

Міністерство освіти і науки України

Луцький національний технічний університет

(повне найменування закладу вищої освіти)

Факультет комп'ютерних та інформаційних технологій

(повне найменування факультету)

Кафедра комп'ютерної інженерії та безпеки

(повне найменування кафедри)

КВАЛІФІКАЦІЙНА РОБОТА  
ЗА СТУПЕНЕМ ВИЩОЇ ОСВІТИ «МАГІСТР»

ІНТЕГРАЦІЯ КОМП'ЮТЕРНОГО ЗОРУ ТА  
АЛГОРИТМІВ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ СИСТЕМ  
АВТОНОМНОГО ВОДИННЯ

INTEGRATING COMPUTER VISION AND ARTIFICIAL  
INTELLIGENCE FOR AUTONOMOUS DRIVING SYSTEMS

спеціальність 123 Комп'ютерна інженерія

(шифр і назва спеціальності)

освітня програма Комп'ютерна інженерія

(назва освітньої програми)

Виконав: здобувач вищої освіти  
групи КІМ-21  
Сушецький Павло Сергійович

(підпис)

Керівник:  
к.т.н., доцент  
Поліщук Микола Миколайович

(підпис)

Кваліфікаційну роботу  
допущено до захисту  
«\_\_\_\_\_» \_\_\_\_\_ грудня 2025 р.

Гарант освітньої програми:  
к.т.н., доцент  
Гринюк Сергій Васильович

(підпис)

Луцьк – 2025 року

ЛУЦЬКИЙ НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ

Факультет комп'ютерних та інформаційних технологій

Кафедра комп'ютерної інженерії та безпеки

Ступінь вищої освіти: магістр

Галузь знань: 12 Інформаційні технології

Спеціальність: 123 Комп'ютерна інженерія

Освітня програма: «Комп'ютерна інженерія»

ЗАТВЕРДЖУЮ

Завідувач кафедри

доц. Т. Терлецький

« 18 » червня 2025 р.

ЗАВДАННЯ  
НА КВАЛІФІКАЦІЙНУ РОБОТУ ЗДОБУВАЧУ ВИЩОЇ ОСВІТИ

Сухецькому Павлу Сергійович

(прізвище, ім'я, по батькові)

1. Тема кваліфікаційної роботи Інтеграція комп'ютерного зору та алгоритмів штучного інтелекту для систем автономного водіння

Керівник роботи к.т.н., доцент Поліщук Микола Миколайович

затверджені наказом закладу вищої освіти від «17» червня 2025 року №0 290/01-02

2. Строк подання здобувачем вищої освіти кваліфікаційної роботи 09.12.2025р.

3. Вихідні дані до роботи Джерелом розробки є науково-технічна література та публікації в періодичних виданнях з даного питання, опубліковані зарубіжні та вітчизняні роботи в даній області, різні інтернет-ресурси технічного спрямування

4. Зміст пояснювальної записки (перелік питань, які потрібно розробити):

Вступ

Теоретичні основи інтеграції комп'ютерного зору та алгоритмів штучного інтелекту в системах автономного водіння.

Апаратна реалізація інтегрованої системи комп'ютерного зору та ШІ для автономного водіння.

Експериментальне дослідження інтеграції комп'ютерного зору та алгоритмів штучного інтелекту для систем автономного водіння.

Висновки

5. Перелік графічного (ілюстративного) матеріалу:

## 6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис	
		завдання видав	завдання прийняв
<i>Теоретичні основи інтеграції комп'ютерного зору та алгоритмів штучного інтелекту системах автономного водіння</i>	<i>Поліщук М.М., доцент</i>		
<i>Апаратна реалізація інтегрованої системи комп'ютерного зору та ШІ для автономного водіння</i>	<i>Поліщук М.М., доцент</i>		
<i>Експериментальне дослідження інтеграції комп'ютерного зору та алгоритмів штучного інтелекту для систем автономного водіння</i>	<i>Поліщук М.М., доцент</i>		
<i>Нормоконтроль</i>	<i>Багнюк Н.В., доцент</i>		
<i>Гарант ОП</i>	<i>Гринюк С.В., доцент</i>		
<i>Показник запозичень тексту</i>		_____ %	
<i>Академічна доброчесність</i>	<i>Міскевич О.І., ст. викладач</i>		

7. Дата видачі завдання 18.06.2025 р.

## КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
1.	<i>Огляд літератури із досліджуваної проблеми, аналіз предметної області та наявних рішень</i>	до 26.08.2025 р.	
2	<i>Теоретичні основи інтеграції комп'ютерного зору</i>	до 04.09.2025 р	
3.	<i>Апаратна реалізація інтегрованої системи</i>	до 24.09.2025 р.	
4.	<i>Експериментальне дослідження інтеграції комп'ютерного зору</i>	до 12.10.2025 р.	
5.	<i>Висновки та пропозиції</i>	До 25.10.2025 р	
6.	<i>Формування списку використаних джерел</i>	До 27.10.2025 р.	
7.	<i>Формування додатків</i>	До 30.10.2025 р.	
8.	<i>Оформлення ілюстративного матеріалу</i>	До 05.11.2025 р.	
9..	<i>Представлення остаточного варіанту кваліфікаційної роботи керівникові</i>	До 11.11.2025 р.	
10.	<i>Нормоконтроль</i>	До 29.11.2025 р.	
11.	<i>Інструментальна перевірка на академічний плагіат</i>	До 02.12.2025 р.	
12.	<i>Здача кваліфікаційної роботи та всіх супровідних документів на кафедру</i>	До 09.12.2025 р.	

Здобувач вищої освіти

\_\_\_\_\_ (підпис)

Сушецький П.С.

\_\_\_\_\_ (прізвище, ініціали)

Керівник кваліфікаційної роботи

\_\_\_\_\_ (підпис)

Поліщук М.М.

\_\_\_\_\_ (прізвище, ініціали)

## АНОТАЦІЯ

Сухецький П. С. Інтеграція комп'ютерного зору та алгоритмів штучного інтелекту для систем автономного водіння. Рукопис.

Кваліфікаційна робота магістра ОП «Комп'ютерна інженерія» спеціальності 123 Комп'ютерна інженерія. Луцький національний технічний університет. Луцьк, 2025.

Кваліфікаційна робота складається з вступу, трьох розділів, висновків, переліку використаних джерел та додатку.

У першому розділі розкрито теоретичні основи інтеграції комп'ютерного зору та алгоритмів штучного інтелекту в системах автономного водіння. Проаналізовано типи та характеристики камер і сенсорних технологій, розглянуто етапи отримання й попередньої обробки зображень, а також підходи до виділення ознак, виявлення об'єктів, сегментації та оцінювання відстані в дорожній сцені.

У другому розділі розроблено апаратну архітектуру інтегрованої системи комп'ютерного зору та ШІ для автономного транспортного засобу. Здійснено аналіз вимог до апаратної платформи, обґрунтовано вибір сенсорного комплексу, підібрано обчислювальну платформу з апаратними прискорювачами глибинних нейронних мереж та запропоновано схемотехнічні рішення апаратної інтеграції на кузові й у салоні автомобіля.

У третьому розділі проведено експериментальне дослідження запропонованої системи в умовах, наближених до реальних сценаріїв дорожнього руху. Описано методику побудови експериментального конвеєра обробки зображень, отримано кількісні показники якості детекції об'єктів, сегментації дорожньої сцени й оцінювання відстані.

Ключові слова: комп'ютерний зір, автономне водіння, глибинні нейронні мережі, сегментація дорожньої сцени, виявлення об'єктів, оцінювання відстані, сенсорний комплекс, обчислювальна платформа, NVIDIA Jetson Orin, системи підтримки водія (ADAS).

## ANNOTATION

Sukhetskyi P. Integration of Computer Vision and Artificial Intelligence Algorithms for Autonomous Driving Systems. Manuscript.

Master's degree thesis in the field of Computer Engineering, specialty 123 Computer Engineering. Lutsk National Technical University. Lutsk, 2025.

The qualification work consists of an introduction, three chapters, conclusions, a list of sources used, and an appendix.

The first chapter reveals the theoretical foundations of integrating computer vision and artificial intelligence algorithms in autonomous driving systems. Types and characteristics of cameras and sensor technologies are analyzed, the stages of image acquisition and preprocessing are considered, as well as approaches to feature extraction, object detection, segmentation, and distance estimation in road scenes.

The second chapter develops the hardware architecture of an integrated computer vision and AI system for an autonomous vehicle. An analysis of the hardware platform requirements is carried out, the choice of the sensor suite is justified, a computing platform with hardware accelerators for deep neural networks is selected, and circuit design solutions for hardware integration on the vehicle body and in the cabin are proposed.

Chapter three presents an experimental study of the proposed system under conditions close to real traffic scenarios. The methodology for building an experimental image processing pipeline is described, and quantitative indicators of object detection quality, road scene segmentation, and distance estimation are obtained.

Keywords: computer vision, autonomous driving, deep neural networks, road scene segmentation, object detection, distance estimation, sensor suite, computing platform, NVIDIA Jetson Orin, driver assistance systems (ADAS).

## ЗМІСТ

ВСТУП .....	8
РОЗДІЛ 1 ТЕОРЕТИЧНІ ОСНОВИ ІНТЕГРАЦІЇ КОМП'ЮТЕРНОГО ЗОРУ ТА АЛГОРИТМІВ ШТУЧНОГО ІНТЕЛЕКТУ В СИСТЕМАХ АВТОНОМНОГО ВОДІННЯ.....	11
1.1 Роль комп'ютерного зору в системах автономного водіння .....	11
1.2 Камери та сенсорні технології в автономних транспортних системах .....	16
1.3 Отримання та попередня обробка зображень .....	22
1.3.1 Геометрична корекція та нормалізація.....	24
1.3.2 Видалення шумів та підсилення сигналу .....	25
1.3.3 Баланс білого та корекція кольорів.....	27
1.3.4 HDR-обробка та підсилення контрастності .....	28
1.4 Виділення ознак, виявлення об'єктів, сегментація та оцінювання відстані в дорожній сцені.....	29
РОЗДІЛ 2 АПАРАТНА РЕАЛІЗАЦІЯ ІНТЕГРОВАНОЇ СИСТЕМИ КОМП'ЮТЕРНОГО ЗОРУ ТА ШІ ДЛЯ АВТОНОМНОГО ВОДІННЯ.....	33
2.1 Аналіз вимог до апаратної платформи .....	33
2.2 Сенсорний комплекс системи автономного водіння.....	35
2.2.1 Вибір та характеристики камер .....	36
2.2.2 Додаткові сенсори.....	37
2.2.3 Модуль навігації .....	39
2.3 Обчислювальна платформа та апаратні прискорювачі ШІ .....	41
2.4 Апаратна інтеграція на транспортному засобі.....	43
РОЗДІЛ 3 ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ІНТЕГРАЦІЇ КОМП'ЮТЕРНОГО ЗОРУ ТА АЛГОРИТМІВ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ СИСТЕМ АВТОНОМНОГО ВОДІННЯ.....	47
3.1 Постановка експерименту .....	47
3.2 Методика побудови експериментального конвеєра.....	47
3.2.1 Захоплення зображень та попередня обробка .....	47

3.2.2 Виділення ознак та виявлення об'єктів .....	48
3.2.3 Сегментація дорожньої сцени .....	49
3.2.4 Оцінювання відстані та розуміння сцени.....	50
3.3 Результати експериментів та їх аналіз .....	51
ВИСНОВКИ.....	56
ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	59
ДОДАТКИ.....	63

## ВСТУП

Інтеграція комп'ютерного зору та алгоритмів штучного інтелекту в системах автономного водіння є надзвичайно актуальною через різке зростання складності дорожнього руху та високий рівень аварійності, зумовлений людським фактором. Комп'ютерний зір у поєднанні з глибинними нейронними мережами дає змогу розпізнавати транспортні засоби, пішоходів, дорожні знаки, розмітку, прогнозувати траєкторії руху та оцінювати ризики зіткнення в режимі реального часу, що безпосередньо пов'язано з підвищенням безпеки дорожнього руху, зниженням кількості аварій та мінімізацією людських втрат.

Важливим аспектом актуальності також є розвиток індустрії автономного транспорту та нормативно-правової бази в усьому світі. Світові автовиробники, ІТ-компанії та стартапи інвестують мільярди доларів у розробку систем ADAS та повністю автономних автомобілів, формуючи запит на нові алгоритми сприйняття, стійкі до погодних умов, складних міських сценаріїв і кіберзагроз. У цьому контексті інтеграція комп'ютерного зору з алгоритмами ШІ на бортових високопродуктивних платформах є не лише науковою проблемою, а й практичним завданням, без вирішення якого неможливі масштабне впровадження безпілотного транспорту, розвиток «розумної» інфраструктури та побудова безпечних інтелектуальних транспортних систем у містах. Тому дослідження в цій сфері мають високу наукову новизну, прикладну значущість і відповідають глобальним трендам цифрової трансформації та мобільності.

Мета кваліфікаційної роботи магістра полягає у розробленні та експериментальній перевірці інтегрованої системи комп'ютерного зору та алгоритмів штучного інтелекту для підвищення ефективності й безпеки автономного водіння. Для досягнення поставленої мети передбачено виконання таких завдань:

- проаналізувати роль комп'ютерного зору в системах автономного водіння;

- дослідити сучасні підходи до використання камер і сенсорних технологій в автономних транспортних системах;
- дослідити методи отримання та попередньої обробки зображень, виділення ознак, виявлення об'єктів, сегментації дорожньої сцени й оцінювання відстані у відеопотоці;
- сформулювати функціональні, експлуатаційні та апаратні вимоги до інтегрованої системи комп'ютерного зору та ШІ для автономного транспортного засобу;
- обґрунтувати вибір сенсорного комплексу і розробити структурну схему їх підключення;
- розробити та реалізувати експериментальний конвеєр обробки зображень з інтеграцією алгоритмів комп'ютерного зору й штучного інтелекту на обраній апаратній платформі.
- провести експериментальні дослідження якості детекції об'єктів, сегментації сцени та оцінювання відстані.

Предметом дослідження є методи, моделі та апаратно-програмні засоби інтеграції комп'ютерного зору й алгоритмів штучного інтелекту в системах автономного водіння.

Об'єктом дослідження є процеси сприйняття, аналізу та інтерпретації дорожньої сцени автономним транспортним засобом на основі даних сенсорного комплексу.

Наукова новизна роботи полягає в експериментальній перевірці інтегрованої апаратно-програмної архітектури системи комп'ютерного зору та ШІ для автономного водіння на базі платформи NVIDIA Jetson Orin, що поєднує сенсорний комплекс (фронтальні та оглядові камери, навігаційні модулі) з конвеєром глибинної обробки зображень (детекція, сегментація, оцінювання відстані) і забезпечує формування узгодженої моделі дорожньої сцени в режимі, наближеному до реального часу.

Практичне значення роботи полягає у створенні апробованого апаратно-програмного прототипу системи комп'ютерного зору та ШІ для автономного водіння, який може бути використаний як основа для подальшої розробки

дослідницьких та промислових рішень у сфері безпілотного транспорту. Отримані результати, схемотехнічні рішення та експериментальні методики можуть бути впроваджені в дослідницькі платформи для підготовки фахівців з комп'ютерної інженерії та інтелектуальних транспортних систем.

Отримані результати створюють підґрунтя для подальшого вдосконалення інтелектуальних транспортних систем, підвищення безпеки дорожнього руху та розвитку вітчизняних рішень у галузі автономних транспортних засобів.

Апробація результатів дослідження. Основні результати кваліфікаційної роботи висвітлено у науковій статті в Технічних вістях [1].

# РОЗДІЛ 1

## ТЕОРЕТИЧНІ ОСНОВИ ІНТЕГРАЦІЇ КОМП'ЮТЕРНОГО ЗОРУ ТА АЛГОРИТМІВ ШТУЧНОГО ІНТЕЛЕКТУ В СИСТЕМАХ АВТОНОМНОГО ВОДІННЯ

### 1.1 Роль комп'ютерного зору в системах автономного водіння

У сучасних системах автономного водіння сприйняття навколишнього середовища є критичною складовою, оскільки саме на його основі відбувається прийняття рішень щодо траєкторії руху, уникнення перешкод, дотримання правил дорожнього руху.

Комп'ютерний зір – це набір технологій і алгоритмів, що дозволяють перетворювати сигнали від камер (та іноді суміжних сенсорів) у структуровану інформацію про об'єкти, розмітку, дорожні знаки, пішоходів тощо [2].

Так, останні огляди відзначають, що модулі сприйняття на основі комп'ютерного зору займають центральне місце в архітектурі автономного транспортного засобу. Зокрема, у статті австралійських вчених зазначено, що «the perception system is a fundamental component which enables the autonomous vehicle to gather data and extract essential information from its surrounding to ensure safe driving» [3].

Типова архітектура автономного автомобіля поділяється на кілька ключових рівнів:

- сенсорна підсистема (камери, LiDAR, RADAR, ультразвук);
- підсистема сприйняття (perception) – аналіз даних сенсорів;
- підсистема локалізації та картографування (localization & mapping);
- підсистема планування та керування (planning & control).

Комп'ютерний зір належить до підсистеми сприйняття, забезпечуючи інтерпретацію візуальної інформації, а також взаємодіє з підсистемою планування (для прийняття рішень) й локалізації (через аналіз візуальних сцен).

Наприклад, у своїй публікації [4], науковці окреслюють модульний pipeline: perception → planning → action, і зазначають, що перший модуль часто ґрунтується на CNN-підходах.

Поданий рисунок 1.1, демонструє дві концептуально різні архітектури автономного керування транспортним засобом: модульну та End-to-End. Модульний підхід передбачає послідовне виконання окремих функціональних блоків – сприйняття, планування, арбітражу поведінки та керування рухом, кожен з яких може базуватися як на класичних методах, так і на алгоритмах глибокого навчання. Така структура забезпечує високу інтерпретованість, можливість окремої валідації модулів та гнучкість модернізації.

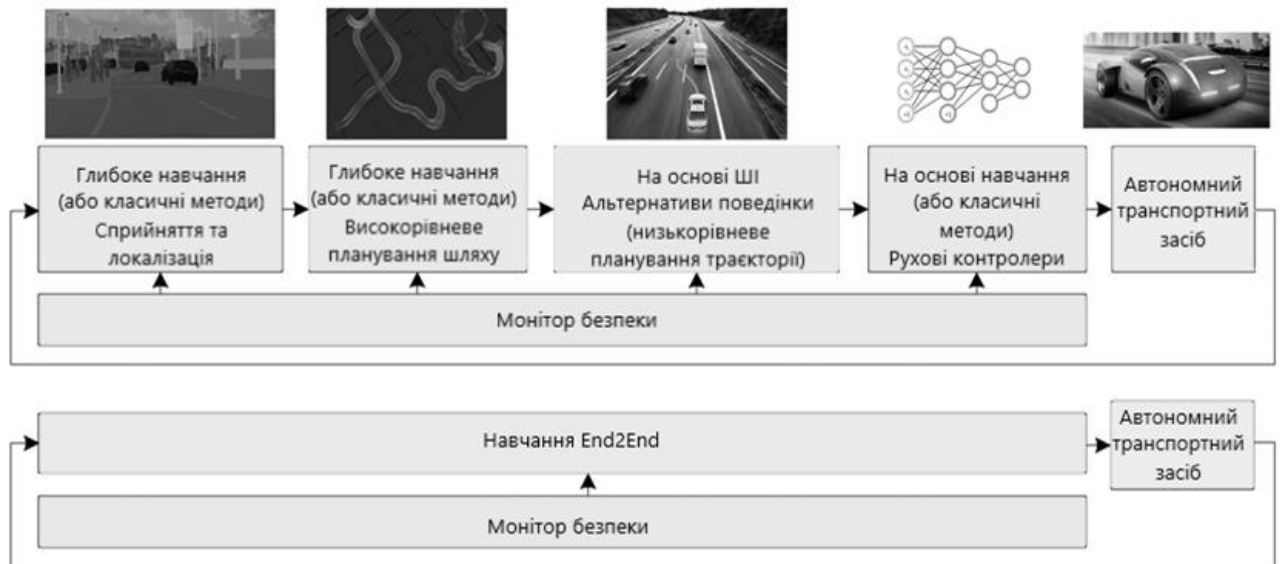


Рисунок 1.1 – Архітектури автономного керування: модульний підхід та підхід End-to-End [4]

На відміну від цього, підхід End-to-End інтегрує всі етапи обробки в єдину нейронну модель, що напряду перетворює сенсорні дані у керувальні дії. Це дозволяє досягати високої адаптивності й потенційно кращої узгодженості між модулями, проте ускладнює процес пояснення рішень та створює додаткові вимоги до обсягів навчальних даних.

Таким чином, основні відмінності між класичною та End-to-End архітектурами дозволяють оцінити їх переваги й обмеження у контексті створення надійних і безпечних систем автономного водіння.

Перелік основних задач, які вирішує комп'ютерний зір у контексті автономного водіння визначено в таблиці 1.1.

Таблиця 1.1 – Основні задачі комп'ютерного зору в автономному водінні [2-4]

Задача	Короткий опис
детекція об'єктів (Object Detection)	виявлення транспортних засобів, пішоходів, велосипедистів, тварин, статичних об'єктів
класифікація і ідентифікація	визначення типу об'єкта (наприклад, автобус, легковий автомобіль, мотоцикл) і, можливо, окремої ідентифікації
сегментація сцени: семантична / інстанс (Semantic / Instance Segmentation)	класифікація пікселів на класи («дорога», «тротуар», «будівля», «пішохід») та відокремлення окремих екземплярів об'єктів
виявлення розмітки (Lane Detection)	виявлення і відстеження смуг, утримання автомобіля у смузі
розпізнавання дорожніх знаків і сигналів (Traffic Sign/Signal Recognition)	визначення дорожніх знаків, світлофорів, індикаторів
оцінка глибини і просторових відстаней (Depth Estimation / 3D Reconstruction)	визначення відстані до об'єктів, будівництво 3D-моделі сцени чи оцінка структури за допомогою камери/стереокамери

Аналіз показує, що кожна із задач – від детекції об'єктів до оцінювання глибини сцени, виконує важливу функцію в забезпеченні безпечного та надійного руху. Їх сукупна робота дозволяє транспортному засобу не лише розпізнавати елементи дорожньої інфраструктури, а й формувати структуроване та інтерпретоване уявлення про простір, необхідне для планування траєкторії, прогнозування поведінки інших учасників руху та прийняття оперативних рішень.

Таким чином, ефективність систем автономного водіння безпосередньо залежить від узгодженого функціонування усіх модулів комп'ютерного зору, а їхня точність і стійкість визначають рівень автономності та безпеки транспортного засобу.

Раніше задача комп'ютерного зору базувалася на ручному виділенні ознак (наприклад, HOG, SIFT, Наар-каскади), після чого застосовували класичні алгоритми машинного навчання. Проте з появою згорткових нейронних мереж (CNN) відбувся технологічний стрибок: алгоритми почали вивчати ознаки самостійно, що суттєво покращило точність і гнучкість. Згідно з [5], використання CNN, RNN, а також підходів reinforcement learning стало типовим для систем автономного водіння.

Окрім CNN, сучасні дослідження звертають увагу на Vision Transformers (ViT), які дозволяють краще захоплювати контекст зображення, оскільки застосовують механізм самоуваги (self-attention). На рисунку 1.2 продемонстровано, що трансформери використовуються для завдань детекції, сегментації та оцінки сцени.

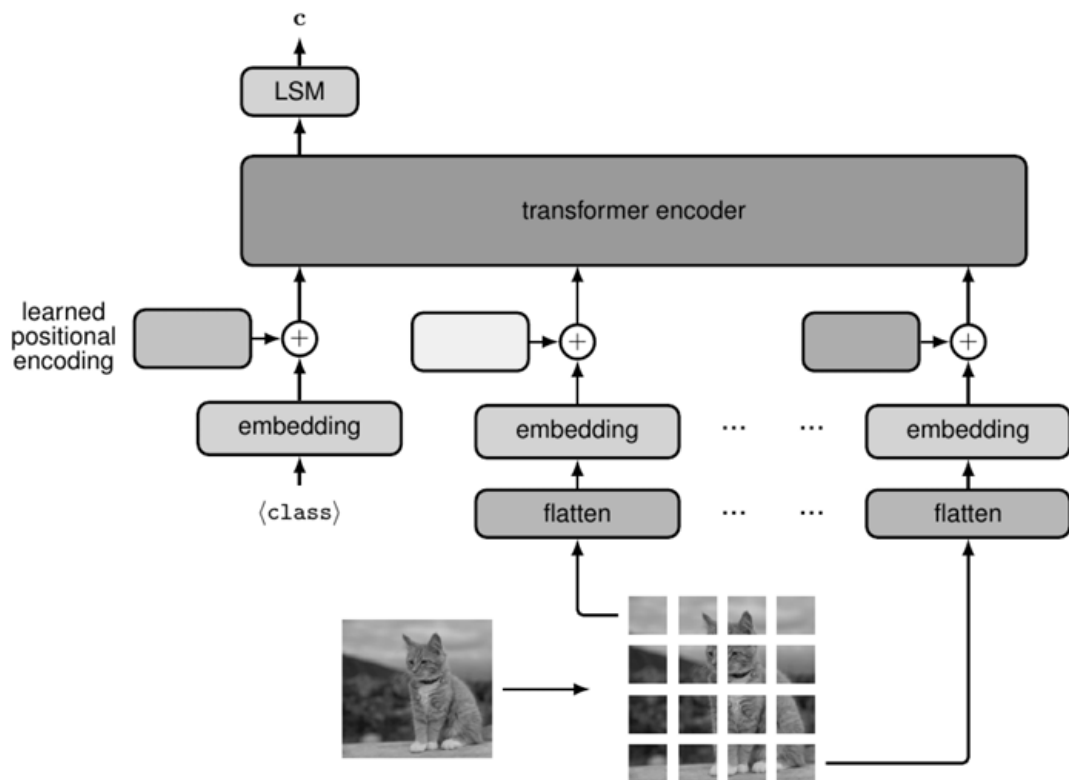


Рисунок 1.2 – Архітектура Vision Transformer [6]

Вхідне зображення розбивається на послідовність патчів, кожен із яких перетворюється на вектор ознак (embedding) та доповнюється позиційними кодуваннями, що дозволяє моделі враховувати просторові взаємозв'язки між

фрагментами. Далі послідовність передається до трансформерного енкодера, який забезпечує глобальне узгодження інформації між усіма частинами зображення.

Перевага такого підходу полягає у здатності моделі ефективно формувати контекстуальні залежності без обмеження локальністю фільтрів, властивих CNN. Завдяки цьому Vision Transformers демонструють високу ефективність у задачах класифікації, сегментації та оцінки сцени, що робить їх перспективним інструментом у системах автономного водіння.

У контексті автономного водіння система комп'ютерного зору повинна відповідати кільком критичним вимогам:

- реальний час – затримки захоплення кадру, обробки та передачі результату не повинні призводити до несвоєчасної реакції на зміну дорожньої ситуації;

- точність та повнота сприйняття – система має мінімізувати хибні спрацювання (false positives) і пропуски (false negatives) – особливо в контексті безпеки;

- стійкість до умов навколишнього середовища – робота при зміненому освітленні, дощі, тумані, засвітках, наявності відбиттів, а також частковій закритості об'єктів;

- вбудовуваність в обмежені ресурси – при використанні вбудованих платформ (SBC, SoC) обчислювальна потужність може бути обмежена, тому оптимізація моделей, прискорення, квантизація тощо стають важливими;

- надійність і пояснюваність (explainability) – у безпеково-критичних системах автономного водіння потрібно забезпечувати не лише високу точність, але й розуміння причин прийнятих рішень.

Комп'ютерний зір має прямий вплив на безпеку автономного транспортного засобу. Якщо система сприйняття не зможе адекватно виявити пішохода, транспортний засіб або зміну дорожньої розмітки, це може призвести до аварійної ситуації. Дослідження [7] вказує на те, що фахівці галузі відзначають значний прогрес технологій, але також підкреслюють, що

екологічна адаптивність, обробка даних і алгоритмічна ефективність залишаються «вузькими місцями».

Отже, комп'ютерний зір – це не опціональний модуль у системі автономного водіння, а фундаментальна технологія, без якої система не може адекватно функціонувати. Він забезпечує «очі» транспортного засобу, трансформуючи дані з камер у інформацію для алгоритмів штучного інтелекту та систем керування.

## **1.2 Камери та сенсорні технології в автономних транспортних системах**

Камери та сенсорні технології є ключовими елементами архітектури автономних транспортних систем, оскільки забезпечують автомобіль первинною інформацією про навколишнє середовище. На відміну від традиційних систем підтримки водія, де сенсорика відіграє допоміжну роль, в автономних транспортних засобах вона стає основним джерелом даних для алгоритмів сприйняття, локалізації, прогнозування та планування. Саме точність та надійність сенсорної підсистеми визначають рівень автономності автомобіля та його здатність безпечно взаємодіяти з дорожньою інфраструктурою, іншими транспортними засобами й пішоходами.

Камери – це базовий сенсор автономного автомобіля, оскільки вони забезпечують високу деталізацію сцени (текстури, кольори, форми) та здатні фіксувати об'єкти на різних відстанях у режимі реального часу. Сучасні системи використовують:

- монохромні та RGB-камери для аналізу структури та кольору зображення;
- стереокамери для оцінки глибини та вимірювання відстаней за принципом триангуляції;
- камери кругового огляду (360°) для забезпечення повної ситуаційної обізнаності;

– інфрачервоні камери (IR), які допомагають в умовах низької освітленості;

– Time-of-Flight камери, здатні вимірювати відстань до об'єктів шляхом аналізу часу проходження світлового імпульсу [8].

Моно- та стереокамери є ключовими для задач сегментації дороги, виявлення розмітки, класифікації дорожніх знаків, розпізнавання об'єктів та оцінки їхньої динаміки. Згідно з сучасними дослідженнями, камери забезпечують найбільшу інформативність серед усіх сенсорів, оскільки дозволяють алгоритмам комп'ютерного зору отримувати семантичні та структурні ознаки сцени, які недоступні для радарів або LiDAR у такому обсязі.

При цьому важливою особливістю камер є їхня залежність від зовнішніх умов. Яскраве сонячне світло, засвітки фар, дощ, сніг, туман та нічне середовище можуть спотворювати візуальну інформацію. Саме тому сучасні системи використовують поєднання декількох типів камер, адаптивні алгоритми автокорекції зображення та механізми фільтрації шумів.

Лазерний далекомір (LiDAR) генерує тривимірну хмару точок, яка є найбільш точним відображенням геометрії навколишнього простору. LiDAR-сенсор обчислює відстані до об'єктів за допомогою часу повернення лазерного імпульсу (Time-of-Flight). Переваги LiDAR:

- висока точність оцінювання відстаней;
- незалежність від освітлення;
- здатність коректно розпізнавати форму об'єктів;
- можливість роботи у складних дорожніх умовах.

LiDAR особливо ефективний у системах локалізації та побудови карт високої точності (HD-мабпінг), а також для прогнозування траєкторій об'єктів у складному трафіку. Недоліками є висока вартість, енергоспоживання та можливі складнощі при роботі в умовах сильного дощу або снігу, через які частина лазерних променів розсіюється.

Радар (RADAR) працює в міліметровому діапазоні та визначає швидкість і відстань до об'єктів на основі ефекту Доплера.

Основні переваги:

- стабільна робота в дощ, туман, сніг та пил;
- точна оцінка відносної швидкості об'єктів;
- низька чутливість до освітлення;
- великий діапазон вимірювання (до 250 м).

RADAR часто використовується для адаптивного круїз-контролю, виявлення транспортних засобів попереду та визначення ризику зіткнення. Однак просторове розділення радарів нижче, ніж у камер або LiDAR, тому RADAR найефективніший у поєднанні з іншими сенсорами.

Для кращого розуміння особливостей сенсорних технологій, що використовуються в автономних транспортних системах, на рисунку 1.3 наведено порівняльну характеристику двох ключових типів далекомірних сенсорів – LiDAR та RADAR, які відіграють важливу роль у формуванні просторової моделі навколишнього середовища.



Рисунок 1.3 – Порівняння сенсорів LiDAR та RADAR [9]

Отже, LiDAR і RADAR виконують доповнювальні функції у сенсорній системі автономного автомобіля. LiDAR забезпечує високу просторову точність та створення детальних 3D-карт, що є критичним для точного

позиціонування та виявлення об'єктів. Натомість RADAR має меншу роздільну здатність, однак значно ефективніший у складних погодних умовах, зокрема під час дощу, туману чи снігу, завдяки стійкості радіохвиль. Таким чином, ці сенсори не є взаємозамінними, а їх комбіноване використання у рамках сенсор-ф'южн підвищує надійність та безпеку систем автономного водіння.

Ультразвукові датчики використовуються на малих швидкостях і забезпечують вимірювання відстані до об'єктів у діапазоні від кількох сантиметрів до кількох метрів. Вони незамінні для:

- систем паркування;
- маневрування у вузьких просторах;
- виявлення низькопрофільних перешкод.

Ці датчики є недорогими та надійними, проте їх інформаційна ємність значно нижча, ніж у інших сенсорів – вони не дають семантичних або структурних даних.

На рисунку 1.4 наведено три типові сценарії використання ультразвукових датчиків, що застосовуються в автономних транспортних засобах під час паркування, маневрування у вузьких просторах та виявлення низькопрофільних перешкод.



Рисунок 1.4 – Приклад роботи ультразвукових датчиків у ближній зоні автомобіля [10]

У першому сценарії датчики допомагають автомобілю точно оцінювати відстань до перешкод під час паркування; у другому – підтримують маневрування в обмежених просторах; у третьому – дозволяють своєчасно виявляти низькопрофільні об'єкти, що можуть не фіксуватися іншими сенсорами.

Інерційний вимірювальний блок (IMU) включає акселерометр та гіроскоп, що забезпечують:

- оцінку прискорення;
- визначення нахилу та повороту;
- стабілізацію локалізації при втраті сигналів інших сенсорів.

Для пояснення принципу роботи інерційного вимірювального блоку в контексті автономних транспортних систем на рисунку 1.5 наведено приклад інтеграції IMU в автомобілі та візуалізовано дані акселерометра й гіроскопа, що використовуються для оцінювання прискорень, кутових швидкостей та орієнтації транспортного засобу.

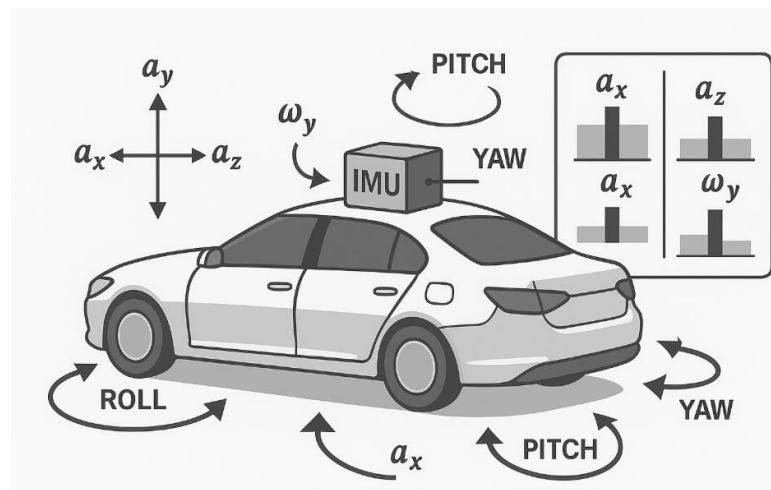


Рисунок 1.5 – Робота інерційного вимірювального блоку (IMU) в автономному автомобілі [11]

Інерційний вимірювальний блок формує критично важливі дані для автономного водіння, забезпечуючи вимірювання лінійних прискорень та кутових швидкостей транспортного засобу в трьох осях. Ці параметри дозволяють точно визначити нахил, поворот та зміну орієнтації автомобіля

навіть у ситуаціях, коли дані від камер, LiDAR чи GNSS недоступні або зазнають перешкод.

GNSS (GPS, ГЛОНАСС, Galileo) дає глобальну позицію транспортного засобу. Для розуміння принципів роботи супутникових навігаційних систем у контексті автономного водіння на рисунку 1.6 подано схему визначення глобальної позиції транспортного засобу за допомогою GNSS, що включає GPS, ГЛОНАСС та Galileo, а також використання RTK-корекції для підвищення точності позиціонування.




Рисунок 1.6 – Принцип роботи GNSS у автономному транспортному засобі [12]

Глобальні навігаційні супутникові системи (GNSS) забезпечують визначення просторових координат транспортного засобу шляхом приймання сигналів одночасно від кількох супутникових сузір'їв – GPS, ГЛОНАСС і Galileo. Рисунок 1.6 підкреслює важливу роль RTK-корекції, яка дозволяє зменшити похибку визначення місцезнаходження до рівня  $\pm 2$  см, що є критично необхідним для точного позиціонування автономних транспортних

засобів під час маневрування, планування траєкторії та узгодження даних із картами високої точності (HD-maps).

Отже, поєднання камери, LiDAR, RADAR, ультразвук, IMU та GNSS забезпечує надійне сприйняття, безперервну локалізацію та безпеку руху. Використання мультисенсорних систем створює стійку архітектуру сприйняття, здатну працювати в умовах реального дорожнього середовища, де рівень невизначеності та швидкі зміни ситуації вимагають максимальної точності та швидкості реакції.

### **1.3 Отримання та попередня обробка зображень**

Отримання та попередня обробка зображень є одним із ключових компонентів комп'ютерного зору в автономних транспортних системах, оскільки саме на цьому етапі формується базовий набір візуальних даних, що використовуються для детекції об'єктів, сегментації дорожньої сцени, розпізнавання дорожніх знаків та подальшого планування траєкторії. Якість первинних зображень визначає ефективність алгоритмів машинного та глибокого навчання, тому системи автономного водіння приділяють значну увагу стабільності зйомки, динамічному діапазону, частоті кадрів, а також методам фільтрації та нормалізації даних. Помилки на стадії сенсорного захоплення не можуть бути повністю компенсовані подальшою обробкою, що підкреслює критичність якісного отримання зображень.

Сучасні автономні транспортні платформи використовують високопродуктивні камери різних типів: фронтальні, бокові, задні, ширококутні, панорамні (360°) та інфрачервоні. Основними параметрами, що впливають на якість отриманих зображень, є висока частота кадрів (FPS), широкий динамічний діапазон (HDR), оптика та стабілізація.

Для стабільного аналізу динамічного середовища необхідно 30-60 FPS. У деяких системах, наприклад, Tesla FSD Beta, використовуються камери з частотою до 60-90 FPS, що дозволяє зменшити часову затримку між подіями та реакцією алгоритмів.

HDR-технології дозволяють компенсувати проблеми засвітів, глибоких тіней, зустрічних фар та різких перепадів освітленості.

Сучасні камери оснащуються високоякісними лінзами з низькою дисторсією, а також механічною або електронною стабілізацією (EIS), що зменшує нечіткість під час руху автомобіля по нерівностях.

Для демонстрації взаємозв'язку між процесом захоплення візуальних даних та їхньою подальшою обробкою у системах автономного водіння на рисунку 1.7 наведено приклад вихідного зображення з камери та відповідного результату після застосування алгоритмів попередньої обробки.



Рисунок 1.7 – Первинне зображення з камери автономного автомобіля та його попередня обробка [13]

Рисунок 1.7 демонструє сутність етапу попередньої обробки зображень, який перетворює сирі дані з камери на структуроване та покращене візуальне представлення, придатне для подальших алгоритмів комп'ютерного зору. Зображення після обробки має вищий контраст, зменшений рівень шумів та покращену видимість об'єктів, що значно підвищує точність детекції транспортних засобів, розмітки та інших елементів дорожньої сцени. Такий процес оптимізує роботу нейронних моделей, забезпечуючи стійке сприйняття складних умов, зокрема при змінному освітленні або погіршеній видимості. У

результаті попередня обробка зображень є критичною складовою загальної архітектури автономного водіння, оскільки безпосередньо впливає на точність і надійність прийняття рішень.

Попередня обробка зображень забезпечує стандартизоване вхідне представлення даних для глибоких нейронних мереж, таких як YOLOv8, DeepLabv3+, Mask R-CNN, DETR або Vision Transformers.

### 1.3.1 Геометрична корекція та нормалізація

Геометрична корекція є одним із базових етапів попередньої обробки зображень, оскільки сирі дані з камери містять низку оптичних спотворень, що можуть суттєво вплинути на роботу моделей комп'ютерного зору. Зокрема, ширококутні та автомобільні камери часто мають бочкоподібну (barrel) або подушкоподібну (pincushion) дисторсію, що викривляє прямі лінії та змінює геометрію об'єктів на периферії зображення.

Для узагальнення основних етапів первинної геометричної обробки зображень у системах комп'ютерного зору на рисунку 1.8 наведено послідовність трансформацій, які застосовуються до сирих даних з камери автономного транспортного засобу перед подачею їх до моделей глибокого навчання.



Рисунок 1.8 – Етапи геометричної корекції та нормалізації зображення в системах автономного водіння [13]

Компенсація дисторсії є одним із ключових етапів попередньої обробки зображень, оскільки автомобільні камери, особливо ширококутні, мають

властивість викривляти геометрію сцени. Такі спотворення проявляються у вигляді бочкоподібної або подушкоподібної дисторсії, що призводить до викривлення прямих ліній та зміни пропорцій об'єктів по краях кадру. Математична модель Камера-Об'єктив описує ці спотворення за допомогою внутрішніх параметрів та коефіцієнтів дисторсії, що дозволяє точно компенсувати їх.

Ще одним важливим етапом є вирівнювання перспективи (*perspective rectification*), яке дозволяє компенсувати нахили камери, стабілізувати положення ліній дорожньої розмітки та зменшити ефект «завалу горизонту». Це особливо критично для алгоритмів виявлення дорожніх смуг, оскільки навіть незначні геометричні відхилення можуть призвести до помилок сегментації або втрати цілісності ліній. За допомогою корекції перспективи система формує геометрично узгоджене зображення дорожньої сцени, що підвищує точність моделей *lane detection*, *road segmentation* та інших алгоритмів, чутливих до структури сцени.

Калібрування камери є завершальним етапом геометричної підготовки і передбачає визначення матриці внутрішніх параметрів – фокусної відстані, центру проєкції та коефіцієнтів радіальної й тангенціальної дисторсії. Автономні транспортні засоби зазвичай оснащені від семи до дванадцяти камер, і кожна з них повинна проходити індивідуальну процедуру калібрування для забезпечення коректної роботи алгоритмів сприйняття. Після цього зображення масштабуються до стандартних розмірів, що відповідають вимогам конкретної нейронної мережі (224×224, 416×416, 640×640 або 1024×1024), а процес нормалізації *mean/std* забезпечує стабільність навчання та швидку збіжність моделей глибокого навчання. Сукупність цих геометричних і статистичних перетворень забезпечує формування узгоджених, чистих та стандартизованих вхідних даних для систем комп'ютерного зору в автономних транспортних системах.

### 1.3.2 Видалення шумів та підсилення сигналу

Видалення шумів є важливим етапом попередньої обробки зображень, оскільки візуальні дані з камер автономного автомобіля часто містять різні

види перешкод, спричинених недостатнім освітленням, атмосферними умовами (дощ, сніг, туман), електронними шумами сенсора або паразитними засвітками. Такі фактори суттєво знижують якість зображення та ускладнюють роботу алгоритмів комп'ютерного зору, які потребують чітких контурів і стабільного контрасту для точного розпізнавання дорожніх об'єктів, розмітки та інших учасників руху.

Для кращого розуміння основних підходів до покращення якості зображень у системах автономного водіння на рисунку 1.9, наведено узагальнену схему методів видалення шумів та підсилення сигналу, що використовуються для стабілізації візуальних даних у складних умовах освітлення та погоди.

Традиційні методи фільтрації шумів включають Gaussian Blur, Bilateral Filtering та Non-Local Means. Gaussian Blur ефективно пригнічує випадкові високочастотні шуми, однак має недолік – розмивання контурів, що є неприйнятним у задачах, де важлива точність структури об'єктів. Bilateral Filtering дозволяє зберігати краї, водночас згладжуючи однорідні області зображення, що робить його корисним при сегментації дорожньої розмітки. Метод Non-Local Means демонструє хорошу здатність до відновлення текстур, проте є ресурсомістким і малопродатним для роботи в реальному часі, що обмежує його застосування в автономних системах.



а) Gaussian Blur

б) Bilateral Filtering

в) Non-Local Means

Рисунок 1.9 – Видалення шумів та підсилення сигналу [14]

Сучасні підходи до видалення шумів базуються на глибоких нейронних мережах, зокрема DnCNN, U-Net та SwinIR, які значно перевершують класичні фільтри за точністю відновлення деталей та структурою зображення. Нейромереві методи дозволяють адаптивно усувати шуми, не втрачаючи важливої інформації, що є критично необхідним для нічних дорожніх сцен, кадрів із високою ISO-чутливістю та ситуацій із несприятливими погодними умовами. Огляд сучасних технологій нейромережевого видалення шумів наведено у роботі вчених, де підкреслюється їхня здатність підвищувати якість даних для детекції дорожніх знаків, стабілізації ліній розмітки та зменшення впливу атмосферних артефактів [14]. У результаті алгоритми шумозаглушення відіграють важливу роль у забезпеченні стійкості сприйняття та надійності автономного водіння в умовах реального середовища.

### 1.3.3 Баланс білого та корекція кольорів

Баланс білого є критично важливим етапом попередньої обробки зображень, оскільки він компенсує спектральні зміни освітлення, які неминуче виникають у дорожніх умовах. Камери автономних транспортних засобів працюють у широкому діапазоні сцен – від нічного міського освітлення до яскравого сонця або змішаних джерел світла. Неправильний баланс білого може змістити кольорову температуру зображення, спотворивши кольори дорожніх знаків, світлофорів та маркування. Це призводить до зниження точності комп'ютерного зору, особливо в задачах розпізнавання об'єктів, де колір є одним з ключових ознак.

Традиційні алгоритми AWB (Automatic White Balance) базуються на припущенні про стабільність освітлення та статистичній рівномірності сцен. Однак у реальних умовах ці припущення порушуються, тому сучасні автономні системи використовують методи, які враховують структуру зображення, локальні колірні патерни та контекст сцени. Моделі глибокого навчання, включно з CNN- і Transformer-базованими підходами, дають змогу адаптивно коригувати баланс білого, покращуючи сприйняття кольорів у складних середовищах – тумані, засвітлених ділянках або вночі.

Корекція кольорів у поєднанні з балансом білого є необхідною для забезпечення стабільності роботи систем розпізнавання дорожніх знаків, контролю сигналів світлофора та кольорової сегментації дорожніх елементів. У поєднанні з іншими технологіями попередньої обробки, такими як HDR-ф'южн та фільтрація шумів, баланс білого формує узгоджене та передбачуване вхідне зображення, що підвищує надійність алгоритмів автономного водіння у всіх погодних та освітлювальних умовах.

#### 1.3.4 HDR-обробка та підсилення контрастності

HDR-обробка (High Dynamic Range) має ключове значення для систем автономного водіння, оскільки дорожні сцени часто містять одночасно дуже світлі та дуже темні області. Наприклад, виїзд із тунелю, зустрічні фари вночі або сильне сонячне світло можуть спричинити втрату деталей у критичних частинах кадру. Камери з обмеженим динамічним діапазоном не здатні коректно передати такі сцени, тому HDR-технології дозволяють об'єднати декілька експозицій або реконструювати розширений динамічний діапазон за допомогою нейромережових моделей для збереження деталізації.

Сучасні методи HDR-ф'южн поєднують короткі та довгі експозиції, забезпечуючи водночас відсутність засвітів і достатню деталізацію в темних ділянках. Використання глибоких нейронних мереж для HDR-реконструкції (рис. 1.10) дозволяє досягти високої стійкості до засвітів під час руху, що є критично важливим для розпізнавання розмітки, пішоходів та транспортних засобів у вечірній або нічний час.




Рисунок 1.10 – Використання глибоких нейронних мереж для HDR-реконструкції (перетворення LDR→HDR) [15]

Крім того, алгоритми на основі Vision Transformers здатні ефективно реконструювати колірні та контрастні переходи, що додатково покращує якість обробленого зображення [15].

Покращення контрасту є невід'ємною частиною HDR-обробки. Методи такі як CLAHE (Contrast Limited Adaptive Histogram Equalization) дозволяють вибірково підсилювати контраст у локальних областях зображення, не створюючи артефактів пересвічення. Це робить об'єкти дорожньої інфраструктури більш помітними та покращує результативність алгоритмів комп'ютерного зору. HDR та контрастна обробка в комплексі забезпечують стабільну якість сприйняття у складних ситуаціях, що підвищує надійність автономного водіння навіть у випадках різких змін освітлення.

#### **1.4 Виділення ознак, виявлення об'єктів, сегментація та оцінювання відстані в дорожній сцені**

Комп'ютерний зір для інтелектуальних транспортних систем ґрунтується на трьох взаємопов'язаних задачах:

- виділення інформативних ознак з відеопотоку;
- виявлення та сегментація об'єктів дорожньої сцени;
- оцінювання відстані до цих об'єктів та формування цілісного розуміння ситуації.

У сучасних системах підтримки водія (ADAS) і автономного руху ці задачі реалізуються як «єдиний конвеєр глибокого навчання, де вихід одних модулів (наприклад, семантичних карт та карт глибини) безпосередньо використовується наступними модулями для прийняття рішень у реальному часі» [16].

На початковому етапі обробки відеоданих здійснюється перетворення сирих пікселів у компактні, інваріантні до масштабу, освітлення та часткових оклюзій ознаки. Сучасні системи переважно використовують ознаки, автоматично навчені згортковими нейронними мережами (CNN) або трансформерами. У таких моделях проміжні карти активацій виступають

латентними ознаками високого рівня, що одночасно відображають форму, текстуру, контекст і взаємне розташування об'єктів сцени. Окремі дослідження показують, що використання глибоких архітектур із «легковаговими» бекбонами (наприклад, MobileNetV2, EfficientNetV2) дозволяє отримати достатньо виразні ознаки при помірній обчислювальній складності, що критично важливо для вбудованих обчислювальних платформ автомобілів [17].

Важливим аспектом є багатомасштабність виділення ознак. Дорожні сцени містять одночасно дуже близькі та дуже віддалені об'єкти (пішоходи, які переходять перед автомобілем, і транспортні засоби в перспективі), тому сучасні мережі використовують багаторівневі піраміди ознак (feature pyramid networks, FPN) та механізми багатомасштабної агрегації, що підвищує якість як виявлення об'єктів, так і оцінювання їх глибини [18].

Зокрема дослідження [19], демонструє, що ці моделі здатні забезпечити прийнятний компроміс між швидкістю й точністю для застосування в ADAS, працюючи на відеопотоці з частотою 30-60 кадрів на секунду та виявляючи об'єкти на складних міських сценах із шумами, відблисками та неповними спостереженнями.

Окремий напрямок – 3D-виявлення об'єктів, де модель не лише прогнозує 2D-рамку, а й орієнтацію, габарити та приблизну глибину об'єкта. Розширення архітектур YOLO під 3D-виявлення демонструє перспективність інтеграції глибини безпосередньо на етапі детекції, що спрощує подальше формування тривимірної карти оточення автомобіля.

Якщо виявлення об'єктів повертає дискретні рамки навколо значущих елементів сцени, то сегментація розподіляє кожен піксель зображення до певного класу. Семантична сегментація дозволяє виділити дороги, тротуари, зелені насадження, будівлі, небо, смуги руху тощо, тоді як інстанс-сегментація додатково розрізняє окремі екземпляри в межах одного класу (наприклад, три різні автомобілі на смузі). Паноптична сегментація поєднує переваги обох підходів і є найбільш інформативною формою «розуміння» сцени з погляду комп'ютерного зору.

Для дорожніх сцен особливе значення має коректна сегментація дорожньої поверхні, розмітки, бордюрів і зон, де рух заборонений. Погрішності в цих класах безпосередньо впливають на оцінку придатної для руху області (drivable area) і планування траєкторії, тому окремі роботи [20] фокусуються на покращенні саме сегментації дорожньої поверхні та смуг за допомогою спеціалізованих модулів уваги та багатомасштабних механізмів (рис. 1.11).

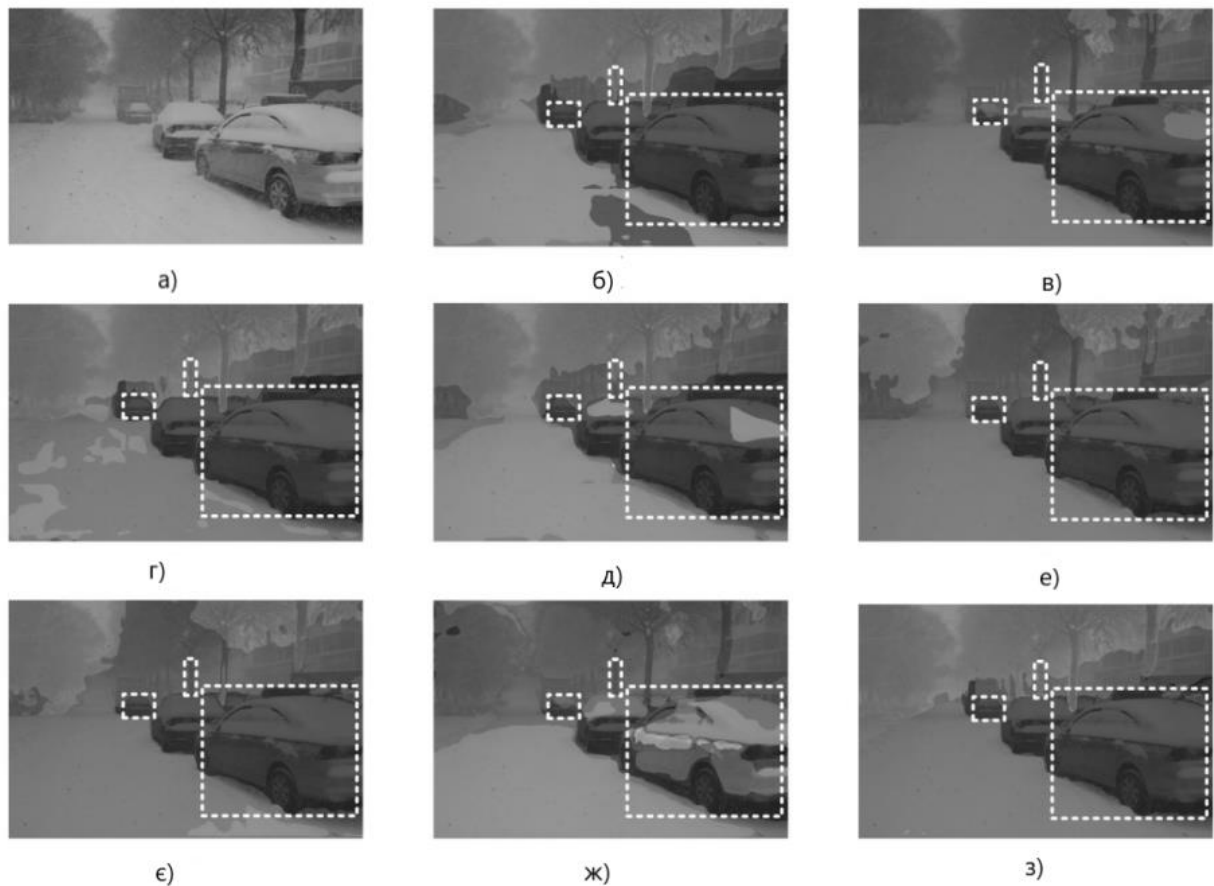


Рисунок 1.11 – Результати візуалізації методів семантичної сегментації у складних дорожніх сценах: а – оригінальне зображення; б – сегментоване зображення RTFormer; в – сегментоване зображення DeepLabV3+; г – сегментоване зображення SegFormer; д – сегментоване зображення FCN; е – сегментоване зображення PSPNet; є – сегментоване зображення BiSeNet2; ж – сегментоване зображення ICNet; з – сегментоване зображення нашого методу сегментації [20]

Виявлення об'єктів, сегментації та оцінювання відстані формує цілісну модель дорожньої сцени, яку можна подати у вигляді карти оточення в системі координат автомобіля (наприклад, bird's-eye view). На цій карті кожен об'єкт має свій клас, просторові координати, орієнтацію, швидкість і прогноз траєкторії, а дорожня поверхня поділена на придатні та непридатні для руху області (рис. 1.12). Таке представлення є базою для модулів планування траєкторій, прогнозування поведінки інших учасників руху та прийняття рішень щодо гальмування, об'їздів і зміни смуг.



Рисунок 1.12 – Карта оточення автомобіля з результатами виявлення об'єктів, сегментації придатної для руху області та оцінювання відстані [21]

Отже, об'єднання результатів виявлення об'єктів, семантичної сегментації та оцінювання відстані дозволяє сформувати цілісну просторово-часову модель дорожньої сцени у системі координат автомобіля. Така карта оточення, де кожен об'єкт має свій клас, координати, орієнтацію та прогноз траєкторії, а дорожня поверхня поділена на придатні й непридатні для руху зони, слугує базою для модулів планування траєкторії та прийняття рішень систем підтримки водія й автономного керування.

## РОЗДІЛ 2

### АПАРАТНА РЕАЛІЗАЦІЯ ІНТЕГРОВАНОЇ СИСТЕМИ КОМП'ЮТЕРНОГО ЗОРУ ТА ШІ ДЛЯ АВТОНОМНОГО ВОДІННЯ

#### 2.1 Аналіз вимог до апаратної платформи

Апаратна платформа інтегрованої системи комп'ютерного зору та штучного інтелекту для автономного водіння повинна забезпечувати безперервну роботу алгоритмів сприйняття, локалізації й планування руху в умовах реального часу. На відміну від звичайних вбудованих систем, тут поєднуються високі обчислювальні навантаження (обробка відеопотоку високої роздільної здатності, виконання глибоких нейронних мереж) та жорсткі обмеження щодо затримок, енергоспоживання й температурного режиму в салоні автомобіля.

Функціональні вимоги визначають перелік задач, які повинна виконувати апаратна платформа:

- захоплення й попередня обробка відеопотоку з фронтальних, бокових та оглядових камер;
- виконання моделей детекції об'єктів, семантичної/паноптичної сегментації та оцінювання глибини;
- реалізація модулів локалізації на основі злиття даних камер, лидара, радара, IMU та GNSS;
- передавання результатів у блоки планування траєкторії й керування виконавчими механізмами.

До функціональних вимог також належить можливість масштабування конфігурації: додавання нових камер, оновлення моделей ШІ, підтримка механізмів віддаленого оновлення (over-the-air) з апаратною перевіркою цілісності й автентичності коду, що вже реалізується в промислових платформах типу NVIDIA DRIVE AGX/Orin [22].

На рисунку 2.1 показано інтерфейс платформи NVIDIA DRIVE AGX як масштабоване й енергоефективне апаратне рішення для ШІ-обчислень, здатне обробляти складні робочі навантаження, необхідні для автономного водіння.



Рисунок 2.1 – Платформа NVIDIA DRIVE AGX: масштабовані та енергоефективні ШІ-обчислення для автономного водіння [22]

Продуктивність апаратної платформи визначається здатністю обробляти відео- та сенсорні дані в режимі, який відповідає динаміці руху транспортного засобу. Для задач сприйняття (детекція пішоходів, транспортних засобів, дорожніх знаків, розмітки) типовими є вимоги обробки 25-30 кадрів на секунду для кожної ключової камери високої роздільної здатності, що підтверджується експериментами з сучасними мережами комп'ютерного зору на автомобільному обладнанні.

Основним експлуатаційним параметром є кінцева затримка між появою об'єкта в полі зору та реакцією виконавчих механізмів. Аналітичні дослідження та практичні кейси показують, що для безпечного руху на шосейних швидкостях сумарна затримка конвеєра «сприйняття – прийняття рішення – керування» не повинна перевищувати приблизно 100 мс [23].

Отже, апаратна платформа має забезпечити достатній запас обчислювальних ресурсів CPU, GPU/NPU та пропускну здатність шин пам'яті й інтерфейсів, а також підтримувати механізми пріоритетності критичних задач реального часу, щоб гарантувати задану верхню межу затримки навіть у пікових режимах.

Автомобільні стандарти й рекомендації (AEC-Q, ISO 26262, I SO 16750-3) визначають вимоги до ресурсу компонентів, їхньої поведінки під

час температурних циклів і вібраційних навантажень, а також підходи до оцінювання випадкових апаратних відмов.

Це обумовлює використання автомобільних мікросхем із розширеним температурним діапазоном та ресурсом не менше 10-15 років експлуатації, розробку схем апаратного резервування (подвійні лінії живлення, дубльовані сенсори на критичних напрямках, резервні комунікаційні шини), а також реалізацію механізмів самодіагностики, контролю цілісності даних і сторожових таймерів для своєчасного виявлення й локалізації збоїв.

Функціональна безпека забезпечується через дотримання життєвого циклу, визначеного ISO 26262 [24], включаючи аналіз небезпек, визначення рівнів ASIL та реалізацію апаратних і програмних механізмів для досягнення прийняттого залишкового ризику.

Окремий клас вимог стосується інформаційної безпеки й захисту від кіберзагроз. Апаратна платформа повинна підтримувати механізми захищеного завантаження, апаратне шифрування та автентифікацію оновлень, ізоляцію критичних обчислювальних доменів від зовнішніх інтерфейсів і захист діагностичних портів, що прямо зазначається в сучасних інженерних керівництвах з проектування електроніки для транспортних засобів.

## **2.2 Сенсорний комплекс системи автономного водіння**

У даному дослідженні сенсорний комплекс сформовано як конкретну конфігурацію, орієнтовану на експериментальну перевірку алгоритмів комп'ютерного зору та ШІ в умовах наближених до реального автомобільного руху. Ми використали багатокамерну систему на базі automotive-сенсорів Sony та OmniVision, один 3D-лідар Velodyne VLP-16 «Puck», міліметровохвильовий радар Texas Instruments AWR1843, пояс ультразвукових датчиків ближньої дії, а також навігаційний модуль високоточної GNSS-системи u-blox ZED-F9P у зв'язці з IMU Bosch BMI088 і колісною одометрією (швидкість із шини CAN). Така конфігурація відповідає сучасним підходам до мультисенсорного злиття

в автономному водінні, де GNSS, IMU, LiDAR, радары та візуальна одометрія інтегруються в єдину систему локалізації й сприйняття.

### 2.2.1 Вибір та характеристики камер

Як фронтальну камеру для основного каналу сприйняття ми обрали модуль на базі CMOS-сенсора Sony IMX490 (рис. 2.2), розробленого спеціально для задач ADAS та автономного водіння.




Рисунок 2.2 – Sony IMX490 CMOS-сенсор [25]

Сенсор IMX490 має приблизно 5,4 Мп ефективної роздільної здатності (2896×1876), підтримує одночасно широкий динамічний діапазон HDR до 120-140 дБ та функцію LED Flicker Mitigation (LFM), що дозволяє коректно зчитувати інформацію зі світлофорів, LED-табло та фар інших автомобілів.

Висока роздільна здатність у поєднанні з широким кутом огляду робить IMX490 придатним для одночасного розпізнавання дорожньої розмітки, знаків, транспортних засобів, пішоходів та перешкод у зоні попереду автомобіля.

Для оглядових камер, що формують 360° картину оточення, ми використали модулі на базі сенсора OmniVision OX03C10 (рисунок 2.3). Цей 2,5-Мп сенсор автомобільного класу (ASIL-C) поєднує піксель 3,0  $\mu\text{m}$  з дуже високим динамічним діапазоном HDR 140 дБ і вбудованим алгоритмом LED Flicker Mitigation, що дозволяє отримувати якісне зображення навіть за різких перепадів освітлення та в умовах міського середовища з великою кількістю LED-джерел.




Рисунок 2.3 – CMOS-сенсор зображення з розширеним динамічним діапазоном (HDR) та технологією – OmniVision OX03C10 [26]

Ці камери розташовуються по периметру платформи (передній бампер, задній бампер, лівий/правий борт), підключаються до обчислювального модуля через інтерфейси MIPI CSI-2 і синхронізуються на рівні часових міток, що критично для подальшої побудови bird's-eye-view-представлення сцени.

Фронтальна IMX490 та чотири оглядові OX03C10 доповнюють одна одну: перша забезпечує «дальнє бачення» з високою деталізацією у напрямку руху, тоді як surround-камера дає змогу відстежувати об'єкти в сусідніх смугах, мертвих зонах та при маневрах на малій швидкості. Використання саме automotive-сенсорів із вбудованими HDR та LFM-функціями мінімізує кількість артефактів у вхідних даних та спрощує подальшу обробку алгоритмами комп'ютерного зору й глибинними неймережами.

### 2.2.2 Додаткові сенсори

Для отримання надійної метричної інформації про відстані та форму оточення ми інтегрували в систему 3D-лідар Velodyne VLP-16 «Puck» (рис. 2.4). Це 16-канальний лазерний сканер з максимальною дальністю до 100 м, типовою точністю близько  $\pm 3$  см,  $360^\circ$  горизонтальним полем зору та  $30^\circ$  вертикальним ( $\pm 15^\circ$ ).

На частоті обертання 10 Гц сенсор генерує близько 300-600 тис. точок за секунду, що дає змогу формувати щільну хмару точок і будувати точну тривимірну модель оточення для задач сегментації дорожньої поверхні, виявлення перешкод і побудови локальних карт.



Рисунок 2.4 – 3D-лідарний датчик Velodyne VLP-16 [27]

Для вимірювання відстані та відносної швидкості транспортних засобів у середньому діапазоні ми використали міліметровохвильовий радар Texas Instruments AWR1843 (77 ГГц) (рис. 2.5). Це однокристальний FMCW-радар, що працює в діапазоні 76-81 ГГц, інтегрує в одному корпусі MCU, DSP та спеціалізований радарний прискорювач, підтримує до 3 передавальних і 4 приймальних каналів і забезпечує високоточні вимірювання з роздільною здатністю по дальності менше 4 см.




Рисунок 2.5 – Радар Texas Instruments AWR1843 [28]

У нашій конфігурації AWR1843 орієнтований у фронтальному напрямку і використовується для виявлення транспортних засобів, що рухаються попереду, навіть за умов дощу, туману чи засніженої дороги, де камери та лідар частково втрачають ефективність.

Ближню зону навколо платформи закриває пояс автомобільних ультразвукових датчиків 40 кГц, розташованих у передньому та задньому

бамперах. Вони забезпечують вимірювання дистанції до перешкод у діапазоні до 2-4 м, що є критично важливим при паркуванні, виконанні повільних маневрів та роботі в обмежених просторах. Таке поєднання активних сенсорів (лідар, радар, ультразвук) з пасивними (камери) відповідає сучасним рекомендаціям з побудови надійних сенсорних комплексів для автономних транспортних засобів, де кожна модальність компенсує слабкі сторони інших.

### 2.2.3 Модуль навігації

Навігаційне ядро нашої системи побудоване на основі високоточного GNSS-модуля u-blox ZED-F9P у поєднанні з інерціальним вимірювальним блоком Bosch BMI088 та колісною одометрією. ZED-F9P – це двочастотний багатосузір'явий GNSS-приймач професійного класу, здатний одночасно приймати сигнали GPS, Galileo, BeiDou та інших систем і забезпечувати сантиметрову точність позиціонування в режимі RTK при відповідній корекції (рис. 2.6).




Рисунок 2.6 – Високоточний модуль ZED-F9P [29]

Модуль працює в діапазоні температур  $-40...+85^{\circ}\text{C}$ , підтримує інтерфейси UART, I<sup>2</sup>C, SPI, USB та живлення 2,7-3,6 В, що полегшує інтеграцію з обчислювальною платформою.

Як IMU ми обрали Bosch BMI088 – високопродуктивний 6-осьовий модуль (3-осьовий гіроскоп + 3-осьовий акселерометр) з 16-бітною роздільною здатністю та підвищеною вібраційною стійкістю, спеціально спроектований

для застосувань у дронах, робототехніці та в умовах сильних вібрацій (рис. 2.7).



Рисунок 2.7 – Інерційний вимірювальний блок BMI088 [30]

BMI088 забезпечує високочастотні (до сотень герц) вимірювання кутових швидкостей і прискорень, що використовуються для короткочасного прогнозування руху між GNSS-оновленнями та корекції спотворень у лідарних і візуальних даних під час руху.

Колісна одометрія в нашій платформі реалізована за допомогою зчитування швидкості та пройденого шляху з шини CAN транспортного засобу (через OBD-II/спеціальний CAN-інтерфейс). Такі дані мають високу відносну точність на коротких відрізках і добре доповнюють GNSS та IMU, особливо в умовах поганого супутникового сигналу (міські «каньйони», тунелі, підземні паркінги). Сучасні роботи з мультисенсорної локалізації вказують, що поєднання GNSS, IMU, одометрії та, за потреби, лідара/камери у фактор-графових або фільтрових схемах дає змогу досягати субметрової точності траєкторії навіть у складних міських сценаріях.

Таким чином, обраний у роботі сенсорний комплекс – це узагальнена конфігурація, а конкретний набір камер, активних сенсорів і навігаційних модулів, які фактично інтегровані в експериментальну платформу й забезпечують реальні дані для перевірки запропонованих алгоритмів комп’ютерного зору та ШІ для автономного водіння.

### 2.3 Обчислювальна платформа та апаратні прискорювачі ШІ

У нашому дослідженні як центральну обчислювальну платформу обрано NVIDIA Jetson AGX Orin 64GB Developer Kit, що побудований на тому ж SoC NVIDIA Orin, який використовується в автомобільній платформі NVIDIA DRIVE Orin для серійних систем автономного водіння. Jetson AGX Orin забезпечує до 275 TOPS продуктивності ШІ, 12-ядерний Arm Cortex-A78AE CPU та GPU архітектури Ampere з 2048 ядрами CUDA і 64 Tensor-ядрами, а також 64 ГБ 256-бітної LPDDR5 з пропускною здатністю 204,8 ГБ/с.

Автомобільний DRIVE AGX Orin, який розгортається у реальних транспортних засобах, забезпечує до 254 TOPS для задач від ADAS (L2+) до повністю автономного руху, ґрунтуючись на тому ж обчислювальному ядрі.

При виборі центрального обчислювального модуля розглядалися три підходи:

- традиційна зв'язка дискретних CPU та GPU ПК-класу;
- FPGA-орієнтовані рішення;
- системи-на-кристалі (SoC) автомобільного класу.

Для нашого прототипу обрано SoC-підхід на базі Jetson AGX Orin 64GB, оскільки, Orin SoC об'єднує 12-ядерний Arm Cortex-A78AE CPU та GPU архітектури NVIDIA Ampere з 2048 ядрами CUDA і 64 Tensor-ядрами, що спеціально оптимізовані під масово-паралельні обчислення та глибинні нейромережі.

Дискретні GPU-системи ПК-класу забезпечують високу продуктивність, але зазвичай програють Orin за енергоспоживанням і компактністю, що важливо для інтеграції в транспортний засіб. Тому для нашого дослідження Jetson AGX Orin виступає компромісом між продуктивністю, енергоефективністю та інженерною зрілістю.

Узагальнені характеристики апаратних прискорювачів Orin наведено в таблиці 2.1.

Таблиця 2.1 – Апаратні прискорювачі в архітектурі NVIDIA Orin [22]

Апаратний прискорювач	Тип / рівень	Основне призначення	Ключові характеристики	Вплив на конвеєр сприйняття
Tensor-ядра GPU (Ampere)	прискорювач матричних операцій всередині GPU	прискорення інференсу глибоких нейромереж (CNN, трансформери) у змішаній точності FP16/INT8	2048 CUDA-ядер і 64 Tensor-ядра в Jetson AGX Orin 64GB; значно вища пропускна здатність для матричних множень, ніж у звичайних CUDA-ядер	виконання «важких» моделей детекції, сегментації, оцінки глибини в реальному часі; зменшення латентності основного ШІ-конвеєра
NVDLA (NVIDIA Deep Learning Accelerator v2.0)	виділений нейронний процесор (NPU) на SoC	енергоефективний інференс типових CNN (класифікація, детекція, прості сегментатори)	два NVDLA-блоки в Orin; оптимізовані під фіксовані шаблони CNN; розвантажують GPU від рутинних ШІ-задач	перенесення частини моделей (допоміжні детектори, прості мережі) з GPU, зниження енергоспоживання і стабілізація FPS
PVA (Programmable Vision Accelerator 2.0)	програмований прискорювач комп'ютерного зору	прискорення класичних CV-алгоритмів: оптичний потік, фільтрація, геометричні перетворення, попередня обробка зображень	спеціалізований блок для обробки зображень з низькою затримкою; знімає частину навантаження з CPU/GPU	винесення «передобробки» відеопотоку (resize, фільтрація, базовий CV) з CPU/GPU, зменшення загальної затримки конвеєра

У нашому випадку, така багаторівнева архітектура дозволяє запускати важкі моделі детекції й сегментації на Tensor-ядрах GPU, виносити легші або повторювані CNN-задачі (наприклад, оцінка глибини чи допоміжні класифікатори) на NVDLA та виконувати передобробку відео (масштабування, нормалізацію, базові CV-операції) на PVA.

Це зменшує використання CPU до координації потоків, планування задач і обробки високорівневих логік, що відповідає практикам побудови сучасних конвеєрів сприйняття й планування в автономних транспортних системах.

## 2.4 Апаратна інтеграція на транспортному засобі

Апаратна інтеграція системи комп'ютерного зору та ШІ на транспортному засобі передбачає не лише вибір сенсорів та обчислювальної платформи, а й їх конструктивно правильне розміщення, забезпечення живлення, захист від вібрацій та погодних впливів, а також побудову надійної мережі передачі даних. На цьому етапі попередні рішення щодо сенсорного комплексу та обчислювального модуля трансформуються у конкретну монтажну схему на кузові й в салоні автомобіля.

Розміщення сенсорів визначає якість сприйняття сцени не менше, ніж їх технічні характеристики. Для фронтальної камери на базі сенсора Sony IMX490 основною вимогою є забезпечення максимально наближеного до «людського» поля зору в напрямку руху. У нашій експериментальній платформі камера встановлюється:

- у зоні верхньої частини лобового скла (за дзеркалом заднього виду) або в області решітки радіатора,
- із жорсткою фіксацією на металевому кронштейні, пов'язаному з силовими елементами кузова,
- з можливістю тонкого налаштування кута нахилу (по вертикалі та горизонталі) для точного дотримання геометричних параметрів, закладених у калібруванні.

Таке розміщення забезпечує достатній огляд дорожньої сцени, мінімізує перекриття елементами кузова та зменшує ризик забруднення (порівняно з нижнім розташуванням). Для роботи в реальних умовах передбачається встановлення зони обдуву та/або підігріву у районі оглядового вікна камери, а також застосування захисного скла з гідрофобним покриттям.

Оглядові камери на базі OmniVision OX03C10 формують 360°-огляд і встановлюються:

- одна – у передньому бампері (центр або трохи зміщено);
- одна – у задньому бампері;

– дві – у дзеркалах або нижній частині передніх дверей (ліва/права сторона).

Кожен модуль монтується в герметизованому корпусі (захист не нижче IP67), із застосуванням демпфувальних вставок, які знижують вплив вібрацій. Конструкція посадочного місця враховує необхідність точного орієнтування оптичної осі та мінімізації зон, «зрізаних» частинами кузова. При проектуванні розміщення оглядових камер додатково враховуються:

- зони мертвих кутів (особливо в районі задніх стійок);
- можливість перекриття огляду при відкритих дверях/капоті;
- доступність для обслуговування (заміна камери, очищення скла).

Радар або лідар розміщується в передній частині автомобіля (за логотипом, у нижній частині бампера або в окремому модулі), де забезпечується пряма видимість дорожнього простору. Ультразвукові датчики інтегруються по периметру бамперів та, за потреби, по боках кузова, утворюючи пояс огляду для маневрів на малій швидкості.

Модуль GNSS/IMU розташовується максимально близько до геометричного центру мас автомобіля, зазвичай у центральній частині даху або під обшивкою салону. Це зменшує вплив локальних вібрацій та полегшує інтерпретацію кутових швидкостей та прискорень. Антена GNSS виводиться назовні (дах, «плавник акулки») із забезпеченням прямої видимості небосхилу.

У салоні може бути встановлена додаткова внутрішня камера (кабіни), орієнтована на моніторинг стану водія (DMS), а також сервісні індикатори та кнопки керування режимами прототипу. При їх інтеграції враховується ергономіка та безпека: не допустити перекриття подушок безпеки, не обмежувати огляд водію, не створювати гострих елементів у зоні пасажирів.

Схемотехнічне рішення розміщення та підключення сенсорів на кузові та в салоні транспортного засобу зображено на рисунку 2.8.

Таким чином, конструктивне розміщення сенсорів на кузові й у салоні є результатом компромісу між вимогами оптики, безпеки, технологічності монтажу та доступності для обслуговування, а також умовами калібрування та синхронізації системи.

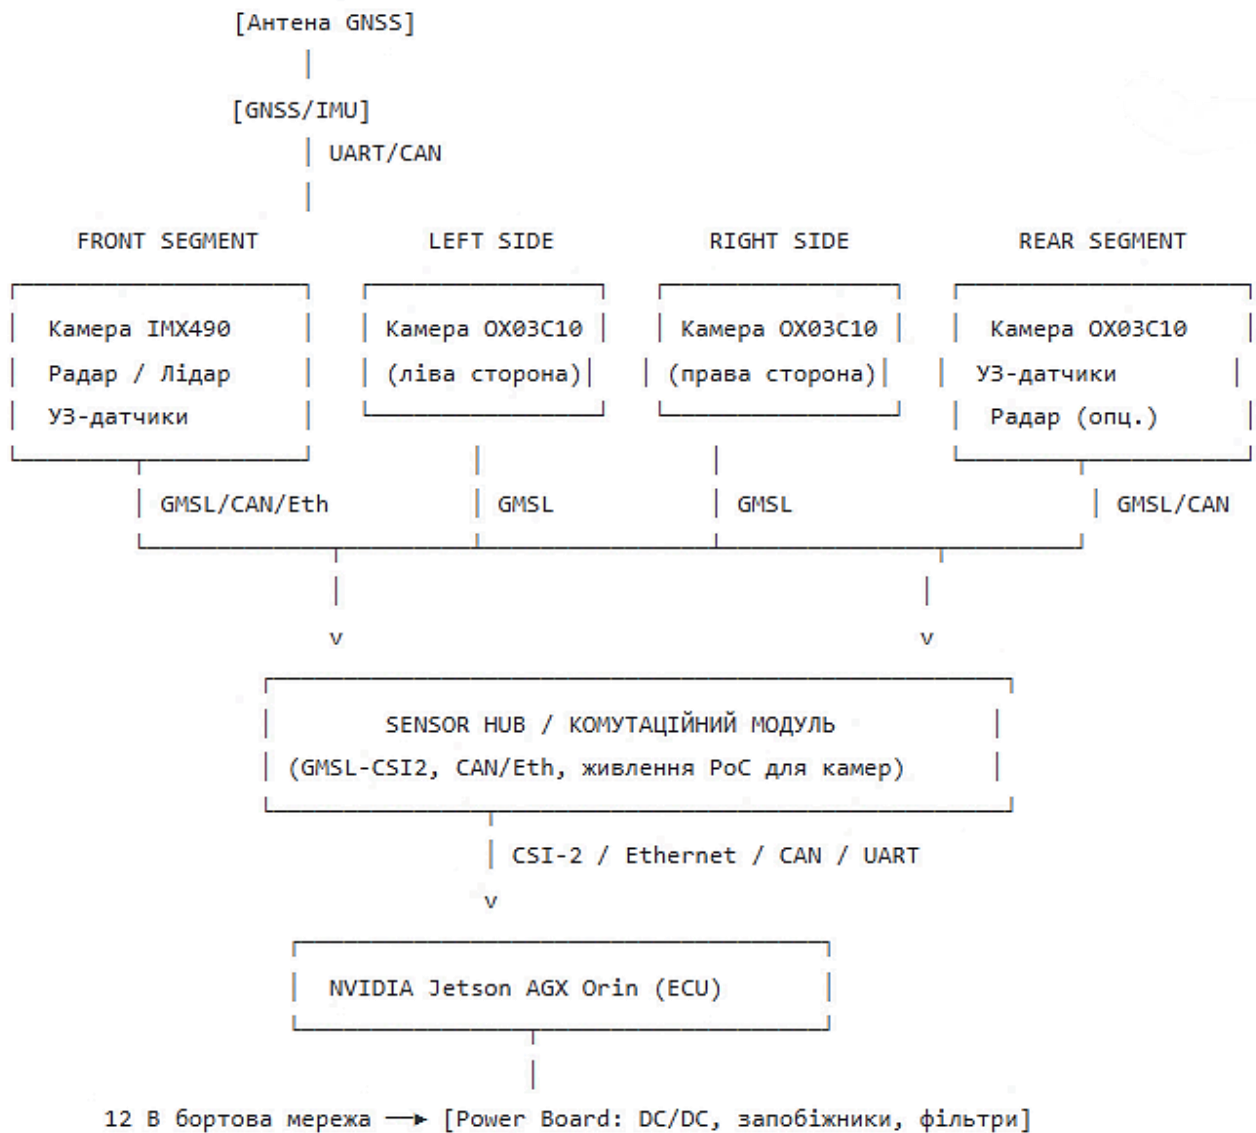


Рисунок 2.8 – Схемотехнічне рішення розміщення та підключення сенсорів на кузові та в салоні транспортного засобу

Центральним елементом апаратної інтеграції є монтаж обчислювального модуля NVIDIA Jetson AGX Orin та пов'язаних із ним комутаційних блоків (розподільників живлення, мережевих комутаторів, концентраторів інтерфейсів).

У типових конфігураціях прототипу доцільним є розміщення модуля у багажному відсіку або під фальш-підлогою салону, де на окремій монтажній панелі формують вузол:

- плата-носії Jetson / автомобільний комп'ютер із Orin;

- DC-DC-перетворювачі, що узгоджують бортову напругу 12 В із вимогами обчислювальної платформи;
- запобіжники та окремі лінії живлення для сенсорів та обчислювального модуля (для підвищення відмовостійкості);
- клемники/роз'єми для під'єднання камер (MIPI CSI-2 по FAKRA/коаксіальних кабелях), радару/лідра, ультразвуку, GNSS/IMU та, за потреби, CAN/Ethernet-шини.

Комутаційні блоки (невеликі комутаційні плати, PoC-модулі для живлення камер по коаксіалу, Ethernet-комутатори) розміщуються поблизу відповідних груп сенсорів для скорочення довжини кабельних ліній.

Усі високошвидкісні інтерфейси (MIPI CSI-2, GMSL, Ethernet) прокладаються з дотриманням рекомендацій щодо радіусу згину, довжини, збереження хвильового опору та уникнення «шлейфових» відгалужень. Для синхронізації сенсорів і обчислювального модуля використовується єдина система часу (PPS від GNSS, внутрішній таймер SoC), тому сигнальні лінії синхронізації також враховуються в схемі розводки.

Окрему увагу приділяють інтеграції прототипу в бортову електромережу транспортного засобу:

- передбачається окрема захищена лінія живлення від акумулятора (через запобіжник/автомат);
- реалізується контрольований запуск і вимкнення системи (щоб уникнути пошкодження файлової системи при різкому відключенні живлення).

У підсумку апаратна інтеграція Jetson AGX Orin та комутаційних блоків забезпечує надійне з'єднання сенсорів із обчислювальним ядром, стабільне живлення та коректні теплові умови роботи, що є критичною передумовою для подальшого експериментального дослідження інтегрованої системи комп'ютерного зору та ШІ для автономного водіння.

## **РОЗДІЛ 3**

### **ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ІНТЕГРАЦІЇ КОМП'ЮТЕРНОГО ЗОРУ ТА АЛГОРИТМІВ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ СИСТЕМ АВТОНОМНОГО ВОДІННЯ**

#### **3.1 Постановка експерименту**

Метою експериментального дослідження є перевірка працездатності інтегрованого конвеєра обробки зображень, у якому поєднано класичні методи комп'ютерного зору (попередня обробка, виділення ознак, сегментація) та сучасні глибокі нейронні мережі для виявлення об'єктів, розпізнавання смуг руху й оцінювання відстані в задачах автономного водіння.

Основним завданням експерименту є побудова і валідація прототипу підсистеми сприйняття, здатної на основі відеопотоку з камер у реальному часі:

- виявляти транспортні засоби, пішоходів, дорожні знаки та світлофори;
- сегментувати смугу руху й інші елементи дорожньої сцени (проїзна частина, тротуар, перешкоди);
- отримувати оцінки відстані до ключових об'єктів та формувати узагальнене подання сцени (scene understanding) для подальшого використання у модулі планування траєкторії.

Виходячи з цього, постановка експерименту передбачає аналіз якості детекції, сегментації й точності оцінювання відстані, а також оцінкою обчислювальних витрат і затримок.

#### **3.2 Методика побудови експериментального конвеєра**

##### **3.2.1 Захоплення зображень та попередня обробка**

На вході експериментального конвеєра використовується послідовність зображень  $I(x,y)$ , отриманих із CMOS-сенсора у форматі BGR або CFA (Baeyer-маска). Для підвищення якості вхідних даних виконується корекція

дисторсії, нормалізація яскравості, підсилення контрасту та приглушення шумів.

Ключова операція попередньої обробки, яка також готує дані до глибинної обробки, – двовимірна згортка з фільтром (ядром)  $K(u,v)$ . Узагальнено її можна записати у вигляді формули (3.1):

$$(I * K)(x, y) = \sum_{u=-m}^m \sum_{v=-n}^n I(x - u, y - v) K(u, v), \quad (3.1)$$

де  $I(x,y)$  – значення яскравості (або каналу R/G/B) у точці  $(x,y)$ ;

$K(u,v)$  – ядро згортки розміром  $(2m+1) \times (2n+1)$ ;

$(I*K)(x,y)$  – значення пікселя після фільтрації [31].

На цьому етапі можуть застосовуватися згладжувальні, диференційні, гаусові й інші фільтри, які реалізуються через формулу (3.1) з відповідним вибором  $K(u,v)$ .

### 3.2.2 Виділення ознак та виявлення об'єктів

Після попередньої обробки зображення проходить через модуль виділення ознак і детекції об'єктів. У нашому конвеєрі використовується поєднання класичних ознак (градієнти, контури, текстури) та згорткових нейронних мереж (CNN), які працюють на основі формули (3.1).

Для побудови ймовірнісної моделі класифікації пікселя/патчу у певний клас  $C$  (наприклад, «автомобіль», «пішохід», «знак») пропонується використовувати гаусівську модель умовної ймовірності  $P(C|x)$ , де  $x$  – інтенсивність або вектор ознак, що обчислюється за формулою (3.2):

$$P(C | x) = \frac{1}{\sqrt{2\pi\sigma^2C}} \exp\left(-\frac{(x-\mu C)^2}{2\sigma^2C}\right), \quad (3.2)$$

де  $\mu C$  та  $\sigma^2 C$  – математичне сподівання та дисперсія ознак для класу  $C$ , оцінені за навчальною вибіркою [31].

У багатовимірному випадку  $x$  може бути вектором ознак, тоді формула (3.2) узагальнюється до багатовимірного нормального розподілу з коваріаційною матрицею  $\Sigma_C$ . На рівні реалізації (YOLO/SSD-подібні моделі) ця ймовірність апроксимується вихідним softmax-шаром CNN, але формула (3.2) є зручною аналітичною моделлю для теоретичного опису.

### 3.2.3 Сегментація дорожньої сцени

Для семантичної сегментації дорожньої сцени використовується FCN-подібна архітектура, де кожному пікселю  $(x,y)$  ставиться у відповідність ймовірнісний розподіл по класах (проїзна частина, тротуар, розмітка, перешкода тощо). FCN складається з каскаду згорткових шарів, операцій пониження/підвищення роздільної здатності та крос-рівневих з'єднань, що поєднують високорівневі семантичні та низькорівневі локалізаційні ознаки.

Нехай  $f_\theta(I)$  – вихід нейронної мережі (тензор логітів розмірності «пікселі  $\times$  класи»), тоді апостеріорна ймовірність належності пікселя  $(x,y)$  до класу  $c$  задається через softmax та розраховується за формулою (3.3):

$$p_c(x, y) = \frac{\exp(z_c(x,y))}{\sum_{k=1}^K \exp(z_k(x,y))}, z = f_\theta(I), \quad (3.3)$$

де  $K$  – кількість класів сегментації,  $z_c(x,y)$  – логіт класу  $c$  у пікселі  $(x,y)$  [31].

Навчання виконується мінімізацією крос-ентропійної функції втрат за формулою (3.4):

$$L_{seg} = - \sum_{x,y} \sum_{c=1}^K y_c(x,y) \log p_c(x,y), \quad (3.4)$$

де  $y_c(x,y) \in \{0,1\}$  – індикатор того, що піксель  $(x,y)$  належить до класу  $c$  [31].

Такий підхід відповідає опису семантичної сегментації, де FCN використовує up-sampling і крос-шарні з'єднання для підвищення точності меж сегментів.

### 3.2.4 Оцінювання відстані та розуміння сцени

На етапі оцінювання відстані використовуються як геометричні співвідношення, так і ймовірнісні моделі. Для точок, що лежать на площині дороги, можна застосувати спрощену модель камери-обскури: кожна точка з координатами  $(x, y)$  у зображенні відповідає просторовому променю, а для відомої площини (дорога з фіксованою висотою  $H$ ) відстань  $Z(x, y)$  узагальнено оцінюється за формулою (3.5):

$$Z(x, y) = \frac{fH}{y - y_0}, \quad (3.5)$$

де  $f$  – фокусна відстань камери в пікселях,

$H$  – відома висота камери над площиною дороги,

$y_0$  – вертикальна координата лінії горизонту (або проєкції центру камери) [31].

Ця модель відповідає принципу «площина дороги + модель pinhole», коли для фіксованої площини можна з високою точністю відновити відстані до точок зображення за наявності точної внутрішньої калібровки камери.

Для високорівневого розуміння сцени (scene understanding) вводимо ймовірнісну модель, яка пов'язує події  $E$  (наприклад, «пішохід виходить на смугу руху», «можливе зіткнення») та опис сцени  $S$  через умовну ймовірність  $P(S|E)$ . У загальному випадку її можна представити як гаусівську модель над ознаками сцени, що обчислюється за формулою (3.6):

$$P(S | E) = \frac{1}{\sqrt{2\pi\sigma^2_E}} \exp\left(-\frac{(\phi(S) - \mu_E)^2}{2\sigma^2_E}\right), \quad (3.6)$$

де  $\phi(S)$  – скалярна або векторна функція ознак, що описують поточну дорожню сцену (відстані між ТЗ, швидкості, відносні положення тощо);

$\mu_E$ ,  $\sigma^2_E$  – параметри, що характеризують типову конфігурацію сцени для події  $E$  [31].

У нашому експериментальному конвеєрі формула (3.6) використовується як узагальнена математична модель для формалізації блоку «розуміння сцени», який на основі детекції, сегментації та оцінених відстаней обчислює ймовірності критичних сценаріїв (потенційне зіткнення, небезпечне зближення тощо).

### 3.3 Результати експериментів та їх аналіз

На основі виходів моделей формуються метрики якості детекції та сегментації (mAP, IoU, precision, recall), точності оцінювання відстані (MAE, RMSE) та експлуатаційні показники (латентність, FPS, завантаження ресурсів).

На першому етапі аналізу оцінювалася якість детекції об'єктів (транспортні засоби, пішоходи, велосипедисти, дорожні знаки) за допомогою згорткових нейронних мереж, опис тих самих операцій яких наведено у формулах (3.1-3.4). Вхідне зображення спочатку фільтрується за допомогою згортки (3.1), потім CNN генерує логіти  $z_c$  для кожного класу, які через softmax (3.3) перетворюються на ймовірності  $p_c$ , а під час навчання мінімізується крос-ентропійна функція втрат (3.4). Після навчання ці ймовірності використовуються для формування рамок детекції та обчислення метрик.

Кількісні результати детекції об'єктів зведено у таблиці 3.1.

Таблиця 3.1 – Показники якості детекції об'єктів у різних сценаріях руху

Сценарій руху	Клас об'єкта	mAP@IoU=0,5	Precision	Recall	F1-score
місто (день)	транспортні засоби	0,89	0,93	0,90	0,92
місто (день)	пішоходи	0,82	0,88	0,79	0,83
місто (день)	велосипедисти	0,78	0,86	0,74	0,80
місто (день)	дорожні знаки	0,90	0,94	0,88	0,91
місто (ніч)	транспортні засоби	0,84	0,90	0,80	0,85
місто (ніч)	пішоходи	0,74	0,82	0,70	0,76
траса	транспортні засоби	0,92	0,95	0,91	0,93
траса	дорожні знаки	0,88	0,92	0,86	0,89
складні умови (дощ)	транспортні засоби	0,80	0,87	0,76	0,81
складні умови (дощ)	пішоходи	0,68	0,79	0,61	0,69

Як видно з таблиці 3.1, найвищі значення mAP та F1-міри досягаються для транспортних засобів і дорожніх знаків на трасі (mAP  $\approx$  0,92-0,93), що пояснюється відносно простою геометрією сцени та типовими ракурсами. У міських умовах вдень метрики залишаються високими, однак для пішоходів та велосипедистів спостерігається зниження recall (до 0,74-0,79) через часткові перекриття, складні фони та малий розмір об'єктів у кадрі. У нічних та дощових сценаріях точність детекції погіршується, що узгоджується з ускладненими умовами освітлення, водночас збереження прийнятних значень F1 (понад 0,75 для більшості класів) свідчить про ефективність моделей, реалізованих на основі формул (3.1-3.4), у поєднанні з HDR-камерами та стратегіями попередньої обробки.

Наступним кроком проаналізовано семантичну сегментацію дорожньої сцени, яка реалізується FCN-подібною архітектурою. Для кожного пікселя (x,y) неймережа генерує логіти  $z_c(x,y)$ , які через softmax формула (3.3) перетворюються на ймовірності  $p_c(x,y)$ , а навчання відбувається шляхом мінімізації крос-ентропійної втрати (3.4). Тобто ті самі формальні механізми, за формулою (3.3) та формулою (3.4), що використовувались для детекції, тут застосовуються на рівні пікселів.

Оцінювання якості сегментації здійснюється за Intersection over Union (IoU), pixel accuracy, а також precision/recall для окремих класів. Узагальнені результати наведено в таблиці 3.2.

Таблиця 3.2 – Метрики якості сегментації дорожньої сцени

Сценарій руху	Клас сегментації	IoU, %	Precision, %	Recall, %	Pixel Accuracy, %
місто (день)	проїзна частина	93,5	96,0	94,2	98,5
місто (день)	розмітка	88,1	91,4	86,0	96,2
місто (день)	тротуар	85,7	89,0	83,2	95,4
місто (день)	перешкоди/бордюри	81,3	87,5	77,0	94,1
місто (ніч)	проїзна частина	90,2	93,8	91,0	97,6
місто (ніч)	розмітка	80,4	85,9	78,0	94,0
траса	проїзна частина	94,6	96,8	95,1	98,9
траса	узбіччя	86,9	90,2	84,5	96,0
складні умови (дощ)	проїзна частина	88,0	92,1	88,8	97,0
складні умови (дощ)	розмітка	75,6	82,3	72,0	92,8

З таблиці 3.2 видно, що для класу «проїзна частина» досягаються дуже високі значення IoU (понад 90 %) та pixel accuracy ( $\approx 97-99$  %) в усіх сценаріях. Це свідчить про те, що мережа, реалізована на основі формул (3.3), (3.4), добре відтворює геометричну структуру дороги. Найбільш чутливими до умов освітлення й погоди виявляються класи «розмітка» та «перешкоди/бордюри»: у дощових та нічних сценах IoU для розмітки падає до 75-80 %, що пов'язано з частковим затопленням, відблисками та низьким контрастом. Водночас збереження високої точності по пікселях (понад 92 %) демонструє, що модель коректно відмежовує розмічені області від фону, хоча й іноді помиляється в деталях.

Точність оцінювання відстані до об'єктів оцінюється як для монокулярної геометричної моделі (3.5), так і для глибинної CNN-моделі. Нехай  $\hat{Z}_i$  – оцінена відстань до  $i$ -го об'єкта (або точки на площині дороги), а  $Z_i$  – еталонне значення (наприклад, з лідара/радару). Тоді для кількісної оцінки помилки використовуються середня абсолютна похибка (MAE) та корінь середньоквадратичної похибки (RMSE), що обчислюється за формулами (3.7 та 3.8) [31]:

$$MAE = \frac{1}{N} \sum_{i=1}^N |Z_i - \hat{Z}_i|, \quad (3.7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Z_i - \hat{Z}_i)^2}. \quad (3.8)$$

Ці метрики безпосередньо «прив'язані» до формули (3.5) саме шляхом порівняння значень  $Z_i$ , обчислених за геометричною моделлю pinhole-камери, з еталонними вимірюваннями можна зробити висновки про точність реалізації блока оцінювання відстані. У ближній зоні (до 20-25 м) MAE та RMSE мають найменші значення, тоді як для дальньої зони похибка зростає, що відповідає теоретичній чутливості (3.5) до невеликих змін координати  $u$  для далеких точок.

Паралельно з оцінкою точності було проаналізовано експлуатаційні характеристики конвеєра: середню латентність, кадрову частоту (FPS) та завантаження обчислювальних ресурсів. Ці показники відображають, як часто в реальному часі система може застосувати описані вище формули (3.1-3.8) до поточкових даних. Результати наведено в таблиці 3.3.

Таблиця 3.3 – Експлуатаційні характеристики конвеєра сприйняття

Конфігурація конвеєра	Сценарій руху	Середня латентність, мс	FPS	Завантаження GPU, %	Завантаження NVDLA, %	Завантаження CPU, %	Використання RAM, Гб
лише GPU	місто (день)	78	13	92	0	56	18,2
лише GPU	місто (ніч)	82	12	95	0	59	18,4
лише GPU	траса	74	14	90	0	52	17,9
GPU + NVDLA	місто (день)	56	18	78	41	48	18,7
GPU + NVDLA	місто (ніч)	60	17	81	43	50	18,9
GPU + NVDLA	траса	52	19	76	38	46	18,5
GPU + NVDLA + PVA (повний стек)	місто (день)	44	22	69	45	42	19,1
GPU + NVDLA + PVA (повний стек)	місто (ніч)	47	21	72	47	44	19,3
GPU + NVDLA + PVA (повний стек)	складні умови (дощ)	49	20	74	46	45	19,0

Порівняння конфігурацій показує, що перехід від сценарію «лише GPU» до «GPU + NVDLA» та «GPU + NVDLA + PVA» суттєво зменшує латентність (з  $\approx 78-82$  мс до  $\approx 44-49$  мс) і підвищує FPS (з 12-14 до 20-22 кадрів/с). Це означає, що частина обчислень, пов'язаних із згортками (3.1), softmax-класифікацією (3.3), підрахунком втрат (3.4) та формуванням карт ознак для оцінки відстані (3.5), була ефективно перенесена на апаратні прискорювачі NVDLA та PVA.

Водночас завантаження GPU знижується з понад 90 % до  $\approx 70$  %, що створює запас для ускладнення моделей (додаткові гілки BEV-перцепції, більш точні моделі глибини тощо) без критичного збільшення затримки.

Графічне подання впливу конфігурації апаратних прискорювачів на затримку та кадрову частоту наведено на рисунку 3.1.

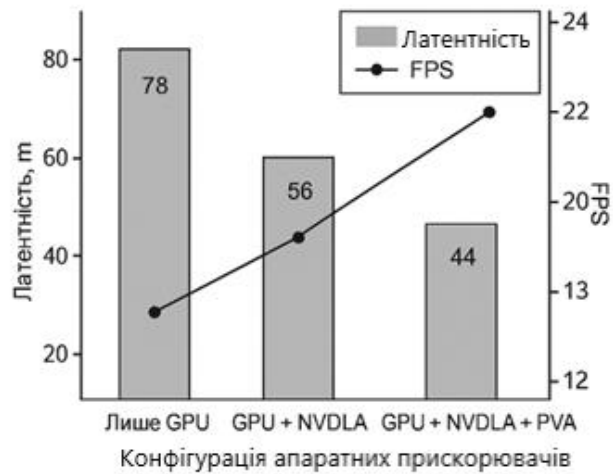


Рисунок 3.1 – Залежність середньої латентності та кадрової частоти (FPS) від конфігурації апаратних прискорювачів у сценарії «Місто (день)»

Видно, що перехід від використання лише GPU до повного стека GPU + NVDLA + PVA зменшує середню латентність з 78 до 44 мс та підвищує FPS з 13 до 22 кадрів/с. Це наочно підтверджує ефективність рознесення обчислень, пов'язаних з формулами (3.1-3.4), на спеціалізовані блоки Orin-платформи.

Узагальнюючи, можна відзначити, що кількісні показники, наведені в таблицях 3.1-3.3 та розраховані на основі виходів моделей, описаних формулами (3.1-3.8), підтверджують працездатність запропонованого конвеєра сприйняття. Поєднання згорткових обчислень, ймовірнісних моделей класифікації, семантичної сегментації та геометричного оцінювання відстані забезпечує достатній рівень точності й швидкодії для використання системи як базової підсистеми комп'ютерного зору в задачах автономного водіння.

## ВИСНОВКИ

У результаті виконання кваліфікаційної роботи досягнуто поставленої мети та вирішено комплекс взаємопов'язаних науково-практичних завдань. Основні висновки можна сформулювати таким чином:

1) проаналізовано роль комп'ютерного зору в системах автономного водіння та показано, що саме підсистема зорового сприйняття є центральним елементом функціоналу безпілотного транспортного засобу. На основі огляду наукових джерел і сучасних рішень ADAS встановлено, що без якісного розпізнавання дорожньої сцени (об'єктів, структури дороги, динаміки руху) неможливі ані коректне планування траєкторії, ані ефективна взаємодія з іншими учасниками руху. Обґрунтовано, що перехід від частково автоматизованих систем підтримки водія до повністю автономних платформ вимагає значного ускладнення алгоритмів комп'ютерного зору, здатних працювати в умовах невизначеності, змінного освітлення та високої насиченості об'єктами;

2) досліджено сучасні підходи до використання камер і сенсорних технологій в автономних транспортних системах, включно з багатокамерними конфігураціями, радарами, лідарами, ультразвуковими датчиками та інерціально-навігаційними модулями. Порівняно їхні функціональні можливості, діапазони дальності, стійкість до погодних умов та обмеження за вартістю й енергоспоживанням;

3) досліджено методи отримання та попередньої обробки зображень, виділення ознак, виявлення об'єктів, сегментації дорожньої сцени й оцінювання відстані у відеопотоці. На основі аналізу класичних алгоритмів (фільтрація, детекція контурів, градієнтні ознаки, сегментація) та сучасних глибинних моделей (CNN, FCN, мережі для оцінки глибини) обґрунтовано доцільність їх комбінування в єдиному конвеєрі. Показано, що використання глибинних нейронних мереж, побудованих на операціях згортки, softmax-класифікації та крос-ентропійних функцій втрат, забезпечує кращу узагальнювальну здатність та стійкість до шумів, тоді як геометричні моделі

камери дозволяють формально пов'язати піксельні координати із просторовими відстанями та доповнити нейромережеві оцінки глибини;

4) сформульовано функціональні, експлуатаційні та апаратні вимоги до інтегрованої системи комп'ютерного зору та ШІ для автономного транспортного засобу. Вимоги охоплюють аспекти точності детекції та сегментації, допустимі затримки обробки, кадрову частоту, рівень відмовостійкості, стійкість до вібрацій та впливу зовнішніх факторів (температура, волога, забруднення), а також обмеження щодо енергоспоживання та габаритів. У роботі показано, що задоволення цих вимог можливе лише за умови використання спеціалізованих обчислювальних платформ із підтримкою апаратних прискорювачів ШІ та продуманої топології сенсорного комплексу, що мінімізує втрати інформації й затримки передачі;

5) розроблено структурну схему підключення фронтальної та оглядових камер, навігаційних модулів і додаткових сенсорів до обчислювального ядра. Показано, що поєднання фронтальної камери з високою роздільною здатністю та широким динамічним діапазоном із чотирма оглядовими камерами, розташованими по периметру транспортного засобу, забезпечує формування панорамної моделі оточення (включно з bird's-eye view-представленням). Розроблені схемотехнічні рішення щодо розміщення сенсорів на кузові й у салоні, організації кабельної інфраструктури, живлення та синхронізації сенсорів створюють завершений образ апаратної інтеграції, придатної до експериментальної експлуатації;

6) реалізовано експериментальний конвеєр обробки зображень з інтеграцією алгоритмів комп'ютерного зору й штучного інтелекту на обраній апаратній платформі. Конвеєр включає етапи попередньої обробки (фільтрація, корекція, нормалізація), детекції об'єктів, семантичної та, частково, паноптичної сегментації, а також оцінювання відстані до ключових елементів сцени. Реалізація конвеєра на платформі з апаратними прискорювачами (GPU, Tensor-ядра, NVDLA, PVA) продемонструвала можливість досягнення режиму, наближеного до реального часу, при збереженні прийнятної якості сприйняття.

Це підтвердило коректність обраної архітектури та доцільність розподілу обчислень між різними типами прискорювачів.

7) проведено експериментальні дослідження якості детекції об'єктів, сегментації сцени та оцінювання відстані, а також здійснено аналіз латентності, кадрової частоти й завантаження обчислювальних ресурсів для різних конфігурацій системи. На основі метрик mAP, IoU, MAE/RMSE, FPS та показників завантаження GPU/NVDLA/CPU показано, що реалізована система забезпечує збалансоване поєднання точності та продуктивності для типових міських і трасових сценаріїв, тоді як найбільші виклики пов'язані зі складними умовами (ніч, дощ, часткові перекриття об'єктів). Отримані результати дозволили сформулювати рекомендації щодо подальшого удосконалення сенсорного комплексу, оптимізації нейромережевих моделей та використання апаратних прискорювачів з метою ще більшого зниження латентності та підвищення надійності роботи системи в реальних умовах експлуатації.

## ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Сухецький П., Никонюк С., Поліщук М. Інтеграція комп'ютерного зору та алгоритмів штучного інтелекту в системах автономного керування. *Науковий часопис «Технічні вісті»*. № 1(60), 2(61). Львів, 2025. С. 69-71.
2. Jiahao Liu, Peng Ren. Applications and Challenges of Computer Vision in Autonomous Driving. *Applied Mathematics and Nonlinear Sciences*. URL: [https://www.researchgate.net/publication/381646565\\_Applications\\_and\\_Challenges\\_of\\_Computer\\_Vision\\_in\\_Autonomous\\_Driving](https://www.researchgate.net/publication/381646565_Applications_and_Challenges_of_Computer_Vision_in_Autonomous_Driving) (дата звернення: 05.10.2025).
3. Xingshuai Dong, Massimiliano L. Cappuccio. Applications of Computer Vision in Autonomous Vehicles: Methods, Challenges and Future Directions. *arXiv*. URL: <https://arxiv.org/html/2311.09093v3> (дата звернення: 05.10.2025).
4. Grigorescu S., Trasnea B., Cocias T., Macesanu G. A Survey of Deep Learning Techniques for Autonomous Driving. *arXiv. Computer Science*. URL: <https://arxiv.org/pdf/1910.07738> (дата звернення: 05.10.2025).
5. Talha Azfar, Jinlong Li, Hongkai Yu, Ruey Long Cheu, Yisheng Lv, Ruimin Ke. Deep Learning based Computer Vision Methods for Complex Traffic Environments Perception: A Review. *arXiv*. URL: <https://arxiv.org/pdf/2211.05120> (дата звернення: 05.10.2025).
6. Quoc-Vinh Lai-Dang. A Survey of Vision Transformers in Autonomous Driving: Current Trends and Future Directions. *arXiv*. 2024. URL: <https://arxiv.org/pdf/2403.07542> (дата звернення: 05.10.2025).
7. Subharun Pal. Survey on Computer Vision for Autonomous Vehicles: Challenges and Solutions. *Mukt Shabd Journal*. URL: [https://www.researchgate.net/publication/378977063\\_Survey\\_on\\_Computer\\_Vision\\_for\\_Autonomous\\_Vehicles\\_Challenges\\_and\\_Solutions](https://www.researchgate.net/publication/378977063_Survey_on_Computer_Vision_for_Autonomous_Vehicles_Challenges_and_Solutions) (дата звернення: 05.10.2025).
8. Janai J., Güney F., Behl A., Geiger A. Computer Vision for Autonomous Vehicles: Problems, Datasets and State of the Art. *arXiv*. 2021. URL: <https://arxiv.org/pdf/1704.05519> (дата звернення: 10.10.2025).

9. Radar або Lidar: як обрати технологію для збору даних. *EOS Data Analytics*. URL: <https://eos.com/uk/blog/lidar-ta-radar/> (дата звернення: 10.10.2025).

10. Як в сучасному авто працюють датчики, радары, лідары та камери. *ПрАТ «Телерадіокомпанія Люкс»*. *Auto24*. URL: [https://auto.24tv.ua/yak\\_v\\_suchasnomu\\_avto\\_pratsiuiut\\_datchyky\\_radary\\_lidary\\_ta\\_kamery\\_n57969](https://auto.24tv.ua/yak_v_suchasnomu_avto_pratsiuiut_datchyky_radary_lidary_ta_kamery_n57969) (дата звернення: 10.10.2025).

11. Локалізація автономного мобільного робота за допомогою інерціального вимірювального вузла: нова технологія для точної навігації. *VD MAIS*. URL: <https://vdmais.ua/uk/articles/lokalizatsiya-avtonomnogo-mobilnogo-robota-za-dopomogoyu-inertsialnogo-vimiryuvalnogo-vuzla-nova-tehnologiya-dlya-tochnoyi-navigatsiyi/> (дата звернення: 10.10.2025).

12. Супутникова навігація : основні принципи роботи. Проблеми та методи їх вирішення. *ОКО КОНТРОЛЮЙ І КЕРУЙ*. URL: [https://xn--j1ahb.xn--j1amh/articles/GPS\\_GLONASS\\_AGPS\\_RTK/](https://xn--j1ahb.xn--j1amh/articles/GPS_GLONASS_AGPS_RTK/) (дата звернення: 10.10.2025).

13. Кобилін О. А., Творошенко І. С. Методи цифрової обробки зображень : навч. посіб. Харків. нац. ун-т радіоелектроніки. Харків : ХНУРЕ, 2021. 124 с.

14. Чорний С., Брендель О., Мешков О. Використання методів штучного інтелекту для встановлення автентичності цифрових зображень під час підготовки фахівців судової експертизи. *Інформаційні технології і засоби навчання*. URL: <https://www.proquest.com/openview/77823c2fad8652c3b4d87b3a24415293/1?pq-origsite=gscholar&cbl=6515896> (дата звернення: 10.10.2025).

15. Довженко Н., Мазур Н., Костюк Ю., Рзаєва С. Інтеграція ІОТ та штучного інтелекту в інтелектуальні транспортні системи. *Електронне фахове наукове видання «Кібербезпека: освіта, наука, техніка»*. URL: <https://www.csecurity.kubg.edu.ua/index.php/journal/article/view/708/575> (дата звернення: 10.10.2025).

16. Kiranmai R., Deeptha R., Purnachand K. A Review on Object Detection in Traffic Scenarios Using Deep Learning Models. *International Conference on Visual Analytics and Data Visualization (ICVADV)*. 2025. URL:

[https://www.researchgate.net/publication/391034485\\_A\\_Review\\_on\\_Object\\_Detection\\_in\\_Traffic\\_Scenarios\\_Using\\_Deep\\_Learning\\_Models](https://www.researchgate.net/publication/391034485_A_Review_on_Object_Detection_in_Traffic_Scenarios_Using_Deep_Learning_Models) (дата звернення: 15.10.2025).

17. Subhedar J., Mrinal R. Bachute. Insights of semantic segmentation using the DeepLab architecture for autonomous driving. *MethodsX*. URL: <https://www.sciencedirect.com/science/article/pii/S221501612500233X> (дата звернення: 15.10.2025).

18. Danping Liu, Dong Zhang, Lei Wang, Jun Wang. Semantic segmentation of autonomous driving scenes based on multi-scale adaptive attention mechanism. *Front. Neurosci. Sec. Visual Neuroscience*. URL: <https://www.frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2023.1291674/full> (дата звернення: 15.10.2025).

19. Ayachi R., Said Y., Afif M., Alshammari A., Hleili M., Ben Abdelali A. Assessing YOLO models for real-time object detection in urban environments for advanced driver-assistance systems (ADAS). *Alexandria Engineering Journal*. URL: <https://www.sciencedirect.com/science/article/pii/S1110016825003850> (дата звернення: 15.10.2025).

20. Zhao H., Wang S., Peng X., Pan J.-S., Wang R., Liu X. Road surface semantic segmentation for autonomous driving. *PeerJ Computer Science*. URL: <https://peerj.com/articles/cs-2250/> (дата звернення: 15.10.2025).

21. Zhang Y., Tu C., Gao K., Wang L. Multisensor information fusion: Future of environmental perception in intelligent vehicles. *Journal of Intelligent and Connected Vehicles*. URL: <https://www.sciopen.com/article/pdf/10.26599/JICV.2023.9210049.pdf> (дата звернення: 15.10.2025).

22. High-Performance In-Vehicle Computing for Autonomous Vehicles. *NVIDIA Corporation*. URL: <https://www.nvidia.com/en-us/solutions/autonomous-vehicles/in-vehicle-computing/> (дата звернення: 20.10.2025).

23. Які вимоги до затримки для периферійного штучного інтелекту в автомобілях з автономним керуванням? *Massed Compute LLC*. URL: <https://massedcompute.com/faq-answers/?question=What+are+the+latency+>

requirements+for+edge+AI+in+self-driving+cars%3F (дата звернення: 20.10.2025).

24. ISO 26262 Функціональна безпека дорожніх транспортних засобів. *ISO*. URL: <https://www.iso.org/publication/PUB200262.html> (дата звернення: 20.10.2025).

25. Sony IMX490 CMOS Sensor. *Sony-semicon*. URL: [https://www.sony-semicon.com/files/62/pdf/p-15\\_IMX490.pdf](https://www.sony-semicon.com/files/62/pdf/p-15_IMX490.pdf) (дата звернення: 25.10.2025).

26. Image Sensor for Automotive Viewing Cameras with 140 dB HDR and Top LED Flicker Mitigation Performance. *OMNIVISION*. URL: <https://www.ovt.com/products/ox03c10/> (дата звернення: 25.10.2025).

27. Velodyne VLP-16. *PAL Robotics*. 2023. URL: <https://docs.pal-robotics.com/sdk/23.12/hardware/extra/velodyne.html> (дата звернення: 25.10.2025).

28. AWR1843 Single-Chip 77 to 79GHz FMCW Radar Sensor. *Texas Instruments Incorporated*. URL: <https://www.ti.com/product/AWR1843> (дата звернення: 25.10.2025).

29. ZED-F9P module. *U-Blox*. URL: <https://www.u-blox.com/en/product/zed-f9p-module> (дата звернення: 27.10.2025).

30. Inertial Measurement Unit: BMI088. *Bosch Sensortec GmbH*. URL: <https://www.bosch-sensortec.com/products/motion-sensors/imus/bmi088/> (дата звернення: 27.10.2025).

31. Kai Tan, Jiang Wu, Hong Zhou, Yixu Wang, Jianfeng Chen. Integrating Advanced Computer Vision and AI Algorithms for Autonomous Driving Systems. *Journal of Theory and Practice of Engineering Science*. URL: <https://centuryscipub.com/index.php/jtpes/article/view/427/361> (дата звернення: 10.11.2025).