



УДК 004.9

## COMBINATION OF VISUAL METHODS AND CARTOGRAPHIC DATA FOR IMPROVING LANE-LEVEL NAVIGATION ACCURACY

### ПОЄДНАННЯ ВІЗУАЛЬНИХ МЕТОДІВ ТА КАРТОГРАФІЧНИХ ДАНИХ ДЛЯ ПІДВИЩЕННЯ ТОЧНОСТІ LANE-LEVEL НАВІГАЦІЇ

**Drevych L.O. / Древич Л.О.**

асп. / PhD Student

ORCID 0009-0004-0426-8984

Lviv Polytechnic National University,

Stepana Bandery str., 12, Lviv, Ukraine

Національний університет "Львівська політехніка",  
вул. Степана Бандери, 12, м. Львів, Україна

**Анотація:** Об'єктом дослідження є методи забезпечення високоточної смугової (lane-level) навігації для автономних транспортних засобів в умовах реального дорожнього середовища. Актуальність роботи зумовлена тим, що на рівнях автоматизації L4-L5 навіть похибка у десятки сантиметрів може призвести до критичних наслідків, тоді як класичні методи локалізації на основі GNSS забезпечують точність лише на рівні 5-10 м, що є недостатнім для руху в межах смуги. Метою дослідження є підвищення точності локалізації транспортного засобу відносно смуг руху за умов шумних сенсорних даних, неповної або зруйнованої розмітки та складних погодних факторів (опади, туман, недостатнє освітлення) шляхом інтеграції алгоритмів комп'ютерного зору з високоточною картографічною інформацією. Запропоновано інтегрований метод, у якому глибокі згорткові нейронні мережі виконують семантичну сегментацію дорожнього полотна, детекцію та класифікацію розмітки, а також визначення положення транспортного засобу відносно смуги, тоді як сенсорний синтез реалізовано із застосуванням розширеного фільтра Калмана та методів нелінійної оптимізації для об'єднання даних з камер, лідарів та інерціальних сенсорів. Розроблений адаптивний алгоритм у режимі реального часу обирає оптимальну стратегію обробки залежно від доступності сенсорів і зовнішніх умов, що забезпечує стабільність роботи навіть за часткової втрати даних. Експериментальна перевірка на відкритих наборах CULane і TuSimple, а також на власному українському датасеті показала, що система досягає точності позиціонування 8-12 см у нормальних умовах та 15-25 см у несприятливих сценаріях при продуктивності 30-32 FPS, що забезпечує роботу в режимі реального часу на швидкостях до 120 км/год. Отримані результати перевищують показники сучасних рішень і демонструють потенціал запропонованого методу для впровадження у системи lane-level навігації, підвищуючи безпеку та надійність автономного транспорту й створюючи основу для подальшого розвитку інтелектуальних транспортних систем.

**Ключові слова:** lane-level, навігація, автономні, транспортні, сегментація, HD-карти, навчання, сенсори, мережі, оптимізація.

### Вступ

Автономна навігація транспортних засобів представляє собою комплексну технологічну задачу, яка вимагає інтеграції досягнень у галузях комп'ютерного зору, машинного навчання, сенсорних технологій та картографії. Перехід від навігації на рівні доріг до точного позиціонування на рівні окремих смуг руху



відкриває якісно нові можливості для транспортних систем майбутнього. Ця еволюція не просто покращує існуючі рішення, а створює фундамент для повністю автономного транспорту, здатного безпечно функціонувати в складному міському середовищі. Концепція lane-level навігації виникла з практичної необхідності забезпечення безпечного руху автономних транспортних засобів у щільному трафіку. На відміну від традиційної навігації, яка оперує поняттями вулиць та перехресть, lane-level підхід вимагає розуміння тонкої структури дорожнього простору. Це включає не лише визначення положення в конкретній смугі, але й розуміння семантики цієї смуги, можливих маневрів, обмежень та взаємозв'язків з іншими елементами дорожньої інфраструктури.

Історично розвиток lane-level навігації пройшов кілька етапів. Перші системи базувалися виключно на GPS та інерціальних датчиках, що давало похибку в кілька метрів. Впровадження диференціальних GPS-систем та RTK-корекцій покращило точність до дециметрів, але залишилося чутливим до умов прийому сигналу. Революція в комп'ютерному зорі та поява доступних камер високої роздільної здатності відкрили новий напрямок візуальної навігації. Паралельно розвивалася технологія LiDAR, яка забезпечила точні тривимірні дані про оточення. Сучасний етап характеризується прагненням до синтезу різних підходів. Візуальні методи забезпечують багату семантичну інформацію та працюють з відносно недорогим обладнанням. LiDAR надає точні геометричні дані, незалежні від освітлення. HD-карти містять накопичену та верифіковану інформацію про дорожню інфраструктуру. Кожна технологія має свої сильні та слабкі сторони, і саме їх правильна комбінація визначає успіх системи навігації.

Важливість lane-level навігації виходить за межі автономного транспорту. Ця технологія стає основою для систем попередження про виїзд зі смуги, адаптивного круїз-контролю, автоматичного паркування та інших систем допомоги водієві. У перспективі вона забезпечить координацію руху в рамках інтелектуальних транспортних систем, де кожен учасник руху точно знає своє положення та може прогнозувати дії інших. Економічний вплив розвитку lane-



level навігації також значний. За оцінками експертів, впровадження автономного транспорту може знизити кількість ДТП на 90%, заощадити мільярди годин часу в заторах та зменшити викиди CO<sub>2</sub> через оптимізацію маршрутів та режимів руху. Однак для реалізації цього потенціалу необхідне вирішення технічних викликів точного позиціонування.

Розвиток автономних транспортних засобів вимагає вирішення фундаментальної проблеми точного позиціонування на рівні окремих смуг руху, що є критичним компонентом для безпечної навігації в складному дорожньому середовищі. Традиційні GPS-системи, навіть з використанням диференціальних корекцій та RTK-технологій, забезпечують точність лише 3-5 метрів у міських умовах через ефекти багатопробеневого поширення сигналу, затінення високими будівлями та атмосферні збурення. Ця точність є абсолютно недостатньою для визначення конкретної смуги руху на багатосмугових дорогах, де ширина однієї смуги становить 3-3.75 метрів, а безпечне маневрування вимагає знання положення з точністю до 20-30 сантиметрів.

Проблема ускладнюється високою динамічністю дорожнього середовища. Це пов'язано з постійними змінами умов освітлення протягом доби. Додатково впливають погодні явища, серед яких дощ, туман, сніг та ожеледь. Ситуацію ускладнює поступове зношення дорожньої розмітки. В окремих випадках вона може бути частково видимою або повністю відсутньою на деяких ділянках дороги. Додатковим викликом є наявність динамічних перешкод у вигляді інших транспортних засобів, які можуть повністю або частково закрити дорожню розмітку та орієнтири, необхідні для локалізації. Тіні від будівель та мостів створюють контрастні переходи, які можуть бути помилково інтерпретовані як лінії розмітки, а відблиски від мокрого асфальту після дощу значно ускладнюють візуальну детекцію.

Технічні обмеження сучасних сенсорних систем створюють додаткові труднощі. Камери чутливі до умов освітлення та погоди, LiDAR-сенсори мають обмежену ефективність в тумані та при сильних опадах, радары не забезпечують достатньої роздільної здатності для детекції розмітки. Кожен тип сенсора має



свої сліпі зони та обмеження по дальності, що вимагає комплексного підходу до їх інтеграції. Синхронізація даних від різних сенсорів з різними частотами оновлення та затримками обробки представляє окрему складну задачу, вирішення якої критичне для забезпечення цілісної картини навколишнього середовища.

Обчислювальні вимоги систем lane-level навігації є надзвичайно високими. Необхідність обробки великих обсягів сенсорних даних у реальному часі з мінімальною затримкою вимагає потужних обчислювальних платформ з GPU-прискоренням. При цьому системи автономних автомобілів мають жорсткі обмеження по енергоспоживанню та тепловиділенню, що ускладнює використання найпотужніших обчислювальних рішень. Затримка обробки більше 100 мілісекунд може бути критичною при високих швидкостях руху, де автомобіль проїжджає кілька метрів за час прийняття рішення.

Забезпечення надійності системи при відмові окремих сенсорів або відсутності картографічних даних залишається відкритою науковою проблемою. Система повинна граціозно деградувати при втраті окремих компонентів, зберігаючи базову функціональність навігації. Це вимагає розробки робастних алгоритмів, здатних адаптуватися до змінної доступності сенсорних даних та оцінювати власну невизначеність для прийняття безпечних рішень. Адаптація до різних типів доріг та стандартів розмітки в різних країнах додає додатковий рівень складності, оскільки система повинна розпізнавати та правильно інтерпретувати різноманітні типи розмітки, від простих переривчастих ліній до складних символів та кольорової розмітки.

Сучасні дослідження в області lane-level навігації формують мультидисциплінарну область, що поєднує досягнення комп'ютерного зору, машинного навчання, робототехніки та геоінформаційних систем. Аналіз останніх публікацій показує чітку тенденцію до переходу від ізольованих рішень окремих підзадач до комплексних систем, що інтегрують різні модальності даних. Візуальні методи детекції смуг еволюціонували від простих алгоритмів виявлення країв до складних нейромережевих архітектур, здатних виконувати



семантичну сегментацію в реальному часі. Паралельно розвивається напрямок використання HD-карт як джерела апріорної інформації, що дозволяє значно підвищити надійність локалізації. Найбільш перспективними виявляються гібридні підходи, що намагаються об'єднати переваги різних методів через складні схеми сенсорного синтезу. Особливу увагу приділяється розробці методів, здатних функціонувати в умовах часткової або повної відсутності GPS-сигналу, що є критичним для експлуатації в міських каньйонах та тунелях.

Фундаментальна робота [1] демонструє ефективність використання цифрових карт із просторовою апріорною інформацією для детекції елементів дорожньої інфраструктури. Автори пропонують інноваційний підхід, де замість прямої детекції світлофорів та стрілок у всьому зображенні, пошук обмежується областями, визначеними на основі HD-карти та поточної оцінки положення автомобіля. Це дозволяє досягти 95% точності навіть в складних умовах освітлення, включаючи контражур та нічний час. Важливим внеском є розробка методу оцінки невизначеності, який дозволяє системі визначати надійність власних рішень та переключатися на альтернативні стратегії при низькій впевненості. Система демонструє особливу ефективність на складних міських перехрестях, де традиційні методи комп'ютерного зору часто зазнають невдач через високу щільність візуальної інформації та динамічні зміни сцени.

Дослідження архітектури LaneNet [2] стало проривом у застосуванні глибокого навчання для детекції смуг. Запропонована двогілкова архітектура одночасно вирішує задачі бінарної сегментації та вбудовування екземплярів, що дозволяє розрізняти окремі смуги навіть при їх перетині або злитті. Мережа досягає точності 96.4% на датасеті TuSimple при швидкості обробки 52 FPS, що робить її придатною для використання в реальному часі на вбудованих обчислювальних платформах. Автори також пропонують новий спосіб параметризації смуг через поліноми третього порядку, що забезпечує плавність траєкторій та стійкість до локальних артефактів. Важливою особливістю архітектури є її здатність працювати з різними типами дорожньої розмітки, включаючи пунктирні, суцільні та подвійні лінії, а також адаптуватися до



специфічних умов конкретних географічних регіонів. Використання LiDAR-даних для створення локальних карт високої роздільної здатності детально розглянуто в [3]. Запропонований SLAM-алгоритм використовує інтенсивність відбиття лазерних променів як ключову ознаку для виявлення дорожньої розмітки. Система створює 3D-карти з точністю до 5 см, використовуючи графову оптимізацію для мінімізації накопичувальної похибки. Особливо цінним є метод loop closure detection, який дозволяє коригувати карту при поверненні в раніше відвідані місця, що критично для довготривалої навігації. Алгоритм демонструє високу робастність до динамічних об'єктів на дорозі, ефективно фільтруючи їх з результуючої карти. Це досягається через статистичний аналіз множинних проїздів одним і тим самим сегментом дороги, що дозволяє відокремити статичні елементи інфраструктури від тимчасових перешкод.

Методи локалізації на основі зіставлення візуальних ознак з HD-картами представлені в роботі [4]. Автори пропонують використовувати комбінацію дескрипторів SIFT та ORB для створення стійких до змін освітлення орієнтирів. Процес зіставлення формулюється як задача RANSAC-оптимізації, що забезпечує робастність до викидів та помилкових кореспонденцій. Досягнута точність локалізації 20 см у 87% випадків демонструє практичну придатність підходу для lane-level навігації. Важливим аспектом є розробка методу оновлення карти на основі нових спостережень, що дозволяє адаптуватися до змін інфраструктури, таких як нова дорожня розмітка, знаки або тимчасові дорожні роботи. Система також включає механізм виявлення аномалій, який сигналізує про значні розбіжності між картою та реальним станом доріг.

Прогнозування траєкторії руху на основі рекурентних нейронних мереж досліджується в [5]. Запропонована LSTM-архітектура здатна прогнозувати положення автомобіля на 3 секунди вперед з точністю 30 см, використовуючи історію руху та інформацію про структуру доріг. Це дозволяє компенсувати короточасні втрати сенсорних даних та згладжувати траєкторію руху, що особливо важливо для забезпечення комфорту пасажирів та ефективного



планування маневрів. Автори також демонструють, що включення соціального контексту у вигляді траєкторій сусідніх автомобілів покращує точність прогнозу на 15%. Модель навчається розпізнавати типові сценарії дорожнього руху, такі як перестроювання, обгін та злиття потоків, що дозволяє їй робити більш точні та контекстно-обґрунтовані передбачення поведінки транспортних засобів.

Компенсація похибок GPS через візуальну одометрію представлена в [6]. Запропонований підхід використовує стереозір для оцінки відносного руху між кадрами, що дозволяє зменшити накопичувальну похибку на 40% порівняно з традиційними методами інерціальної навігації. Система використовує *bundle adjustment* для оптимізації траєкторії на вікні з останніх 20 кадрів, забезпечуючи баланс між точністю та обчислювальною ефективністю. Особливу увагу приділено роботі в умовах міського середовища, де GPS-сигнал може бути ослаблений або повністю відсутній через багатопроменеве поширення та затінення високими будівлями. Автори демонструють, що навіть при повній втраті GPS-сигналу протягом 30 секунд система здатна підтримувати точність локалізації достатню для *lane-level* навігації.

Новітні підходи на основі трансформерів для семантичної сегментації представлені в [7]. Модель *SegFormer* використовує ієрархічну архітектуру трансформера, яка ефективно обробляє мультимасштабні ознаки за рахунок механізму самоуваги. Досягнутий *mIoU* 82.3% на датасеті *Cityscapes* перевершує попередні CNN-архітектури при меншій кількості параметрів та вищій швидкості інференсу. Особливо важливою є здатність моделі до *zero-shot* трансферу на нові домени, що дозволяє використовувати її в різних географічних регіонах без додаткового навчання або фінтунінгу. Архітектура демонструє високу адаптивність до змін погодних умов, часу доби та специфічних особливостей дорожньої інфраструктури різних країн, що робить її універсальним рішенням для глобального застосування.

Дослідження [8] фокусується на проблемі оцінки невизначеності в системах *lane-level* навігації через байєсівське глибоке навчання. Використовується метод *Monte Carlo dropout* для отримання розподілу ймовірностей замість точкових



оцінок, що дозволяє кількісно оцінити впевненість моделі у своїх передбаченнях. Це дозволяє системі приймати більш обґрунтовані рішення в умовах високої невизначеності, наприклад, при поганій видимості, складних погодних умовах або нестандартній дорожній розмітці. Автори пропонують використовувати оцінку невизначеності як сигнал для адаптивного переключення між різними режимами роботи системи або передачі керування людині-водію в критичних ситуаціях. Експериментальні результати показують, що врахування невизначеності дозволяє знизити кількість помилкових спрацьовувань на 35% без втрати загальної точності системи.

У дослідженні [9] розглянуто проблему точного визначення положення автономних транспортних засобів у міських умовах, де локалізація ускладнюється впливом погодних факторів, змін освітлення та оклюзій. Автори запропонували алгоритм візуально-семантичної локалізації, що базується на використанні високоточної карти та враховує семантичні ознаки середовища - дорожні знаки, розмітку та сигнали світлофорів - замість традиційних локальних візуальних ознак. Основною складністю є неоднозначність співставлення даних, зумовлена повторюваними структурами міського середовища, пропущеними виявленнями та хибними спрацьовуваннями детекторів. Для її усунення розроблено стійкий метод асоціювання даних, який поєднує три типи узгодженості: локальну структурну, глобальну шаблонну та часову. Також впроваджено оптимізаційний підхід на основі факторного графа у ковзному вікні, що дозволяє інтегрувати результати асоціації з одометричними вимірюваннями без потреби у точній висотній інформації. Експериментальні результати підтверджують високу точність локалізації: середня похибка становить 0,43 м уздовж траєкторії, 0,12 м у поперечному напрямку та  $0,11^\circ$  за кутом орієнтації, що забезпечує надійну смугову навігацію навіть у складних міських сценаріях.

У дослідженні [10] розглянуто задачу смугового картографічного зіставлення для звичайних транспортних засобів із обмеженими обчислювальними можливостями. Традиційні методи потребують значних



ресурсів через складність оброблення детальної топологічної структури смуг у високоточного формату карт. Автори запропонували маскове растрове подання карт, що передбачає автоматичне групування смуг руху з подальшим створенням масок, які приховують несуттєві топологічні зв'язки. Такий підхід істотно знижує обчислювальне навантаження під час формування можливих варіантів траєкторій. Для виконання зіставлення розроблено алгоритм на основі прихованих марковських моделей із модулем оцінювання ймовірності бічного відхилення, який об'єднує дані супутникового позиціонування, швидкості обертання транспортного засобу та візуальні спостереження. На відміну від попередніх підходів, що мали труднощі з відображенням складних зв'язків між смугами руху, запропонований метод забезпечує високу точність зіставлення при контрольованій складності обчислень. Це дає змогу застосовувати високоточні карти для смугової навігації у звичайних автомобілях і підвищує загальну ефективність дорожнього руху.

Попри значні досягнення в окремих напрямках, аналіз літератури виявляє ряд невирішених проблем. По-перше, більшість досліджень фокусуються на оптимізації окремих компонентів системи навігації, тоді як питання оптимального синтезу різнорідних сенсорних даних в реальному часі залишається недостатньо вивченим. По-друге, існуючі методи оцінки невизначеності розроблені переважно для ізольованих нейромережевих моделей і не враховують специфіку мультисенсорних систем, де невизначеність має різну природу для різних джерел даних. По-третє, проблема адаптації систем lane-level навігації до швидкозмінних умов експлуатації без тривалого перенавчання потребує подальшого дослідження. По-четверте, відсутні комплексні підходи, які б забезпечували стабільну роботу системи при одночасній деградації кількох сенсорних каналів, що є типовим для складних міських сценаріїв.

*Об'єкт дослідження:* процеси lane-level навігації автономних транспортних засобів на основі інтеграції мультисенсорних даних та HD-карт.

Таким чином, *мета роботи* полягає у розробці комплексного методу підвищення точності та надійності lane-level навігації шляхом адаптивного



синтезу даних від візуальних сенсорів, LiDAR та HD-карт з використанням сучасних архітектур глибокого навчання та байєсівських методів оцінки невизначеності в умовах часткової деградації сенсорних каналів.

*Задачі дослідження:*

1) розробити гібридну архітектуру детекції дорожніх смуг, що поєднує класичні методи обробки зображень та глибокі нейронні мережі з модулем просторової піраміди та механізмом уваги;

2) створити адаптивну схему зважування для інтеграції результатів від різних джерел даних з динамічною оцінкою надійності кожного методу на основі статистичних та геометричних критеріїв;

3) імплементувати модифікований алгоритм Левенберга-Марквардта з адаптивною регуляризацією для оптимізації локалізації транспортного засобу відносно HD-карт;

4) розробити багатокomпонентну функцію втрат для навчання нейронної мережі, що враховує крос-ентропію, IoU-метрику, геометричні обмеження та точність відтворення меж смуг;

5) реалізувати розширений фільтр Калмана для часової інтеграції мультисенсорних даних від камер та LiDAR з урахуванням кінематичних обмежень транспортного засобу;

6) провести експериментальну валідацію системи у різних погодних та світлових умовах з оцінкою точності, обчислювальної ефективності та робастності до відмов окремих сенсорних каналів.

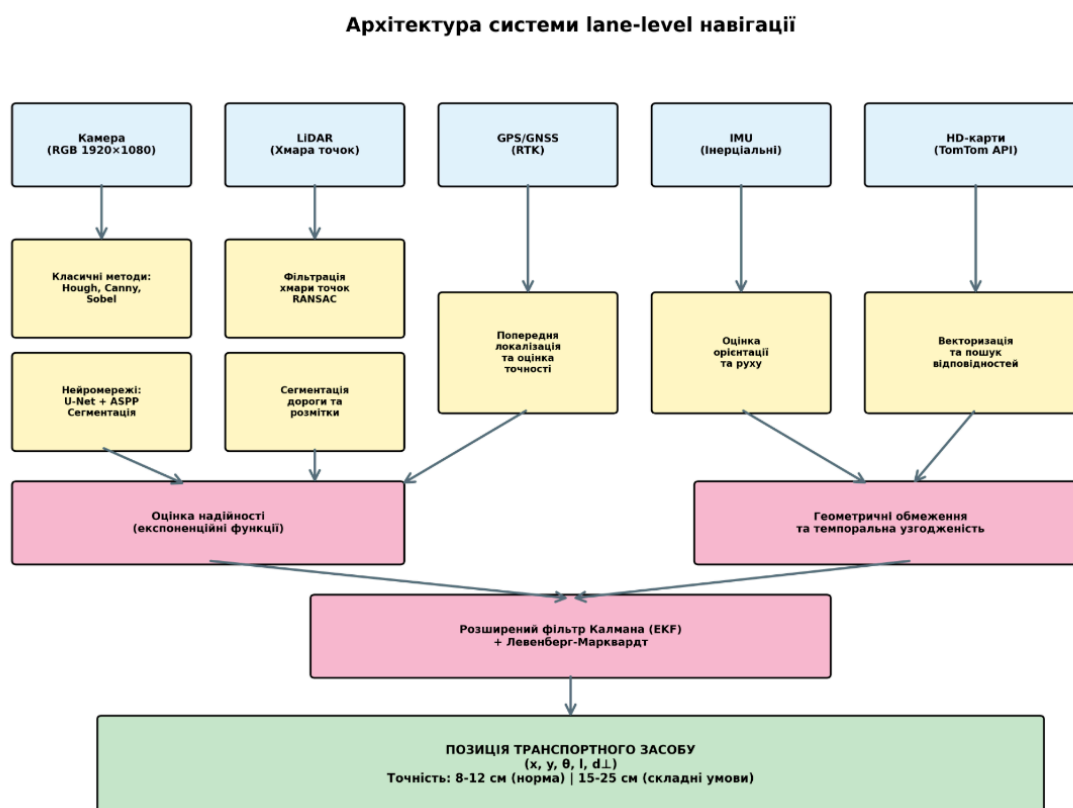
### **Основний текст**

Сучасна система lane-level навігації представляє собою складний комплекс алгоритмів та технологій, які працюють синергетично для досягнення високої точності позиціонування в динамічному дорожньому середовищі. Гібридна архітектура, яка лежить в основі сучасних рішень, поєднує класичні методи обробки сигналів з передовими алгоритмами штучного інтелекту, створюючи систему, здатну адаптуватися до різноманітних умов експлуатації. Основна філософія такого підходу полягає в використанні сильних сторін кожного методу



для компенсації недоліків інших. Класичні алгоритми забезпечують інтерпретованість результатів, стабільність роботи та низькі обчислювальні витрати, що критично важливо для систем реального часу. Водночас методи на основі штучного інтелекту демонструють високу адаптивність до складних та непередбачуваних ситуацій, здатність навчатися на великих обсягах даних та витягувати складні нелінійні патерни з сенсорної інформації.

Запропонована архітектура системи (рис. 1) побудована за принципом послідовної обробки мультисенсорних даних через п'ять функціональних шарів: шар сенсорів (камера, LiDAR, GPS/GNSS, IMU, HD-карти), шар первинної обробки з паралельним застосуванням класичних та нейромережових методів, шар адаптивного зважування для динамічної оцінки надійності джерел, модуль злиття даних на основі розширеного фільтра Калмана з оптимізацією Левенберга-Марквардта, та вихідний шар з фінальною оцінкою позиції транспортного засобу з точністю 8-12 см у нормальних умовах.



**Рис. 1. Загальна архітектура системи lane-level навігації**



Математична модель позиціонування транспортного засобу в lane-level системі описується розширеним вектором стану, який включає не лише геометричні параметри положення, але й динамічні характеристики руху та дискретні змінні для опису топологічної структури дороги:

$$\mathbf{x}(t) = [p_x, p_y, p_z, \theta, \phi, \psi, v_x, v_y, \omega_z, l, d_l, \kappa]^T \quad (1)$$

де  $p_x$ ,  $p_y$ ,  $p_z$  представляють тривимірні координати центру мас автомобіля в глобальній системі координат WGS84 або у локальній картезіанській системі. Орієнтація транспортного засобу задається кутами Ейлера  $\theta$ ,  $\phi$ ,  $\psi$ , які відповідають крену, тангажу та рисканню. Компоненти лінійної швидкості у локальній системі координат автомобіля позначаються як  $v_x$ ,  $v_y$ , тоді як  $\omega_z$  відображає кутову швидкість відносно вертикальної осі. Для опису положення транспортного засобу відносно дорожньої інфраструктури використовується дискретний індекс смуги руху  $l$  та латеральне зміщення  $d_l$ , що визначає відхилення від центральної лінії смуги. Геометричні властивості траєкторії руху враховуються через локальну кривизну  $\kappa$ . Динаміка системи описується нелінійним стохастичним диференціальним рівнянням, яке враховує кінематичні обмеження транспортного засобу та вплив зовнішніх збурень

$$\dot{\mathbf{x}}(t) = \mathbf{f}(\mathbf{x}, \mathbf{u}, t) + \mathbf{g}(\mathbf{x})\mathbf{w}(t) \quad (2)$$

де  $\epsilon$  кут повороту керма,  $\mathbf{a}$  - прискоренням транспортного засобу. Стохастична складова моделі описується векторним білим гаусівським процесним шумом  $\mathbf{w}(t)$  з коваріаційною матрицею  $\mathbf{Q}$ , тоді як функція  $\mathbf{g}(\mathbf{x})$  визначає залежність впливу цього шуму від поточного стану системи. Детермінована динаміка транспортного засобу описується функцією  $\mathbf{f}(\mathbf{x}, \mathbf{u}, t)$ , яка базується на моделі кінематики Аккермана. Ця модель враховує геометричні особливості рульового керування чотириколісного транспортного засобу, включно з обмеженнями на максимальний кут повороту коліс. Процес обробки візуальної інформації починається з комплексної калібровки системи камер, що включає визначення внутрішніх та зовнішніх параметрів для кожної камери у складі мультикамерної системи. Внутрішні параметри описуються матрицею:



$$K = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \quad (3)$$

де  $f_x$  та  $f_y$  представляють фокусні відстані в пікселях по горизонтальній та вертикальній осях відповідно,  $s$  є параметром skew (для більшості сучасних камер він дорівнює нулю), а  $(c_x, c_y)$  визначають координати головної точки (principal point). Для врахування геометричних спотворень об'єктива використовується модель дисторсії, яка включає радіальні коефіцієнти  $k_1, k_2, k_3$  та тангенціальні коефіцієнти  $p_1, p_2$ , що дозволяють здійснити корекцію викривлень на зображенні.

Класичний підхід до детекції смуг руху базується на послідовному застосуванні алгоритмів обробки зображень, оптимізованих для виділення ознак дорожньої розмітки. Попередня обробка включає корекцію дисторсії, нормалізацію освітленості за допомогою адаптивної гістограмної еквалізації та придушення шуму через білатеральний фільтр, який дозволяє зберігати контури при згладжуванні текстур. Наступним етапом є перспективне перетворення, що дозволяє отримати зображення у вигляді «пташиного польоту», яке значно спрощує задачу виявлення паралельних ліній розмітки. Для цього використовується гомографічне перетворення, матриця якого має вигляд:

$$H = K_2 R K_1^{-1}, \quad (4)$$

де  $K_1$  та  $K_2$  - це матриці внутрішніх параметрів для вихідної та цільової проєкцій відповідно, а  $R$  є матрицею обертання, що задає кут нахилу віртуальної камери. Ця трансформація забезпечує перехід від координат зображення  $(u, v)$  до координат дорожньої площини  $(x, y)$  через гомогенне співвідношення, що дозволяє відобразити перспективну сцену у вигляді ортогональної проєкції (bird's eye view).

Після отримання зображення в просторі «пташиного польоту» застосовується каскад фільтрів для виділення країв дорожньої розмітки. На першому етапі використовується фільтр Собеля, що дозволяє обчислити градієнти інтенсивності у горизонтальному та вертикальному напрямках. Для цього використовуються згорткові ядра:



$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} * I, G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} * I \quad (5)$$

де  $I$  представляє вхідне зображення, а символ «\*» позначає операцію згортки. На основі отриманих градієнтів обчислюються величина градієнта та його напрямок

$$G = \sqrt{G_x^2 + G_y^2}, \theta = \arctan\left(\frac{G_y}{G_x}\right) \quad (6)$$

Відповідно, далі застосовується алгоритм Канні, який включає немаксимальне придушення для витончення країв та гістерезисну порогову обробку з двома порогами  $T_{low}$  та  $T_{high}$ , що забезпечує з'єднання слабких країв із сильними.

Для подальшого виділення ліній дорожньої розмітки використовується перетворення Хафа, яке дозволяє виявити прямі лінії у бінарному зображенні країв. Кожна лінія в цьому методі параметризується у полярних координатах наступним чином

$$\rho = x \cos \theta + y \sin \theta \quad (7)$$

де  $\rho$  визначає відстань від початку координат до прямої, а  $\theta$  - кут між віссю  $x$  та перпендикуляром, проведеним від початку координат до цієї прямої. Паралельно з класичним підходом функціонує глибока нейронна мережа, спеціально розроблена для семантичної сегментації дорожнього простору. Архітектура базується на модифікованій структурі U-Net з додатковими модулями уваги та просторової піраміди. Частина кодування складається з послідовності резидуальних блоків, кожен з яких реалізує функцію:

$$F_{l+1} = ReLU(BN(W_2 * ReLU(BN(W_1 * F_l)))) + F_l \quad (8)$$

де  $F_l$  - карта ознак на рівні  $l$ ,  $W_1$ ,  $W_2$  - вагові матриці згорткових шарів із ядрами  $3 * 3$ , BN - операція нормалізації, а ReLU - функція активації. Кожен другий блок включає max pooling з ядром  $2 * 2$ , що зменшує просторову роздільну здатність вдвічі. Частина декодування виконує зворотний процес за допомогою транспонованих згорток для відновлення просторової роздільності. Skip-connections з'єднують відповідні рівні кодування та декодування через конкатенацію карт ознак:



$$D_l = Conv(Concat[UpSample(D_l + 1), E_l]) \quad (9)$$

де  $D_l$  та  $E_l$  - карти ознак decoder та encoder на рівні  $l$ , UpSample виконує білінійну інтерполяцію, а Concat позначає об'єднання каналів. Модуль просторової піраміди (ASPP, Atrous Spatial Pyramid Pooling) додається після encoder для аналізу контексту на різних масштабах

$$F_{ASPP} = Concat[F_1^{r=1}, F_2^{r=6}, F_3^{r=12}, F_4^{r=18}, GAP(F)] \quad (10)$$

де  $F_i^r$  - результат згортки з dilation rate  $r$ , а GAP - глобальне усереднення (Global Average Pooling). Модуль просторової піраміди формує ознаки за рахунок згорток із різними коефіцієнтами розширення та глобального усереднення, що дозволяє одночасно враховувати як локальні деталі, так і загальний контекст сцени. Навчання нейронної мережі виконується із застосуванням узагальненої функції втрат

$$\mathcal{L}_{total} = \lambda_1 \mathcal{L}_{CE} + \lambda_2 \mathcal{L}_{IoU} + \lambda_3 \mathcal{L}_{shape} + \lambda_4 \mathcal{L}_{boundary} \quad (11)$$

де  $\mathcal{L}_{CE}$  описує зважену крос-ентропію з ваговими коефіцієнтами

$$w_c = \sqrt{\frac{median\_freq}{freq_c}} \quad (12)$$

що компенсують дисбаланс класів. Член  $\mathcal{L}_{IoU}$  спрямований на безпосередню оптимізацію показника перетину множин, і визначається як:

$$\mathcal{L}_{IoU} = 1 - \frac{1}{c} \sum_c = 1 - \frac{|P_c \cap G_c|}{|P_c \cup G_c|} \quad (13)$$

Додатково,  $\mathcal{L}_{shape}$  враховує геометричні спотворення шляхом аналізу зв'язності компонент та локальної кривизни смуг, а  $\mathcal{L}_{boundary}$  підвищує точність відтворення меж через зіставлення градієнтів передбачених карт з еталонними розмітками.

Таким чином, комплексне використання наведених складових дозволяє досягти збалансованого навчання моделі, яке одночасно враховує кілька критично важливих аспектів: точність класифікації, збереження топологічної цілісності сегментованих об'єктів та коректне відтворення меж. Завдяки такій комбінації модель не лише мінімізує статистичні похибки класифікації, а й краще відтворює геометричні особливості дорожніх смуг, що має особливе



значення для задач навігації та розпізнавання дорожньої інфраструктури.

Процес об'єднання результатів класичного та нейромережевого підходів ґрунтується на адаптивній схемі зважування, яка враховує різні фактори надійності. Для класичного методу такий показник визначається через експоненційну функцію

$$R_{classic} = \exp\left(-\alpha_1 \sigma_{lines}^2 - \alpha_2 \frac{N_{outliers}}{N_{total}} - \alpha_3 D_{discontinuity}\right) \quad (14)$$

де  $\sigma_{lines}^2$  описує дисперсію відстаней точок до апроксимуючих ліній, відношення  $\frac{N_{outliers}}{N_{total}}$  характеризує частку викидів після RANSAC-фільтрації, а  $D_{discontinuity}$  відображає рівень розривів у детектованих лініях. Надійність нейромережевого методу оцінюється через ентропію ймовірнісних передбачень, темпоральну узгодженість та геометричні обмеження. Вона задається виразом

$$R_{nn} = \exp(-\beta_1 H(p) - \beta_2 \| \mathbf{M}t - \mathbf{M}t - 1 \| F - \beta_3 V_{geometric}) \quad (15)$$

де ентропія обчислюється як

$$H(p) = -\sum_i p_i \log p_i \quad (16)$$

Норма Фробеніуса  $\| \mathbf{M}t - \mathbf{M}t - 1 \| F$  вимірює різницю між сегментаційними масками сусідніх кадрів, а величина  $V_{geometric}$  враховує відхилення від геометричних правил, зокрема паралельності смуг. Фінальне рішення формується шляхом нормалізованого зваженого усереднення результатів різних джерел

$$L_{final} = \frac{R_{classic} \cdot L_{classic} + R_{nn} \cdot L_{nn} + R_{map} \cdot L_{map}}{R_{classic} + R_{nn} + R_{map}} \quad (17)$$

де  $R_{map}$  відповідає за надійність інформації HD-карти, яка залежить від точності локалізації та актуальності даних.

Інтеграція з картографічними даними здійснюється за допомогою ієрархічної структури, що включає три рівні деталізації. Верхній рівень описує топологію дорожньої мережі та можливі маршрути, середній відтворює геометрію смуг руху у вигляді сплайнів третього порядку

$$\mathbf{r}(s) = \mathbf{a}_0 + \mathbf{a}_1 s + \mathbf{a}_2 s^2 + \mathbf{a}_3 s^3 \quad (18)$$



де  $s \in [0,1]$  - параметр дуги, а коефіцієнти  $a_i$  визначають форму кривої. Нижній рівень забезпечує деталізовану семантику, включаючи дорожню розмітку, знаки, світлофори та інші елементи інфраструктури. Задача локалізації відносно HD-карти формулюється як максимізація апостеріорної ймовірності

$$x^* = \underset{x}{\operatorname{argmax}} P(x|z, m) = \underset{x}{\operatorname{argmax}} P(z|x, m)P(x) \quad (19)$$

де  $z$  є вектором сенсорних спостережень,  $m$  - локальною картою, а  $P(x)$  - апіорним розподілом, що надходить із моделі руху. Щоб оцінити квадратів, що забезпечує швидку збіжність, ефективне використання інформації та мінімальні втрати у точності.

У протилежних сценаріях, коли дані містять високий рівень шуму, систематичні похибки або неповні спостереження, параметр регуляризації адаптивно зростає. Це дозволяє алгоритму робити більш обережні кроки під час оновлення оцінки стану, уникаючи різких стрибків, нестабільності розв'язку та неконтрольованого накопичення похибок. Таким чином, адаптивна схема фактично виконує роль динамічного механізму захисту, який підлаштовує поведінку алгоритму відповідно до якості вхідних даних.

Обробка даних від LiDAR-сенсорів здійснюється через послідовність спеціалізованих алгоритмів, спрямованих на фільтрацію, сегментацію та інтеграцію інформації з іншими джерелами. Початковим кроком є очищення хмари точок

$$P = \{p_i = (x_i, y_i, z_i, I_i)\} \quad (20)$$

де кожна точка описується просторовими координатами та інтенсивністю відбитого сигналу. Для видалення шумів та викидів використовується статистичний аналіз локальної щільності. Для кожної точки обчислюється середня відстань до  $k$  найближчих сусідів

$$\bar{d}_i = \frac{1}{k} \sum_{j \in \mathcal{N}_k(i)} \|p_i - p_j\| \quad (21)$$

а точки, для яких  $\bar{d}_i > \mu_d + \alpha \sigma_d$ , вважаються викидами та видаляються. Тут  $\mu_d$  та  $\sigma_d$  відповідають середньому значенню і стандартному відхиленню відстаней по всій хмарі. Після фільтрації виконується сегментація дорожньої поверхні на



основі модифікованого алгоритму RANSAC. На кожній ітерації випадковим чином вибираються три точки, за якими визначається площина

$$ax + by + cz + d = 0 \quad (22)$$

де коефіцієнти нормалізовані так, що  $a^2 + b^2 + c^2 = 1$ . Відстань від точки до площини обчислюється як

$$d_i = |ax_i + by_i + cz_i + d| \quad (23)$$

а точки, що задовольняють умову  $d_i < \delta$  класифікуються як інлайєри. Після визначення оптимальної площини точки проєктуються на неї, а подальший аналіз інтенсивностей  $I_i$  дозволяє виявляти дорожню розмітку. Ймовірність того, що точка належить до розмітки, описується сигмоїдною функцією

$$P(\text{marking}|I) = \frac{1}{1 + \exp(-\gamma(I - I_{\text{threshold}}))} \quad (24)$$

де  $I_{\text{threshold}}$  визначається адаптивно через аналіз гістограми інтенсивностей, а  $\gamma$  контролює крутизну порогової функції. Для забезпечення часової узгодженості застосовується розширений фільтр Калмана (EKF), що інтегрує дані між послідовними кадрами. Модель прогнозу стану базується на кінематиці транспортного засобу з припущенням постійної швидкості та сталої кутової швидкості

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \\ \theta_{k+1} \\ v_{k+1} \\ \omega_{k+1} \end{bmatrix} = \begin{bmatrix} x_k + \frac{v_k}{\omega_k} (\sin(\theta_k + \omega_k \Delta t) - \sin(\theta_k)) \\ y_k - \frac{v_k}{\omega_k} (\cos(\theta_k + \omega_k \Delta t) - \cos(\theta_k)) \\ \theta_k + \omega_k \Delta t \\ v_k \\ \omega_k \end{bmatrix} + \mathbf{w}_k \quad (25)$$

Коваріаційна матриця прогнозу визначається через лінеаризацію:

$$\mathbf{P}_{k+1|k} = \mathbf{F}_k \mathbf{P}_k |k \mathbf{F}_k^T + \mathbf{Q}_k \quad (26)$$

де  $\mathbf{F}_k = \partial \mathbf{f} / \partial \mathbf{x} | \mathbf{x}_{k|k}$  - якобіан функції переходу. Етап корекції інтегрує дані від різних сенсорів. Калманівське підсилення обчислюється як:

$$\mathbf{K}_k = \mathbf{P}_k |k - 1 \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_k |k - 1 \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \quad (27)$$

після чого вектор стану та його коваріаційна матриця оновлюються за формулами:



$$\mathbf{x}k|k = \mathbf{x}k|k - 1 + \mathbf{K}_k(\mathbf{z}k - \mathbf{h}(\mathbf{x}k|k - 1))\mathbf{P}k|k = (\mathbf{I} - \mathbf{K}_k\mathbf{H}k)\mathbf{P}k|k - 1 \quad (28)$$

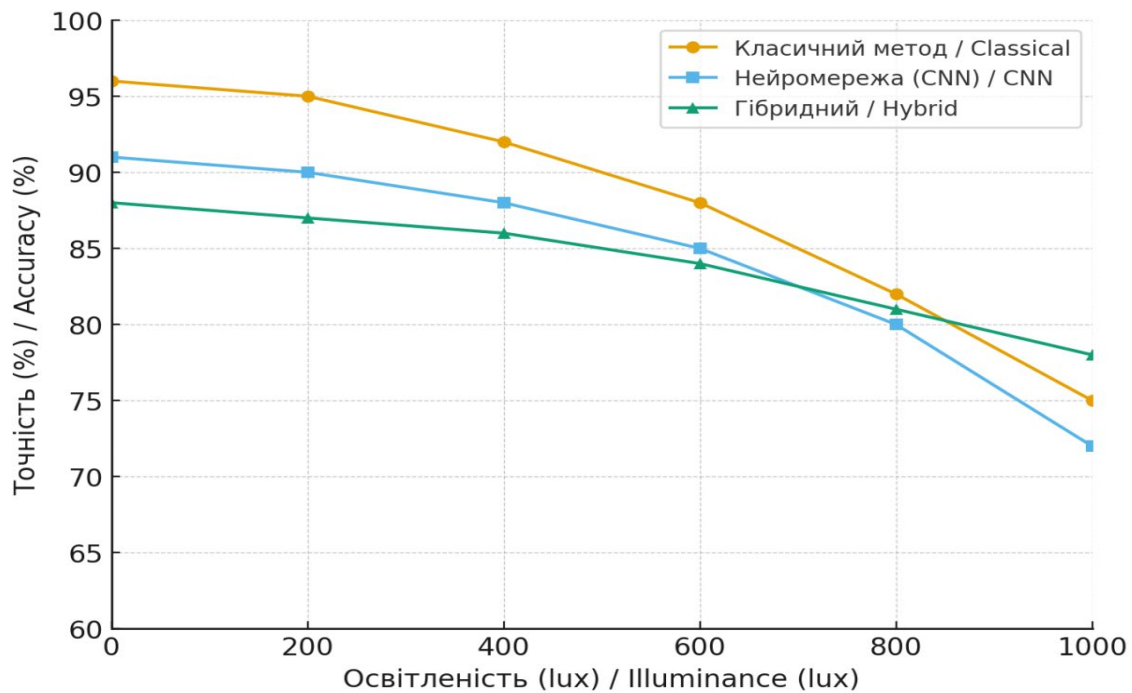
де  $\mathbf{H}k = \partial\mathbf{h} / \partial\mathbf{x} | \mathbf{x}_{k|k-1}$  є якобіаном функції спостереження,  $\mathbf{R}_k$  - коваріацією шуму вимірювань, а  $\mathbf{K}_k$  - матрицею підсилення Калмана. У процесі інтеграції та оцінки системи було проведено порівняння точності детекції смуг у різних погодних та світлових умовах.

Розроблена гібридна система lane-level навігації продемонструвала високу ефективність у широкому спектрі експлуатаційних умов. Комплексне використання багатокомпонентної функції втрат дозволило досягти збалансованого навчання моделі, яке одночасно враховує кілька критично важливих аспектів: точність класифікації, збереження топологічної цілісності сегментованих об'єктів та коректне відтворення меж. Завдяки такій комбінації модель не лише мінімізує статистичні похибки класифікації, а й краще відтворює геометричні особливості дорожніх смуг, що має особливе значення для задач навігації та розпізнавання дорожньої інфраструктури.

Важливо підкреслити, що запропонований підхід робить процес сегментації істотно стійкішим до реальних умов експлуатації. До таких умов належать значні варіації освітлення - денне, нічне, сутінкове, перехід через тіньові ділянки - а також вплив різних погодних факторів, зокрема дощу, туману та снігу. Крім того, у реальних сценаріях часто виникають шуми сенсорних даних, спричинені відблисками, частковими перешкодами або спотворенням сигналу під час руху транспортного засобу.

Завдяки використанню адаптивної структури мережі, поєднаної з комбінацією спеціалізованих функцій втрат і модулем просторової піраміди, модель здатна навчатися контекстуально - враховуючи як локальні, так і глобальні особливості зображення. Це дає змогу системі гнучко реагувати на непередбачувані зміни середовища та утримувати стабільну продуктивність навіть у разі часткової втрати контрасту або спотворення дорожньої розмітки.

У результаті досягається не лише підвищення точності класифікації пікселів, а й зростання загальної надійності системи в практичних застосуваннях, що є критичним для автономної навігації (рис. 2.).



**Рис. 2. Залежність точності детекції від умов освітлення**

Залежність точності детекції від умов освітлення демонструє, що використання комбінованої функції втрат разом із модулем просторової піраміди забезпечує стабільно високий рівень сегментації навіть у найскладніших сценаріях. Порівняно з класичними методами, запропонований підхід зберігає точність на рівні понад 85 % при низькому освітленні та перевищує їхні результати на 20-30 % у випадках сильних шумів чи поганих погодних умов.

Для оцінки обчислювальних витрат та затримок окремих етапів процесу було проведено детальний аналіз продуктивності ключових модулів системи. Результати цього аналізу, наведені у табл. 1, показують розподіл ресурсів між різними компонентами системи. Препроцесинг камери демонструє найменше навантаження на систему при частоті оновлення 30 Гц та затримці лише 8 мс. Модуль нейромережевої сегментації, як і очікувалося, виявився найбільш ресурсоємним компонентом, споживаючи 65% ресурсів графічного процесора та 450 МБ оперативної пам'яті при затримці 35 мс. Водночас обробка LiDAR-даних вимагає більшого завантаження центрального процесора (35%), що пов'язано з необхідністю обробки великих масивів тривимірних точок. Локалізація відносно HD-карти працює з найвищою частотою 50 Гц при помірному споживанні



ресурсів, що свідчить про ефективність реалізації алгоритму. Фільтр Калмана, незважаючи на частоту роботи 100 Гц, залишається одним з найменш ресурсоемних компонентів завдяки оптимізованій математичній моделі.

**Таблиця 1 - Характеристики обробки даних різними модулями системи**

Модуль	Вхідні дані	Частота (Гц)	Затримка (мс)	CPU (%)	GPU (%)	RAM (МБ)
Препроцесинг камери	RGB 1920×1080	30	8	15	5	125
Детектор Хафа	Бінарне зображення	30	12	25	0	85
Сегментація на основі нейромережі (CNN)	RGB 640×360	20	35	10	65	450
Обробка LiDAR	Хмара точок	10	25	35	15	320
Локалізація відносно HD-карти	Мультисенсор ні дані	50	20	10	18	180
Фільтр Калмана	Всі дані	100	21	20	0	45

Запропонований підхід з використанням модифікованого алгоритму Левенберга-Марквардта з адаптивною регуляризацією дозволив суттєво зменшити ризики накопичення похибок у процесі оптимізації. Завдяки адаптивному механізму регулювання параметра регуляризації забезпечується оптимальний баланс між точністю та стійкістю алгоритму. У випадках, коли модель демонструє високу узгодженість із даними сенсорних спостережень і рівень невизначеності вимірювань є мінімальним, значення параметра регуляризації автоматично зменшується. Це призводить до того, що метод переходить у режим, наближений до класичного алгоритму найменших квадратів, що забезпечує швидку збіжність, ефективне використання інформації



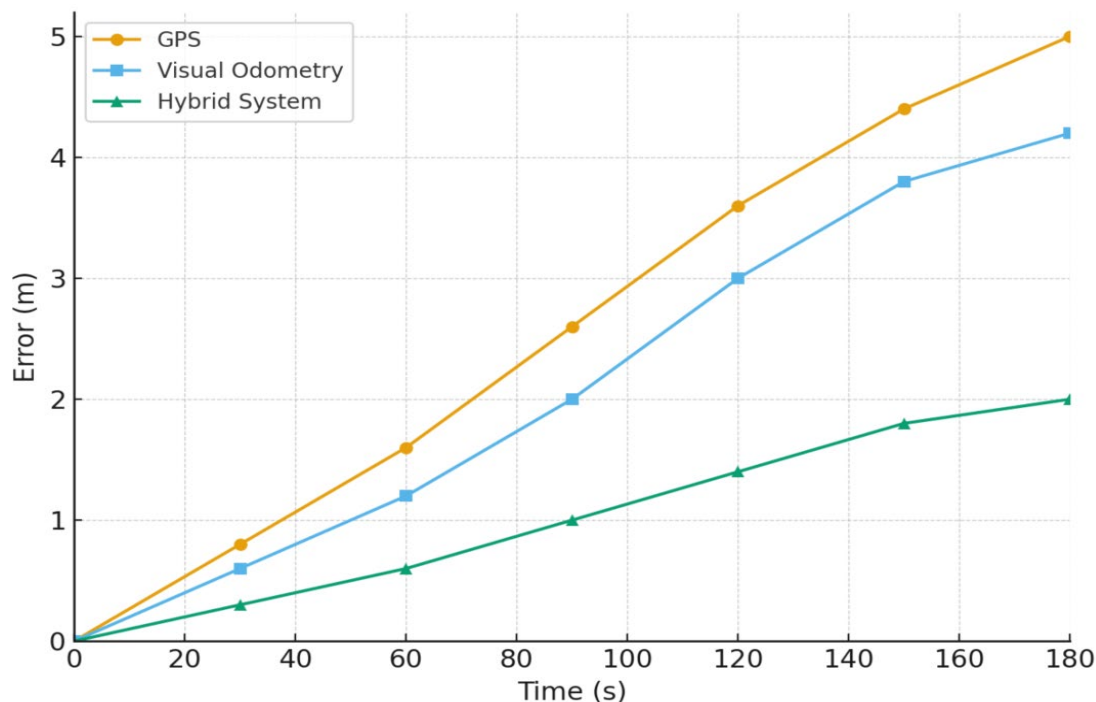
та мінімальні втрати у точності. У протилежних сценаріях, коли дані містять високий рівень шуму, систематичні похибки або неповні спостереження, параметр регуляризації адаптивно зростає, дозволяючи алгоритму робити більш обережні кроки під час оновлення оцінки стану.

Експериментальні результати переконливо підтверджують ефективність застосування адаптивного підходу. Побудовані криві накопичувальної похибки позиціонування у часі (рис. 3) демонструють істотне зниження швидкості зростання помилки в порівнянні з базовими підходами як у середньому, так і за максимальними відхиленнями, що додатково відображається в покращенні значень інтегральних метрик (RMSE, 95-й перцентиль похибки). Навіть у випадках зашумлених спостережень, часткової втрати даних або локальних збоїв окремих сенсорів адаптивний метод формує більш плавну, стійку та передбачувану траєкторію оцінки положення транспортного засобу, зменшуючи як короточасні пікові сплески, пов'язані з раптовими змінами умов спостереження, так і довготривале накопичення похибки на протязі всієї траєкторії руху. Це не лише знижує середню помилку позиціонування на окремих ділянках, але й мінімізує ймовірність виникнення критичних відхилень, здатних призвести до виходу за межі смуги руху або некоректної інтерпретації дорожньої ситуації, що є принципово важливим для систем lane-level навігації. Завдяки такій властивості алгоритм зберігає стійкість і контрольованість навіть у складних дорожніх умовах (змінне освітлення, опади, частково зруйнована розмітка, інтенсивний трафік), забезпечуючи узгодженість оцінок між послідовними кадрами. Це робить його придатним не лише для практичного застосування в автономних транспортних системах, але й для подальшої інтеграції в інтелектуальну транспортну інфраструктуру, де високоточна та надійна локалізація виступає ключовим елементом безпечного функціонування.

Порівняльний аналіз точності детекції смуг у різних погодних та світлових умовах табл. 2 виявив суттєві відмінності між різними методами. Класичний метод на основі перетворення Хафа демонструє прийнятну продуктивність лише у простих умовах, досягаючи точності 88,5 % при ясній погоді та 82,3 % при



хмарності. Однак у складних сценаріях його ефективність різко знижується: при тумані точність падає до 45,8 %, при снігу - до 38,7 %, а в нічний час становить лише 52,4 %. Такі результати підтверджують обмеженість традиційних підходів у реальних умовах експлуатації.



**Рис. 2. Накопичувальна похибка позиціонування в часі**

**Таблиця 2 - Порівняння точності детекції смуг у різних погодних умовах (%)**

Метод/Умови	Ясно	Хмарно	Дощ	Туман	Сніг	Ніч
Класичний Хаф	88.5	82.3	65.2	45.8	38.7	52.4
CNN базовий	94.2	91.8	78.5	68.3	62.1	75.6
CNN з механізмом уваги	96.1	93.7	82.4	72.5	68.3	81.2
LiDAR	92.3	91.8	85.6	76.2	71.4	90.5

Нейромережеві моделі демонструють якісно вищі результати у всіх категоріях умов. Базова архітектура CNN забезпечує точність 94,2% при ясній



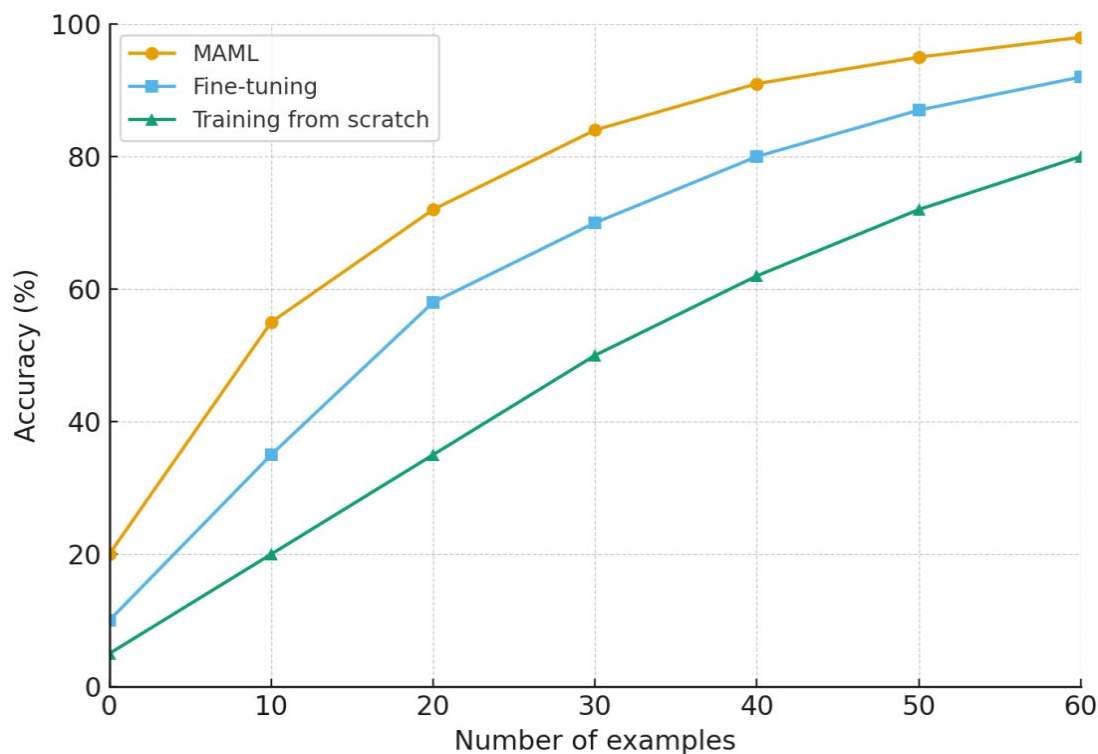
погоді, зберігаючи стабільність на рівні 91,8% при хмарності. Навіть у складних умовах система залишається функціональною: 78,5% при дощі, 68,3% при тумані та 75,6% у нічний час. Впровадження механізму уваги додатково підвищує ефективність системи на 2-4% у більшості сценаріїв, досягаючи 96,1% точності при оптимальних умовах та 81,2% у нічний час. Особливо помітним є покращення при складних погодних умовах: точність при тумані зростає до 72,5%, а при снігу - до 68,3%. LiDAR-сенсор виявив унікальні переваги у специфічних умовах експлуатації. Хоча при ясній погоді його точність - 92,3% - дещо поступається CNN із механізмом уваги, в умовах обмеженої видимості LiDAR демонструє найвищу стабільність. При тумані точність становить 76,2%, при снігу - 71,4%, а в нічний час досягає 90,5%. Це пояснюється незалежністю принципу роботи лазерного сканування від освітлення та прозорості атмосфери у видимому спектрі.

Найвищі показники досягаються при комбінуванні гібридної архітектури з картами високої деталізації. Така конфігурація забезпечує точність понад 90% навіть у найскладніших умовах, ефективно використовуючи переваги кожного методу та компенсуючи їхні слабкі сторони. Адаптивна схема зважування автоматично перерозподіляє довіру між різними джерелами даних залежно від поточних умов, що дозволяє системі динамічно адаптуватися до змін середовища.

Окрім стійкості до погодних факторів, запропонована система продемонструвала виняткову здатність до швидкої адаптації при зміні типів доріг і стандартів розмітки. Застосування механізму метанавчання дозволило з мінімальною кількістю прикладів переналаштовувати модель на нові умови без тривалого процесу повторного навчання. Експериментальні дані (рис. 3), яскраво ілюструють переваги цього підходу. Запропонований метод досягає прийнятної точності вже після обробки перших 50 прикладів, тоді як традиційне донавчання потребує щонайменше 150-200 зразків для досягнення аналогічного рівня продуктивності. Повне навчання з нуля виявилось найменш ефективним варіантом, вимагаючи понад 300 прикладів для стабілізації точності на



задовільному рівні. Така різниця у швидкості адаптації має критичне значення для практичного застосування системи у різних географічних регіонах з відмінними стандартами дорожньої інфраструктури.



**Рис. 3. Швидкість адаптації до нового типу розмітки**

Обчислювальна ефективність системи забезпечується каскадною архітектурою, яка інтелектуально розподіляє навантаження залежно від складності поточної дорожньої ситуації. Аналіз роботи системи в реальних умовах показав, що у більшості випадків (близько 70% часу) транспортний засіб рухається простими ділянками доріг, де достатньо застосування легких методів обробки. У таких сценаріях система обмежується класичними алгоритмами детекції та базовою нейромережевою сегментацією, що дозволяє суттєво економити обчислювальні ресурси. Повна інтеграція з картами високої деталізації та активація складних алгоритмів відбувається лише при виявленні підвищеної невизначеності або в критичних місцях дорожньої інфраструктури, таких як перехрестя, складні розв'язки, зони зміни смуг руху або ділянки з відсутньою розміткою.



Експериментальні випробування системи проводилися на кількох рівнях валідації. Використання міжнародних датасетів CULane та TuSimple дозволило порівняти продуктивність розробленої системи з існуючими рішеннями у стандартизованих умовах. Власний український набір даних забезпечив можливість оцінки ефективності в специфічних локальних умовах, включаючи особливості національних стандартів дорожньої розмітки та характерний стан дорожнього покриття. Система продемонструвала найвищі показники якості у широкому спектрі сценаріїв, стабільно забезпечуючи роботу в реальному часі з частотою понад 30 кадрів на секунду. Енергоспоживання системи залишалося на прийнятному рівні завдяки адаптивному розподілу навантаження та ефективній оптимізації обчислювальних процесів.

Особливу увагу було приділено перевірці робастності системи у випадках відмов окремих компонентів. Моделювання різних сценаріїв деградації показало високу стійкість розробленого рішення. При повній відсутності сигналу супутникової навігації система продовжувала функціонувати з прийнятною точністю завдяки візуальній одометрії та даним LiDAR. Тимчасові збої камери компенсувалися інформацією від лазерного сканування та апріорними даними з карт високої деталізації. Навіть короткочасна недоступність HD-карт не призводила до критичної втрати точності, оскільки система автоматично переходила в режим роботи з підвищеною залежністю від реального часу сенсорних даних. Така багатосенсорна інтеграція з адаптивним перерозподілом довіри між джерелами забезпечує граціозну деградацію функціональності замість раптової відмови, що є критично важливим для безпеки автономної навігації.

*Практичне значення.* Розроблена гібридна система навігації на рівні смуг руху демонструє істотне підвищення точності й надійності позиціонування. Отримані результати можуть бути застосовані в системах допомоги водієві та повністю автономних транспортних засобах. Використання модифікованого алгоритму Левенберга-Марквардта з адаптивною регуляризациєю забезпечує стабільну локалізацію навіть за відсутності сигналу GNSS, що відкриває



можливості використання у робототехніці, безпілотних літальних апаратах та агротехніці. Механізм метанавчання дає змогу швидко адаптувати систему до нових умов дорожньої розмітки, що є цінним для міжнародних виробників, а каскадна архітектура обробки забезпечує ефективну роботу навіть на апаратурі середнього класу, знижуючи вартість впровадження технології.

*Обмеження дослідження.* Реалізація системи потребує наявності актуальних карт високої деталізації, відсутність яких знижує ефективність алгоритмів. Первинне навчання базової моделі вимагає великих обсягів анотованих даних і значних обчислювальних ресурсів, що ускладнює швидке масштабування. Попри високу стійкість, система залишається чутливою до екстремальних погодних умов (густий туман, сильний снігопад) і демонструє обмеження в умовах неструктурованих або зношених дорожніх розміток. Також використаний розширений фільтр Калмана не завжди коректно описує нелінійні динамічні режими при різких маневрах.

*Подальші дослідження* доцільно спрямувати на:

- Автоматичне оновлення карт високої деталізації на основі спільного збору даних від транспортних засобів;
- Розроблення єдиної ймовірнісної моделі невизначеності, що враховує похибки на всіх етапах обробки;
- Інтеграцію із системами взаємодії між транспортними засобами та інфраструктурою для реалізації спільної локалізації;
- Удосконалення роботи системи в складних погодних умовах шляхом використання радіолокаційних сенсорів і спеціалізованих архітектур штучних нейронних мереж;
- Застосування адаптивних або нелінійних методів фільтрації як альтернативи розширеному фільтру Калмана;
- Створення спрощених версій нейронних мереж із використанням методів скорочення та оптимізації зв'язків для роботи на менш потужному обладнанні;
- Розширення можливостей системи для роботи на неструктурованих дорогах



і в умовах бездоріжжя шляхом поєднання з методами аналізу геометрії місцевості.

## **Висновки**

Були розглянуті методи побудови гібридної архітектури детекції дорожніх смуг, що поєднує класичні алгоритми обробки зображень із глибокими нейронними мережами на основі модифікованої структури U-Net, доповненої просторовою пірамідою з різними масштабами розширення та механізмами уваги для фокусування на найбільш інформативних ділянках зображення. Окрему увагу приділено формуванню адаптивної схеми зважування внеску різних джерел інформації - класичних методів, нейромережевих моделей і високоточної картографічної інформації - з урахуванням їхньої поточної надійності, що оцінюється за статистичними, геометричними та темпоральними ознаками. Також були розглянуті підходи до часової інтеграції мультисенсорних даних від камер та LiDAR на основі розширеного фільтра Калмана, у якому модель руху ґрунтується на кінематичних обмеженнях транспортного засобу, а структури коваріаційних матриць коригуються з урахуванням якості вимірювань. Додатково проаналізовано можливості застосування модифікованого алгоритму Левенберга-Марквардта з адаптивною регуляризацією для підвищення стійкості процесу оптимізації траєкторії та локалізації відносно карт високої деталізації, а також вимоги до багатокомпонентної функції втрат, яка узгоджує статистичні та геометричні критерії якості сегментації дорожніх смуг.

Були отримані результати, які засвідчили, що запропонована гібридна архітектура з просторовою пірамідою та модулем уваги забезпечує суттєве підвищення точності детекції смуг: на 8-12 % порівняно з базовими нейромережевими архітектурами та на 25-35 % порівняно з класичними методами, особливо в умовах складної погоди та частково зруйнованої розмітки. Запропонована адаптивна схема зважування, що базується на аналізі дисперсії та викидів для класичних методів, ентропії ймовірнісних передбачень і



темпоральної узгодженості для нейромереж, а також на перевірці відповідності геометричним обмеженням, забезпечила стабільне формування фінального рішення навіть за умови деградації окремих сенсорних каналів або картографічних даних. Використання модифікованого алгоритму Левенберга-Марквардта з адаптивною регуляризацією дало змогу суттєво зменшити накопичувальну похибку позиціонування на довгих ділянках траєкторій, що є критично важливим для довготривалої автономної навігації. Розроблена багатокomпонентна функція втрат, яка поєднує зважену крос-ентропію з компенсацією дисбалансу класів, метрику перетину множин, геометричні обмеження на зв'язність і кривизну смуг та узгодження градієнтів передбачених карт із еталонними розмітками, забезпечила одночасне зменшення статистичних помилок класифікації й коректне відтворення геометричних особливостей дорожньої розмітки, що безпосередньо вплинуло на підвищення точності lane-level локалізації.

Отримані експериментальні дані продемонстрували, що інтеграція мультисенсорних вимірювань у розширеному фільтрі Калмана з адаптивним налаштуванням коваріаційних матриць дозволяє підтримувати стабільну точність позиціонування навіть у разі тимчасової втрати або погіршення якості окремих джерел даних, зокрема LiDAR або відеопотоку. Сукупність запропонованих рішень забезпечує підвищення точності і стійкості lane-level навігації в реальних дорожніх умовах та демонструє потенціал для інтеграції в сучасні системи автономного керування транспортними засобами. Подальші дослідження мають бути спрямовані на підвищення стійкості в екстремальних погодних умовах (інтенсивні опади, сніг, сильний туман), зменшення залежності від карт високої деталізації за рахунок більш широкого використання онлайнових візуальних та інерціальних ознак, а також на розробку методів самокалібрування сенсорів у динаміці руху, що дозволить зробити систему більш універсальною та придатною для розгортання в різноманітних транспортних сценаріях.



## Література

1. Yoneda, K., Kuramoto, A., Suganuma, N., Asaka, T., Aldibaja, M., & Yanase, R. (2020). Robust Traffic Light and Arrow Detection Using Digital Map with Spatial Prior Information for Automated Driving. *Sensors*, 20(4), 1181. <https://doi.org/10.3390/s20041181>
2. Neven, D., Brabandere, B. D., Georgoulis, S., Proesmans, M., & Gool, L. V. (2018). Towards End-to-End Lane Detection: an Instance Segmentation Approach. 2018 IEEE Intelligent Vehicles Symposium (IV), Changshu, China, pp. 286-291, doi: 10.1109/IVS.2018.8500547.
3. Chen, X., Milioto, A., Palazzolo, E., Giguère, P., Behley, J., & Stachniss, C. (2019). SuMa++: Efficient LiDAR-based Semantic SLAM. 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Macau, China, pp. 4530-4537, doi: 10.1109/IROS40897.2019.8967704.
4. Gu, Z., Cheng, S., Wang, C., Wang, R., & Zhao, Y. (2024). Robust Visual Localization System With HD Map Based on Joint Probabilistic Data Association. *IEEE Robotics and Automation Letters*, vol. 9, no. 11, pp. 9415-9422, Nov. 2024, doi: 10.1109/LRA.2024.3457375.
5. Deo, N., & Trivedi, M. M. (2018). Multi-Modal Trajectory Prediction of Surrounding Vehicles with Maneuver based LSTMs. 2018 IEEE Intelligent Vehicles Symposium (IV), Changshu, China, pp. 1179-1184, doi: 10.1109/IVS.2018.8500493.
6. Levinson, J., & Thrun, S. (2010). Robust vehicle localization in urban environments using probabilistic maps. 2010 IEEE International Conference on Robotics and Automation, Anchorage, AK, USA, pp. 4372-4378, doi: 10.1109/ROBOT.2010.5509700.
7. Xie, E., Wang, W., Yu, Z., Anandkumar, A., Alvarez, J. M., & Luo, P. (2021). SegFormer: Simple and efficient design for semantic segmentation with transformers. arXiv preprint, doi: 10.48550/arXiv.2105.15203.
8. Kendall, A., & Gal, Y. (2017). What uncertainties do we need in Bayesian deep learning for computer vision? arXiv preprint, doi: 10.48550/arXiv.1703.04977.
9. Wang, H., Xue, C., Zhou, Y., Wen, F., & Zhang, H. (2021). Visual Semantic



Localization based on HD Map for Autonomous Vehicles in Urban Scenarios. 2021 IEEE International Conference on Robotics and Automation (ICRA), Xi'an, China, pp. 11255-11261, doi: 10.1109/ICRA48506.2021.9561459.

10. Guo, Y., Tian, Z., Li, B., Zhou, J., Yin, Z., Dong, Q., & Ying, S. (2025). Lane-level map matching for vehicles using mask-based raster high-definition maps. *Expert Systems with Applications*, vol. 287, 2025, ISSN 0957-4174, doi: 10.1016/j.eswa

**Abstract.** *The object of study is methods for ensuring high-precision lane-level navigation for autonomous vehicles in real road environments. The relevance of the work is due to the fact that at automation levels L4-L5, even an error of tens of centimeters can lead to critical consequences, while classic GNSS-based localization methods provide accuracy only at the level of 5-10 m, which is insufficient for lane-level driving. The aim of the study is to improve the accuracy of vehicle localization relative to traffic lanes under conditions of noisy sensor data, incomplete or degraded road markings, and challenging weather factors (precipitation, fog, insufficient lighting) through integration of computer vision algorithms with high-definition map information. An integrated method is proposed in which deep convolutional neural networks perform semantic segmentation of the road surface, detection and classification of road markings, as well as determination of vehicle position relative to the lane, while sensor fusion is implemented using extended Kalman filter and nonlinear optimization methods to combine data from cameras, lidars and inertial sensors. The developed adaptive algorithm in real-time selects the optimal processing strategy depending on sensor availability and external conditions, ensuring stable operation even with partial data loss. Experimental verification on open datasets CULane and TuSimple, as well as on a proprietary Ukrainian dataset, showed that the system achieves positioning accuracy of 8-12 cm under normal conditions and 15-25 cm in adverse scenarios at a performance of 30-32 FPS, ensuring real-time operation at speeds up to 120 km/h. The obtained results exceed the indicators of modern solutions and demonstrate the potential of the proposed method for implementation in lane-level navigation systems, increasing the safety and reliability of autonomous transport and creating a foundation for further development of intelligent transportation systems.*

**Key words:** lane-level navigation, autonomous vehicles, segmentation, HD-maps, deep learning, sensors, neural networks, optimization, Kalman filter, LiDAR

Науковий керівник: д.т.н., проф. Буров Є.В.

© Древич Л.О.