

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет
Кафедра

Комп'ютерної інженерії та управління
Комп'ютерних інтелектуальних технологій та систем

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти

другий (магістерський)

Нейромережева обробка відеоінформації
в безпілотних автомобілях
(тема)

Виконав:

студент II курсу, групи КІТМ-22-1

Дмитро КАНУКОВ

(власне ім'я, прізвище)

Спеціальність 123 Комп'ютерна інженерія

(код і повна назва спеціальності)

Тип програми освітньо-професійна

(освітньо-професійна або освітньо-наукова)

Освітня
програма

Комп'ютерні
інтелектуальні технології

(повна назва освітньої програми)

Керівник

професор кафедри КІТС

Олександр БЕЗСОНОВ

(посада, власне ім'я, прізвище)

Допускається до захисту

Зав. кафедри

(підпис)

Олег РУДЕНКО

(власне ім'я, прізвище)

2023 р.

Харківський національний університет радіоелектроніки

Факультет	Комп'ютерної інженерії та управління
Кафедра	Комп'ютерних інтелектуальних технологій та систем
Рівень вищої освіти	другий (магістерський)
Спеціальність	123 Комп'ютерна інженерія
Тип програми	освітньо-професійна
Освітня програма	Комп'ютерні інтелектуальні технології

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

« _____ » _____ 202_ р.

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові _____ Канукову Д.С.
(прізвище, ініціали)

1. Тема роботи (проекту) Нейромережева обробка відеоінформації в безпілотних автомобілях

затверджена наказом університету від «03» листопада 2023р. № 1290Ст

2. Термін подання студентом роботи до екзаменаційної комісії _____ 202_ р.

3. Вихідні дані до роботи (проекту) _____

1) виявлення основних характеристик та властивостей об'єкту керування;

2) побудова тестової моделі нейронної мережі;

3) мова програмування – Python;

4. Перелік питань, що потрібно опрацювати в роботі _____

1) огляд предметної області;

2) аналіз об'єкту дослідження;

3) огляд існуючих рішень;

4) розробка програми;

5) експериментальні дослідження;

6) висновки.

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (п.5 включається до завдання за рішенням кафедри)

Слайд-презентація – 10 слайдів

6. Консультанти розділів роботи (п.6 включається до завдання за наявністю консультантів згідно до наказу, зазначеному у п.1)

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 завдання на кваліфікаційну роботу	06.11.2023 - 09.11.2023	Виконано
2	Огляд інструментів для розробки	09.11.2023 - 15.11.2023	Виконано
3	Створення програмного коду	15.11.2023 - 19.12.2023	Виконано
4	Оформлення матеріалів кваліфікаційної роботи	19.12.2023 - 12.01.2024	Виконано
5	Перевірка керівником проекту	13.01.2024	Виконано
6	Перевірка на плагіат	14.01.2024	Виконано
7	Перевірка нормоконтролем	15.01.2024	Виконано
8	Перевірка зав. кафедрою, рецензування	16.01.2024	Виконано
9	Захист проекту	25.01.2024 - 27.01.2024	Виконано

Дата видачі завдання 06 листопада 2023 р.

Студент _____
(підпис)

Керівник роботи _____ проф. кафедри КІТС О.О. Безсонов
(підпис) (посада, ініціали, прізвище)

РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 79 сторінок, 26 рисунків, 2 таблиць, 21 джерел.

LiDAR, PBS, RWA, HSTO, HSSO, НАЙСУЧАСНІШІ ТЕХНОЛОГІЇ АВТОМАТИЗОВАНОГО ВОДІННЯ, БАГАТОЗІСТАВНИЙ ВАНТАЖНИЙ АВТОНОМНИЙ ТРАНСПОРТНИЙ ЗАСІБ.

Метою роботи є дослідження та початок розробки автопілотної системи для далеkobійного транспорту на основі аналізу відеопотоку з камери. Вивчення нюансів, пов'язаних з розробкою автопілота, специфічних для далеkobійників, і вибір оптимального методу реалізації, а також дослідження способів застосування нейромереж для ефективної обробки відеоданих в системах автономного водіння. Мета полягає у вдосконаленні способів сприйняття та аналізу оточуючого середовища для підвищення безпеки та продуктивності безпілотних автомобілів.

У ході виконання роботи було проаналізовано нюанси щодо створення автопілота для далеkobійного транспорту, вивчено особливості далеkobійних вантажівок, їх вимоги і виклики, пов'язані з автопілотною системою. Також було оглянуто алгоритми обробки аналізу відеопотоку, виявлення об'єктів та прийняття рішень з використанням штучного інтелекту.

До основних конструктивних, технологічних та експлуатаційно-технічних характеристик та показників можна віднести:

- використання передових нейромережових архітектур для точної та швидкої обробки відеоданих;
- інтеграція системи обробки відеоінформації у вбудовані системи безпілотного водіння.
- забезпечення реального часу обробки та аналізу великих обсягів відеоданих.

Ця розробка включає в себе успішну імплементацію нейромережевої системи обробки відео для безпілотних автомобілів. За допомогою цієї системи вдалося підняти точність та надійність виявлення та розпізнавання об'єктів у відеопотоці, що дозволило автомобілям ефективніше функціонувати в різноманітних умовах дорожнього руху.

Рекомендується впровадження такої системи у сфері автопрому для забезпечення безпеки та ефективності безпілотних автомобілів. Також розглядається можливість застосування в інших галузях, де необхідна точна обробка та аналіз великих обсягів відеоданих, таких як робототехніка, безпека та медицина.

ABSTRACT

Explanatory note of master's qualification work: 79 pages, 26 figures, 2 tables, 21 sources.

LiDAR, PBS, RWA, HSTO, HSSO, THE MOST MODERN TECHNOLOGIES OF AUTOMATED DRIVING, MULTI-COMPONENT TRUCK AUTONOMOUS VEHICLE.

The purpose of the work is research and the beginning of the development of an autopilot system for long-distance transport based on the analysis of the video stream from the camera. Studying the nuances associated with the development of autopilot, specific for truck drivers, and choosing the optimal method of implementation, as well as researching methods of using neural networks for effective processing of video data in autonomous driving systems. The goal is to improve the way the environment is perceived and analyzed to improve the safety and performance of self-driving cars.

In the course of the work, the nuances of creating an autopilot for long-distance transport were analyzed, the features of long-distance trucks, their requirements and challenges related to the autopilot system were studied. Processing algorithms for video stream analysis, object detection and decision-making using artificial intelligence were also reviewed.

The main structural, technological, operational and technical characteristics and indicators include:

- use of advanced neural network architectures for accurate and fast processing of video data;
- integration of the video information processing system into built-in systems of unmanned driving;
- provision of real-time processing and analysis of large volumes of video data.

This development includes the successful implementation of a neural network video processing system for self-driving cars. With the help of this system, it was possible to increase the accuracy and reliability of detection and recognition of objects in the video stream, which allowed cars to function more efficiently in various traffic conditions.

It is recommended to implement such a system in the automotive industry to ensure the safety and efficiency of self-driving cars. Applications in other fields where accurate processing and analysis of large volumes of video data are required, such as robotics, security, and medicine, are also being considered.

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет
Кафедра

Комп'ютерної інженерії та управління
Комп'ютерних інтелектуальних технологій та систем

АНОТАЦІЯ
КВАЛІФІКАЦІЙНОЇ РОБОТИ
Пояснювальна записка

рівень вищої освіти

другий (магістерський)

Нейромережева обробка відеоінформації
в безпілотних автомобілях
(тема)

Виконав:

студент II курсу, групи КІТм-22-1

Дмитро КАНУКОВ

(власне ім'я, прізвище)

Спеціальність 123 Комп'ютерна інженерія

(код і повна назва спеціальності)

Тип програми освітньо-професійна

(освітньо-професійна або освітньо-наукова)

Освітня
програма

Комп'ютерні
інтелектуальні технології

(повна назва освітньої програми)

Керівник

професор кафедри КІТС

Олександр БЕЗСОНОВ

(посада, власне ім'я, прізвище)

2023 р.

АНОТАЦІЯ

Кануков Д.С. Нейромережева обробка відеоінформації в безпілотних автомобілях. – Магістерська кваліфікаційна робота.

У магістерській кваліфікаційній роботі вирішено актуальну тему підвищення безпеки пересування людей автодорогами, в особливості великовагових транспортних засобів (AHVs), акцентується увага на вивченні активних систем безпеки (AVSSs), таких як антиблокувальні системи гальм. Ці технології відносяться до "систем реактивної безпеки", які реагують на поточний стан автомобіля. Хоча ефективні, вони не враховують людські помилки, які часто є причиною дорожньо-транспортних пригод.

Основна проблема виникає через людські помилки, і вирішенням є впровадження автономного водіння, яке усуває людський фактор з процесу керування. Перехідний період передбачає, що більшість транспортних засобів отримають можливість автономного водіння. З кінця 1990-х років вже існують системи попередження про виїзд зі смуги та адаптивний круїз-контроль для прогнозування стану транспортного засобу та навколишнього середовища.

Для легкових автомобілів розроблено кілька прогнозуючих систем безпеки (PSS), які мають функції напівавтономного керування. Проте AHVs, які мають вищий ризик на автомагістралях, отримали менше уваги у розробці PSS. У цьому курсовому проекті досліджується стан технологій для автономних та напівавтономних AHV, аналізуються їх переваги та недоліки, і визначаються напрямки майбутніх досліджень.

У контексті поточних технологій для автономних та напівавтономних великовагових транспортних засобів (AHV), слід відзначити, що розвиток систем безпеки таких автомобілів є важливим завданням, особливо з урахуванням їхнього великого ризику на дорогах. Однією з перспективних технологій є системи детекції втомленості та відволікання водія, які можуть сприяти зменшенню аварій внаслідок людських помилок. Розробка систем

штучного інтелекту, які взаємодіють з іншими транспортними засобами та інфраструктурою, також є актуальною темою досліджень. Такі системи можуть покращити координацію та безпеку на дорозі, надаючи автомобілям здатність обмінюватися інформацією та уникати конфліктних ситуацій.

Зокрема, важливим напрямком є інтеграція датчиків із здатністю аналізувати поведінку інших учасників руху, щоб передбачати їхні наміри та дії. Це може сприяти вчасному реагуванню системи автономного керування на непередбачувані ситуації та забезпечити високий рівень безпеки на дорозі.

Однак разом із технологічними вдосконаленнями важливо враховувати етичні, юридичні та соціальні аспекти впровадження автономних транспортних засобів. Такий комплексний підхід дозволяє створити баланс між інноваціями та забезпеченням безпеки та ефективності на дорозі.

На сучасному етапі розвитку автономних великовагових транспортних засобів (АНВ) відбувається значний прогрес у напрямку вдосконалення систем штучного інтелекту та навігації. Однією з перспективних областей є використання технології машинного навчання для покращення спрогнозованості поведінки і реакцій автономних транспортних засобів у різних дорожніх сценаріях.

Також важливим напрямком є розробка та впровадження комунікаційних протоколів для ефективного обміну інформацією між різними АНВ та іншими учасниками дорожнього руху. Системи "Vehicle-to-Everything" (V2X) можуть забезпечити взаємодію між транспортними засобами, інфраструктурою та пішоходами, сприяючи безпеці та оптимізації трафіку.

З врахуванням енергоефективності та екологічних аспектів важливо також звертати увагу на розробку технологій електричного та гібридного приводу для великовагових транспортних засобів, що сприятиме зменшенню викидів та експлуатаційних витрат. Окрім того, у сфері безпеки важливим є вдосконалення систем виявлення та уникнення колізій за допомогою передових сенсорів, таких як лідари, радары та камери. Впровадження технологій обробки відеоданих та обробки об'єктів може значно підвищити рівень безпеки та

надійності автономних великовагових транспортних засобів. Ці напрямки свідчать про те, що розвиток автономної технології великовагового транспорту набуває великого масштабу та включає в себе широкий спектр інновацій.

Автономне водіння в автосимуляторах – це аспект в галузі віртуальної реальності та ігор, який дозволяє гравцям відчувати себе за кермом автомобіля, обладнаного технологіями автономного водіння. Цей елемент гри відображає інноваційні рішення, які реальні автовиробники впроваджують у своїх транспортних засобах. Однією з ключових особливостей автономного водіння в автосимуляторах є можливість гравця спостерігати, як штучний інтелект або автоматизована система приймає рішення щодо маршруту, об'їзду перешкод, дотримання правил дорожнього руху та взаємодії з іншими автомобілями. Гравець може бути учасником цього процесу, приймаючи рішення або навіть перехоплюючи керування в деяких ситуаціях. Також, автономне водіння в ігрових симуляторах може включати елементи віртуальної реальності (VR) для покращення іммерсії. Гравець може відчувати віртуальну подорож через використання VR-шолома та відповідного обладнання, що дозволяє відчуття реальних вібрацій, звуків та рухів. Такі ігрові автономні системи можуть служити як навчальний інструмент, де гравці можуть експериментувати з різними технологіями, відчувати власноруч вплив автономних систем на автомобіль, а також розвивати навички управління та взаємодії з автоматизованими системами на дорозі.

Переваги автономного водіння в автосимуляторах:

- навчання та експериментація, бо гравці можуть вивчати принципи роботи технологій автономного водіння, експериментувати з різними алгоритмами та відчувати їхні впливи на поведінку автомобіля;
- розвиток навичок управління, бо граючи в автосимулятори з елементами автономного водіння, гравці можуть розвивати свої навички в управлінні автомобілем в умовах, що можуть виникнути під час використання технологій самої водіння;

- іммерсивний досвід, бо з використанням віртуальної реальності гравець може відчувати себе за кермом автомобіля, отримуючи іммерсивний досвід віртуальної подорожі;
- розвага та відпочинок, бо автосимулятори з елементами автономного водіння можуть також служити засобом розваги та відпочинку, дозволяючи гравцям насолоджуватися ігровим процесом та відчувати атмосферу автономних технологій.

Хоча недоліки автономного водіння в автосимуляторах теж присутні і найпомітніші з них такі як:

- віддаленість від реальності, бо віртуальний світ автосимулятора може відрізнятися від реальності, і тому ефективність навчання та перенос навичок у реальний світ можуть бути обмеженими;
- обмежена точність імітації, бо деякі технічні аспекти автономного водіння можуть бути складно або неповністю імітовані в симуляторах, що обмежує повноту дослідження та розуміння функціональності таких систем;
- неврахування непланових ситуацій, бо симулятори можуть не повністю враховувати всі можливі внепланові сценарії та складні умови на дорозі, що реально можуть виникнути;
- відсутність фізичного впливу, бо гравці можуть не відчувати фізичних аспектів реального водіння, таких як гальмування, прискорення та реакція автомобіля на дорожні умови.

У цілому, автономне водіння в автосимуляторах має свої переваги та обмеження, проте воно виступає як захоплюючий інструмент для освоєння та експериментів у світі автомобільних технологій.

На жаль точних деталей про комерційну складову автопілотів [1], можливо, ще не існує, проте можна зазначити, що автопілот – це технологічний елемент, який дозволяє автомобілю частково або повністю виконувати функції водія за допомогою різноманітних сенсорів, камер, радарів та інших систем. Комерційна складова автопілоту могла б включати в себе апаратне

забезпечення (системи датчиків, обчислювальні блоки, активаційні системи тощо), а також програмне забезпечення, яке визначає стратегії поведінки автомобіля в різних ситуаціях на дорозі. Ці технології можуть включати системи розпізнавання вулиць і дорожніх знаків, адаптивний круїз-контроль, системи уникнення зіткнень, автоматичне паркування та інші функції, спрямовані на поліпшення безпеки та зручності водіння.

Системи автопілоту в автомобілях використовують різноманітні датчики та технології для розпізнавання дороги, об'єктів, пішоходів, знаків та інших елементів навколишнього середовища. Основні елементи, які використовуються для цього, включають:

- камери, бо багато автомобілів оснащені вбудованими камерами, які фіксують зображення навколишнього середовища. Камери можуть використовуватися для розпізнавання дорожньої розмітки, інших автомобілів, пішоходів та знаків;
- лідари (лазерні датчики) використовують лазерне випромінювання для створення тривимірної точної карти навколишнього простору. Вони можуть допомагати автомобілю визначати відстані до об'єктів, розпізнавати перешкоди, а також визначати шлях руху;
- радары вимірюють відстань до навколишніх об'єктів, визначаючи їхню швидкість та напрямок руху. Вони допомагають системі автопілоту в розпізнаванні і взаємодії з іншими транспортними засобами;
- сонари аналогічно до лідарів використовують звукові хвилі для визначення відстаней та розташування об'єктів;
- датчики інфрачервоного випромінювання можуть використовуватися для виявлення теплових слідів, таких як двигаючіся пішоходи або тварини;
- системи GPS, глобальна система позиціонування використовується для визначення точного положення автомобіля на карті та в плануванні маршруту.

Системи автопілоту інтегрують ці дані, використовуючи алгоритми машинного навчання та штучного інтелекту, щоб розпізнавати дорогу, уникати перешкод, дотримуватися правил руху та реагувати на зміни в навколишньому середовищі. Вони також можуть ідентифікувати та розпізнавати знаки дорожнього руху, світлофори, пішохідні переходи та інші елементи інфраструктури.

Метою кваліфікаційної роботи є аналіз та початок розробки автопілотної системи для далеkobійного транспорту на основі вивчення відеопотоку з камери. Основний фокус націлено на розгляд аспектів, пов'язаних з розробкою автопілота, що є специфічними для далеkobійників. Також проводиться вибір оптимального методу реалізації та дослідження можливостей застосування нейромереж для ефективної обробки відеоданих в системах автономного водіння.

Головна мета полягає в удосконаленні способів сприйняття та аналізу навколишнього середовища з метою підвищення безпеки та продуктивності безпілотних автомобілів.

Об'єктом дослідження цієї роботи є процес обробки відеоінформації за допомогою нейромереж у контексті їхнього використання в безпілотних автомобілях. Дослідження спрямоване на вивчення та оптимізацію використання нейромереж для ефективної обробки відеоданих, що надходять з різних джерел, з метою забезпечення безпечного та продуктивного автономного руху автомобілів.

Предметом дослідження є конкретний процес обробки відеоданих через нейромережі з метою досягнення більшої точності, ефективності та надійності у функціонуванні системи автономного водіння.

LiDAR, PBS, RWA, HSTO, HSSO, НАЙСУЧАСНІШІ ТЕХНОЛОГІЇ АВТОМАТИЗОВАНОГО ВОДІННЯ, БАГАТОЗІСТАВНИЙ ВАНТАЖНИЙ АВТОНОМНИЙ ТРАНСПОРТНИЙ ЗАСІБ.

Публікації здобувача за темою роботи:

1. Кануков Д.С. Система допомоги керуванням транспортом на основі розпізнавання знаків дорожнього руху. Наукові дослідження: парадигма інноваційного розвитку: збірник тез наукових праць XIII Міжнародної наукової конференції (Прага, Чехія, «29» грудня 2022 року) / ГО «Міжнародний науковий центр розвитку науки та технологій», 2022. — 60 с.

2. Кануков Д.С. Покращення управління проектами за рахунок використання штучного інтелекту. Інформаційне суспільство: технологічні, економічні та технічні аспекти становлення (випуск 74): матеріали Міжнародної наукової інтернет-конференції, (м. Тернопіль, Україна – м. Переворськ, Польща, 6-7 лютого 2023 р.) / ГО “Наукова спільнота”; WSSG w Przeworsku. – Тернопіль : ФО-П Шпак В.Б. – 215 с. – ISSN 2522-932X.

3. Кануков Д.С., Митцева О.С. Експоненційні проривні технології та необхідні навички для індустрії 4.0. Наука сьогодення: від досліджень до стратегічних рішень: матеріали VI Міжнародної студентської наукової конференції, м. Суми, 2 червня, 2023 рік / ГО «Молодіжна наукова ліга». — Вінниця: ГО «Європейська наукова платформа», 2023. — 268 с., ISBN 978-617-8126-53-7. DOI: <https://doi.org/10.36074/liga-inter-02.06.2023>.

4. Кануков Д.С., Аксак Н.Г. Огляд багатоагентного навчання з підкріпленням для підключених та автоматизованих транспортних засобів. Наука сьогодення: від досліджень до стратегічних рішень: матеріали VI Міжнародної студентської наукової конференції, м. Суми, 2 червня, 2023 рік / ГО «Молодіжна наукова ліга». — Вінниця: ГО «Європейська наукова платформа», 2023. — 268 с., ISBN 978-617-8126-53-7. DOI: <https://doi.org/10.36074/liga-inter-02.06.2023>.

5. Кануков Д.С., Сердюк Н.М. Особливості програмування для високопродуктивних обчислень на edge accelerators. Наука сьогодення: від досліджень до стратегічних рішень: матеріали VI Міжнародної студентської наукової конференції, м. Суми, 2 червня, 2023 рік / ГО «Молодіжна наукова

ліга». — Вінниця: ГО «Європейська наукова платформа», 2023. — 268 с., ISBN 978-617-8126-53-7. DOI: <https://doi.org/10.36074/liga-inter-02.06.2023>.

6. Кануков Д.С., Сердюк Н.М., Особливості та перспективи візуального відстеження об'єктів. Наука сьогодення: від досліджень до стратегічних рішень: матеріали VI Міжнародної студентської наукової конференції, м. Суми, 2 червня, 2023 рік / ГО «Молодіжна наукова ліга». — Вінниця: ГО «Європейська наукова платформа», 2023. — 268 с., ISBN 978-617-8126-53-7. DOI: <https://doi.org/10.36074/liga-inter-02.06.2023>.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ.....	19
ВСТУП.....	20
1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ПОСТАНОВКА ЗАДАЧІ.....	21
1.1 Аналіз предметної області.....	21
1.2 Постановка задачі.....	25
2 АНАЛІЗ ДАЛЕКОБІЙНОГО ТРАНСПОРТУ.....	26
2.1 Класифікація автономності та необхідні модулі.....	26
2.2 Типи ANVs.....	27
2.3 Маневрені характеристики ANV.....	28
2.4 Моделі транспортних засобів, що використовуються в розробці автоматизованого контролера водіння.....	30
2.5 Переваги автономних ANV та перешкоди для впровадження.....	32
3 ОГЛЯД ТЕХНОЛОГІЙ ТА ПРИСТРОЇВ ДЛЯ ANV.....	33
3.1 Слідування маршрутом та бічне керування ANVS.....	33
3.2 Сенсорні технології для автономних ANVS.....	36
4 ЗАВДАННЯ ДЛЯ АВТОНОМНИХ ТРАНСПОРТНИХ ЗАСОБІВ.....	42
4.1 Сприйняття для автономних транспортних засобів.....	42
4.2 Планування руху для автономних транспортних засобів.....	43
4.3 Розпізнавання пішоходів під час автономного водіння.....	47
4.4 Розпізнавання дорожніх знаків для автономного водіння.....	49
4.5 Розпізнавання дорожньої розмітки для автономного водіння.....	50
5 НАВЧАННЯ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ.....	55
5.1 Особливості використаної обраної CNN.....	56
5.2 Огляд системи DAVE-2.....	57
5.3 Збір даних для CNN.....	60
5.4 Архітектура мережі.....	62

5.5 Деталі навчання	64
5.6 Моделювання.....	65
5.7 Оцінювання.....	66
ВИСНОВОК.....	70
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ.....	72
ДОДАТОК А. ГРАФІЧНИЙ МАТЕРІАЛ КВАЛІФІКАЦІЙНОЇ РОБОТИ	75

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

Автопілот – це технологічний елемент, який дозволяє автомобілю частково або повністю виконувати функції водія за допомогою різноманітних сенсорів, камер, радарів та інших систем;

AGV – автономний наземний транспортний засіб (англ., autonomous ground vehicles);

AHV – з'єднані великовагові транспортні засоби (англ., articulated heavy vehicles);

AVSS – активні системи безпеки транспортних засобів (англ., active vehicle safety systems);

PSS – прогнозовані системи безпеки (англ., predictive safety systems);

LiDAR – це метод геодезії, який вимірює відстань до цілі шляхом освітлення цілі лазерним світлом і вимірювання відбитого світла за допомогою датчика (англ., Light Detecting & Ranging);

GPS – це глобальна система позиціонування використовується для визначення точного положення автомобіля на карті та в плануванні маршруту;

IMU – це електронні пристрої, які можуть вимірювати силу тіла, кутову швидкість і магнітне поле (від англ., «інерціальні одиниці вимірювання»);

CNN – згорткова нейронна мережа (англ., Convolutional neural network);

PBS – стандарти на основі продуктивності (англ., performance-based standards);

RWA – це співвідношення між максимальним рухом першої та останньої одиниць транспортного засобу під час певного маневру рульового керування та швидкістю транспортного засобу.

ВСТУП

Для підвищення безпеки з'єднаних великовагових транспортних засобів (articulated heavy vehicles – AHVs), приділено увагу дослідженню активних систем безпеки транспортних засобів (active vehicle safety systems – AVSSs), наприклад, антиблокувальних систем гальм. Ці технології активної безпеки автомобіля класифікуються як «системи реактивної безпеки», призначені для реагування на поточний стан автомобіля. Ці системи ефективні, але не враховують вплив помилки водія.

Основна причина дорожньо-транспортних пригод пов'язана з людськими помилками [2]. Рішенням проблеми є автономне водіння, яке усуває людський фактор із контуру керування. Буде перехідний період, протягом якого більшість транспортних засобів матимуть деякі можливості автономного водіння. З кінця 1990-х років були запропоновані системи попередження про виїзд зі смуги руху та адаптивний круїз-контроль. Ці технології класифікуються як «прогнозовані системи безпеки» (predictive safety systems – PSS), враховуючи не лише поточний стан автомобіля, але й прогнозований стан транспортного засобу та небезпеку для навколишнього середовища.

Для легкових транспортних засобів було досліджено кілька PSS. Ці PSS мають функції напіваавтономного керування. AHV становлять у 7,5 разів більший ризик, ніж легкові автомобілі під час експлуатації автомагістралей. Однак набагато менше уваги приділено дослідженню PSS для AHV. У цьому проекті розглядається поточний стан основних технологій, запропонованих і досліджених для автономних і напіваавтономних AHV. Обговорюються та аналізуються плюси та мінуси технологій. У результаті огляду визначаються майбутні дослідницькі зусилля.

1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ПОСТАНОВКА ЗАДАЧІ

1.1 Аналіз предметної області

Автомобільна промисловість рухається до нової ери автономних наземних транспортних засобів (autonomous ground vehicles – AGV). Термін AGV відноситься до автомобіля, який може здійснювати навігацію під час руху шосе або міським рухом і навіть бездоріжжям без втручання людини.

Оскільки програмне забезпечення, комп'ютери, датчики та підключені мережі все частіше використовуються, конструкція таких транспортних засобів зазнає значних змін. Щорічно у світі внаслідок ДТП гине близько 1,25 мільйона людей [3]. У таблиці 1.1 наведені статистичні дані щодо авто ДТП у США та Канаді та участь людського фактору, де 93% серйозних ДТП відбуваються через людські помилки. У 2016 році понад 37 000 людей загинули в приблизно 32 000 смертельних автотранспортних пригодах у Північній Америці [4], а також економічні витрати від аварій неймовірно високі, рятівні та фінансові вигоди від технології допомоги водієві стають незаперечними.

Таблиця 1.1 – Авто ДТП у США та Канаді та участь людського фактору

Критерії	США	Канада
Загальна кількість аварій за рік	5.5 млн.	290 тис.
Людські причини як основний фактор	93%	80%
Економічні витрати від аварій	277 млрд. \$	37 млрд. \$
Загальна кількість ДТП зі смертельними наслідками та травмами за рік	2.22 млн.	165 140
Смертельні ДТП на рік	32,367	1,895
Загальна кількість аварій зі смертельними наслідками та травмами за рік за участю великої вантажівки	96129	12000

AGV мають потенціал для зменшення людських помилок в аваріях, тим самим значно захищаючи пасажирів, водіїв і пішоходів і зменшуючи фінансові витрати. Використання передових систем допомоги водієві (Advanced Driver Assistance Systems – ADAS), напр. Адаптивний круїз-контроль (Adaptive Cruise Control – ACC), асистент руху в заторах (Traffic Jam Assistant – TJA) і системи запобігання зіткнень, смертельні ДТП зменшилися в Європі між 2001 і 2015 роками на 48% [5]. На рисунку 1.1 представлена історія застосування функцій допомоги водієві та їх потенційна майбутня еволюція.

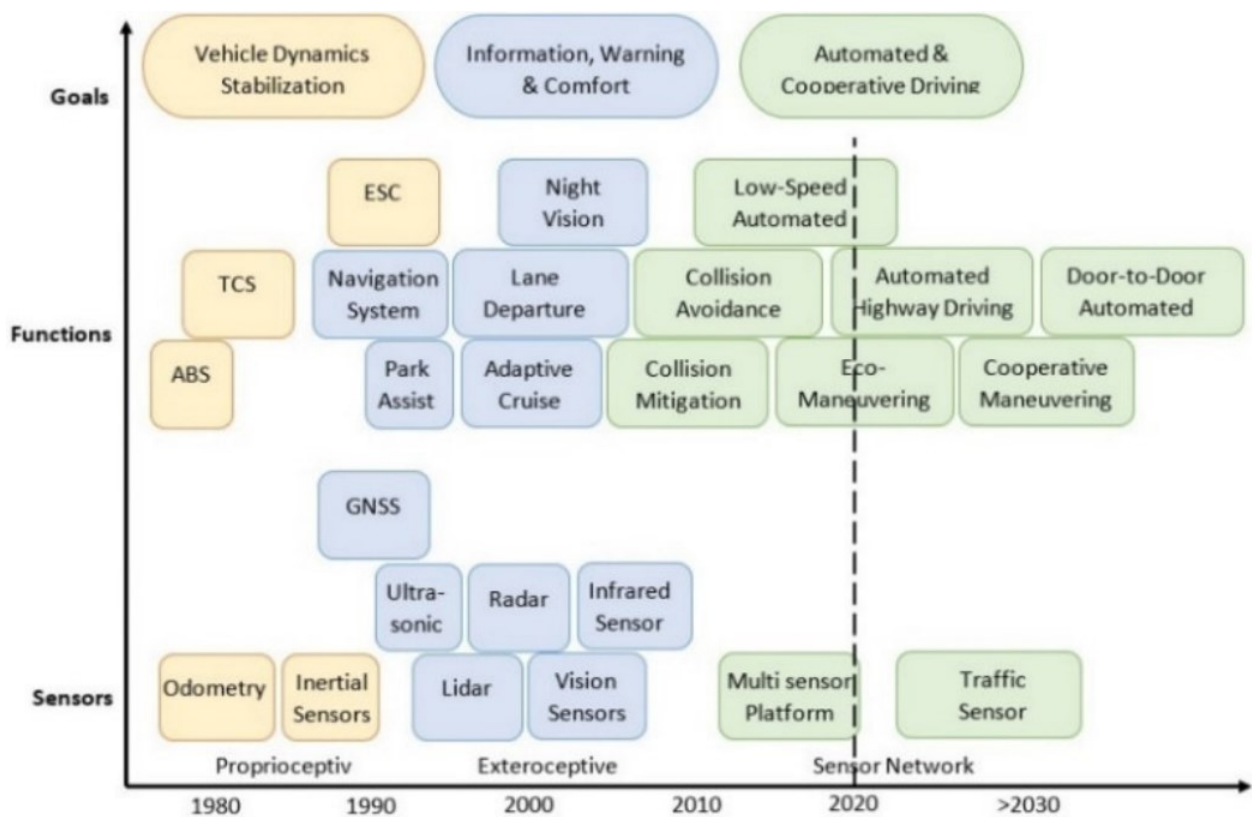


Рисунок 1.1 – Еволюція функцій допомоги водієві з точки зору ринку

Оскільки безпека автоматизованого водіння має першочергове значення, урядам необхідно терміново розробити керівні принципи безпеки транспортних засобів для проектування AGV [6]. Очікується, що керівні принципи визначать аспекти дизайну, які виробники повинні враховувати під час розробки, тестування та розгортання таких транспортних засобів.

Останнім часом було запропоновано багато методів проектування автономних транспортних засобів, але література зосереджена на напіваавтономному та автономному керуванні одиночними транспортними засобами, наприклад, автомобілями. Важкі транспортні засоби демонструють унікальні поперечні динамічні характеристики. Наприклад, статична межа перекидання для важких вантажівок може становити лише 0,35 g, тоді як межа перекидання для легкових автомобілів зазвичай становить 1,1 g [7].

У 1997 році Національне управління безпеки дорожнього руху США повідомило про понад 15 000 аварій з перекиданням комерційних транспортних засобів, з яких 9400 були перекиданнями ANV [8]. З іншого боку, смертність внаслідок ДТП у США у 2017 році зросла до 5,8 відсотка порівняно з 2016 роком [9]. Проте мало уваги приділялося автономному керуванню цими великими автомобілями.

Для підвищення безпеки транспортних засобів комерціалізовано AVSS, використовується, наприклад, контроль стійкості автомобіля [10]. Ці AVSS можна класифікувати як реактивні системи безпеки (reactive safety systems – RSS), призначені для реагування на поточний стан автомобіля [11]. Хоча RSS ефективні для підвищення безпеки, вони не враховують вплив помилок водія.

Як зазначалося раніше, людські помилки спричиняють переважну більшість дорожніх зіткнень [6], і потенційним вирішенням проблеми людських помилок є автономне водіння [12], що виключає людський фактор із контуру керування. Масове розгортання систем автономного водіння гальмується через відсутність формальних підходів для перевірки безпеки таких систем у довільних ситуаціях [8-9].

Індустрія автоматизованого водіння пройшла довгий шлях, і все ще буде тривалий перехідний період, у якому більшість транспортних засобів матимуть певні можливості автономного водіння. На рисунку 1.2 зображено короткий графік розвитку автоматизованого управління транспортними засобами та функцій безпеки.

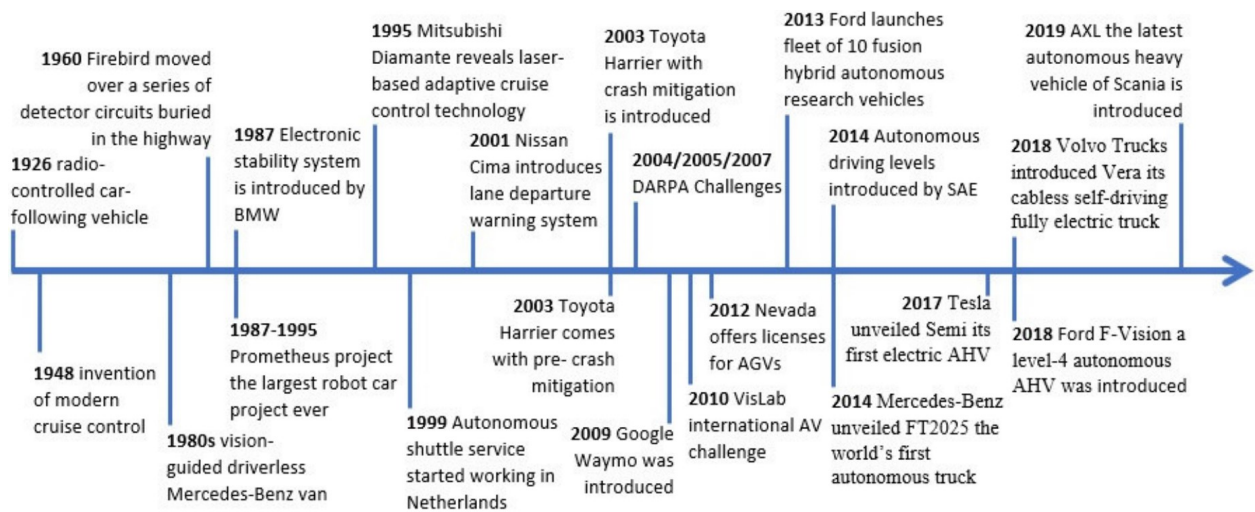


Рисунок 1.2 – Графік релізу систем автоматизованого водіння транспортних засобів

З кінця 1990-х років були розроблені та вдосконалені системи допомоги водієві, наприклад, система запобігання виїзду зі смуги руху. Ці системи класифікуються як «системи прогнозованої безпеки» (predictive safety systems – PSS), які враховують не лише поточний стан автомобіля, але й прогнозований стан автомобіля та небезпеки. Останні два десятиліття стали свідками широких досліджень напівавтономних транспортних засобів, які є транспортними засобами, керованими людиною, з можливостями автономного керування [13].

Ці транспортні засоби є автоматизованими транспортними засобами рівня 2/3 [14]. На сьогоднішній день дослідження напівавтономного та автономного водіння в основному були присвячені легковим автомобілям. Великі вантажні транспортні засоби становлять у 7,5 разів більший ризик, ніж легкові автомобілі під час експлуатації автомагістралей. Однак набагато менше уваги було приділено дослідженню цих PSS для багато-з'єднаних транспортних засобів і, зокрема, AHV.

Останнім часом кілька досліджень стосувалися автономного водіння зчленованих будівельних транспортних засобів, зчленованих транспортних засобів з автоматизованим паркуванням заднім ходом і будівельних вантажівок [9]. Ці автономні системи були розроблені лише з урахуванням

низькошвидкісного планування траєкторії та відстеження на основі кінематичного керування, нехтуючи високошвидкісною динамічною поведінкою зчленованих транспортних засобів, напр. розгойдування причепа, удари та перекидання. Взаємодія людини і машини була досліджена для покращення пасивного керування зчленованими транспортними засобами. Але взаємодія не враховується в автономному керуванні.

У літературі немає жодного опублікованого дослідження щодо напіваавтономного водіння зчленованих транспортних засобів і, особливо, АВТ [7]. У цьому курсовому проекті розглядаються деякі академічні дослідження та технологічні розробки в області автономних і напіваавтономних важких транспортних засобів з акцентом на АНУ за останні роки.

1.2 Постановка задачі

У цьому проекті треба зосередитись на аналізі нюансів властивих розробці автопілотної системи саме для далекобійних вантажівок, як базується на відеопотоку з камери у реальному часі. Мета полягає у вивченні особливостей далекобійного транспорту, підбору оптимальних технологій та пристроїв для потенційного створення повністю автономних транспортних засобів, які забезпечують автоматичне керування вантажівками на основі відеоаналізу.

2 АНАЛІЗ ДАЛЕКОБІЙНОГО ТРАНСПОРТУ

2.1 Класифікація автономності та необхідні модулі

Для автоматизації наземних транспортних засобів потрібен стандартний набір термінології та правил із таксономією та визначеннями для координації всіх зусиль, докладених у цій галузі. У 2014 році SAE International представила новий стандарт J3016, щоб полегшити співпрацю та полегшити спілкування в технічних і політичних областях. На рисунку 2.1 узагальнено рівні автоматизації водіння на основі цього стандарту.

Level	Name	Dynamic Driving Task (DDT)		DDT Fallback	Operational Design Domain (ODD)
		Sustained lateral and longitudinal vehicle motion control	Object and Event Detection and Response (OEDR)		
<i>Driver performs part or all of the DDT</i>					
0	No Driving Automation	Driver	Driver	Driver	N/A
1	Driver Assistance	Driver and System	Driver	Driver	Limited
2	Partial Driving Automation	System	Driver	Driver	Limited
<i>Automated Driving System (ADS "System") performs the entire DDT (while engaged)</i>					
3	Conditional Driving Automation	System	System	Fallback-ready user	Limited
4	High Driving Automation	System	System	System	Limited
5	Full Driving Automation	System	System	System	Unlimited

Рисунок 2.1 – Рівні автоматизації водіння [14]

Згідно з системою автономного транспортного засобу складається з трьох основних модулів, а саме:

- а) зондування та прогнозування для підготовки даних у режимі реального часу, щоб система могла розпізнавати миттєве місцезнаходження транспортного засобу та навколишнє оточення та створювати ряд даних для обробки системою.

- б) планування використання наданих даних для розробки безпечного та можливого шляху.
- в) контроль прийняття відповідних стратегій контролю, щоб привести транспортний засіб до бажаного шляху.

Після розробки відповідної стратегії керування приводи працюють як завершальний етап автоматизованого керування. У звичайному транспортному засобі водій регулює швидкість, натискаючи педаль газу або педаль гальма та повертаючи кермо, щоб керувати транспортним засобом правильним і безпечним шляхом. З іншого боку, автономні транспортні засоби потребують деяких приводів для перетворення вхідних електричних сигналів від контролера в механічні рухи для керування рульовим керуванням, дроселем двигуна тощо.

2.2 Типи АНVs

АНV – це комбінація двох або більше жорстких транспортних засобів, які з'єднані між собою механічними з'єднаннями, які називаються зчіпками, у точках з'єднання. На рисунку 2.2 показано важливі частини АНV.




Рисунок 2.2 – Типи транспортних вузлів і зчеплень, що використовують в АНV

Два найпопулярніших АНВ використовують лише один причіп, тобто тягач-напівпричіп і вантажівка з повним причепом. Багатопричіпні комбінації зазвичай утворюються шляхом з'єднання одного або кількох додаткових причепів до тягача-напівпричепа.

Комбінації з більш ніж одним причепом часто називають автопоїздами. Залежно від типу зчеплення між причепами їх називають А-, В- або С-поїздами. Рисунок 2.3 ілюструє три конфігурації.

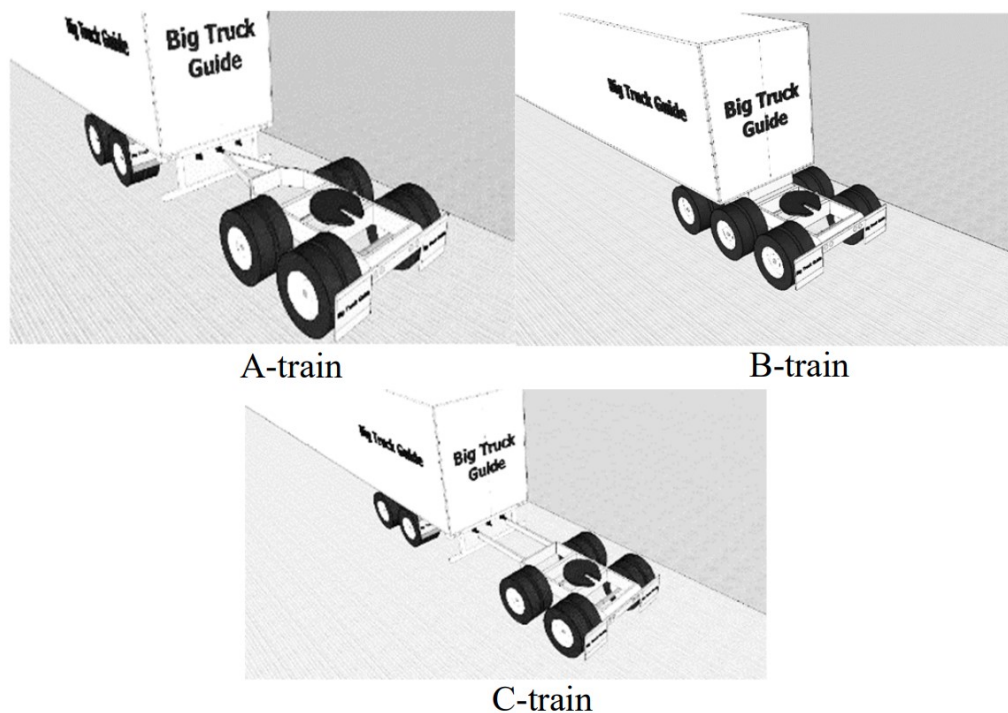


Рисунок 2.3 – Кріплення двох причепів один до одного в Північній Америці

2.3 Маневрені характеристики АНВ

Деякі правила для АНВ встановлено на основі стандартів на основі продуктивності (performance-based standards – PBS). Ці правила включають конкретні критерії ефективності, в яких необхідний рівень продуктивності визначається кількісно [7]. Один із прикладів характеристик, заснованих на продуктивності, визначених для руху АНВ в поперечному та поздовжньому напрямках, можна знайти в [15] і класифікувати їх за двома категоріями:

- а) характеристики поздовжнього напрямку, включаючи здатність до старту, здатність долати підйоми, здатність до прискорення, гальмівний шлях і здатність до утримання на схилі;
- б) характеристики бокового напрямку, що включають посилення назад (RWA), ширину траєкторії (SPW), високошвидкісне перехідне відстеження (HSTO), високошвидкісне стаціонарне відстеження (HSSO), коефіцієнт демпфування повороту (YDC), пряма лінія поза треком (SLO), час бокового кліренсу (LCT), порогове значення стійкого перекидання (SRT) і здатність до уповільнення в повороті.

Найважливішими бічними характеристиками для високошвидкісного маневрування є RWA, HSTO, HSSO та YDC, які описуються наступним чином:

- а) RWA – це співвідношення між максимальним рухом першої та останньої одиниць транспортного засобу під час певного маневру рульового керування та швидкістю транспортного засобу. Це вказує на підвищений ризик перекидання або відкидання напівпричепа. Максимальне задне посилення, дозволене австралійським PBS, у 5,7 разів перевищує порогове статичне перекидання;
- б) Характеристики відхилення від колії, HSTO та HSSO, описують бічне відхилення між траєкторією передньої осі та траєкторією найбільш сильного відхилення від колії осі напівпричепа. Приклади HSTO та HSSO наведено на рисунках 2.4 і 2.5. Ці показники вказують на додатковий простір, необхідний для напівпричепа при певному маневрі рульового керування та швидкості автомобіля;
- в) YDC – це коефіцієнт демпфування найменш демпфованого кута шарнірного з'єднання під час коливань у вільному куті транспортного засобу після певного маневру рульового керування та швидкості транспортного засобу. Довший час демпфування може призвести до більшого навантаження на водія та підвищеного ризику для безпеки інших учасників дорожнього руху.




Рисунок 2.4 – Маневр зміни смуги, що ілюструє HSTO, RA та YDC [7]




Рисунок 2.5 – Стационарний маневр, що ілюструє HSSO [7]

2.4 Моделі транспортних засобів, що використовуються в розробці автоматизованого контролера водіння

Протягом десятиліть досліджень бокової динаміки транспортних засобів переважно використовувалася лінійна модель керування, відома як модель велосипеда. Моделі транспортних засобів зазвичай передбачають, що кузов автомобіля є твердим тілом із зосередженою підресореною масою в центрі ваги. Зазвичай використовувана модель, яка враховує лише бічні рухи та рухи від ухилу, відома як модель керування. Є три основні моделі транспортних засобів,

включаючи геометричні, кінематичні та динамічні моделі. У геометричній моделі враховуються лише геометричні розміри автомобіля. Кінематична модель просто розглядає рух транспортного засобу з точки зору прискорення, швидкості та положення. Динамічна модель, інакше, розглядає рух транспортного засобу з точки зору його внутрішніх сил, інерційних та енергетичних властивостей.

Моделі, що використовуються для тягачів-напівпричепів, мають широкий діапазон складності від великих багатокузовних комбінацій з численними ступенями свободи, які вимагають дорогих розрахунків порівняно з простими моделями велосипедів із 3 DOF. У багатьох опублікованих дослідницьких роботах, таких як [8], використовувалася спрощена 3-колісна лінійна модель із 5 DOF. Цієї простої моделі здається цілком достатньою для аналізу поперечної стійкості тягача-напівпричепа на траєкторії, дотримуючись розробки стратегії керування, яка є невід'ємною частиною будь-якого автономного проекту АНУ. На рисунку 2.6 показана схема цієї моделі.




Рисунок 2.6 – Схематичне зображення моделі АНУ

2.5 Переваги автономних ANV та перешкоди для впровадження

Таблиця 1 висвітлює масштаби ДТП у Північній Америці та вказує на те, що більшість аварій стається через людські помилки, включаючи неуважність, відволікання або перевищення швидкості. Крім того, це вказує на те, що значна частина смертельних аварій пов'язана з важкими транспортними засобами, що включають ANV. У результаті, чим більше важкий транспортний засіб використовує автономність, тим менше буде аварій зі смертельними наслідками. Погана погода, наприклад туман і сніг, є ще однією складною ситуацією для водіїв, яку можна вирішити за допомогою датчиків і штучного інтелекту як невід'ємної частини автоматизованого водіння в ANV.

Окрім підвищення безпеки ANV, дослідники вважають, що використання лише функції ACC як примітивної функції автономності може збільшити економію палива та затори на дорозі на 23-39% та 8-13% відповідно для всіх транспортних засобів у потоці руху по шосе. Крім того, за оцінками, до 2025 року 5-20% усіх автомобілів будуть або автономними, або напівавтономними, а кінцевий глобальний фінансовий вплив становитиме від 200 до 1,9 трильйонів доларів.

Першим бар'єром на шляху до великомасштабного ринку автономних ANV є вартість, через технологію, яка потребує додаткових нових датчиків, комунікаційних мереж, навігаційних пристроїв і спеціального програмного забезпечення. Наприклад, системи LiDAR на додачу до інших датчиків коштують до 70 000 доларів США для LiDAR великої дії, що, здається, є життєво важливим принаймні для поточної технології автоматизованого водіння ANV.

Інші проблеми включають відсутність законодавства, що стосується водіння автономних ANV, обмеження щодо сертифікації AV, виникнення проблем щодо страхування та відповідальності та занепокоєння щодо електронної безпеки, комп'ютерних хакерів і терористичних програм.

3 ОГЛЯД ТЕХНОЛОГІЙ ТА ПРИСТРОЇВ ДЛЯ АНУ

3.1 Слідування маршрутом та бічне керування АНVS

Існує дві основні цілі для управління АНУ в рамках автономного та напіваавтономного водіння. Щоб контролювати як поздовжню, так і поперечну динаміку за допомогою вбудованої системи керування зі складним програмним забезпеченням, яке насправді є кодами, написаними для виконання роботи. Алгоритми керування включають вищий рівень контролю (контроль стратегії) та нижчий рівень контролю (контроль автомобіля).

Перший приймає рішення на основі даних, отриманих від інфраструктури та інших транспортних засобів, на які впливають шляхом маневру. Останнє включає в себе керування транспортним засобом, дросельною заслінкою та гальмами.

Управління поздовжньою динамікою АНУ в основному стосується регулювання швидкості транспортного засобу з метою збереження достатнього простору між транспортними засобами.

Для реалізації успішного поздовжнього контролю необхідні чотири типи даних. Швидкість і прискорення транспортного засобу-господаря, швидкість і прискорення транспортного засобу, що йде попереду, відстань до транспортного засобу, що веде, а також у разі взводу швидкість і прискорення першого транспортного засобу.

Бічне управління АНУ полягає в проїзді транспортного засобу близько до центру потрібної смуги, яка включає не тільки пряму ділянку дороги, але й криву дорогу, а також об'їзд (маневр утримування смуги).

За таких складних умов експлуатації перекидання є типовою аварією, з якою АНУ може стикатися під час зміни смуги руху або поворотів, що часто призводить до важких результатів, наприклад, до значних фінансових витрат і смертельних випадків. Зазвичай це пов'язано з вищим центром ваги (CG)

важких транспортних засобів порівняно з легковими. Отже, для підвищення стійкості на крені слід використовувати ефективні стратегії контролю, такі як активне керування підвіскою, активне рульове керування та активне гальмування. Слідування шляху є життєво важливим питанням для автономного водіння. Контроль руху за траєкторією для AGV передбачає автономне маневрування транспортним засобом за допомогою керма. Це допоможе автомобілю слідувати бажаним шляхом, визначеним навігаційною системою за допомогою датчиків. Існують різні стратегії бокового керування ANV під час слідування траєкторії. Деякі дослідники запропонували використовувати активну систему рульового керування причепом для покращення слідування траєкторії та контролю стійкості AGV.

Наприклад, у дослідженні [4] модель прогнозуючого контролера була використана, щоб змусити транспортний засіб слідувати траєкторії та куту повороту, передбаченому для причепа, мінімізуючи кут бокового ковзання для різних умов автомобіля. Розроблений контролер ефективно покращив бічну стійкість і відхилення причепа за допомогою чисельного моделювання. В іншому дослідженні [5] активний контролер рульового управління причепом на основі LQR призначений для покращення поперечної стійкості тягача-напівпричепа на високих швидкостях і маневреності на низьких швидкостях.

Дослідники використовували лінійну модель 3-DOF та алгоритм оптимізації роя частинок із симуляцією відпалу на основі середовища TruckSim-Simulink, і результати були цікавими. Був запропонований метод поперечно-поздовжнього керування, щоб уникнути різання під час автоматизованого керування [15]. Засікання було попереджено завдяки використанню механізму проти змотування, який контролював кут з'єднання від перевищення межі. Посилання повідомляє про дослідницьку роботу, в якій прийнята стратегія керування, щоб змусити тягач і напівпричіп ANV рухатися різними шляхами на різних швидкостях транспортного засобу та за наявності зовнішніх перешкод. Вони використовували контролер на основі нелінійної кінематики для низьких швидкостей, тоді як він не підходив для високих

швидкостей через значні зміни характеристик бічного ковзання. Таким чином, вони поєднали як низькошвидкісні, так і високошвидкісні контролери, використовуючи залежне від швидкості посилення в середньому діапазоні швидкостей. Результати моделювання довели покращення маневреності на низьких швидкостях і підвищення стабільності на високих швидкостях.

В іншій дослідницькій роботі [7] був представлений новий контролер утримування смуги руху, щоб утримувати позицію АНУ (бічну та кутову) на смузі, а також підтримувати її стабільність у критичній ситуації. Вони використали оптимальну техніку керування та нечітку стратегію контролю, щоб адаптувати контролер до різних поведінок водіїв. Система була в основному керованою людиною АНУ, яка належним чином реагувала у випадку, коли АНУ відхилявся від бажаного шляху.

Для демонстрації ефективності розроблених контролерів використовувалися різні тестові маневри. Була запропонована конструкція контролера для вирішення проблеми слідування траєкторії для зчленованих роботизованих транспортних засобів, які були обладнані декількома позаосьовими причепами [5]. Контролер був високомасштабованим нелінійним каскадом, який не вимагав встановлення найкоротшої відстані до ідеального шляху. Замість цього він використовував опорний шлях сегментного взводу (запроваджений дослідниками), щоб забезпечити проходження асимптотичного шляху.

Емпіричні результати показали малу чутливість розробленого регулятора до невизначеності параметрів. В іншому дослідженні була введена нова стратегія керування режимом ковзання (SMC) для відстеження траєкторії зчленованих транспортних засобів. Розроблений контролер націлений на досягнення кращих можливостей відстеження, мінімізуючи помилку відстеження та зменшуючи феномен тріскання. SMC було отримано на основі нелінійної кінематичної моделі зчленованого автомобіля, а стійкість стратегії керування перевірено за методом стійкості Ляпунова. Нарешті, дослідники оцінили продуктивність свого контролера в різних сценаріях шляхів,

використовуючи дрібномасштабну модель. Що стосується запобігання перекиданню у важких транспортних засобах, посилення задокументувало комбінований активний стабілізатор поперечної стійкості (AARB) і активний контролер гальмування. Посилення представило стратегію керування лінійним квадратичним статичним вихідним зворотним зв'язком, використовуючи як AARB, так і електронну програму стабільності для більш ефективного вирішення проблеми перекидання.

В одному дослідженні [15] стратегія керування на основі MPC була розроблена для покращення стійкості на крені під час маневру за траєкторією. У той час як гальмо та рульове керування взаємопов'язані в контролері верхнього рівня (UPC), результати моделювання продемонстрували, що ця багаторівнева структура керування гарантує відстеження шляху з невеликою похибкою. Дослідники представили AARB, включаючи гідравлічний привід із чотирма електронними сервоклапанами, для активного керування важким транспортним засобом шляхом вирішення проблеми оптимізації LQ, де передне рульове керування вважається невизначеним порушенням [15].

Результати моделювання в частотній і часовій областях підтвердили значне покращення з точки зору стабільності перекидання. У роботі [15] була запропонована нова стратегія контролю стійкості на крені для важких транспортних засобів, яка називається динамічним шляхом на основі теорії ігор, який слідує за інтерактивною спільною стратегією проти крену (AAR). Це справді був кооперативний контролер стабільності слідування за креном, який мав двох гравців, тобто AARB і AS, визначених за допомогою теорії рівноваги Неша зі зворотним зв'язком.

3.2 Сенсорні технології для автономних AHVS

Спосіб, за допомогою якого автономний транспортний засіб дізнається про навколишнє середовище, відбувається через його датчики. Датчики повинні бути здатні забезпечувати як перцептивний, так і локаційний огляд

навколишнього середовища, щоб транспортний засіб міг приймати рішення в режимі реального часу. Датчики використовуються для виявлення доріг, учасників руху, включаючи транспортні засоби та пішоходів, перешкод на їх шляху та периферійного середовища. У більшості ситуацій ці датчики мають бути здатні визначати відстань між транспортним засобом та іншими суміжними об'єктами, а також їхні відносні швидкості.

Як правило, немає різниці в типі датчиків, що використовуються для легкових транспортних засобів і АНУ. Відмінності в основному стосуються розташування датчиків і їх кількості. Наприклад, однією з відмінностей є місце на кузові транспортних засобів, у які слід вбудовувати датчики через різноманітність розмірів, застосування та рівня автономності різних класів транспортних засобів. Існує багато типів датчиків, призначених для використання в автономному керуванні, деякі з них більш поширені, і їх можна класифікувати за двома основними категоріями, як показано на рисунку 3.1.

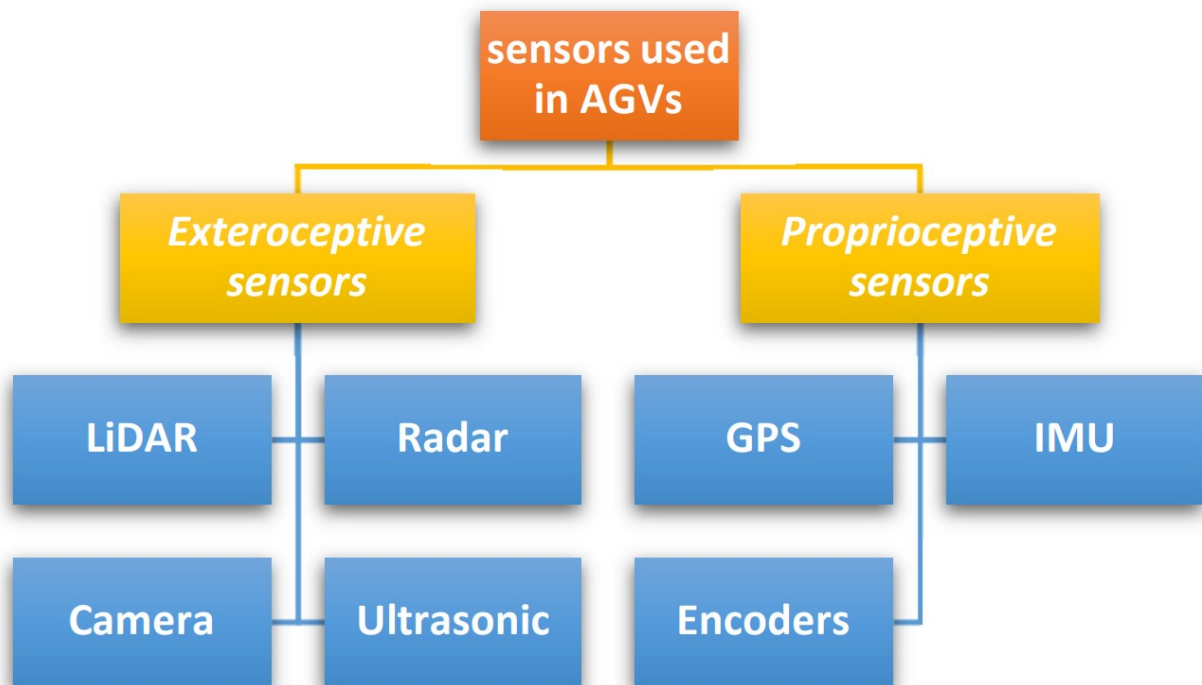


Рисунок 3.1 – Основні датчики, що використовуються в автоматизованому водінні

LiDAR (Light Detecting & Ranging) — це метод геодезії, який вимірює відстань до цілі шляхом освітлення цілі лазерним світлом і вимірювання відбитого світла за допомогою датчика. Різниця в часі повернення лазера та довжина хвиль можна використовувати для створення цифрових тривимірних зображень цілі. Важливим параметром датчиків LiDAR є відстань, яку вони можуть виявити для розпізнавання об'єктів. Погодні умови, наприклад, рівень вологості та рівень відбивної здатності об'єкта, значно впливають на дальність виявлення. Сучасні датчики LiDAR здатні вимірювати відстані зі швидкістю понад 150 кілогерц (150 000 імпульсів на секунду) і класифікуються як датчики дальнього радіусу дії з діапазоном понад 250 м або малого радіусу дії [6].

Повний потенціал цих датчиків ще не повністю вивчений через їх високу вартість і низьку доступність. Це складні механічні системи дзеркал, які забезпечують повну видимість на 360° і можуть коштувати цілий статок. Сьогодні спостерігається зсув у бік розробки недорогих датчиків LiDAR, які більш підходять для широкого використання. Наприклад, твердотільний LiDAR та інфрачервоний LiDAR. На рисунку 3.2 показано сенсорні технології, включаючи LiDAR, які можна використовувати, щоб зробити АНВ здатним рухатися самостійно.

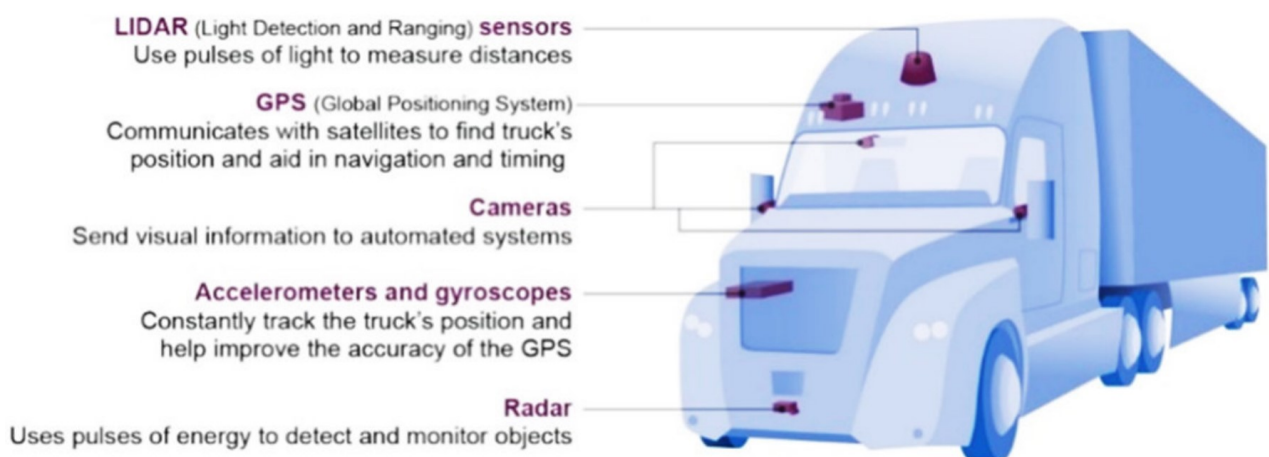


Рисунок 3.2 – Сенсорні технології, які можуть бути використані в автономних АНВ [8]

Радар – це технологія, яка використовує електромагнітне випромінювання для вимірювання відстані, кута та швидкості об'єктів. Він працює за принципом радіочастот, які можна використовувати в декількох частотних діапазонах. (наприклад, 24 ГГц, 79 ГГц). Вища роздільна здатність виявлення досягається за рахунок вищих частот, і це дозволяє системі розрізняти багато об'єктів у навколишньому середовищі. На відміну від LiDAR, радар має менший вплив погодних умов.

Радіолокаційні датчики класифікуються на датчики ближнього і середнього діапазону від 50 м до 100-150 м і далекого радіусу дії, здатні виявляти об'єкти на відстані 250 м [7]. Оскільки ці типи датчиків набагато дешевші, ніж датчики LiDAR, і здатні виявляти об'єкти за будь-яких погодних умов, радарні датчики більше підходять для цілей автономного водіння. Однак їх мале поле зору (FOV), яке зазвичай становить 45° , вважається негативним моментом порівняно з LiDAR.. Важливою перевагою радарів є те, що вони здатні визначати відносну швидкість спостережуваних об'єктів, що є перевагою для автоматичного гальмування або адаптивного круїз-контролю в AGV.

Камера працює на основі пасивних датчиків світла для отримання цифрового зображення охопленої області простору. Камери можуть виявляти як рухомі, так і статичні об'єкти в своєму оточенні. Однією з головних можливостей камер є те, що вони можуть ідентифікувати кольори та текстури. Це може підвищити сприйняття автономного водіння. Вони також дешеві та легкодоступні. Мінусом цього датчика є те, що вони чутливі до несприятливих погодних умов і низької інтенсивності світла.

Крім того, оскільки зображення є 2D, розпізнавання відстані до об'єкта за допомогою зображення може бути визначено лише за допомогою складних алгоритмів обробки [3]. У таблиці 3.1 представлено порівняння функціональностей сенсорних технологій.

Незважаючи на недоліки камер, на конференції 2019 року TESLA оголосила, що вони знайшли дуже успішні методи (поєднання алгоритмів глибокого навчання, штучного інтелекту та потужних графічних процесорів)

для використання лише кількох камер для ефективного розпізнавання навколишнього середовища автомобіля замість використання дуже дорогих датчиків LiDAR або Radar.

Таблиця 3.1 – Порівняння функціональностей сенсорних технологій

Критерії	Радар	LiDAR	Ультразвук	Камера
Виявлення на дуже короткій відстані (до 1м)	Нормально	Погано	Дуже добре	Нормально
Виявлення на короткій відстані (1-30 м)	Дуже добре	Дуже добре	Погано	Добре
Дальнє виявлення (30-100 м)	Дуже добре	Середньо	Немає	Погано
Кут $<10^{\circ}$	Добре	Дуже добре	Погано	Добре
Кутова роздільна здатність	Добре	Дуже добре	Погано	Добре
Вимірювання швидкості авто	Є	Немає	Немає	Немає
Погані погодні умови	Дуже добре	Погано	Добре	Погано
Ніч	Дуже добре	Дуже добре	Дуже добре	Обмежено

Вони вважають, що наступному поколінню автономних транспортних засобів просто потрібні камери, встановлені в різних місцях кузова транспортного засобу, і використання датчиків обробки зображень і глибокого навчання, які використовуються для навчання центрального процесора приймати найкращі рішення в кожній конкретній ситуації водіння. GPS (супутникові радіонавігаційні системи) є звичайними датчиками геолокації та

навігації. Інерціальні одиниці вимірювання (IMU) – це електронні пристрої, які можуть вимірювати силу тіла, кутову швидкість і магнітне поле. IMU в поєднанні з кодерами є електромеханічними пристроями, які можуть перетворювати лінійне або кутове положення вала в аналоговий або цифровий сигнал. GPS, IMU та кодери є трьома життєво важливими датчиками, які допомагають автомобілям керувати автономно.

Враховуючи важливість розширених можливостей датчиків для автономних транспортних засобів, інженери та дослідники активно працюють над новими технологіями та підходами. Однією з перспективних напрямків є використання радарів та лідарів, які можуть надавати додаткову інформацію про оточуючий простір. Радари визначають відстань до об'єктів за допомогою висилання радіосигналів і аналізу їх відбиття, що дозволяє отримувати точні дані про рух і розташування навколишніх об'єктів. Лідари, у свою чергу, використовують лазерне випромінювання для точного вимірювання відстаней та створення тривимірних карти оточення.

Додатково, сенсори для виявлення звуків та відслідковування акустичних сигналів можуть бути використані для покращення сприйняття оточуючого середовища, забезпечуючи системі додаткові дані для прийняття рішень. Використання тепловізорів може стати корисним для виявлення та класифікації об'єктів в низьких світлових умовах або в умовах обмеженої видимості.

Окрім цього, розвиток комунікаційних технологій може допомогти автономним транспортним засобам обмінюватися інформацією між собою, сприяючи більш ефективному управлінню рухом на дорозі та попередженню небезпечних ситуацій.

Усі ці інновації спрямовані на те, щоб зробити автономне водіння ще безпечнішим та надійнішим, забезпечуючи транспортним засобам здатність адаптуватися до різноманітних умов на дорозі та надавати водієві високоякісний та ефективний допоміжний сервіс.

4 ЗАВДАННЯ ДЛЯ АВТОНОМНИХ ТРАНСПОРТНИХ ЗАСОБІВ

4.1 Сприйняття для автономних транспортних засобів

Сприйняття є критично важливим аспектом автономного водіння, оскільки автомобіль повинен взаємодіяти із навколишнім середовищем, аналізувати його та реагувати на зміни в реальному часі. Техніка сприйняття, заснована на методі глибокого навчання для автоматизованих систем водіння, використовує інноваційні методи обробки даних, зокрема хмару точок виявлення та визначення діапазону світла (LiDAR), і відома під назвою мережі одночасного сегментування та виявлення (SSADNet).

SSADNet використовує комплексні алгоритми глибокого навчання для ефективного аналізу інформації від сенсорів. Ця технологія дозволяє автономному транспортному засобу відокремлювати та ідентифікувати різні об'єкти в навколишньому середовищі, такі як інші транспортні засоби, пішоходи, дорожні знаки та інші елементи інфраструктури.

Хмара точок виявлення дозволяє отримувати тривимірні дані про оточуючий простір, а LiDAR забезпечує точні відстані до об'єктів. Використання цих даних в SSADNet дозволяє автомобілю створювати детальну та точну модель свого оточення, що робить можливим більш точне прийняття рішень під час руху.

SSADNet використовується для реалізації завдань сегментування та виявлення об'єктів одночасно, що підвищує ефективність та точність процесу сприйняття в автономних транспортних засобах. Ця технологія вирішує виклики, пов'язані зі складністю дорожнього середовища та різноманітністю об'єктів, з якими може стикатися автономний автомобіль у реальних умовах руху.

4.2 Планування руху для автономних транспортних засобів

У рамках планування руху також важливо враховувати та адаптуватися до стилю водіння сусідніх транспортних засобів, керованих людьми. Аналізуючи їхні дії, автономний транспортний засіб може прогнозувати можливі зміни швидкості, траєкторії та інших параметрів руху, що дозволяє ефективно взаємодіяти з оточуючим трафіком та мінімізувати ризик виникнення непередбачених ситуацій.

Оцінювання та адаптація до змін смуги є ще однією важливою частиною планування руху. Системи автоматизованого транспортного засобу повинні здати облік не тільки руху на поточній смузі, але і можливості зміни смуги з урахуванням інших учасників дорожнього руху. Це включає в себе планування безпечних маневрів, які дозволяють уникнути конфліктів з іншими транспортними засобами та забезпечують плавний перехід між смугами. Планування руху, як важлива складова системи керування автономними транспортними засобами, представлено на рисунку 4.1.

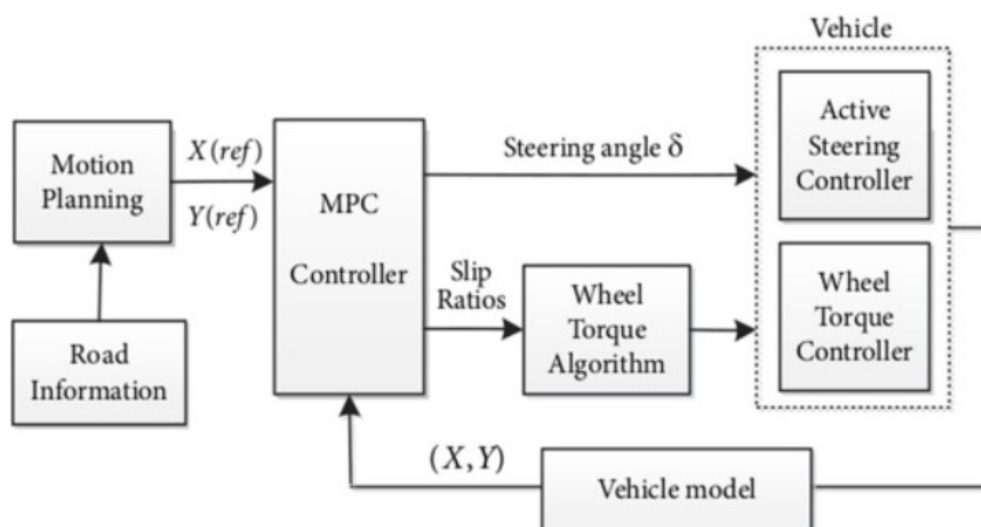


Рисунок 4.1 – Блок-схема керування автономним транспортним засобом

Цей процес включає в себе аналіз даних від усіх доступних датчиків, прийняття рішень на основі цих даних та вибір оптимального маршруту та стратегії руху. Планування руху дозволяє автономним транспортним засобам адаптуватися до змінних умов дорожнього руху та забезпечує безпечне та ефективне переміщення в будь-якому середовищі.

Алгоритм планування руху [16] визначає бажані шляхи для певних сценаріїв. Техніка на основі вибірки, штучне потенційне поле (APF), методика оптимального керування є трьома ключовими категоріями методу розробки алгоритму для планування руху. APF створює можливе поле руху транспортного засобу на основі тяги до цілі та відштовхування перешкоди, а потім досліджує шлях, який є найкоротшим до цілі, залежно від потенційного градієнта поля, і в цьому обчислювальна вартість невелика. Незважаючи на те, що алгоритм створює поле для поточного стану транспортного засобу та даних навколишнього середовища, він навряд чи може врахувати майбутні дії за кермом.

У вибіркового методі проблема безперервного планування перетворюється на чітко-пошукову. Насамперед простір конфігурації дискретизується на послідовність пробних точок, а потім досліджується порядок точок, які відповідають вимогам місії. Випадкове дерево є одним із найбільш часто використовуваних для цієї мети. Планувальник руху використовує стан транспортного засобу, який включає в себе поперечне прискорення, швидкість відхилення та поздовжню швидкість як його вхідні дані. Він керує транспортним засобом, використовуючи кут повороту керма та поздовжнє прискорення.

Динамічна модель із одним зв'язком (SDM) використовується для керування різними впливами динамічного зв'язку шляхом виділення та впорядкування складного. Модель, побудовану на Reinforcement-Learning (RL), можна використовувати для контролю швидкості. Щоб підвищити продуктивність водіння, встановлюється функція винагороди за допомогою

звернення до статистики водіння людини та поєднання пов'язаних з безпекою характеристик водіння, ефективності та легкості. Разом зі створеною функцією винагороди, коли агент RL навчається регулювати швидкість транспортного засобу таким чином, щоб отримати максимальну віддачу від сукупних винагород, щоб уникнути потенційних небезпек, запланована модель RL поєднується разом із підходом до запобігання зіткненням для перевірки безпеки. Алгоритм під назвою Глибокий детермінований градієнт політики (DDPG) добре працює в полі безперервного контролю та використовується для копіювання мережі акторів разом із мережею критиків.

Використовується глибокий детермінований градієнт політики (DDPG), оскільки прискорення транспортного засобу є недискретною змінною. Середній час прогресу для моделі DDPG, MPC-залежного алгоритму ACC і водіїв-людей становить 1,24 с, 1,23 с і 1,61 с відповідно. MPC-залежний алгоритм ACC і модель DDPG можуть відстежувати найкращий транспортний засіб з ефективним і безпечним часом. ShufflePointNet, яка є глобальною нейронною мережею, використовується для вивчення локальних зображень для даних хмари точок. Алгоритм нейронної мережі під назвою Light Gated Recurrent Unit (Li-GRU) використовується для оцінки траєкторії.

Метою планування траєкторії зазвичай є пошук можливого зв'язку від вихідного стану для досягнення цільового стану. Попереднє прогнозування для автономних транспортних засобів можна зробити за допомогою підкріпленого навчання та глибокого зворотного підкріплення. Інтерфейс між автоматизованим транспортним засобом і навколишнім середовищем можна змоделювати як стохастичний марковський процес прийняття рішень (MDP) і навмисний метод водіння досвідченого водія як мішені для ерудиції.

Спочатку для дослідження можливого шляху на карті перешкод використовується алгоритм випадкового дерева цільового швидкого дослідження (GDRRT), а потім використовується пошук найдалшого вузла (FNS), щоб отримати послідовність життєво важливих. Політика довільної

вибірки, яку підтримує випадкове дерево швидкого дослідження (RRT), має широкий спектр досліджень, високу швидкість дослідження, високу обчислювальну майстерність, а під час планування шляху немає необхідності розробляти моделі перешкод.

Загальна схема автоматизованої системи водіння, яка складається з контролера, картографування середовища, сприйняття та планування руху, показана на рисунку 4.2. Упорядкована система керування включає глобальне планування шляху (GPP), прийняття рішень, локальне планування шляху та піраміди керування від низького до високого рівня, як показано на рисунку 4.2.

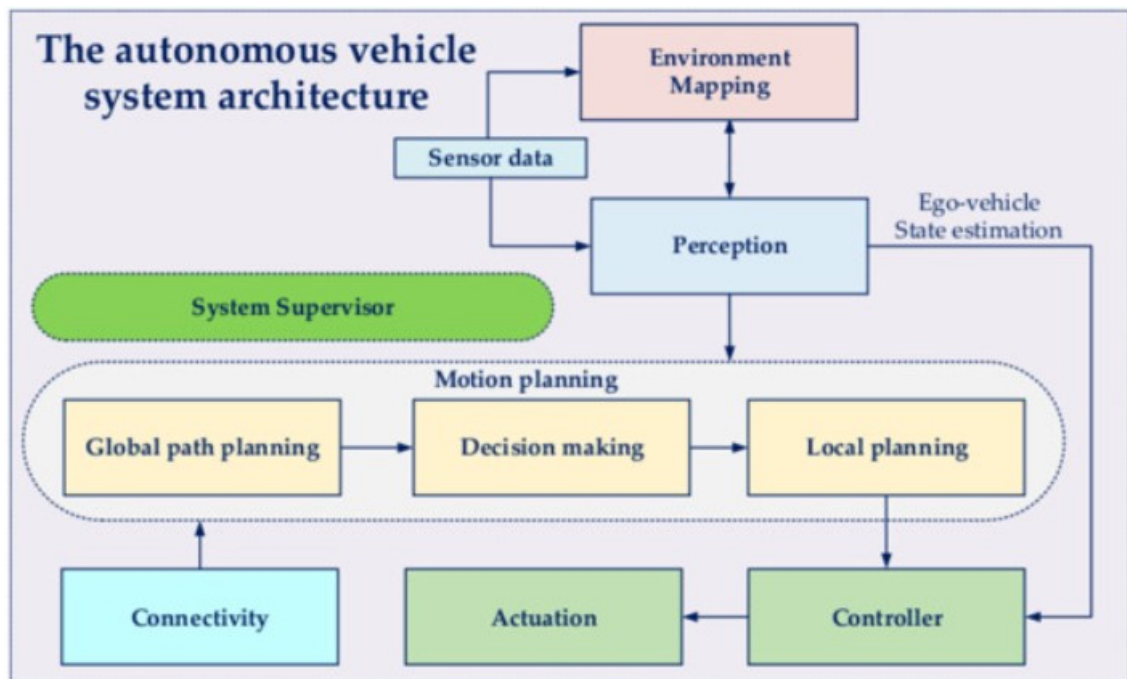


Рисунок 4.2 – Блок-схема планування руху системою автономного водіння

Планувальник локального маршруту (LPP) створює локальну траєкторію для автоматизованого транспортного засобу як для структурованих, так і для неструктурованих сценаріїв. Алгоритм Amalgam A-star у режимі реального часу разом із картою сітки зайнятості використовується для виявлення ефективного

шляху запобігання перешкодам. Потім виконується планування локального шляху, щоб створити безпечну та задоволену траєкторію в неструктурованих обставинах. Можна використовувати інноваційну практику планування шляху з урахуванням ризиків для автономних транспортних засобів, засновану на телематичній поведінковій інформації.

4.3 Розпізнавання пішоходів під час автономного водіння

Розпізнавання пішоходів є одним із життєво важливих завдань автономного водіння. Важливим фактором, який впливає на застосування методів виявлення пішоходів під час автономного водіння, є великий обсяг обробки даних, що призводить до високих вимог до надійності та фактичної продуктивності використовуваного алгоритму.

Методи розпізнавання пішоходів можна розділити на дві групи з точки зору отримання ознак. Один – це метод машинного навчання, заснований на штучних функціях, а другий – метод глибокого навчання, побудований на функціях згорткової нейронної мережі (CNN).

Структура методів машинного навчання включає вилучення ознак і класифікатори. Функції тут в основному включають «гістограму орієнтованих градієнтів (HOG)», локальний бінарний шаблон (LBP), модель деформованої частини (DPM) і функцію агрегатного каналу (ACF). Класифікатори включають «Машину опорних векторів (SVM)», «Дерево рішень (DT)», «Випадковий ліс (RF)» та Ada-Boost.

Структура методів глибокого навчання складається з глибокої CNN і класифікатора, який використовує глибоку CNN для виділення ознак, а в типових структурах, таких як «GoogleNet», «ZFNet», «AlexNet», «VGGNet» і ResNet, класифікатор зазвичай це звичайна повнозв'язана нейронна мережа. R-CNN, «YOLO» та інші фреймворки виявлення глибокого навчання покращили

продуктивність виявлення пішоходів, ніж традиційне машинне навчання, але навчання їхніх моделей включає апаратне забезпечення з високою обчислювальною потужністю та величезними наборами даних.

Алгоритм агрегатного каналу (ACF) є одним із широко відомих алгоритмів виявлення пішоходів. Алгоритм ACF побудовано на «Інтегральних функціях каналу (ICF)», а в алгоритмі використовується класифікатор AdaBoost, що складається з 2048 дворівневого дерева рішень. Обмеження цього алгоритму полягає в тому, що існує кілька пропущених виявлень, коли ціль прихована або мала. Щоб подолати це обмеження, можна використовувати алгоритм виявлення пішоходів, побудований на суміші п'ятирівневої структури згортової нейронної мережі та класифікатора AdaBoost (CNN–AdaBoost). Загальна архітектура алгоритму CNN–AdaBoost показана на рисунку 4.3.

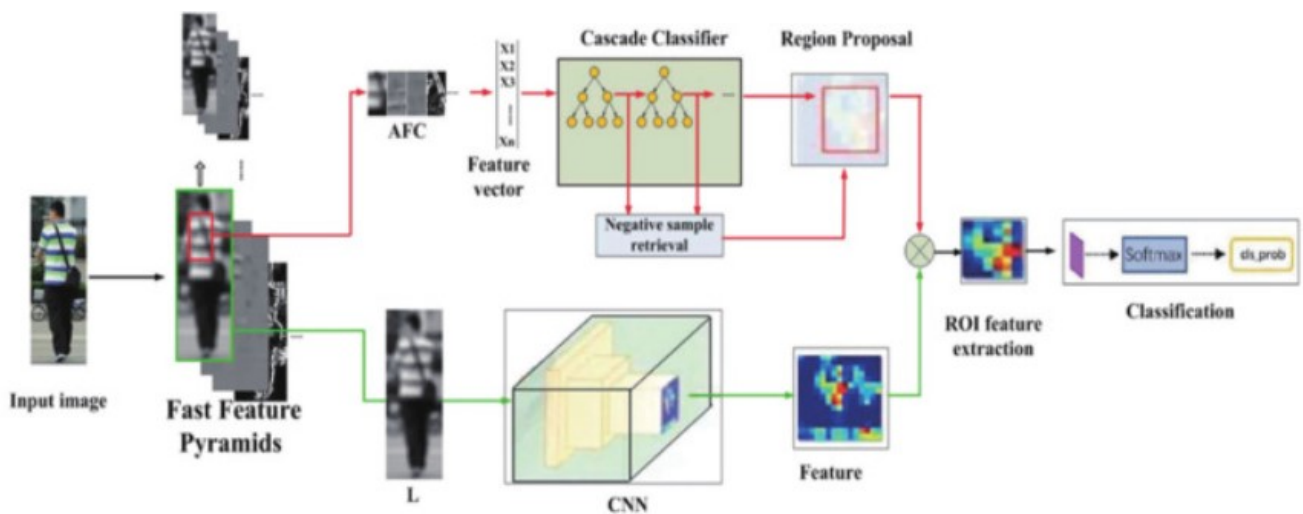


Рисунок 4.3 – Блок-схема архітектури алгоритму CNN–AdaBoost

Архітектура включає чотири частини: швидку піраміду функцій, вибір пропозицій регіону, вилучення функцій CNN і частину обробки функцій. Алгоритм ACF має найвищу швидкість виявлення, але рівень помилкових

виявлень є найвищим, причому кількість помилкових виявлень на кадр досягає 3,784. Алгоритм «Locally Decorrelated Channel Features (LDCF)» має менше помилкових виявлень, але частота пропущених виявлень вища, ніж у запропонованого методу, і його ефективність виявлення низька.

Середній час виявлення кадру становить 0,1255 с. Алгоритм CNN–AdaBoost має нижчий коефіцієнт виявлення промахів, ніж алгоритм ACF, зберігаючи при цьому вищу швидкість виявлення. Середній час виявлення кадру становить 0,0809 с, що близько до швидкості алгоритму ACF.

4.4 Розпізнавання дорожніх знаків для автономного водіння

Ще одним важливим завданням автономного водіння є розпізнавання дорожніх знаків на основі відео, відстеження та розпізнавання через відсутність зв'язку транспортного засобу з інфраструктурою (V2I) в існуючій транспортній системі. Конвеєр обробки для світлофорного детектора в реальному часі показаний на рисунку 4.4.

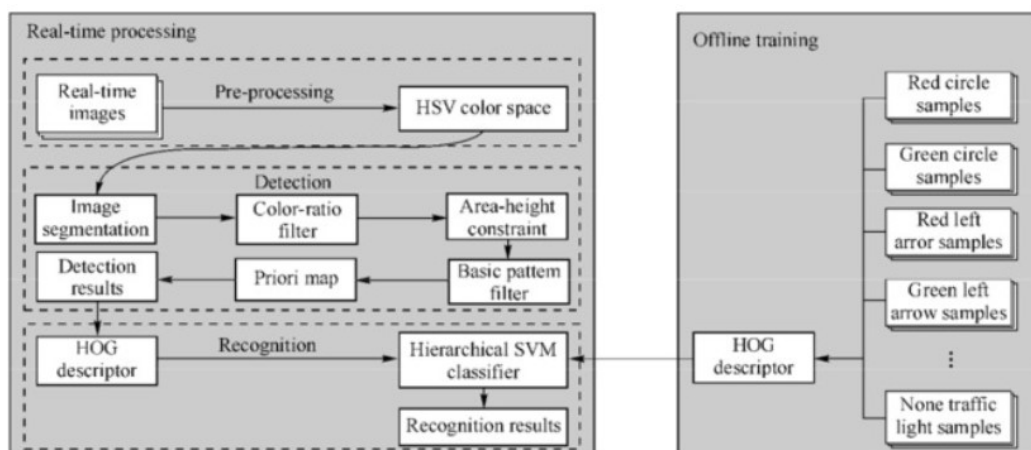


Рисунок 4.4 – Блок-схема конвеєру обробки для детектора світлофора в реальному часі

Емпіричний пошук ROI спочатку намагається виявити всі ймовірні світлофори (з певним фоном помилок), а потім класифікатор CNN намагається класифікувати справжній клас кожної ROI, а потім показує результат. Для алгоритму, що використовує камеру, потік обробки зображення буде розділено на три етапи, які включають попередню обробку, виявлення та розпізнавання.

Спочатку колірний простір червоний, зелений, синій (RGB) перетворюється на відтінок, насиченість, значення (HSV) як ключову частину попередньої обробки. На етапі виявлення метод порогу містичного кольору використовується для початкової фільтрації, а тим часом попередні дані використовуються для дослідження сцени таким чином, щоб швидко створити регіони-кандидати.

4.5 Розпізнавання дорожньої розмітки для автономного водіння

Виявлення дорожньої розмітки є важливою діяльністю для автономного водіння. Удосконалений швидший R-CNN, який має нову структуру, яка враховує багатопланове поєднання функцій, може використовуватися для розмітки доріг/виявлення смуги руху.

Система виявлення для нанесення дорожньої розмітки містить 3 мережі:

- а) екстрактор ознак (VGG-16) із об'єднанням функцій;
- б) мережа детекторів – швидкий детектор R-CNN, який містить рівень об'єднання ROI (регіон інтересів) і класифікацію;
- в) «Region-Proposal-Network (RPN)».

Модуль об'єднання функцій для виявлення дорожньої розмітки показано на рисунку 4.5 та конвеєр для моделі виявлення показаний на рисунку 4.6.

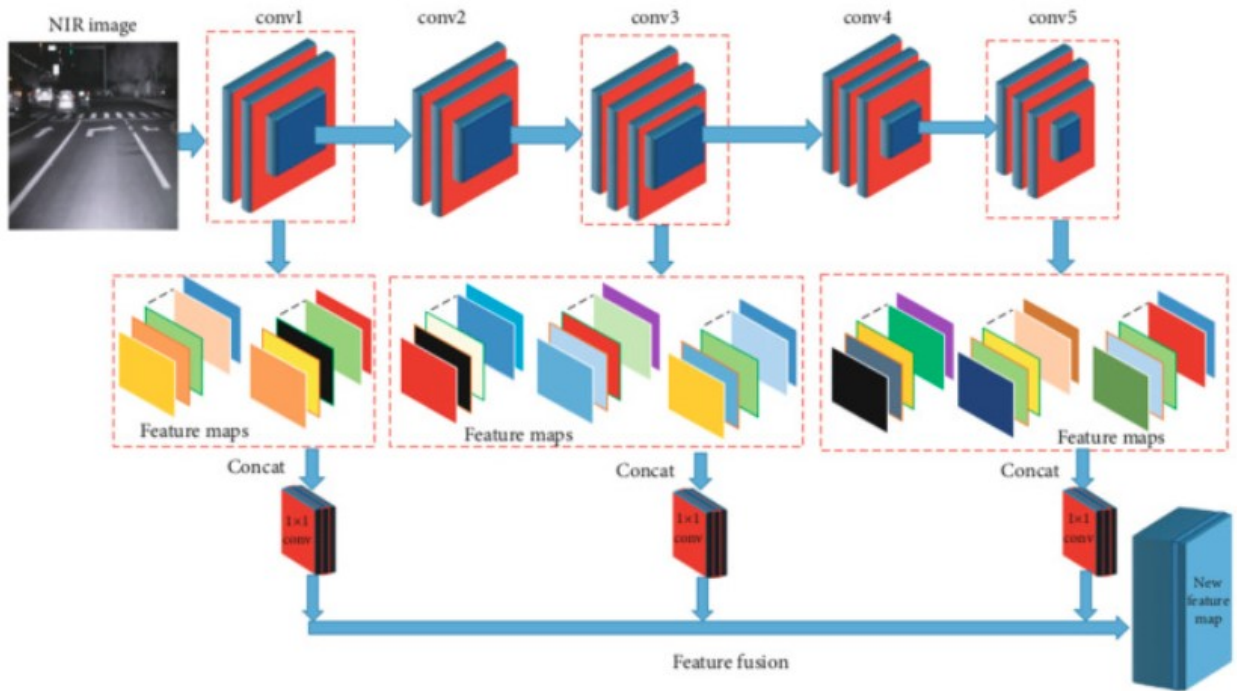


Рисунок 4.5 – Блок-схема модулю об'єднання функцій.

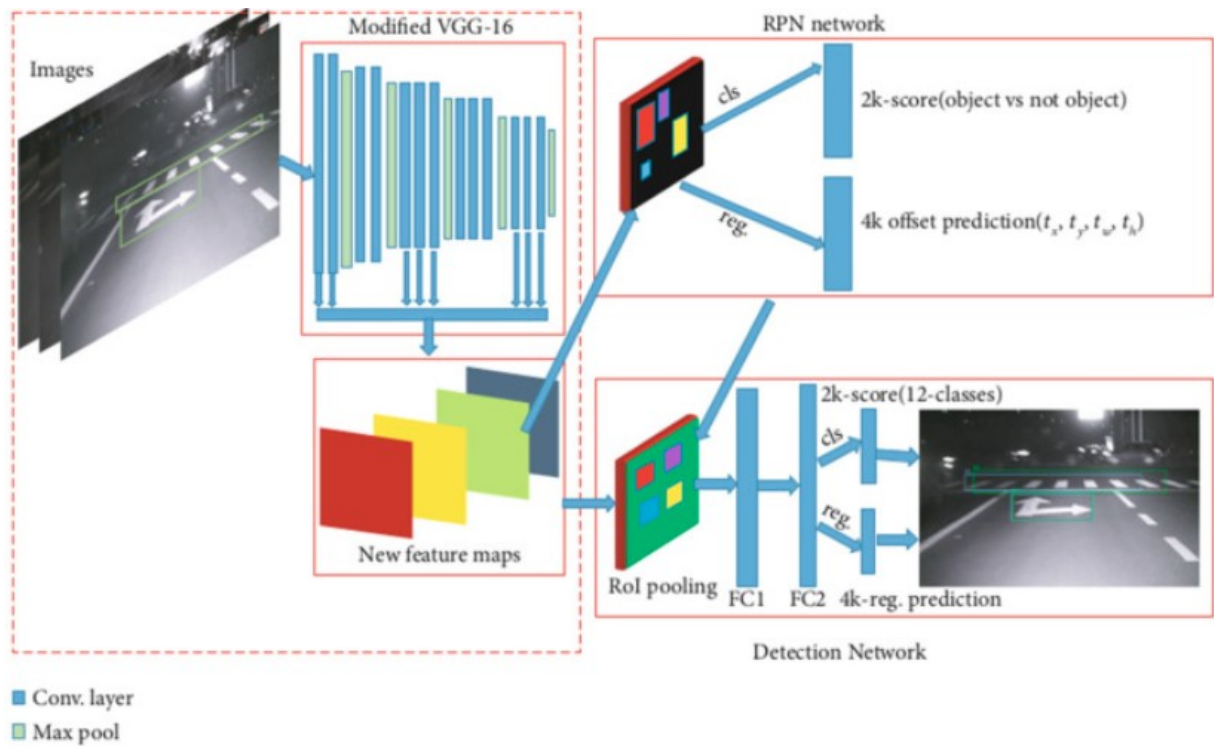


Рисунок 4.6 – Блок-схема конвеєру для моделі виявлення

Розпізнати дорожні знаки на зображеннях важко, це через блокування дорожніх знаків транспортними засобами, невідповідність кута огляду, варіації умов освітлення, багатогранний фон, погіршену якість зображення та тіні. Дорожня розмітка та система розпізнавання дорожніх знаків важливі для систем допомоги водієві та автономних транспортних засобів [17]. Розмітка проїжджої частини може бути різноманітною, наприклад, розмітка смуги руху, символи зі стрілками, символи обмеження швидкості, пішохідного переходу та написи.

Сучасна тенденція розпізнавання об'єктів [18] у нічний час має «дальню інфрачервону (FIR)» та ближню інфрачервоні камери як надійну систему отримання зображення. Остання тенденція розпізнавання на основі глибокого навчання зосереджується на місії виявлення без нагляду, оскільки основа для глибокого навчання вимагає великих даних для навчання, щоб ефективно спростити набір даних для оцінювання.

Дорожню розмітку виявляють за допомогою таких методів, як YOLO, яка є геніальною згортковою нейронною мережею (CNN) для пошуку об'єктів у режимі реального часу та Single-Shot Detector (SSD) або методом на основі пропозиції області. Регіональна згорточна нейронна мережа (R-CNN) має значне визнання у висновках щодо розмітки доріг у поточні роки. «Швидкий R-CNN» і «швидший R-CNN» були розроблені на основі R-CNN.

Обидва є регіональними який є геніальною згортковою нейронною мережею (CNN) для пошуку об'єктів у реальному часі та одноразовим детектором (SSD) або методом на основі пропозиції області. Регіональна згорточна нейронна мережа (R-CNN) має значне визнання у висновках щодо розмітки доріг у поточні роки. «Швидкий R-CNN» і «швидший R-CNN» були розроблені на основі R-CNN. Обидва є регіональними який є геніальною згортковою нейронною мережею (CNN) для пошуку об'єктів у реальному часі та одноразовим детектором (SSD) або методом на основі пропозиції області.

RPN – це частина мережі, яка використовує прив'язки в кожному місці пікселяміджу для класової скептичної категоризації. Змусити модель сприймати та ідентифікувати всю розмітку на дорозі може бути дуже складно, оскільки небагато наборів даних містять текстову інформацію, а різні країни використовують різні символи для позначення даних. Залежна мережа “VGG-16” вдосконаленого більш швидкого R CNN змінюється за допомогою методу багаторівневого злиття ознак. Використовується метод злиття функцій інтеграції шарів згортки в сцену для виділення елементів зображення. Ця зміна підвищує ефективність повного виявлення моделі за рахунок використання переваг дрібних шарів і глибоких шарів мережі Visual Geometry Group-VGG-16. Фактична оптимальна зона, в якій може проїхати людина, і система розпізнавання смуги для автономного водіння залежать від даних LIDAR і даних зору. Техніка об'єднання на рівні функцій для LIDAR і даних бачення, а також ідеальний підхід до вибору використовується для виявлення найкращої області для керування.

Алгоритм системи має дві ключові частини, які включають визначення оптимальної придатної для руху області залежно від об'єднання функцій, а друга частина – тимчасове визначення смуги руху. Перша частина гарантує, що транспортний засіб рухається в безпечній зоні, тоді як друга частина обмежує визначення смуги в регіоні, де людина може їхати. Блок-схема для алгоритму показана на рисунку 4.7. Алгоритм розпізнавання забороненої смуги свідомо реалізований на основі автоматизованої категоризації найкращого регіону, в якому людина може проїхати. Система плідно управляє як облаштованими, так і невпорядкованими дорогами. Він здогадується, чи потрібно використовувати метод виявлення смуги залежно від злиття, відсутність ручного перемикання чи використання даних із «GPS» та «Географічної інформаційної системи (GIS)». У разі організованих доріг розташовуються смуги та межі доріг. Для невпорядкованих доріг система розрізняє регіон, яким може проїхати транспортний засіб, і межі дороги. Злиття рівня функцій використовується для виявлення керованої області.

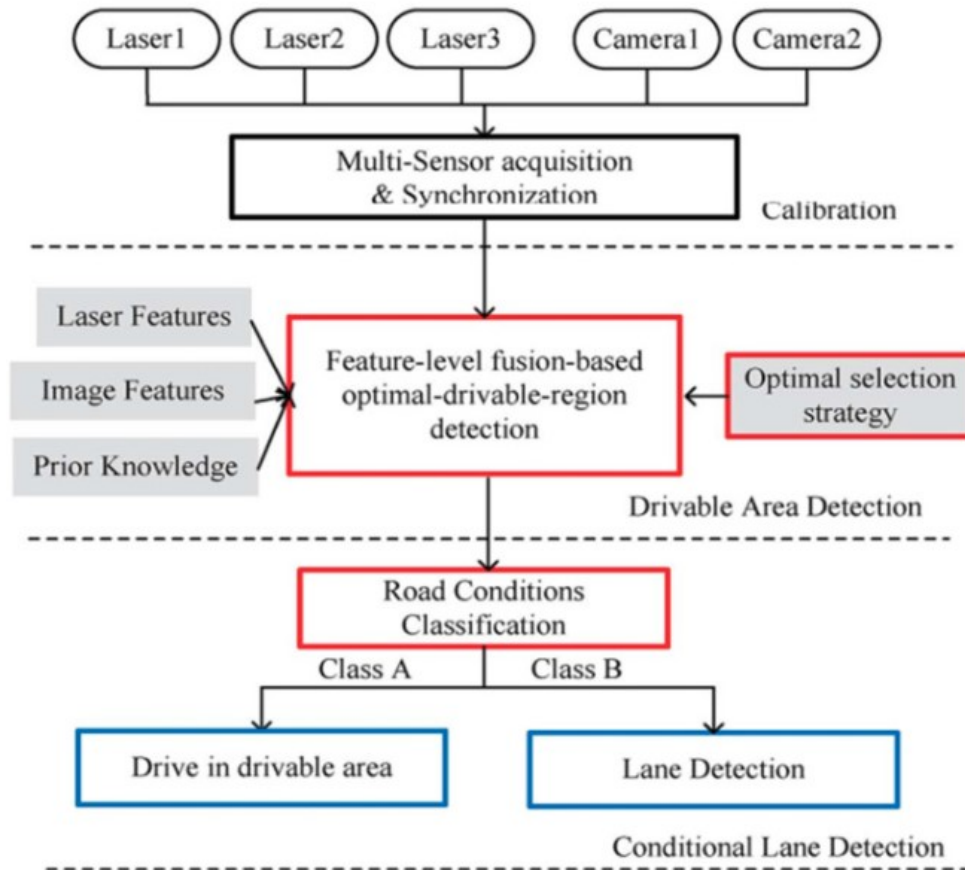


Рисунок 4.7 – Блок-схема алгоритму планування руху

Техніка визначення смуги обмежена найкращою зоною для проїзду та корисна лише тоді, коли дорога оцінюється як достатньо широка. Система виділяє найкращу прохідну зону, яка знаходиться попереду транспортного засобу, замість ідентифікації кожного пікселя дорожнього покриття, що є неефективним і непотрібним для автономного водіння транспортного засобу.

5 НАВЧАННЯ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ

Було навчено згортову нейронну мережу (CNN) відображати необроблені пікселі з однієї фронтальної камери безпосередньо на команди керування. Цей наскрізний підхід виявився напрочуд потужним. З мінімальними навчальними даними від людей система вчиться керувати транспортним затором на місцевих дорогах із розміткою або без неї, а також на шосе. Він також працює в місцях з нечіткими візуальними вказівками, наприклад на стоянках і на ґрунтових дорогах.

Система автоматично вивчає внутрішні представлення необхідних етапів обробки, таких як виявлення корисних дорожніх особливостей, використовуючи лише кут повороту керма як навчальний сигнал. Ми ніколи не навчали його явно виявляти, наприклад, контури доріг.

Порівняно з явною декомпозицією проблеми, як-от виявлення розмітки смуги руху, планування шляху та контроль, наша наскрізна система оптимізує всі етапи обробки одночасно. Ми стверджуємо, що це зрештою призведе до кращої продуктивності та зменшення систем.

Результатом стане краща продуктивність, оскільки внутрішні компоненти самостійно оптимізуються для максимізації загальної продуктивності системи замість оптимізації проміжних критеріїв, вибраних людиною, таких як наприклад, визначення смуги руху.

Зрозуміло, що такі критерії вибрано для простоти людської інтерпретації, що автоматично не гарантує максимальної продуктивності системи. Менші мережі можливі, тому що система вчиться вирішувати проблему за допомогою мінімальної кількості кроків обробки.

5.1 Особливості використаної обраної CNN

CNN зробили революцію в розпізнаванні образів. До широкого впровадження CNN більшість завдань розпізнавання образів виконувалися за допомогою початкової стадії ручного виділення ознак з наступним класифікатором. Проривом CNN є те, що функції вивчаються автоматично з навчальних прикладів. Підхід CNN є особливо потужним у задачах розпізнавання зображень, оскільки операція згортки фіксує двовимірну природу зображень. Крім того, використовуючи ядра згортки для сканування всього зображення, потрібно вивчити порівняно небагато параметрів порівняно із загальною кількістю операцій.

Незважаючи на те, що CNN із навченими функціями комерційно використовуються більше двадцяти років, їхнє впровадження вибухнуло за останні кілька років через дві нещодавні події. По-перше, великі марковані набори даних, такі як Large Scale Visual Recognition Challenge (ILSVRC), стали доступними для навчання та перевірки. По-друге, алгоритми навчання CNN реалізовано на масивних паралельних графічних процесорах (GPU), які надзвичайно прискорюють навчання та логічні висновки.

У цій роботі описується CNN, який виходить за рамки розпізнавання образів. Він вивчає весь конвеєр обробки, необхідний для керування автомобілем. Підготовка до цього проекту була зроблена більше 10 років тому в проекті Агентства перспективних оборонних досліджень (DARPA), відомому як DARPA Autonomous Vehicle (DAVE) [19], під час якого машина з радіокеруванням (RC) проїжджала крізь алею де весь шлях був заповнений сміттям. DAVE був навчений годинам водіння людини в схожих, але не ідентичних середовищах. Навчальні дані включали відео з двох камер у поєднанні з лівим і правим кермом та командами від людини-оператора. Багато в чому DAVE-2 був натхненний піонерською роботою Померло, який у 1989 році створив систему автономного наземного транспортного засобу в нейронній

мережі (ALVINN). Це продемонструвало, що наскрізна навчена нейронна мережа справді може керувати автомобілем на дорогах загального користування. Ця робота відрізняється тим, що багато років прогресу дозволяють нам застосовувати набагато більше даних і обчислювальної потужності для вирішення цього завдання. Крім того, наш досвід роботи з CNN дозволяє нам використовувати цю потужну технологію. ALVINN використовував повністю підключену мережу, яка є крихітною за сьогоденнішими стандартами.

Незважаючи на те, що DAVE продемонстрував потенціал наскрізного навчання та дійсно використовувався для виправдання запуску програми DARPA Learning Applied to Ground Robots (LAGR), продуктивність DAVE не була достатньо надійною, щоб забезпечити повну альтернативу більш модульним підходам до їзди по бездоріжжю. Середня відстань DAVE між аваріями становила близько 20 метрів у складних умовах. Дев'ять місяців тому NVIDIA розпочала нову роботу, спрямовану на створення надійної системи DAVE для руху по дорогах загального користування. Основна мотивація для цієї роботи полягає в тому, щоб уникнути необхідності розпізнавати конкретні визначені людиною особливості, такі як розмітка смуг руху, огорожі або інші автомобілі, і уникнути необхідності створювати колекцію правил «якщо, то, інакше» на основі спостерігаючи за цими особливостями.

5.2 Огляд системи DAVE-2

На рисунку 5.1 показана спрощена блок-схема системи збору даних для навчання для DAVE-2. За лобовим склом автомобіля для збору даних встановлено три камери. Відео з міткою часу з камер знімається одночасно з кутом повороту керма, який застосовує людина-водій. Ця команда керування отримується шляхом натискання на шину мережі контролера (CAN)

автомобіля. Щоб зробити систему незалежною від геометрії автомобіля, було представлено команду керування як 1 ділити на радіус повороту в метрах. Це використовується замість радіусу, щоб запобігти сингулярності під час руху прямо (радіус повороту для руху прямо дорівнює нескінченності). При 1 діленої на радіус повороту плавно переходить через нуль від лівих поворотів (від'ємні значення) до правих поворотів (додатні значення).

Навчальні дані містять окремі зображення, взяті з відео, у поєднанні з відповідною командою керування. Навчання з даними лише людини-водія недостатньо. Мережа повинна навчитися відновлюватися після помилок. Інакше автомобіль буде повільно зносити з дороги. Тому навчальні дані доповнюються додатковими зображеннями, які показують автомобіль у різних зміщеннях від центру смуги руху та обертаннях від напрямку дороги.

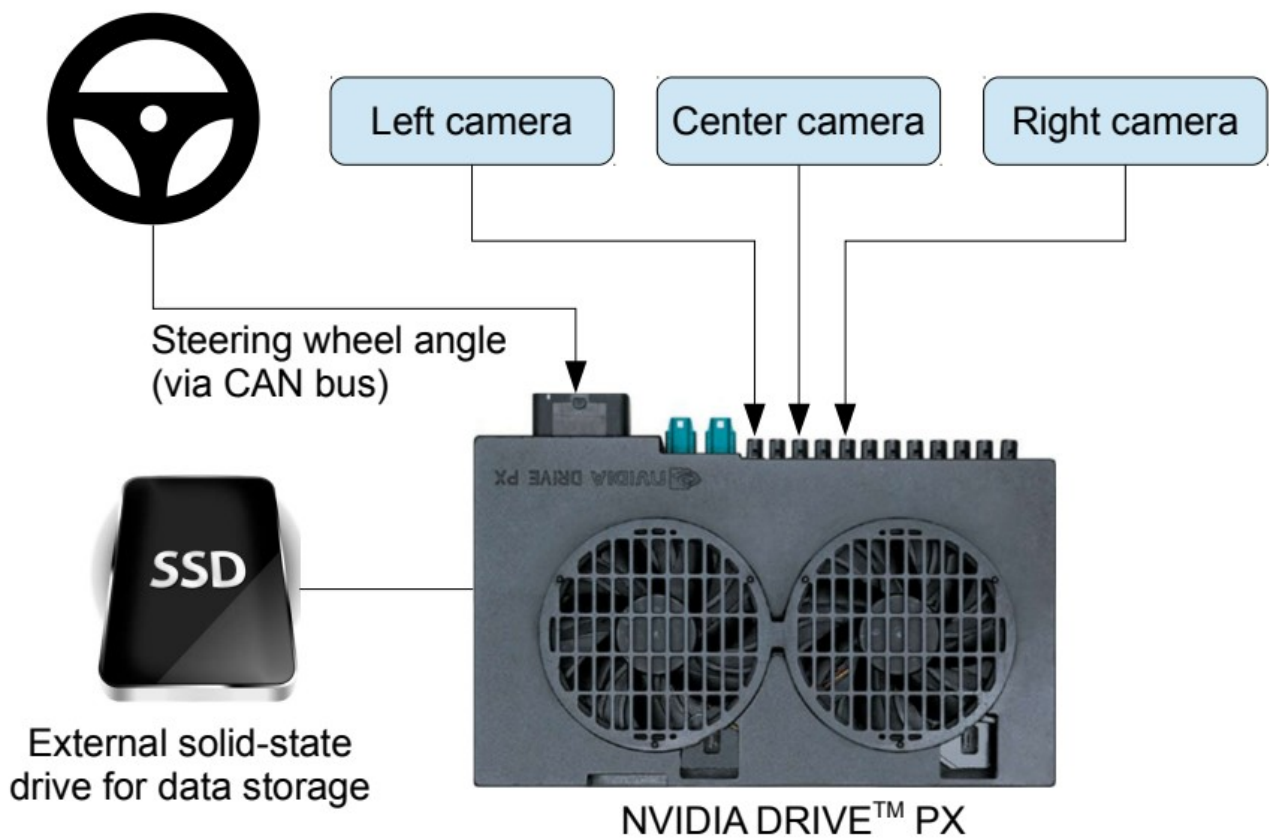


Рисунок 5.1 – Блок-схема загального вигляду системи збору даних

Зображення для двох конкретних зсувів поза центром можна отримати з лівої та правої камери. Додаткові зсуви між камерами та всі повороти імітуються трансформацією точки огляду зображення з найближчої камери. Для точної трансформації точки огляду потрібні знання 3D-сцени, яких ми не маємо.

Тому ми наближаємо перетворення, припускаючи, що всі точки під горизонтом знаходяться на рівній поверхні, а всі точки над горизонтом нескінченно далеко.

Це добре працює для рівнинної місцевості, але вносить спотворення для об'єктів, які стирчать над землею, таких як автомобілі, стовпи, дерева та будівлі. На щастя, ці спотворення не становлять великої проблеми для навчання мережі.

Позначку керма для трансформованих зображень налаштовано так, щоб повертати автомобіль назад у потрібне розташування та орієнтацію за дві секунди. Блок-схема нашої системи навчання показана на рисунку 5.2.

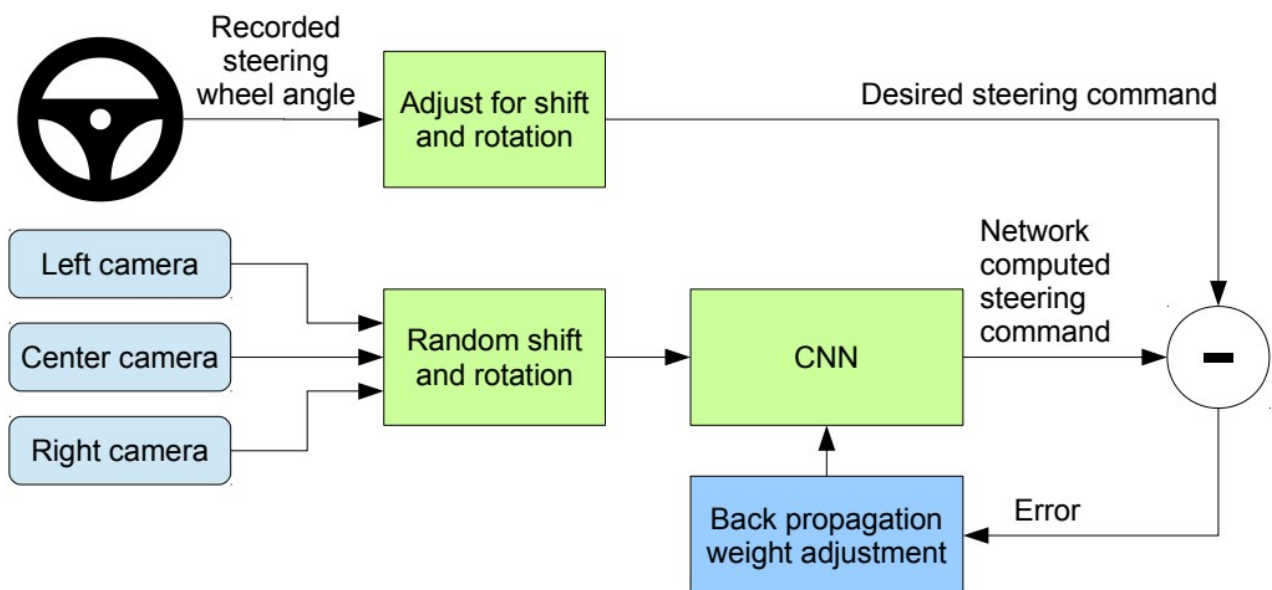


Рисунок 5.2 – Блок-схема навчання нейронної мережі

Зображення надходять у CNN, який потім обчислює запропоновану команду керування. Запропонована команда порівнюється з бажаною командою для цього зображення, а ваги CNN регулюються, щоб наблизити вихід CNN до бажаного. Регулювання ваги здійснюється за допомогою зворотного поширення, реалізованого в пакеті машинного навчання Torch 7.

Після навчання мережа може генерувати керування з відеозображень однієї центральної камери. Саме використання однієї камери робить усю систему меншою, легшою, дешевшою та універсальною. Ця конфігурація показана на рисунку 5.3.

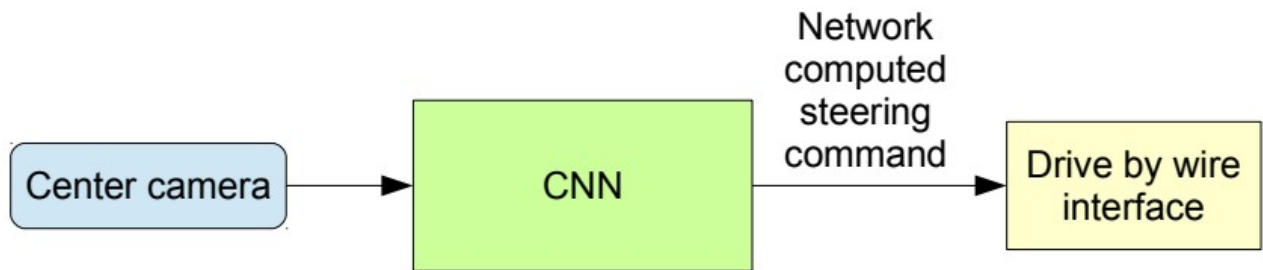


Рисунок 5.3 – Блок-схема навченої мережі, яка використовується для генерування команд керування з однієї передньої центральної камери

5.3 Збір даних для CNN

Ідея полягає в тому, що у нас є людина-водій, яка просто їздить і ми записуємо всі ці дані, а потім ми збираємося отримати машину для клонування цієї поведінки, тому ми називаємо цей процес поведінковим клонуванням, і для цього ми збираємося побудувати дев'ятишарову згорткову мережу. У нас є два входи, наш кут повороту і наші набори камер, це вхідні дані, тому ми можемо розглядати проблему як проблему навчання під наглядом.

Данні створені людиною, ми можемо порівняти результати разом, щоб обчислити помилку чи втрату між двома скажімо кутами камери та кермом з автономного автомобіля, а потім кути камери в змінній керма з даних, створених людиною, а потім ми просто векторизуємо обидва ці значення в одне значення і знаходимо різницю між цими значеннями, і ця різниця є нашою помилкою.

Ми використовуємо це поширення для них, оновлюємо наші ваги на основі цього значення помилки, тому це значення ваги або це значення помилки повертається назад, тому зображення надсилаються в CNN для навчання, а потім для правильного тестування.

Після завершення тренування даної автономної моделі для тестування, можемо розглядати цей процес у вигляді симулятора з точки зору клієнтської архітектури сервера. У цьому контексті, сервер виступає у ролі симулятора, який імітує невелику 3D-гру, а клієнт – це програма на Python. Проте, функціональність, яку ми розробляємо, обмежується лише циклом зворотного зв'язку.

Конкретно, те, що ми програмуємо [20] та що вона виконує, це в основному цей цикл зворотного зв'язку. З іншими словами, клієнт передає серверу дані про кути повороту та прискорення, а сервер отримує резервні копії зображень автомобіля та даних про кути повороту. Це дозволяє серверу ефективно аналізувати та вдосконалювати навички автономного автомобіля, використовуючи зібрані дані.

Основна ідея полягає в тому, що клієнт і сервер взаємодіють у формі обміну даними, в якому клієнт передає інструкції про керування, а сервер відправляє назад зібрані дані та інформацію про стан автомобіля. Цей процес зворотного зв'язку схематично зображений на рисунку 5.4, який відображає цикл взаємодії між клієнтом і сервером, що є основною концепцією того, як це працює.

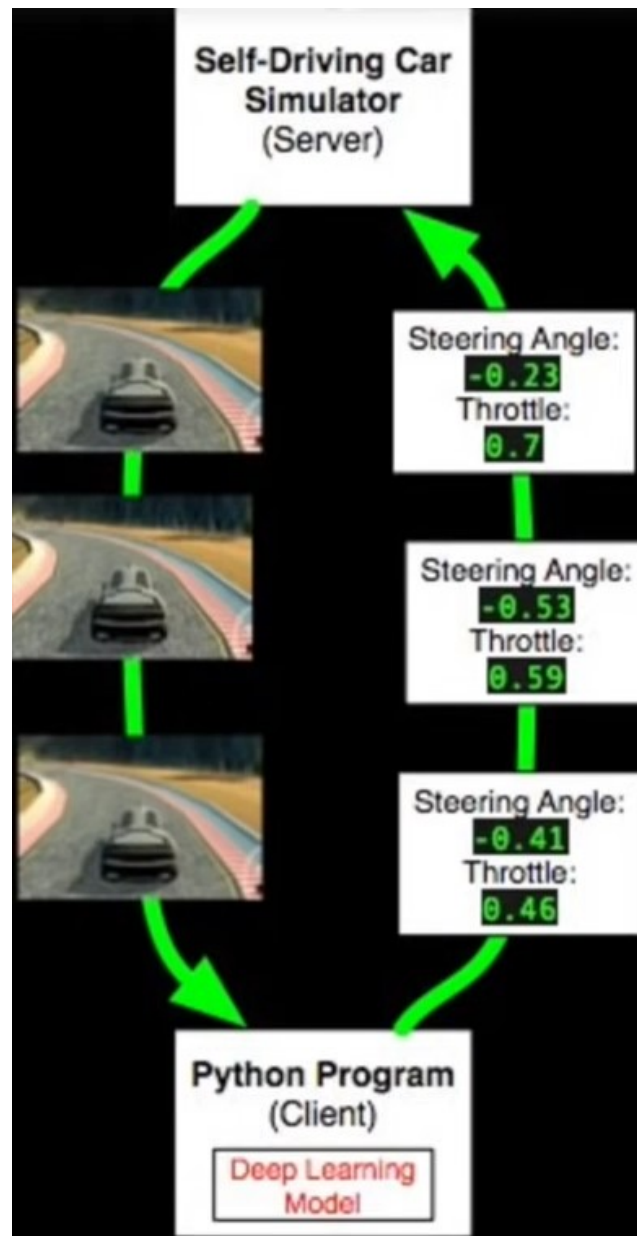


Рисунок 5.4 – Блок-схема циклу зворотного зв'язку

5.4 Архітектура мережі

Ми тренуємо вагові коефіцієнти нашої мережі, щоб мінімізувати середньоквадратичну помилку між командою керування, виведеною мережею, і командою водія-людини, або скоригованою командою керування для нецентральных і повернутих зображень. Архітектура мережі показана на

рисунку 5.5. Мережа складається з 9 рівнів, включаючи рівень нормалізації, 5 згорткових рівнів і 3 повністю зв'язані рівні. Вхідне зображення розбивається на площини YUV і передається в мережу.




Рисунок 5.5 – Архітектура CNN.

Перший рівень мережі виконує нормалізацію зображення. Нормалізатор жорстко закодований і не налаштовується в процесі навчання. Виконання нормалізації в мережі дозволяє змінювати схему нормалізації відповідно до архітектури мережі та прискорювати її за допомогою обробки GPU.

Згорткові шари були розроблені для виконання виділення ознак і були обрані емпірично через серію експериментів, які змінювали конфігурації шарів. Використовуються смугові згортки в перших трьох згорткових шарах із кроком 2×2 і ядром 5×5 і згортку без смуг із розміром ядра 3×3 у двох останніх згорткових шарах.

Слідуюмо за п'ятьма згортковими шарами з трьома повністю з'єднаними шарами, що ведуть до вихідного контрольного значення, яке є зворотним радіусом повороту. Повністю підключені рівні призначені для роботи в якості контролера для керування, але зауважимо, що, наскрізно навчаючи систему, неможливо зробити чіткий розрив між тим, які частини мережі функціонують переважно як екстрактор функцій, а які служити контролером.

5.5 Деталі навчання

Першим кроком до навчання нейронної мережі є вибір кадрів для використання. Зібрані нами дані позначаються типом дороги, погодними умовами та діяльністю водія (перебування на смузі руху, зміна смуги руху, поворот тощо). Щоб навчити CNN рухатися по смузі, ми вибираємо лише дані, де водій залишався на смузі, а решту відкидаємо. Потім ми знімаємо це відео зі швидкістю 10 FPS. Вища частота дискретизації призведе до включення зображень, які дуже схожі, і тому не нададуть багато корисної інформації. Щоб усунути упередження щодо прямолінійного руху, навчальні дані включають більшу частку кадрів, які представляють повороти дороги.

Після вибору остаточного набору кадрів ми доповнюємо дані, додаючи штучні зсуви та повороти, щоб навчити мережу відновлюватися після неправильного положення чи орієнтації. Величина цих збурень вибирається випадковим чином із нормального розподілу. Розподіл має нульове середнє значення, а стандартне відхилення вдвічі перевищує стандартне відхилення, яке вимірюється з людьми-водіями.

5.6 Моделювання

Перш ніж тестувати навчену CNN, спочатку оцінюємо продуктивність мережі в моделюванні. Спрощена блок-схема системи моделювання показана на рисунку 5.6. Симулятор знімає попередньо записані відео з передньої бортової камери на керованому транспортному засобі для збору даних і генерує зображення, які приблизно виглядають, якби CNN замість цього керував транспортним засобом. Ці тестові відео синхронізовані за часом із записаними командами керування, які генерує людина-водій.

Оскільки люди-водії можуть не постійно їздити по центру смуги, ми вручну калібруємо центр смуги, пов'язаний із кожним кадром у відео, яке використовує симулятор. Ми називаємо цю позицію «основною правдою».

Симулятор перетворює оригінальні зображення, щоб врахувати відхилення від основної істини. Симулятор отримує доступ до записаного тестового відео разом із синхронізованими командами керування, які виникли під час зйомки відео. Симулятор надсилає на вхід навченого CNN перший кадр вибраного тестового відео, скоригованого на будь-які відхилення від наземної істини. Потім CNN повертає команду керування для цього кадру. Команди керування CNN, а також записані команди людини-водія вводяться в динамічну модель транспортного засобу для оновлення положення та орієнтації змодельованого транспортного засобу.

Потім симулятор змінює наступний кадр тестового відео так, щоб зображення виглядало так, ніби транспортний засіб знаходився в положенні, яке було отримано в результаті виконання команд керма від CNN. Потім це нове зображення передається на CNN, і процес повторюється.

Симулятор записує відстань поза центром (відстань від автомобіля до центру смуги), поворот і відстань, яку проїхав віртуальний автомобіль. Коли відстань від центру перевищує один метр, запускається віртуальне втручання людини, і положення та орієнтація віртуального транспортного засобу скидаються відповідно до правдивості відповідного кадру оригінального тестового відео.

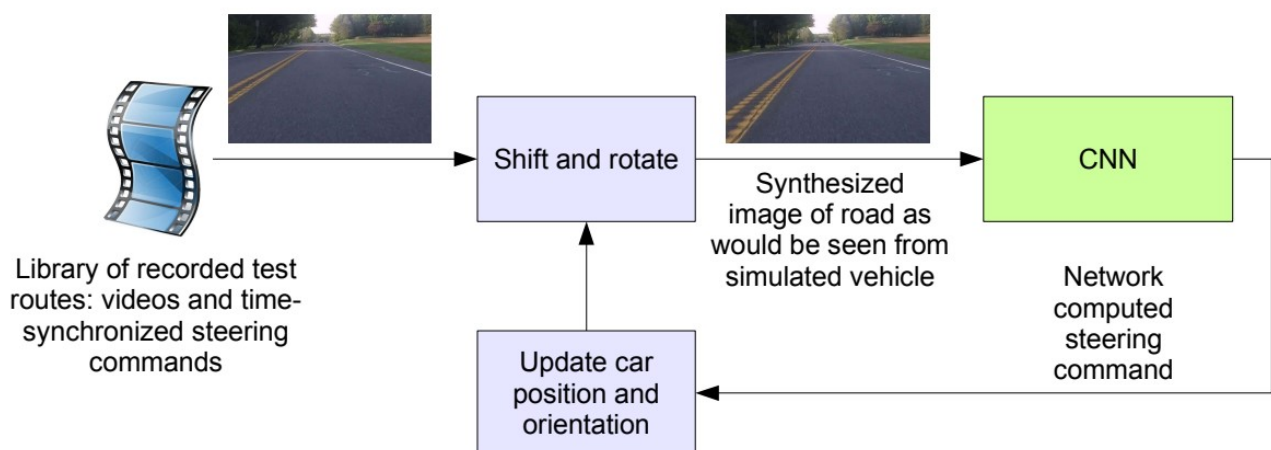


Рисунок 5.6 – Блок-схема симулятора приводу

5.7 Оцінювання

Оцінка мереж виконується в два етапи: спочатку в симуляції, а потім у ході випробувань, результат котрих наведено на рисунку 5.7. Оцінюється, який відсоток часу мережа могла б керувати автомобілем (автономність). Показник

визначається шляхом підрахунку змодельованих втручань людини. Ці втручання відбуваються, коли імітований транспортний засіб відходить від центральної лінії більш ніж на один метр. Припускається, що в реальному житті для фактичного втручання знадобиться загалом шість секунд: це час, необхідний людині, щоб відновити контроль над транспортним засобом, відцентрувати його, а потім перезапустити режим самостійного керування.

Обчислюємо відсоток автономності шляхом підрахунку кількості втручань множенних на 6 секунд, та ділення на час, що минув змодельованого тесту, а потім віднімання результату від 1.



Рисунок 5.7 – Знімок екрана симулятора в інтерактивному режимі.

Виділений широкий прямокутник під горизонтом – це область, яка надсилається на CNN. Таким чином, якби ми мали 10 втручань за 600 секунд, ми б мали значення автономності у 90%. Після того, як навчена мережа продемонструє хорошу продуктивність у симуляторі, мережа завантажується на DRIVETM PX у тестовому автомобілі та відправляється для дорожніх

випробувань. Для цих тестів вимірюється продуктивність як частку часу, протягом якого автомобіль виконує автономне рульове керування. Цей час без урахування перестроювання та повороту з однієї дороги на іншу.

Візуалізація внутрішнього стану CNN на рисунках 5.8 і 5.9 показано активацію перших двох шарів карти функцій для двох різних вхідних даних, ґрунтової дороги та лісу. У разі ґрунтової дороги активації карти функцій чітко показують контури дороги, тоді як у випадку лісу карти функцій містять переважно шум, тобто CNN не знаходить корисної інформації на цьому зображенні. Це демонструє, що CNN навчився самостійно виявляти корисні дорожні особливості, тобто лише з кутом повороту керма як навчальним сигналом. Наприклад, ми ніколи не навчали його чітко розпізнавати контури доріг.




Рисунок 5.8 – Приклад зображення ґрунтової дороги

Верх: підмножина зображення з камери, надісланого на CNN. Внизу зліва: активація карт функцій першого шару. Внизу праворуч: активація карт функцій другого шару. Це демонструє, що CNN навчився самостійно виявляти корисні дорожні особливості, тобто, наприклад, лише з кутом повороту керма як навчальним сигналом. Ми ніколи не навчали його чітко виявляти контури доріг. Активація перших двох карт функцій містить переважно шум, тобто CNN не розпізнає жодних корисних функцій у цьому зображенні.




Рисунок 5.9 – Приклад зображення без дороги

ВИСНОВОК

АНV і особливо багатопричепні АНV (МТАНV) все частіше використовуються в усьому світі через їх економічні та екологічні переваги. Незважаючи на переваги, МТАНV демонструють низьку маневреність і низьку поперечну стійкість порівняно з важкими вантажівками та пасажирськими транспортними засобами через їхню багатоблокову конструкцію, великі розміри та високі центри ваги [9]. У минулих дослідженнях напівавтомного та автономного водіння використовувалися прості моделі водія та транспортного засобу, що обертається [6]. Для ефективного моделювання динаміки МТАНV і точного прогнозування поведінки водія необхідно розробити обчислювально ефективні моделі транспортних засобів і моделі водіїв, які враховують сигнали руху транспортних засобів, що рухаються позаду.

Багатоблокові конструкції та динаміка крену МТАНV накладають більше проблем на оцінку загрози та планування шляху порівняно з випадками легкових автомобілів [21]. Попередні дослідження автономного водіння зчленованих транспортних засобів зосереджувалися на автоматичному керуванні без автоматичного гальмування [6]. Для розробки автономного водіння для АНV під час експлуатації на шосе доцільно враховувати як автоматичне рульове керування, так і гальмування. Було проведено дослідження, щоб визначити відмінні динамічні характеристики АНV між ручним і автоматизованим керуванням при зміні смуги руху, але взаємодія водія-автоматизації-середовища при автоматизованому втручанні не досліджувалися.

Сучасний прогрес у безпілотних транспортних засобах відкриває безпілотне водіння у яскравому майбутньому. Офіційні майбутні прогнози щодо автономних транспортних засобів вказують на те, що величезна кількість автомобільних компаній найближчим часом випустить продукти з напів- і

повністю автономними функціями. Очікується, що до 2035 року більшість транспортних засобів, включаючи важкі комерційні автомобілі, будуть повністю автоматизовані. У цьому курсовому проекті розглядалися історичні та поточні розробки функцій автоматизованого водіння та необхідних технологій з акцентом на ANV. Виявлено, що дослідженню автономного водіння для ANV і, зокрема, МТАNV, приділено мало уваги. У обмежених дослідженнях водіння автомобілів для ANV оцінка загрози через погану маневреність і низьку поперечну стійкість цих великих транспортних засобів не розглядалася.

Було емпірично продемонстровано, що CNN здатні вивчати всю задачу слідування смугі та дорозі без ручного розкладання на виявлення розмітки дороги чи смуги, семантичну абстракцію, планування шляху та керування. Невеликої кількості тренувальних даних за менше ніж сто годин водіння було достатньо, щоб навчити автомобіль працювати в різноманітних умовах, на шосе, місцевих і житлових дорогах у сонячну, хмарну та дощову погоду. CNN може вивчати значущі характеристики дороги за дуже рідкісним навчальним сигналом (лише рульове керування).

Система вчиться, наприклад, виявляти контури дороги без потреби в явних мітках під час навчання. Потрібна додаткова робота, щоб покращити надійність мережі, знайти методи перевірки надійності та покращити візуалізацію етапів внутрішньої обробки мережі.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Кануков Д.С. Покращення управління проектами за рахунок використання штучного інтелекту. Інформаційне суспільство: технологічні, економічні та технічні аспекти становлення (випуск 74): матеріали Міжнародної наукової інтернет-конференції, (м. Тернопіль, Україна – м. Переворськ, Польща, 6-7 лютого 2023 р.) / ГО “Наукова спільнота”; WSSG w Przeworsku. – Тернопіль : ФО-П Шпак В.Б. – 215 с. – ISSN 2522-932X.
2. Кануков Д.С., Митцева О.С. Експоненційні проривні технології та необхідні навички для індустрії 4.0. Наука сьогодення: від досліджень до стратегічних рішень: матеріали VI Міжнародної студентської наукової конференції, м. Суми, 2 червня, 2023 рік / ГО «Молодіжна наукова ліга». — Вінниця: ГО «Європейська наукова платформа», 2023. — 268 с., ISBN 978-617-8126-53-7. DOI: <https://doi.org/10.36074/liga-inter-02.06.2023>.
3. Z. Ni and Y. He, “Design and validation of a robust active trailer steering system for multi-trailer articulated heavy vehicles,” Veh. Syst. Dyn., vol. 3114, 2018.
4. “U.S. Federal Motor Carrier Safety Administration. Large Trucks and bus crash facts 2016.”. URL: <https://cms8.fmcsa.dot.gov/safety/data-and-statistics/large-truck-andbus-crash-facts-2016#A8>.
5. OECD/ITF, Road Safety Annual Report 2015. 2015.
6. Standing Senate Committee on Transport and Communications Senate, “Driving Change-Technology and Future of Autonomous Vehicles,” no. Jan., 2018.
7. P. Nilsson, Traffic Situation Management for Driving Automation of Articulated Heavy Road Transports From driver behaviour towards highway autopilot. 2017.

8. C. Cheng and D. Cebon, “Improving roll stability of articulated heavy vehicles using active semi-trailer steering,” *Veh. Syst. Dyn.*, vol. 46, no. SUPPL.1, pp. 373–388, 2008.
9. World Health Organization. GLOBAL STATUS REPORT ON ROAD SAFETY, no. 1. 2018.
10. A. T. Van Zanten, “Bosch ESP systems: 5 years of experience,” *SAE Tech. Pap.*, no. 724, 2000.
11. S. J. Anderson, S. B. Karumanchi, K. Iagnemma, and J. M. Walker, “The Intelligent CoPilot,” *IEEE Intell. Transp. Syst. Mag.*, no. Apr. 2013, pp. 45–54, 2013.
12. V. A. Shia et al., “Semiautonomous vehicular control using driver modeling,” *IEEE Trans. Intell. Transp. Syst.*, vol. 15, no. 6, pp. 2696–2709, 2014.
13. A. Gray, Y. Gao, T. Lin, J. K. Hedrick, and F. Borrelli, “Stochastic predictive control for semi-autonomous vehicles with an uncertain driver model,” *IEEE Conf. Intell. Transp. Syst. Proceedings, ITSC*, no. 1239323, pp. 2329–2334, 2013.
14. SAE International Surface Vehicle Information Report, “Taxonomy and Definitions for Terms Related to On-Road Motor Vehicle Automated Driving Systems,” SAE Standard J3016, 2016.
15. Proceedings of the Canadian Society for Mechanical Engineering International Congress 2020, CSME Congress 2020, June 21-24, 2020, Charlottetown, PE, Canada. A REVIEW OF ESSENTIAL TECHNOLOGIES FOR AUTONOMOUS AND SEMIAUTONOMOUS ARTICULATED HEAVY vehicles Amir Rahimi, Yuping He. Department of Automotive, Mechanical and Manufacturing, Ontario Tech University, Oshawa, Canada.
16. Кануков Д.С., Аксак Н.Г. Обзор багатоагентного навчання з підкріпленням для підключених та автоматизованих транспортних засобів. Наука сьогодення: від досліджень до стратегічних рішень: матеріали VI

Міжнародної студентської наукової конференції, м. Суми, 2 червня, 2023 рік / ГО «Молодіжна наукова ліга». — Вінниця: ГО «Європейська наукова платформа», 2023. — 268 с., ISBN 978-617-8126-53-7. DOI: <https://doi.org/10.36074/liga-inter-02.06.2023>.

17. Кануков Д.С. Система допомоги керуванням транспортом на основі розпізнавання знаків дорожнього руху. Наукові дослідження: парадигма інноваційного розвитку: збірник тез наукових праць XIII Міжнародної наукової конференції (Прага, Чехія, «29» грудня 2022 року) / ГО «Міжнародний науковий центр розвитку науки та технологій», 2022. — 60 с.

18. Кануков Д.С., Сердюк Н.М., Особливості та перспективи візуального відстеження об'єктів. Наука сьогодення: від досліджень до стратегічних рішень: матеріали VI Міжнародної студентської наукової конференції, м. Суми, 2 червня, 2023 рік / ГО «Молодіжна наукова ліга». — Вінниця: ГО «Європейська наукова платформа», 2023. — 268 с., ISBN 978-617-8126-53-7. DOI: <https://doi.org/10.36074/liga-inter-02.06.2023>.

19. Wojarski, Mariusz, David W. del Testa, Daniel Dworakowski, Bernhard Firner, Beat Flepp, Prasoon Goyal, Lawrence D. Jackel, Mathew Monfort, Urs Muller, Jiakai Zhang, Xin Zhang, Jake Zhao and Karol Zieba. “End to End Learning for Self-Driving Cars.” ArXiv abs/1604.07316 (2016): n. pag.

20. Кануков Д.С., Сердюк Н.М. Особливості програмування для високопродуктивних обчислень на edge accelerators. Наука сьогодення: від досліджень до стратегічних рішень: матеріали VI Міжнародної студентської наукової конференції, м. Суми, 2 червня, 2023 рік / ГО «Молодіжна наукова ліга». — Вінниця: ГО «Європейська наукова платформа», 2023. — 268 с., ISBN 978-617-8126-53-7. DOI: <https://doi.org/10.36074/liga-inter-02.06.2023>.

21. K. Bengler, K. Dietmayer, B. Färber, M. Maurer, C. Stiller, and H. Winner, “Three Decades of Driver Assistance Systems,” IEEE Intell. Transp. Syst. Mag., vol. 6, no. 4, pp. 6–22, 2014.