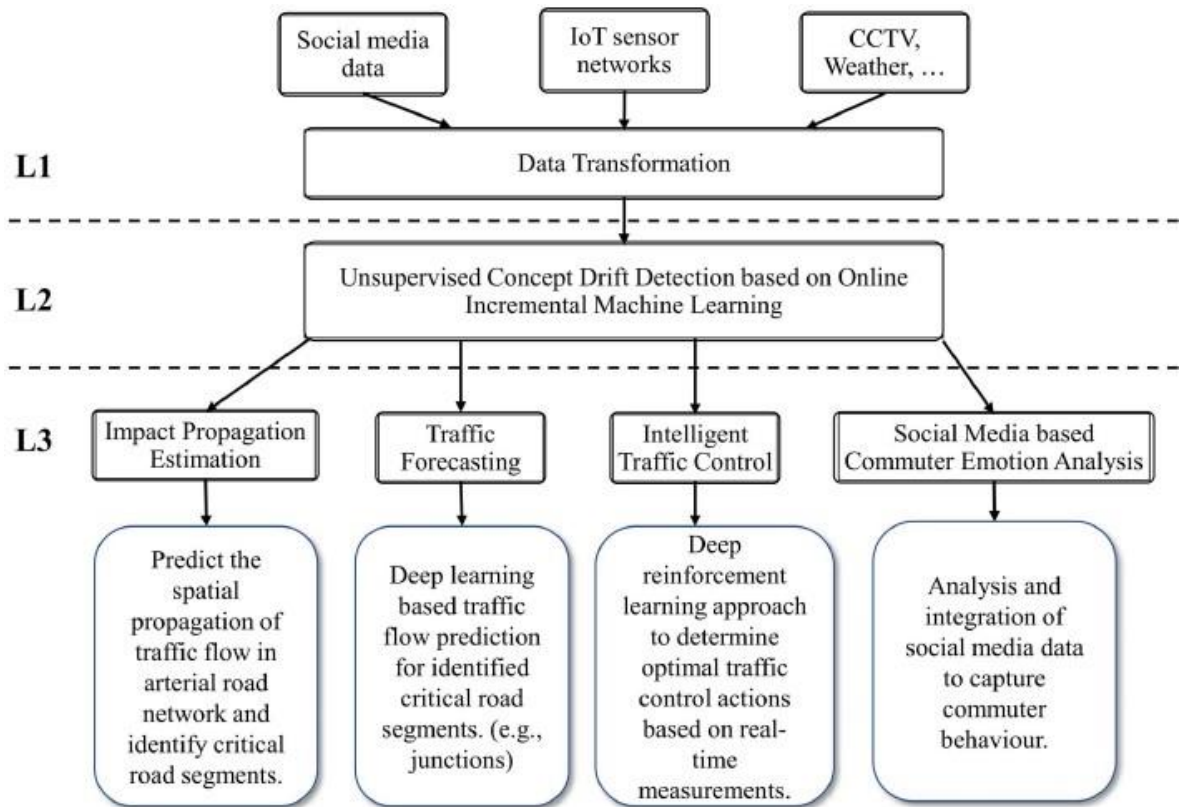


Рисунок 4.1 – Структура інтелектуальної транспортної системи [21]

Після вивчення різних наборів послуг, що надаються архітектурами ARC-IT, FRAME та ISO, було вибрано кілька компонентів для побудови відповідної архітектури для ІТС. В рамках архітектури ARC-IT область управління трафіком була визначена як найбільш придатна для ІТС. Під час огляду послуг, доступних у цьому домені, наголос був зроблений на послуги моніторингу дорожніх сигналів та послуги вимірювання трафіку. Це надзвичайно важливо, оскільки система повинна вимірювати транспортний потік на перехрестях, щоб оптимізувати час сигналів світлофора, таким чином скорочуючи час очікування транспортних засобів. Рисунок 4.2 ілюструє схематичне зображення у форматі ARC-IT [17].

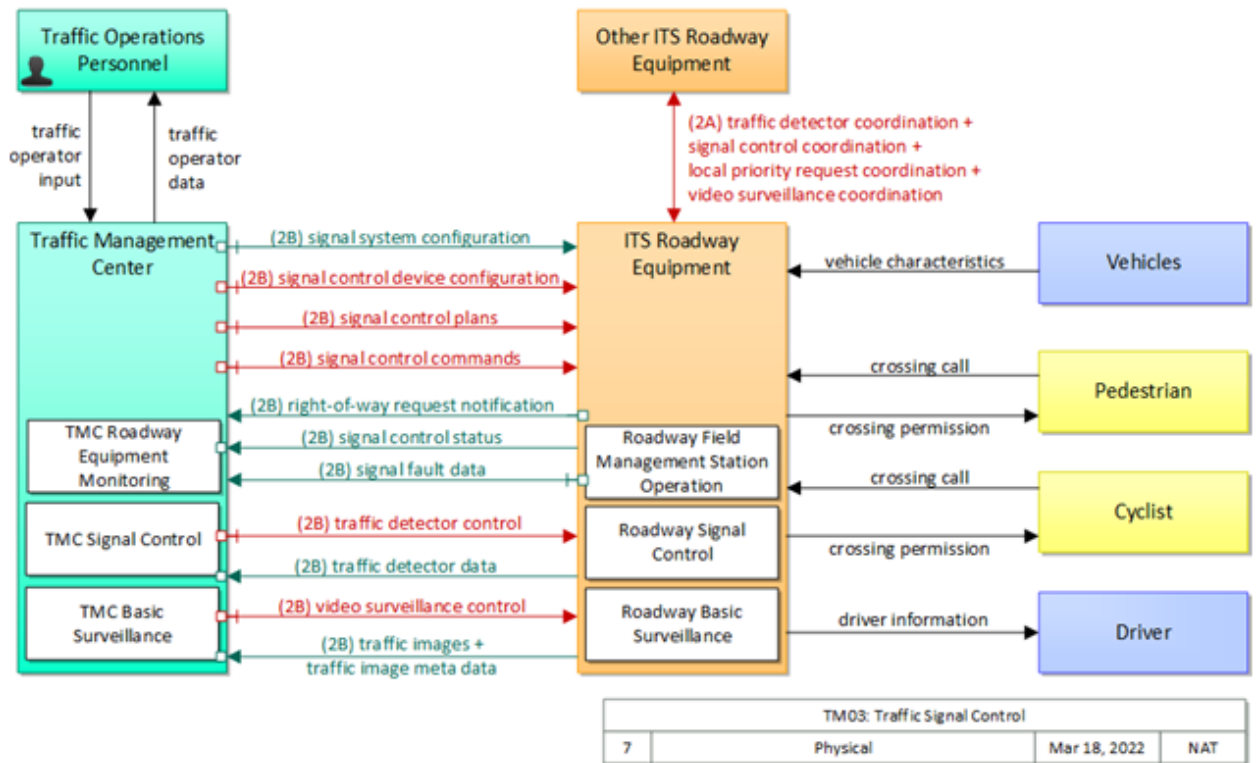


Рисунок 4.2 – Архітектура у форматі ARC-IT [17]

Функціональний блок під назвою "Відеоспостереження", відповідає за захоплення та передачу відеосигналів з різних напрямків конкретного перехрестя до центру управління транспортною системою (ТМС). Цей функціонал надає можливість візуалізувати рівень відеозавантаження для певного перехрестя на основі світлофорних сигналів [26].

Функціональний блок "Управління рухом" виконує конвертацію відеосигналів в дані, які використовуються для визначення довжини черги транспортних засобів у кожному напрямку перехрестя. Отримані дані також транслюються до центру управління транспортною системою (ТМС).

Функціональний блок, позначений як "Управління світлофорами", відповідає за програмування відповідних фаз світлофорних сигналів на конкретному перехресті [26].

Для кожного з пропонованих блоків використовується індивідуальний підхід, який враховує особливості їхньої роботи та вимоги до здатності швидко реагувати на зміну стану, зокрема, на завантаженість транспортних вузлів.

Модель управління транспортним потоком передбачає використання тестових або реальних даних транспортних потоків міста з подальшим аналізом цих даних за допомогою неймереж. Отримані результати використовуються як прогнозна модель завантаженості окремих маршрутів і є вхідними даними для розробки альтернативних маршрутів. Також ці дані слугують вхідними даними для системи управління світлофорами, включаючи їх часові налаштування. Ця інформація також використовується для системи контролю та попередження щодо швидкості на різних смугах руху [27].

Залежно від завантаженості автомагістралей фахівці центру дорожнього руху можуть встановлювати до восьми різних координаційних планів на одній ділянці, які відповідають ранковим, обіднім, вечірнім годинам пік і міжпіковим періодам. Ця система, відома як "Зелена хвиля", призначена для оптимізації руху транспорту та підвищення пропускної спроможності доріг міста на 20-25%. Отже, основний акцент робиться на системі управління світлофорами [14].

## 4.2 Впровадження методу контролю транспортних потоків через регулювання світлофорів

### 4.2.1 Використання місцевого агента (світлофора) для реалізації системи управління на основі визначення завантаженості перехрестя

Перший етап модульної системи управління транспортними потоками включає модуль, який використовує елементи (камери або датчики) для визначення завантаженості шляхів на перехрестях та автоматичного регулювання пріоритетів. На рисунку 4.3 наведено приклад моделювання Т-перехрестя.



Рисунок 4.3 – Приклад Т-перехрестя

Дана система отримує вхідні дані у вигляді зображень з дорожніх камер на транспортних розв'язках, або інших даних з датчиків. Ці дані використовуються для розрахунку інтенсивності руху в реальному часі за допомогою обробки зображень та виявлення об'єктів. Систему можна розділити на три модулі: виявлення транспортних засобів, алгоритм перемикання сигналів і модель моделювання. Зображення передаються в алгоритм виявлення транспортних засобів, який використовує YOLO – натреновану модель розпізнавання об'єктів. Визначається кількість транспортних засобів різних класів для розрахунку щільності руху. Алгоритм перемикання сигналів використовує цю щільність для встановлення таймера зеленого світла для кожної смуги руху, а час червоного світла оновлюється відповідно. Щоб уникнути блокування певної смуги руху, час зеленого світла обмежений максимальним і мінімальним значеннями. Розглядається можливість реалізації цього методу за допомогою систем, таких як Arduino, Raspberry Pi, або інших платформ, здатних до навчання, розпізнавання завантаженості шляхів і адаптації тривалості сигналів світлофору в реальному часі [28].

Зразок технічного впровадження системи визначення та керування з використанням мікрокомп'ютера, або мікрочіпів та датчиків описано далі.

Перша фаза. Отримання зображень кожної смуги в реальному часі.

Камера періодично передає зображення до системи.

Друга фаза. Сканування та визначення щільності трафіку. Система розпізнає кількість автомобілів на кожній смузі та обчислює відносну щільність порівняно з іншими смугами [29].

Третя фаза. Введення цих даних у модуль розподілу часу. Модуль отримує вхідні дані, такі як щільність трафіку, та визначає оптимальний та ефективний часовий інтервал.

Четверта фаза. Результатом є часові інтервали для кожної смуги відповідно. Мікропроцесор передає ці значення на відповідний світлофор.

Розумна система світлофорів, яка використовує дані від датчиків, комунікацію та автоматизовані алгоритми, розроблена для забезпечення більш плавного руху транспорту. Метою є оптимальне керування тривалістю зеленого світла для конкретного світлофора на перехресті. Сигнали світлофора залежать від кількості автомобілів та не постійно світять зеленим світлом; час зеленого світла залежить від інтенсивності руху. Система має два режими: базовий з фіксованою тривалістю (за умовчанням) та автоматична адаптація до завантаженості на основі навчання та розпізнавання об'єктів (з використанням YOLOv3). На рисунку 4.4 представлено аналіз ефективності розпізнавання об'єктів [18].

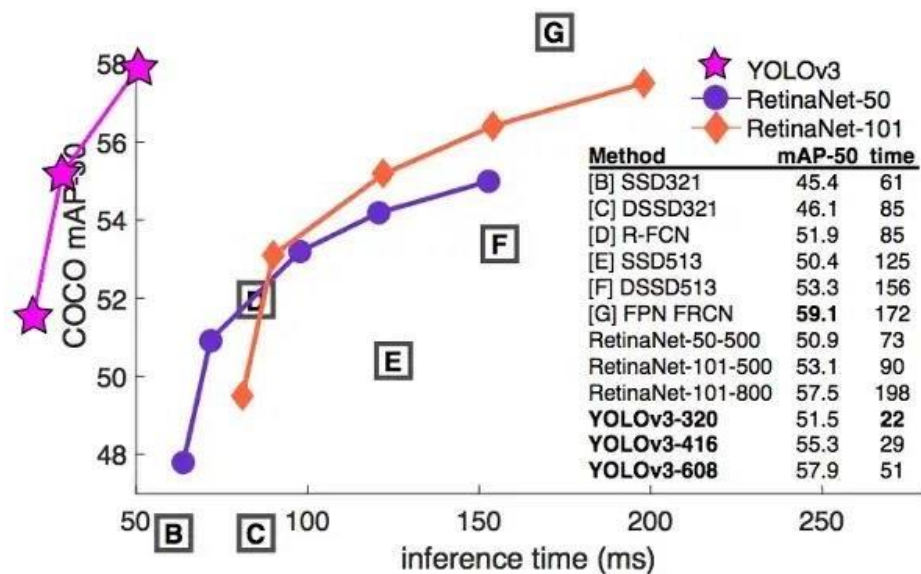


Рисунок 4.4 – Порівняльний графік ефективності

YOLOv3 досягає найкращого балансу між швидкістю та точністю на широкомасштабному наборі даних виявлення об'єктів MS COCO. Ця система виявлення об'єктів у реальному часі відрізняється від інших, таких як системи на основі регіонів із згортковими нейронними мережами (R-CNN), оскільки використовує лише одну нейронну мережу для аналізу всього зображення. Вона розділяє зображення на регіони, генеруючи рамки та ймовірності для кожного, що робить її в 100 разів швидшою за Fast R-CNN. Модель була навчена із використанням завантажених з веб-сайту YOLO попередньо підготовлених ваг. Конфігураційний файл .cfg для навчання було налаштовано відповідно до вимог моделі. Кількість вихідних нейронів на останньому шарі було встановлено рівним числу класів, які модель мала визначати, змінивши параметр 'classes'. У даній системі це становило 4 класи: автомобіль, велосипед, автобус/вантажівка та мотоцикл. Кількість фільтрів також змінювалася за формулою:

$$5*(5+\text{кількість класів}). \quad (4.1)$$

Цей метод простий у виконанні та ефективний, як надійне просте рішення на місцевому рівні. Проте він не враховує ситуацію на інших перехрестях.

4.2.2 Реалізація методу, заснованого на навчанні з підсиленням для керування світлофором.

Головною метою алгоритму навчання з підсиленням (RL) є зменшення очікування транспортних засобів на перехрестях, використовуючи винагороду у вигляді скорочення черги транспортних засобів у кожному з напрямків. Дії, здійснені агентом, породжують новий стан сигналів світлофора. На рисунку 4.5 наведено узагальнену схему процесу навчання за Q-алгоритмом [30].

## Deep Q-Network




Рисунок 4.5 – Процес навчання мережі в рамках моделі RL

Цей новий стан може призвести до збільшення, або зменшення кількості транспортних засобів у кожній черзі. Мета алгоритму полягає в зменшенні довжини усіх довгих черг з новим станом, тим самим отримуючи максимальну винагороду. У випадку, якщо цього не вдається досягти, отримана винагорода буде змінюватися відповідно до визначеної політики.

### 4.2.3 Використання DQN у програмі

Q-навчання – це алгоритм навчання з підкріпленням, який оцінює остаточну винагороду в кожному стані, замість досягнення кінцевого стану, що дозволяє використовувати його в середовищах без кінцевого стану. Цей процес навчання відбувається лише під час першого виконання алгоритму, адже під час кожного нового запуску Q-значення оновлюються, що дозволяє алгоритму постійно навчатися. Після завершення навчання агент вступає в етап регулювання дорожнього руху, де йому доводиться адаптуватися до змін у навколишньому середовищі та отримувати винагороди за виконані дії. Значення Q оновлюються згідно з наступним рівнянням:

$$Q^*(st, ac) \leftarrow (1-\alpha)Q(st, ac) + \alpha(rw + \max Q(\text{наступний стан, усі дії})), \quad (4.2)$$

де  $Q^*(st, ac)$  – нове Q-значення;  
 $Q(st, ac)$  – поточне Q-значення для пари стан-дія;  
 $\alpha$  ( $0 < \alpha \leq 1$ ) – швидкість навчання;  
 $rw$  – винагорода, отримана від навколишнього середовища;  
 $\gamma$  ( $0 \leq \gamma \leq 1$ ) – ставка дисконту, яка визначає, наскільки важливі майбутні винагороди.

Гіперпараметри в алгоритмах Q-навчання включають в себе параметр  $\alpha$  (альфа), що відповідає за швидкість навчання, та параметр  $\gamma$  (гама), який визначає ставку дисконту.

На рисунку 4.6 наведено блок-схему, яка розкриває принципи функціонування алгоритму.

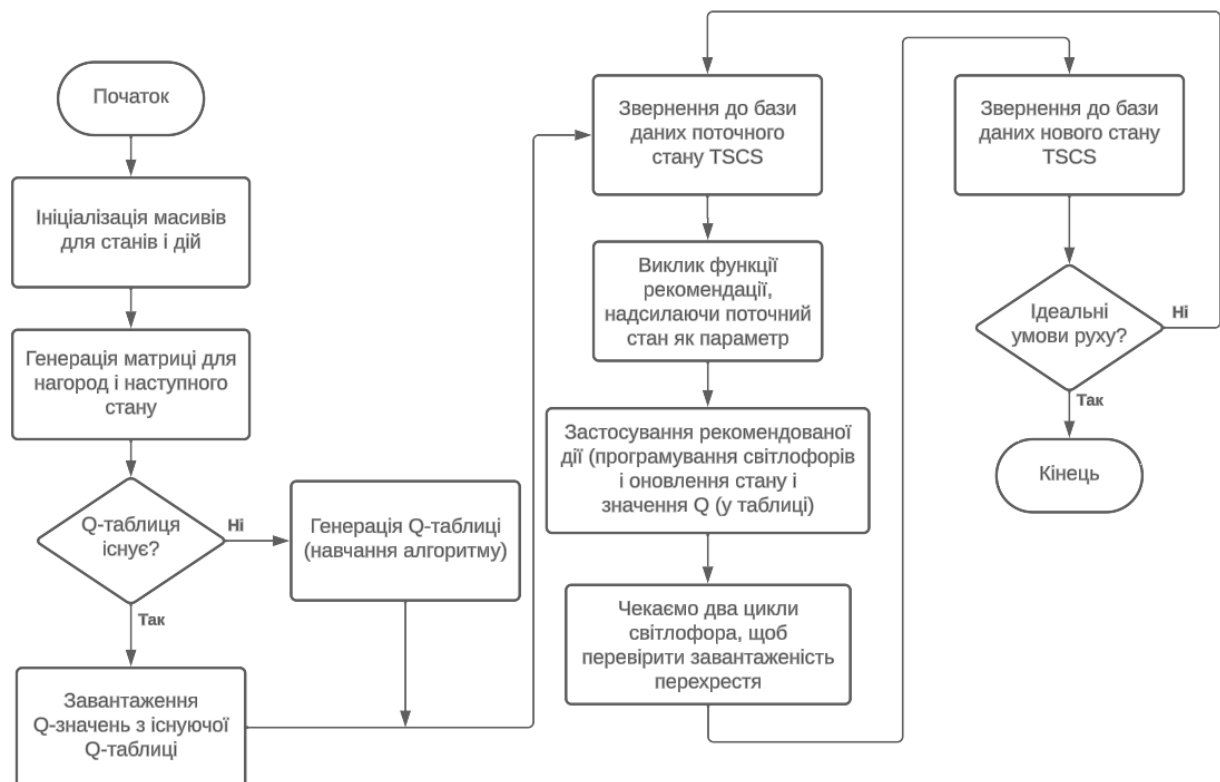


Рисунок 4.6 – Блок-схема алгоритму RL

Оскільки реальне тестування системи, інтегрованої з усіма модулями, виявилось неможливим, була висунута ідея створення моделі для проведення симуляцій за допомогою відповідного програмного забезпечення (SUMO). Реалізацію прикладу алгоритму DQN показано на рисунку 4.7 в контексті

використання SUMO. Архітектура псевдокоду алгоритму DQN представлена в додатку А.1.

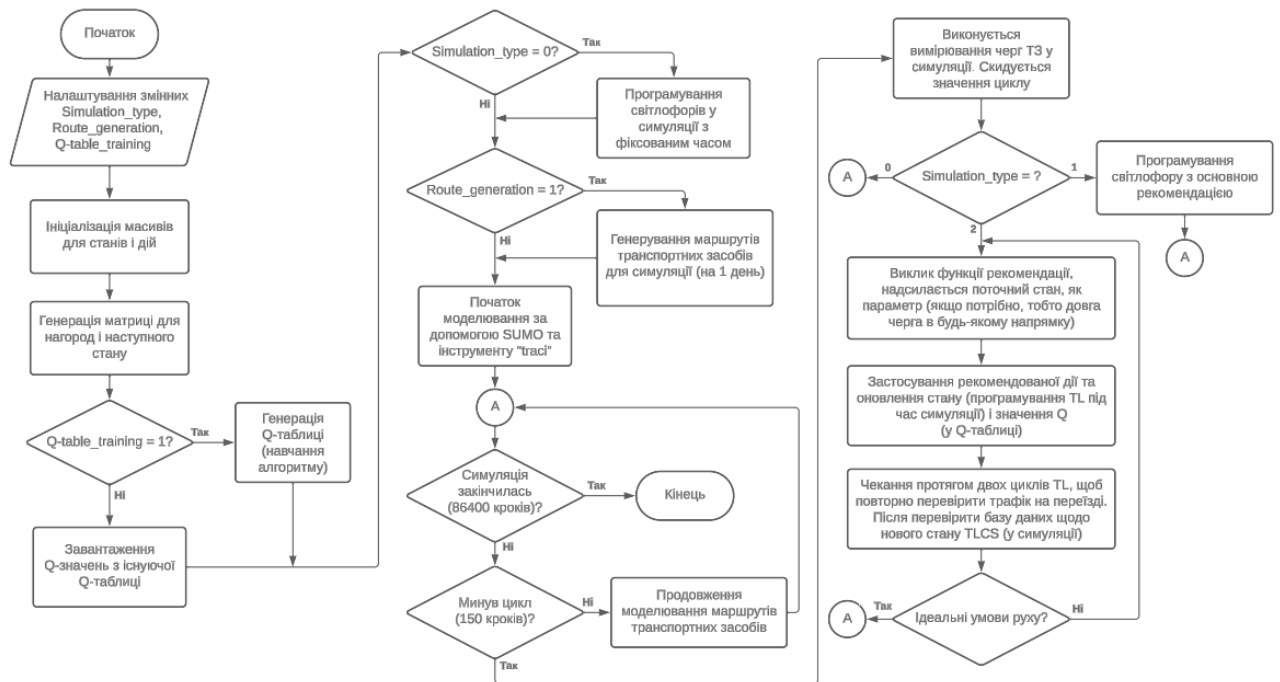


Рисунок 4.7 – Алгоритм роботи DQN з використанням симуляції в SUMO

Основні стратегії управління світлофорами розділяються на централізовані, кластерні та індивідуальні. Найважливіша проблема при централізованому підході – це проблема розмірності, що збільшується при додаванні агентів у систему навчання. Це ускладнює обчислення та витрачає значний час, що не прийнятно для роботи в режимі реального часу. Проблема централізованого управління, пов'язана з «прокляттям розмірності» та труднощами обчислення станів [31].

Кластерна система, що передбачає координацію з найближчими сусідами, розглядається як більш реалізована в практиці і можливий напрямок розвитку програмного продукту, хоча у цьому випадку не застосовувалась. Дослідження підтверджують, що така система є більш ефективною, ніж індивідуальний підхід. На рисунку 4.8 показано концепцію координації дій між сусідніми агентами (світлофорами).

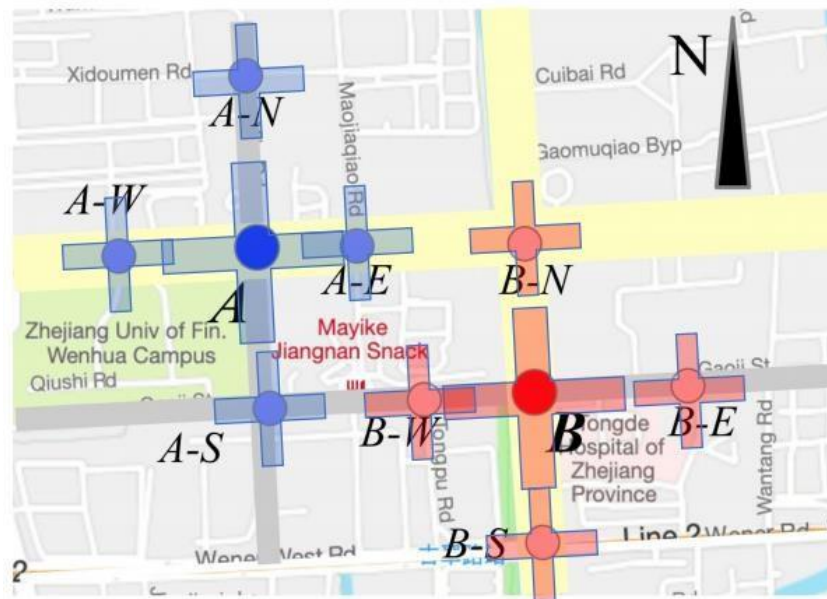


Рисунок 4.8 – Кластерна система керування світлофорами

Для втілення програми керування світлофорами з використанням алгоритму DQN було вибрано індивідуальну модель, так як з технічної точки зору це простіше для демонстрації та реалізації. На рисунку 4.9 наведено схематичне зображення такої системи.

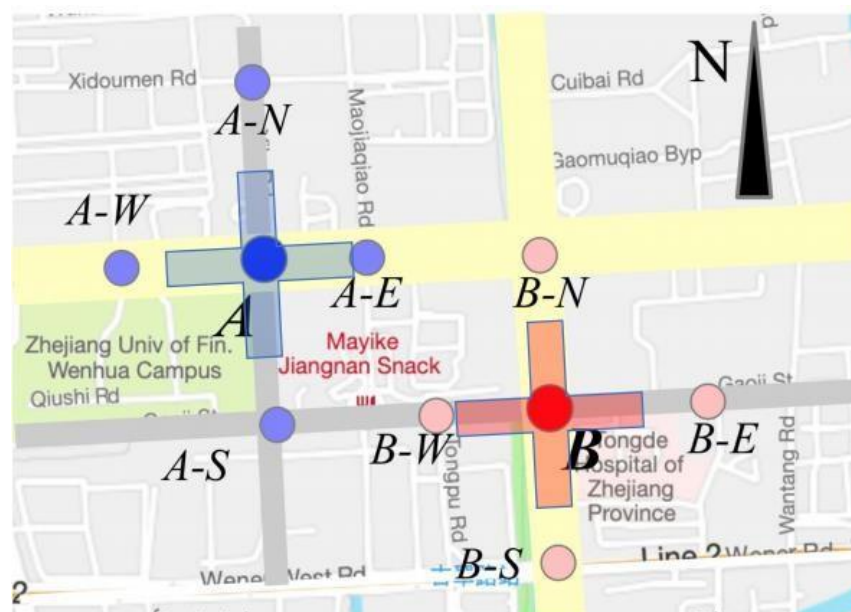


Рисунок 4.9 – Індивідуальна система керування світлофором

Для поліпшення ефективності навчання DQN, в нього вбудовано градієнтний алгоритм метанавчання з AutoRL, який може регулювати

параметр гамма під час навчання. Експерименти включають порівняння продуктивності навчання з використанням різних алгоритмів (DQN) та оптимізаторів (SGD, RMSprop).

Модель завантаженості формується через симуляцію станів з використанням модуля SUMO-GUI. Налаштування моделі можуть бути симульовані на конкретній геометрії, або використовуються реальні мапи та архітектура, побудована відповідно до геометрії та реальних потоків транспорту. Для цього необхідно визначити статистику руху за конкретними маршрутами та навантаженням по годинах. Але можна також використовувати гіпотетичну модель мікроруху на окремому перехресті для моделювання руху та аналізу [32].

Основний модуль програми, `main.py`, відповідає за завантаження агента навчання (у цьому випадку – алгоритм Q-learning) та запуск симуляції `sumo-gui`. Модуль навчання аналізує рух на перехресті та визначає оптимальний варіант регулювання, використовуючи послідовність перемикання сигналів світлофора. Основні налаштування моделі можуть бути змінені за допомогою флагів, які фактично використовуються як API.

Основні флаги моделі включають у себе такі параметри, як кількість епізодів, агент навчання, режим моделі, та використання оптимізаторів (SGD, RMSprop) [22].

Програма проходить кілька фаз: у першій фазі налаштовується середовище SUMO та генерується рух транспорту та робота світлофорів. Дані щодо статистики руху та витраченого часу на перехрестя фіксуються.

У другій фазі, на основі цих даних, агент навчання тестує різні фази роботи світлофора, визначає оптимальний варіант та мінімізує витрати часу для транспортних засобів, що проходять перехрестя.

На рисунку 4.10 показано фрагмент навчання моделі.

```
Step #1001.00 (0ms ?*RT. ?UPS, TraCI: 4ms, vehicles TOT 743 ACT 54 BUF 13)
i_episode: 598
eps_threshold = : 0.8346946746653232
learn_steps: 121280
gamma: tensor(0.9001)
Step #1001.00 (0ms ?*RT. ?UPS, TraCI: 7ms, vehicles TOT 746 ACT 81 BUF 10)
i_episode: 599
eps_threshold = : 0.834446867660534
learn_steps: 121776
gamma: tensor(0.9001)
```

Рисунок 4.10 – Фрагмент навчання моделі

У третій фазі відбувається формування ваг для тренування та створення можливості використання налаштованої моделі для регулювання перехрестя в системі з децентралізованим управлінням.

В результаті процесу навчання отримуються результати, які можна використовувати для регулювання роботи світлофора в режимі, що є більш ефективним порівняно з фіксованим світлофором, наприклад. Ефективність в даному випадку вимірюється часом, який витрачається на очікування в черзі.

Після завершення навчання мережі на конкретних прикладах, можна використовувати отримані ваги для реалізації у конкретних умовах. У даному випадку для демонстрації результатів ми використовуємо той же симулятор SUMO.

У цьому модулі реалізується модель навчання системи управління світлофором, використовуючи не лише показники аналізу завантаженості певних напрямків та надання пріоритету завантаженим, але й аналіз відео за допомогою алгоритмів розпізнавання, таких як YOLO чи інші, або використання датчиків. Це може бути реалізовано також за допомогою методів нелінійного аналізу та пошуку для визначення оптимального часу перемикання фаз світлофора.

Хоча використання навчання з використанням того самого Q-learning (DQN) алгоритму вважається ефективним, застосування його на окремому перехресті може бути обмеженим. На рисунку 4.11 показано моделювання вже на основі навченого агента (світлофора) за допомогою передачі даних до

симулятора SUMO.

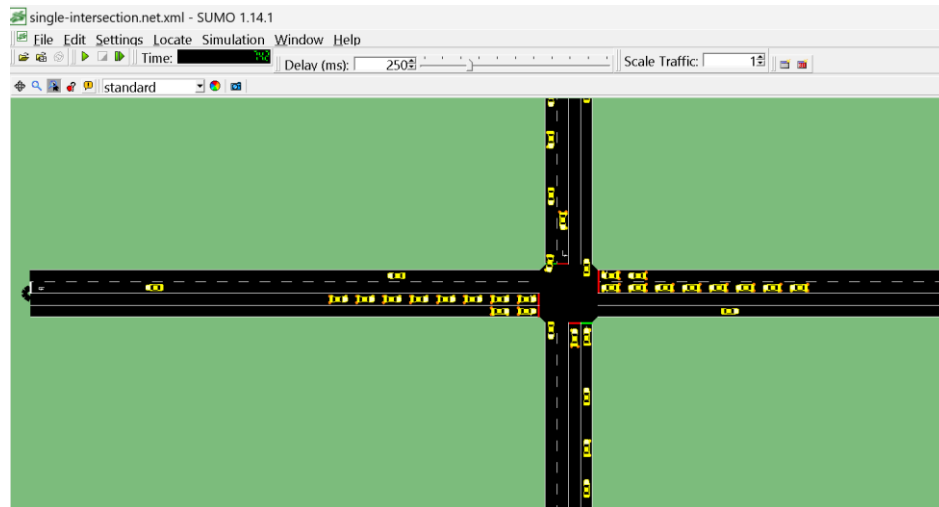


Рисунок 4.11 – Навчений агент за DQN алгоритмом

Проте ключове значення має порівняння застосованого алгоритму навчання з базовим варіантом, який не використовує навчання. Статистика, яку надає симулятор SUMO, дозволяє здійснити порівняння за показником "час втрат на черги".

На рисунку 4.12 представлено порівняння застосованої моделі з базовим варіантом, відображаючи відмінності в умовних налаштуваннях та результати тренувань мережі.

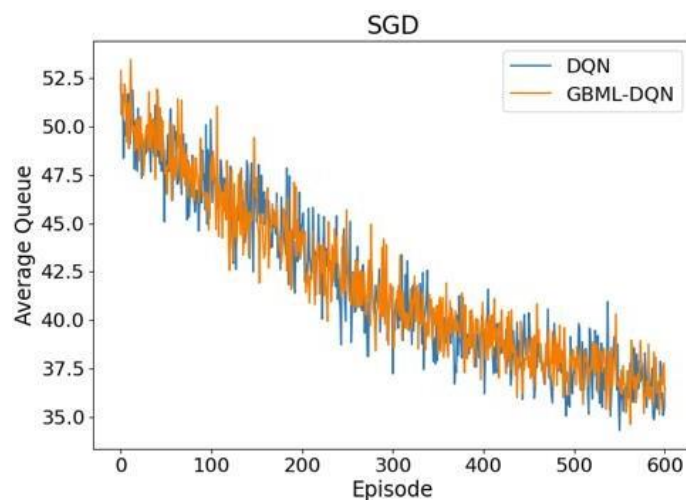


Рисунок 4.12 – Досягнені під час навчання результати та їх вплив на час очікування у черзі

### 4.3 Система регулювання транспортним потоком на основі передбачення та перенаправлення потоків

Для втілення блоку аналізу транспортних потоків та симуляції також використовується наступна модель. Програмний блок, який ґрунтується на Python-скрипті та транспортна статистика, що забезпечує необхідні дані для аналізу. У цьому контексті моделювання даних статистики дозволяє проводити аналіз руху на конкретних ділянках, перехрестях або певних маршрутах (які можна розглядати як графи) та використовувати ці ділянки для аналізу. З метою навчання моделей обрано кілька алгоритмів для можливості порівняння різних підходів. У цьому випадку використано п'ять основних алгоритмів: LSTM, GRU, SAEs, Random Forest та SVR. Структура цих алгоритмів схематично зображена на рисунку 4.13 і подана в додатку А.




Рисунок 4.13 – Алгоритми LSTM та GRU

Даний блок включає у себе модулі `train.py` для навчання та `main.py` для виконання. Модель отримує дані, які зберігаються у файлах у форматі CSV, розділені на групи для навчання та тестування. Результати навчання та відповідні метрики для застосованих алгоритмів навчання зображено на рисунку 4.14.

```

LSTM
explained_variance_score:0.941023
MAPE:16.895268%
MAE:7.302074
MSE:97.678800
RMSE:9.883259
R2:0.939869
GRU
explained_variance_score:0.941564
MAPE:17.668590%
MAE:7.196727
MSE:97.318209
RMSE:9.864999
R2:0.940091
SAEs
explained_variance_score:0.944269
MAPE:17.801078%
MAE:7.058258
MSE:92.077206
RMSE:9.595687
R2:0.943318

```

Рисунок 4.14 – Метрики навчання та показники помилок для різних моделей

В ході виконання ми отримали ваги навченої мережі, які застосували для тестування її функціональності. Результати тестування відображені на рисунку 4.15.




Рисунок 4.15 – Точність прогнозу транспортного потоку

Отже, третій модуль системи призначений для прогнозування обсягів навантаження на конкретні ділянки, міста, або маршрути, залежно від використовуваної статистики. Проте робота цього модуля орієнтована переважно на інформаційний аспект, а не на управління в реальному часі, оскільки ймовірність помилок у передбачення висока.

#### 4.4 Моделювання транспортного потоку та симуляція алгоритму передбачення

У даній роботі для генерації даних, моделювання запропонованого методу управління та для візуальної демонстрації використовується модуль симуляції SUMO. Цей модуль може використовуватися як сервер для обробки трафікових даних та динамічної зміни параметрів. Приклад вулиці, як ілюстрацію кластерної системи управління світлофорами показано на рисунку 4.16.



Рисунок 4.16 – Приклад перехрестя де здійснюється управління світлофорами за допомогою результатів машинного навчання та аналізу статистики

Simulation of Urban Mobility (SUMO) – це потужний симулятор, розроблений для опрацювання великої мережі навантажень та визначеного трафікового попиту, включаючи маршрути транспортних засобів та їхні моделі руху. SUMO також надає важливу інформацію, таку як швидкість транспортних засобів, модель та їхнє місцезнаходження. Однією з ключових особливостей SUMO є інтерфейс управління дорожнім рухом (TraCI), який представляє собою API Python, розглядає симуляцію SUMO як сервер і дозволяє користувачам отримувати інформацію з симуляції трафіку або змінювати її.

Навчання з підкріпленням, як метод машинного навчання, демонструє великий потенціал у розв'язанні складних завдань. Цей метод дозволяє системі отримувати знання та поліпшувати продуктивність шляхом взаємодії з навколишнім середовищем. У контексті управління дорожнім рухом в містах, де зростає кількість транспортних засобів, створення інтелектуальної системи для управління рухом та маршрутизацією стає надзвичайно важливим. Симулятор SUMO відкриває можливості для застосування навчання з підкріпленням, де TraCI виступає важливим інтерфейсом для взаємодії між SUMO та методами навчання з підкріпленням.

TraCI дозволяє здійснювати взаємодію з симуляцією SUMO через різні мови програмування, зокрема Python. Завдяки TraCI можна отримувати дані про рух на дорозі, маніпулювати поведінкою об'єктів онлайн та використовувати цю інформацію для вдосконалення управління трафіком у мережі. Навчання з підкріпленням використовує TraCI для взаємодії з SUMO, щоб оптимізувати політику, виходячи з нагород та стану середовища.

Зміни в трафіку, такі як затори або зміни маршруту, можна емулювати за допомогою TraCI. Затор відображає будь-що, що зупиняє транспорт, таке як дорожні роботи чи аварії. Зміну маршруту можна досягти, змінюючи шлях транспортного засобу в певних умовах. TraCI надає можливості для емуляції таких подій та дозволяє здійснювати динамічний вплив на трафік у симуляції SUMO.

Після виконання програми ми отримуємо три елементи управління трафіком. Перший, управління трафіком у реальному часі, яке визначає пріоритети на перехресті в режимі реального часу. Це досягається за допомогою алгоритму розпізнавання (такого як YOLO), або іншої системи фіксації кількості транспорту на перехресті, що дозволяє оптимізувати локальне завантаження перехрестя.

Другий етап програми включає навчання системи за допомогою більш обґрунтованої моделі, використовуючи алгоритми нелінійного навчання, такі як DQN. Це призводить до значних покращень у статистиці часу простою на перехресті, хоча ці покращення спостерігаються локально. Конкретні показники статистики витрачання часу потребують подальшого визначення на основі реальних прикладів.

Ці два підходи дозволяють здійснювати керування в режимі реального часу.

Третій підхід до програми включає передбачення завантаженості шляхом аналізу статистики руху на певних ділянках чи загальної по місту. Це досягається за допомогою методів нелінійного аналізу та використання алгоритмів, таких як LSTM, GRU, SAE, RF, SVR. За результатами аналізу на певному наборі даних, передбачення демонструє точність на рівні 94%, але для отримання конкретних статистичних показників, тестування повинно бути проведено на реальних локальних даних. Це дозволить отримати конкретну статистику для певних ділянок або територій.

#### 4.5 Висновки до розділу

В даному розділі було ретельно розглянуто аспекти архітектури програмного продукту, де був обґрунтований вибір мови програмування та технології для розробки програми. Крім того, в рамках цього розділу були вирішені такі завдання:

- виконано розгляд модульної архітектури, зокрема мікросервісної структури програми;
- проведено обґрунтування вибору мови програмування Python та інших засобів для розробки;
- проведено аналіз вибору алгоритмів для навчання нейромереж, як ключового інструмента для аналізу та управління;
- здійснено аналіз статистики, спрямований на поліпшення руху транспорту в умовах індивідуальної реалізації на окремому перехресті;
- виконано моделювання та використання симулятора SUMO для представлення результатів навчання моделей.

## 5 ОХОРОНА ПРАЦІ

Згідно з Державними санітарними нормами (ДСН) 3.3.6-042-99, робота в лабораторії з використанням персонального комп'ютера (ПК) відноситься до легких робіт (категорія Іа – легкі фізичні роботи з енерговитратами до 139 Вт або 120 ккал/г). Ця робота передбачає сидяче положення, не вимагає систематичного фізичного напруження і підняття важких предметів [33].


У робочій зоні приміщення відповідно до ДСН 3.3.6.042-99 повинні бути належні умови мікроклімату. Для категорії робіт І а в приміщенні слід дотримуватися наступних норм мікроклімату:

– температура повітря не повинна перевищувати 22-24 °С влітку та 23-25 °С взимку;

– відносна вологість має знаходитися в межах 40-60%;

– швидкість руху повітря не повинна перевищувати 0,1 м/с.

Приміщення, де використовуються персональні комп'ютери, повинні бути оснащені як природним, так і штучним освітленням, яке відповідає вимогам чинної нормативної документації. На рисунку 5.1 наведено приклад розташування робочих місць у приміщенні [33].



1 – вікно; 2 – робоче місце; 3 – комп'ютеризоване робоче місце з ПК та ЖК-монітором

Рисунок 5.1 – План виробничого приміщення

В таблиці 5.1 подано виміряні значення необхідних параметрів для приміщень.

Таблиця 5.1 – Виміряні параметри

Параметр	Фактичне значення	Значення по СН-245-71 чи державному стандарту	Висновок
Шум, дБ	50	46	В межах допустимих значень
Освітленість (загальна), Лк	350	200-400	В межах допустимих значень
Значення К.П.О.,%	1,5	1,6	В межах допустимих значень
Загазованість (концентрація і вид газу), мг/м <sup>3</sup>	Азот 4,8 Аміак 12 Озон 0,05 Свинець 0,01 Хлор 0,7	Азот 5 Аміак 20 Озон 0,1 Свинець 0,01 Хлор 1	В межах допустимих значень
Температура повітря взимку, влітку, °С	21-23 22-24	21-24 22-25	В межах допустимих значень
Відносна вологість, %	45	40-60	В межах допустимих значень
Швидкість руху повітря, м/с	0,15	0,1-0,2	В межах допустимих значень

Як вказано на рисунку 5.1, виробниче приміщення відповідає вимогам ДСН 3.36.037-99, зокрема, в ньому присутнє як природне, так і штучне освітлення, яке не перевищує нормативних вимог. Монітор розташований таким чином, щоб уникнути відблисків світла. Однак, як видно з таблиці 5.1, в приміщенні спостерігається високий рівень шуму, і для його зменшення рекомендується замінити систему охолодження комп'ютера. Додатково, для попередження збільшення концентрації шкідливих елементів, рекомендується проводити регулярне вологе прибирання [33].

## ВИСНОВКИ

Було проведено аналіз матеріалів, що стосується визначення теоретичних засад та практичного застосування понять транспортних потоків, існуючих систем регулювання та аналізу транспортних систем, а також методів їх аналізу та регулювання.

Досліджено існуючі системи регулювання на законодавчому та місцевому рівнях, з акцентом на основні проблеми, пов'язані із системою керування трафіком та униканням заторів. Основна увага була приділена методам регулювання, прогнозування та управління транспортними потоками для покращення транспортної ситуації та зменшення заторів, що в свою чергу призводить до економічних вигід.

Обрано та обґрунтовано вибір набору алгоритмів для створення системи управління транспортними потоками для запобігання заторам. Розглянуті різні алгоритми обробки інформації залежно від рівня системи та необхідності реагування у реальному часі чи з можливістю певної затримки.

Для перевірки результатів роботи системи управління була розроблена модульна система (багатошарова), яка передбачає використання різних алгоритмів, таких як розпізнавання об'єктів та нелінійний аналіз статистики завантаження транспортних шляхів.

Тестування роботи системи теоретично показало, що кожен з методів надає більш ефективний результат у збереженні часу транспортних засобів, демонструючи ефективність активного регулювання порівняно з методами попереднього налаштування. Зазначимо, що більшість цих висновків базувались на дослідницьких роботах і не перевірялися на практиці через обмежений доступ до статистичних даних щодо завантаженості транспортних шляхів у вільному доступі. Запропоновано вирішення цього питання шляхом використання середовища симуляції, такого як система SUMO. За певних умов налаштування ця система може відтворювати карту міста та симулювати транспортні потоки для аналізу та моделювання

алгоритмів аналізу та ефективності активного управління, як світлофорами, так і індивідуальними транспортними засобами.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Методичні вказівки з підготовки та захисту кваліфікаційної роботи здобувачами другого (магістерського) рівня вищої освіти спеціальності 151 Автоматизація та комп'ютерно-інтегровані технології, освітньо-професійних програм: «Автоматизоване управління технологічними процесами», «Комп'ютерно-інтегровані технологічні процеси і виробництва», «Комп'ютеризовані та робототехнічні системи» / Упоряд. І. Ш. Невлюдов, Р. В. Артюх, В. В. Безкоровайний, Н. П. Демська, В. В. Євсєєв, О. І. Филипенко, О. М. Цимбал. – Харків: ХНУРЕ, 2021. – 65 с.
2. ДСТУ 3008: 2015. Інформація та документація. Звіти у сфері науки і техніки. Структура і правила оформлення. К.: ДП “УкрНДНЦ”. 2016. 30 с.
3. Маслов О.А. Визначення задач для реалізації автоматизованої системи контролю руху транспорту // Матеріали 27-й Міжнародний молодіжний форум «Радіоелектроніка та молодь у XXI столітті». 36. матеріалів форуму. Т. 2. Харків: ХНУРЕ. 2023. 51-52 с.
4. H. J. Lee, R. Y. Kim and H. S. Son, “Evaluation of a Smart Traffic Light System with an IOT-based Connective Mechanism,” International Information Institute (Tokyo). Information, vol. 20, no. 2, pp. 953–961, 2017. [Електронний ресурс] – Режим доступу: <https://search.proquest.com/scholarly-journals/evaluation-smart-traffic-light-system-with-iot/docview/2032343134/se-2?accountid=17242>.
5. Інтелектуальні транспортні системи [Електронний ресурс] – Режим доступу: <https://pro-mobility.org/intelektualni-transportni-systemy/>.
6. T. Reed and J. Kidd, “INRIX Global Traffic Scorecard,” 2019. [Електронний ресурс] – Режим доступу: [https://static.poder360.com.br/2019/02/INRIX\\_2018\\_Global\\_Traffic\\_Scorecard\\_Report\\_\\_final\\_.pdf](https://static.poder360.com.br/2019/02/INRIX_2018_Global_Traffic_Scorecard_Report__final_.pdf).

7. US DoT, "Office of International Programs," 7 November 2014. [Электронный ресурс] – Режим доступа: <http://international.fhwa.dot.gov/travelinfo/munich.cfm>.
8. "Intelligent Transportation Systems." Federal Highway Administration, United States Department of Transportation, 2017. [Электронный ресурс] – Режим доступа: [www.fhwa.dot.gov/its/](http://www.fhwa.dot.gov/its/).
9. Li, Qingquan, et al. "Intelligent Transportation Systems: A Comprehensive Review." IEEE Transactions on Intelligent Transportation Systems, vol. 14, no. 4, 2013, pp. 1784-1796.
10. State-of-the-art of vehicular traffic flow modeling /Serge Hoogendoorn // [Электронный ресурс] – Режим доступа: <http://dx.doi.org/10.1243/0959651011541120>.
11. On-Road Intelligent Vehicles Motion Planning for Intelligent Transportation Systems /Rahul Kala, // Robotics and Artificial Intelligence Laboratory, Indian Institute of Information Technology. – 2016.
12. Traffic control systems handbook. // Federal highway administration. 2005. [Электронный ресурс] – Режим доступа: [https://ops.fhwa.dot.gov/publications/fhwahop06006/fhwa\\_hop\\_06\\_006.pdf](https://ops.fhwa.dot.gov/publications/fhwahop06006/fhwa_hop_06_006.pdf)
13. "Smart Transport for Cities: The Future of Transportation." European Commission, 2018. [Электронный ресурс] – Режим доступа: [ec.europa.eu/jrc/en/publication/eur-scientific-and-technical-research-reports/smart-transport-cities-future-transportation](http://ec.europa.eu/jrc/en/publication/eur-scientific-and-technical-research-reports/smart-transport-cities-future-transportation).
14. R. Abduljabbar, H. Dia, S. Liyanage, S.A. Bagloee, Applications of Artificial intelligence in transport: an overview, Sustainability 11 (189) – 2019. [Электронный ресурс] – Режим доступа: <https://doi.org/10.3390/su11010189>.
15. Traffic flow prediction models – A review of deep learning techniques. /Anirudh Ameya Kashyap, Shravan Raviraj, Ananya Devarakonda, Shamanth, R Nayak K, Santhosh K V & Soumya J Bhat. [Электронный ресурс] – Режим доступа: <https://doi.org/10.1080/23311916.2021.2010510>.

16. ARC-IT [Электронный ресурс] – Режим доступа: <https://www.arc-it.net/html/servicepackages/>.
17. A Review of Traffic Congestion Prediction Using Artificial Intelligence/ Akhtar M, Moridpour S. 2021. [Электронный ресурс] – Режим доступа: <https://doi.org/10.1155/2021/8878011>.
18. Traffic Signal Control System Based on Intelligent Transportation System and Reinforcement Learning. Electronics / Hurtado-Gómez, J.; Romo, J.D.; Salazar-Cabrera, R.; Pachón de la Cruz, Á.; Madrid Molina, J.M. 2021, 10, 2363. [Электронный ресурс] – Режим доступа: <https://doi.org/10.3390/electronics10192363>.
19. Real-time object detection YOLOv3 / Karlijn Alderliesten, article [Электронный ресурс] – Режим доступа: <https://medium.com/analytics-vidhya/yolov3-real-time-object-detection-54e69037b6d0>.
20. How to Solve Vehicle Routing Problems: Route Optimization Software and Their APIs [Электронный ресурс] – Режим доступа: <https://www.altexsoft.com/blog/business/how-to-solve-vehicle-routing-problems-route-optimization-software-and-their-apis>.
21. Intelligent Roadway Information System. [Электронный ресурс] – Режим доступа: [https://mnit-rtmc.github.io/iris/road\\_topology.html](https://mnit-rtmc.github.io/iris/road_topology.html).
22. Y. Lv, Y. Duan, W. Kang, Z. Li and F. Wang, "Traffic Flow Prediction With Big Data: A Deep Learning Approach", IEEE Trans. Intell. Transp. Syst., vol. 16, no. 2, pp. 865-873, Apr. 2015.
23. R. Fu, Z. Zhang and L. Li, "Using LSTM and GRU neural network methods for traffic flow prediction," 2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC), 2016, pp. 324-328, doi: 10.1109/YAC.2016.7804912.
24. Fernandez, R., Valenzuela, E., Casanello, F., and Jorquera, C. Evolution of the transyt model in a developing country. Transportation Research Part A: Policy and Practice 40, 5, 2006, 386–398.

25. Revyakina, Yelena & Cherckesova, Larissa & Safaryan, Olga & Porksheyan, Vitaliy & Nikishina, Tatyana & Andryushchenko, Sergey. 2020. Development of intelligent system for automated traffic control. E3S Web of Conferences. 217. 03009.
26. Wided, Ali. Traffic Management system and Traffic Light Control in Smart City to Reduce Traffic Congestion. International Journal of Automation and Smart Technology. 13, 2023. Режим доступу: <https://gigvvy.com/journals/ausmt/articles/ausmt-2023.10.5875/ausmt.v13i1.2464>.
27. Vaghela, Rahul & Solanki, Kamini & Priya, Swaminarayan. Design and Development of Intelligent Traffic Control System. 2023.
28. FRAME [Електронний ресурс] – Режим доступу: <https://frame-online.eu/frame-architecture>.
29. Hidas, P. Modelling lane changing and merging in microscopic traffic simulation. Transportation Research Part C: Emerging Technologies 10, 2002, 351–371.
30. Moganarangan, N. & Balaji, N. & Kumar, R.G. & Balaji, S. & Palanivel, N.. Study on static and dynamic traffic control systems. International Journal of Pure and Applied Mathematics. 119, 2018. 565-578.
31. Mccluskey, T. & Vallati, Mauro & Franco, Santiago. Automated Planning for Urban Traffic Management. 2017. 5238-5240. Режим доступу – <https://www.ijcai.org/proceedings/2017/776>.
32. Bhatnagar, Saumya & Rongge, Guo & McCabe, Keith & Mccluskey, T. & Scala, Enrico & Vallati, Mauro. Leveraging Artificial Intelligence for Simulating Traffic Signal Strategies. 2022. Режим доступу – <https://pure.hud.ac.uk/en/publications/leveraging-artificial-intelligence-for-simulating-traffic-signal->.
33. Стиценко Т.Є., Пронюк Г.В., Сердюк Н.М., Хондак І.І. «Безпека життєдіяльності»: навч. посібник / Т.Є Стиценко, Г.В. Пронюк, Н.М. Сердюк, І.І. Хондак. – Харків: ХНУРЕ, 2018. – 336 с.