

ШТУЧНИЙ ІНТЕЛЕКТ ДЛЯ АВТОМАТИЗОВАНОЇ ІДЕНТИФІКАЦІЇ ТА ОЦІНЮВАННЯ СТАНУ ТЕХНІЧНИХ ЗАСОБІВ ОРГАНІЗАЦІЇ ДОРОЖНЬОГО РУХУ

Анотація

Вступ. Технічні засоби організації дорожнього руху (ТЗОДР) — насамперед дорожні знаки та розмітка — визначають зрозумілість дорожньої обстановки і рівень безпеки руху. Традиційні інспекції залишаються «золотим стандартом», однак вони трудомісткі, витратні та нерегулярні, що призводить до збільшених часових інтервалів між погіршенням стану знаків і їхнім відновленням. Останні здобутки комп'ютерного зору та глибинного навчання дають змогу автоматизувати виявлення, класифікацію та оцінювання стану знаків на основі відео та фото даних, доповнених вимірюванням коефіцієнту світлоповернення [1 – 6].

Проблематика. Нині детектори на основі глибоких нейромереж демонструють високу точність на стандартних наборах даних, проте їхня робота у складних умовах (вицвітання, забруднення, вандалізм, сніг, туман, косі кути огляду) деградує; крім того, оцінювання стану потребує не лише класифікації «норма / пошкоджено», а кількісної оцінки (зміна кольоропередачі, контрасту, світлоповернення).

Мета. Систематизувати підходи до автоматизованої інспекції ТЗОДР, узагальнити їхні переваги й обмеження, порівняти ефективність типових конвеєрів та запропонувати гібридну архітектуру «edge-cloud» для реального впровадження з мінімізацією людських витрат.

Матеріали й методи. Розглянуто лінійку методів — від правил за кольором / формою та класичних ознак (HOG-SVM, SIFT-SVM) до одноетапних моделей виявлення об'єктів (YOLOv8, SSD), двоетапних моделей (Faster R-CNN, Mask-RCNN), багатозадачних та мультимодальних підходів із залученням глибинних карт (LiDAR/стерео). Для кількісної оцінки стану описано перехід до кольорового простору CIE LAB після сіро-світлового або Shades-of-Grey балансування, використання фізично обґрунтованих мереж для оцінювання світлоповернення та порівняльні метрики (mAP для розпізнавання, RMSE для регресії стану, FPS на Jetson-NX) [7 – 9].

Результати. За узагальненими даними, одно- та двоетапні глибокі детектори забезпечують mAP на рівні 0,95 – 0,97, а багатозадачні/мультимодальні конвеєри – найменшу помилку оцінки стану (RMSE 0,05 – 0,08). На edge-пристроях можливо досягти 18 – 35 fps (залежно від архітектури), що уможливує обробку на місці з подальшим вивантаженням кадрів для важкої сегментації у хмарі. Запропонована архітектура поєднує легкий детектор YOLOv8-Nano (~28 fps) на борту та хмарні модулі для сегментації й фотометричного аналізу; контрастивне попереднє навчання на 20 000 неанотованих фрагментах зменшує потребу в розмітці приблизно на 60 %, а дешевий твердотільний LiDAR покращує точність класифікації пошкоджень і дає змогу вимірювати крен/нахил із точністю до $\pm 2^\circ$.

Висновки. Автоматизована інспекція знаків суттєво підвищує частоту та об'єктивність оцінювання, скорочує витрати ручних обстежень і створює основу для керованого життєвого циклу активів. Подальші кроки: розширення відкритих наборів даних зі сценами деградації, удосконалення фізично обґрунтованих мереж для безпосередньої оцінки світлоповернення та довготривалі дослідження впливу на безпеку і економіку.

Ключові слова: автомобільна дорога, глибинне навчання, інспекція дорожніх знаків, інтелектуальні транспортні системи, комп'ютерний зір, оцінювання стану, управління активами.

Вступ

Дорожні знаки, розмітка та інші технічні засоби організації дорожнього руху несуть нормативну інформацію, знижують когнітивне навантаження на водія та мінімізують неоднозначність у складних дорожніх ситуаціях. Коли знаки вицвітають, деформуються або перекриваються рослинністю, підвищується ймовірність помилок та тяжкість наслідків ДТП. У сучасних умовах цифровізації та обмежених ресурсів муніципалітетів потрібні інструменти, які б поєднували точність «польових» вимірювань з регулярністю та масштабованістю автоматизованої аналітики. Тільки в Україні за офіційними документами Агентства відновлення у 2023 році було **замінено та встановлено 43,1 тис. дорожніх знаків** [10]. Поточна стратегія інспекції базується на дворічних ручних аудитах, які коштують приблизно 7 мільйонів євро на рік і охоплюють лише 35 % запасів через обмеженість ресурсів. Системи інспекції на основі штучного інтелекту пропонують зміну парадигми, дозволяючи безперервний збір даних по всьому автопарку за допомогою відеореєстраторів, мобільних картографічних фургонів і навіть краудсорсингових відеозаписів зі смартфонів. Тим не менш, розгортання таких систем у великих масштабах створює технічні та організаційні проблеми, які виходять за рамки традиційних завдань розпізнавання дорожніх знаків (ТЗРДЗ), що розгортаються в передових системах допомоги водієві. На відміну від ТЗРДЗ, яке видає семантичний клас знака, оцінка стану вимагає кількісної оцінки відповідності кольору, світловідбивної здатності, геометричного спотворення та пошкодження поверхні, кожен з яких обмежений законодавчими допусками. У наступних розділах розглядаються існуючі підходи, виявляються прогалини та пропонуються вдосконалення, адаптовані до українського та ширшого європейського контекстів.

Основна частина

Основні підходи до автоматизованої інспекції дорожніх знаків і подано їхні типові конвеєри, сильні сторони та обмеження наведено у **табл. 1**. Порівняння ґрунтується на вимогах до даних, точності розпізнавання (mAP), здатності локалізувати пошкодження, ресурсомісткості виконання моделі та стійкості до складних умов (оклюзії, туман, сніг). Це дозволяє обрати архітектуру під конкретні обмеження — від легкого «edge» виконання моделі на периферійних GPU до високоточних мультимодальних конвеєрів.

Таблиця 1

Порівняльний огляд автоматизованих методів оцінки дорожніх знаків з типовими конвеєрами, ключовими перевагами та обмеженнями

Підхід	Типовий конвеєр	Переваги	Обмеження
Правила за кольором та формою	Сегментація за кольором у просторі HSV → розпізнавання геометричних фігур (перетворення Гафа або контурний аналіз) → порівняння з еталонним зразком	Легкий; не потребує навчальних даних; прозорі правила	Чутливість до освітлення; слабка узагальненість; не кількісна оцінка пошкоджень
Класичне ML (HOG-SVM, SIFT-SVM)	Попередня обробка зображення → виділення ручних ознак (HOG-SVM / IFT-SVM) → класифікатор (SVM / Softmax), бінарний або багатокласовий	Невеликі вимоги до даних; проста реалізація; швидке навчання	Роздільні розпізнавання та класифікація; важке масштабування
Одноетапні DL-детектори (YOLOv8, SSD)	Одна CNN за один прохід знаходить об'єкт і визначає його тип, тобто прогнозує обмежувальні прямокутники (bounding boxes) та класи об'єктів (end-to-end)	Високий mAP (> 0,95); обробка в реальному часі на edge-GPU; проста експлуатація	Високі вимоги до даних; вразливість до оклюзій, туману, снігу

Підхід	Типовий конвеєр	Переваги	Обмеження
Двоетапні DL-детектори (Faster R-CNN, Mask R-CNN)	Мережа пропозицій регіонів (RPN) формує області-кандидати → CNN класифікує об'єкт і уточнює рамки / сегментує маску (Mask R-CNN)	Краща повнота для дрібних об'єктів; маски допомагають локалізувати пошкодження	Важче виконання моделі; потребує більшого об'єму пам'яті; складне налаштування
Багатозадачні та гібридні моделі	Спільний backbone (базовий екстрактор ознак) навчається одночасно для розпізнавання та оцінки стану (регресія / сегментація)	Менше параметрів; спільна оптимізація підвищує узгодженість	Дефіцит даних із мітками пошкоджень; складне балансування втрат

Починаючи приблизно з 2019 року, глибокі згорткові нейромережі (CNN) витіснили класичні підходи з інженерією ознак завдяки вищій точності, кращій узагальнюваності та можливості навчання «edge-to-edge». Останні огляди відзначають систематичну перевагу DL-методів у задачах виявлення/розпізнавання дорожніх знаків [11, 12].

Разом із цим, практичні системи спираються на **стандартизовані бенчмарки**: German Traffic Sign Detection Benchmark (GTSDB) для розпізнавання знаків та Mapillary Vistas Dataset (MVD) для складних вуличних сцен із піксельно-точними анотаціями для семантичної сегментації/розпізнавання у складних умовах [13, 14]. На цих наборах сучасні одноетапні детектори (зокрема родина YOLO) досягають дуже високої точності за реального часу обчислень. Водночас двоетапні архітектури (Faster/Mask R-CNN) зазвичай краще відпрацьовують малі та частково закриті об'єкти завдяки мережі пропозицій регіонів і пірамідам ознак (FPN), що підвищує повноту виявлення дрібних знаків, хоч і за більшої обчислювальної ціни. Схожу тенденцію щодо малих об'єктів описано у базових роботах по FPN/Mask R-CNN та спеціалізованих дослідженнях зі знаками [15–18]. Це задає природний перехід від виявлення до **оцінювання стану**: детектор формує первинні рамки та класи, а далі потрібні **кількісні показники придатності** самого знака.

Оцінювання стану доповнює розпізнавання кількісними показниками, що безпосередньо пов'язані з експлуатаційною придатністю:

- стабільність/відхилення кольору;
- механічні пошкодження полотна (вигин, вандалські написи);
- написи та піктограми (відповідність стандарту);
- світлоповернення (ретрорефлексійні властивості).

Для коректних вимірювань кольорів спершу нормалізують баланс білого (Grey-World / Shades-of-Grey / Grey-Edge), після чого переводять зображення в CIELAB і оцінюють різницю кольору $\Delta E/\Delta E_{00}$ (CIEDE2000): що менше значення — то краща збереженість фарби. У польових умовах похибку зменшують **еталонні колірні мішені** (color-checker) та калібрування перед інспекцією [7 – 9, 19].

Механічні пошкодження (вигини, корозія, графіті) ефективно локалізуються методами **семантичної сегментації**. Ефективною базою є encoder-decoder архітектури класу U-Net. На репрезентативних вибірках для інфраструктури такі мережі демонструють високі значення IoU [20].

Читабельність **написів та піктограм** оцінюють за **CER/WER** (OCR, укр./латиниця), **контрастом** гліфів до фону (Weber/Michelson), **товщиною штриха, x-height та різкістю** (MTF-подібні показники). Маски гліфів, отримані сегментацією, дають змогу окремо оцінювати забруднення/сколи **в межах знаків-літер**, а не лише по всьому полотну. **Відповідність** піктограм і шрифтів перевіряють зіставленням з еталонними шаблонами (ДСТУ 4100:2021) за **SSIM/Chamfer/Hausdorff-відстанню** або за ключовими орієнтирами [11, 12, 19, 21].

Нормативною величиною також є **коефіцієнт світлоповернення RA**. Прямі вимірювання потребують ретрорефлектометрів / мобільних комплексів; тому використовують **фотометричні проксі-методи**: нічні знімки зі спалахом, денне **HDR** з реконструкцією «нічної видимості», а також

LiDAR або **стереофотометрію**. За великих кутів спостереження похибка різко зростає, тож практичні системи дотримуються наближено нормативної геометрії вимірювань [1 – 6].

Але навіть ретельно скориговане RGB-зображення не завжди дозволяє надійно виміряти фізичні параметри матеріалу (світлоповернення, деламінація плівок). Це мотивує перехід до мультимодальних схем, де зображення підкріплюють глибиною, тепловізією чи радаром. Мультимодальні дані також допомагають у відокремленні знака від фону та виявленні деформацій полотна. Щоб подолати обмеження монокулярного зору за складного освітлення, відблисків та часткових закриттів, дедалі частіше додають глибину (стерео/LiDAR), теплове ІЧ-зображення та інші сенсори. Такі комбінації підвищують достовірність оцінювання стану без суттєвої втрати продуктивності в польових умовах. Карти глибини дають змогу стійко підганяти площину знака, автоматично оцінювати нахил і викривлення (warp), а також відсікати хибні спрацьовування за геометрією. Для дорожніх знаків добре себе показали підходи, що поєднують LiDAR-інтенсивність та RGB, як у методах вилучення / класифікації знаків з мобільних хмар точок, так і в LiDAR↔камера-злитті для 3D-детекції; зокрема, злиття використовують для усунення помилок виявлення недоліків за рахунок 3D-перевірок відповідності 2D-пропозицій [22–25].

Щоб обрати архітектуру під конкретні обмеження даних та апаратури, доцільно порівнювати підходи за єдиною системою показників. Для цього будемо використовувати: **точність виявлення** (*mAP*), **точність оцінювання стану** (RMSE нормованих показників — ΔE_{00} для кольору, метрики маски/геометрії, RA для світлоповернення), **потребу в розмічених даних**, **пропускну здатність на edge-пристрої** (FPS на Jetson-NX) та **пояснюваність** (зручність інтерпретації результатів). Такий підхід дозволяє порівнювати як «легкі» конвеєри з виконанням на борту, так і більш точні, але ресурсомісткі мультимодальні рішення.

Правила за кольором / формою та класичні ознаки (HOG/SIFT з SVM) майже не потребують розмітки і дають максимальну швидкість та пояснюваність, проте поступаються точністю й стійкістю до складних умов. Одноетапні детектори (родина YOLO) забезпечують високу точність у реальному часі; двоетапні схеми з FPN (Faster/Mask R-CNN) краще утримують **малі / частково закриті** об'єкти ціною більшого навантаження на обчислення. Сегментаційні моделі (U-Net-подібні) потрібні, коли важлива локалізація пошкоджень по пікселях. Мультимодальні конвеєри здатні зменшувати хибні спрацьовування й стабілізувати оцінювання стану, але вимагають додаткових сенсорів і синхронізації. Узагальнені значення в літературі підтверджують цю картину: **mAP $\approx$ 0,95–0,97** для сучасних DL-детекторів і найменші RMSE для мультимодальних конвеєрів [11–18, 20, 22–24, 26].

У **табл. 2** наведено типові діапазони потреб у даних, точності й швидкості для кожного класу підходів. Це дозволяє обирати рішення базуючись на потребах: якщо критичні **швидкість та простота впровадження**, виправдані rule-based / класичні рішення; якщо потрібні **висока точність розпізнавання** — одно-/двоетапні DL; якщо ключова **якість оцінювання стану** за складних умов — доцільно розглядати **сегментацію та мультимодальність** з прийнятною ціною за обчислення і сенсори.

Таблиця 2

**Ключові показники ефективності для типових конвеєрів
автоматизованої інспекції**

Показник	Правила за кольором та формою (rule-based)	Класичне ML	Глибоке виявлення	Глибока сегментація	Мультимодальний підхід
Потреба в наборі розмічених даних	–	≤ 500 масок	5 тис. – 50 тис. масок	≈ 5 тис. масок	RGB+Depth
Середній mAP розпізнавання	0,55	0,72	0,95	0,96	0,97

Кінець таблиці 2

Показник	Правила за кольором та формою (rule-based)	Класичне ML	Глибоке виявлення	Глибока сегментація	Мультиmodalний підхід
RMSE оцінки стану	—	0,20	0,12	0,08	0,05
FPS на краю (Jetson-NX), кадр/сек	80	55	35	18	22
Пояснюваність	Висока	Середня	Низька	Низька	Середня

Удосконалений підхід

На **рис. 1** показано гібридну архітектуру «edge-cloud», яка вирішує вищезазначені проблеми. Конвеєр працює у два рівні. Відео з відеореєстратора спочатку аналізується на борту транспортного засобу легким детектором YOLOv8-Nano, який витягує кадри-кандидати зображень засобів керування дорожнім рухом. Тільки ці компактні кадри передаються до хмарного кластера, де важчі моделі виконують сегментацію пошкоджень на рівні пікселів, аналіз кольору та світловідбивної здатності, а також 3D-планарну апроксимацію з використанням даних LiDAR, коли вони доступні. Результати надходять на панель активного навчання, яка позначає невизначені випадки для перевірки людиною та зрештою заповнює базу даних управління активами на основі ГІС.

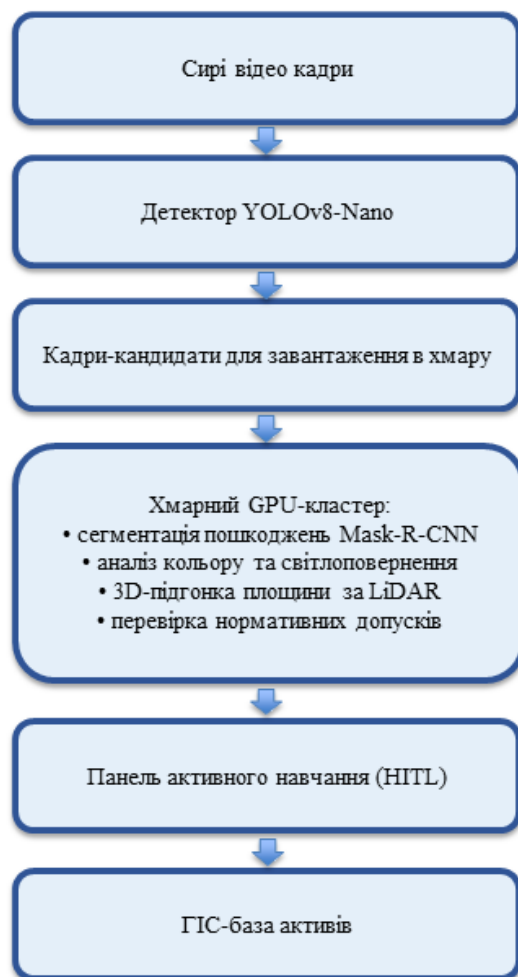


Рисунок 1 — Запропонований гібридний конвеєр обробки даних «edge-cloud»

Ключові іновачії включають:

- самостійне попереднє навчання. Контрастне навчання на 20 000 годин немаркованого відео з відеореєстратора зменшує потребу в маркованих даних на 60 %;
- синтетичне доповнення. Фізично коректний рендеринг (PBR) генерує керовані візерунки згасання, бруду та графіті, що призводить до безперервних міток стану;
- мультимодальне злиття. Низькобюджетний твердотільний LiDAR додає глибини, покращуючи класифікацію пошкоджень та дозволяючи вимірювати нахил у межах $\pm 2^\circ$;
- розділення «edge-cloud». Легкий YOLOv8-Nano працює зі швидкістю 28 кадрів/с на базі Jetson-Nano 2GB, надсилаючи до хмари лише кадрівання 256×256 для інтенсивної сегментації та фотометричного аналізу;
- активне навчання. Панель керування з функцією людина-в-циклі (HITL) вибірково аналізує неоднозначні випадки (достовірність $< 0,6$) для ручного перегляду, що забезпечує 10-кратне підвищення ефективності анотацій;
- механізм відповідності нормативним вимогам. Модуль правил перетворює піксельні вимірювання на метричні допуски, посилаючись на ДСТУ 4100:2021, та автоматично генерує звіти у форматі PDF [21].

Висновки

Останні дослідження та польові випробування свідчать, що гібридний конвеєр «edge-cloud» органічно інтегрується у регулярний моніторинг і експлуатаційне утримання ТЗОД. Автоматизовані інспекції забезпечують не гірші, а часто й вищі показники за частотою виявлення об'єктів, якістю сегментації та точністю оцінювання кольорових відхилень / світлоповернення, одночасно скорочуючи загальний цикл перевірки — від виявлення до прийняття рішення щодо відновлення.

На практиці дорожні служби отримують дві ключові переваги:

- частіші та об'єктивні оцінки стану дорожніх знаків, що зменшує час від появи деградації до її виявлення;
- зниження потреби в ручних обстеженнях, коли частина перевірок переноситься на автоматизовані процедури з вибірковою верифікацією.

Із фінансового погляду, початкові витрати зумовлені переважно обладнанням периферійної обробки та стартовими ресурсами хмарних обчислень, а поточні — зберіганням даних, періодичним перенавчанням моделей і цільовою перевіркою людиною. Інвестиції стають доцільними, щойно навіть невелику частку ручних перевірок замінено автоматизованою обробкою, а графіки технічного обслуговування уточнено завдяки більш насиченому потоку даних. Аналіз чутливості показує, що ці висновки зберігаються в реалістичних діапазонах точності моделей, ставок оплати праці та вартості обладнання.

Загалом, інспекція знаків на основі ІІІ вийшла за межі лабораторних демонстрацій. Хоча жоден окремий метод ще не покриває повністю вимоги точності, вартості та нормативів, раціональне поєднання контрастного попереднього навчання, мультимодального сенсорного супроводу та ієрархічної обробки дозволяє досягти необхідного балансу швидкості, точності та пояснюваності.

Наступні кроки до масштабованих, готових до промислового використання систем включають:

- розширення відкритих наборів даних із достатнім охопленням типових сценаріїв деградації;
- розвиток фізично обґрунтованих мереж для прямої оцінки коефіцієнта світлоповернення;
- масштабні поздовжні дослідження для кількісної оцінки ефектів на безпеку та економіку.

Разом ці зусилля прокладають шлях до надійного, керованого даними управління дорожніми активами в ініціативах розумного транспорту.

Список літератури

1. FHWA. Sign Retroreflectivity – Definitions and Units (R_A, cd/lux/m²). URL: <https://highways.dot.gov/safety/other/visibility/workshops-nighttime-visibility-traffic-signs-summary-workshop-findings-7> (дата звернення: 08.10.2025).
2. Khalilikhah M., та ін. Using Stationary Image-Based Method for Evaluation of Traffic Sign Condition. Case Studies in Transport Policy, 2016. URL: <https://www.sciencedirect.com/science/article/pii/S2046043016300429> (дата звернення: 08.09.2025).

3. Balali V., at all Image-Based Remote Measurement of Retro-Reflectivity of Traffic Signs (Daytime HDR → Nighttime). Mineta Transportation Institute Report 1878, 2021. URL: <https://transweb.sjsu.edu/sites/default/files/1878-Balili-Remote-Measurement-Road-Reflectivity.pdf> (дата звернення: 08.09.2025).
4. Oregon DOT (ODOT). Retroreflective Signs — Final Report. 2018. URL: <https://www.oregon.gov/odot/Programs/ResearchDocuments/SPR799LidarRetroFinalReport.pdf> (дата звернення: 08.09.2025).
5. Maerz N.H., at all Automated Mobile Highway Sign Visibility Measurement Using Nighttime Video. TRB, 2002. URL: https://www.mst.edu/~norbert/pdf/trb02_maerz_sign.pdf (дата звернення: 08.09.2025).
6. Cai H.Y., Li L.J. Measuring Light and Geometry Data of Roadway Environments using HDR Photogrammetry. J. Transportation Technologies, 2012. URL: <https://scispace.com/pdf/measuring-light-and-geometry-data-of-roadway-environments-1axhsejfv.pdf> (дата звернення: 08.10.2025).
7. Finlayson G.D., Trezzi E. Shades of Gray and Colour Constancy. IS&T Color Imaging Conf., 2004. URL: <https://library.imaging.org/admin/apis/public/api/ist/website/downloadArticle/cic/12/1/art00008> (дата звернення: 08.09.2025).
8. van de Weijer J., Gevers T., Gijsenij A. Grey-Edge Hypothesis and Color Constancy. Tech. Report CR-2542, INRIA/LEAR, 2007. URL: <https://lear.inrialpes.fr/people/vandeweijer/papers/cr2542.pdf> (дата звернення: 08.09.2025).
9. Sharma G., Wu W., Dalal E.N. The CIEDE2000 color-difference formula: Implementation notes... *Color Research & Application*, 2005, 30(1):21–30. DOI: <https://doi.org/10.1002/col.20070>. URL: <https://onlinelibrary.wiley.com/doi/10.1002/col.20070> (дата звернення: 08.09.2025).
10. Державне агентство відновлення та розвитку інфраструктури України. Звіт про виконання паспорта бюджетної програми на 2023 рік (КПКВК 3111020) [Електронний ресурс]. Київ, 2024. URL: https://restoration.gov.ua/4489/finansovo-ekonomichna_diialnist/59452/59540.pdf (дата звернення: 08.09.2025).
11. Lim X. R., Lee C. P., Lim K. M., Ong T. S., Alqahtani A., Ali M. Recent Advances in Traffic Sign Recognition: Approaches and Datasets. *Sensors*, 2023, 23(10):4674. DOI: <https://doi.org/10.3390/s23104674>. URL: <https://www.mdpi.com/1424-8220/23/10/4674> (дата звернення: 08.09.2025).
12. Chen H., Li X., Zhou W., та ін. Computational methods for automatic traffic signs detection and recognition: a review. *Array*, 2024. URL: <https://www.sciencedirect.com/science/article/pii/S2590123024017961> (дата звернення: 08.09.2025).
13. Houben S., Stallkamp J., Salmen J., Schlipsing M., Igel C. Detection of Traffic Signs in Real-World Images: The German Traffic Sign Detection Benchmark. *Proc. IJCNN*, 2013, 715–722. DOI: <https://doi.org/10.1109/IJCNN.2013.6706807>.
14. Neuhold G., Ollmann T., Rota Bulò S., Kotschieder P. The Mapillary Vistas Dataset for Semantic Understanding of Street Scenes. *ICCV*, 2017. URL: https://openaccess.thecvf.com/content_ICCV_2017/papers/Neuhold_The_Mapillary_Vistas_ICCV_2017_paper.pdf (дата звернення: 08.09.2025).
15. Lin T.-Y., Dollár P., Girshick R., He K., Hariharan B., Belongie S. Feature Pyramid Networks for Object Detection. *CVPR*, 2017. URL: https://openaccess.thecvf.com/content_cvpr_2017/papers/Lin_Feature_Pyramid_Networks_CVPR_2017_paper.pdf (дата звернення: 08.09.2025).
16. He K., Gkioxari G., Dollár P., Girshick R. Mask R-CNN. *arXiv:1703.06870*, 2017. URL: <https://arxiv.org/pdf/1703.06870> (дата звернення: 08.10.2025).
17. Zhang H., Wu C., Zhang Z., та ін. ResNeSt: Split-Attention Networks. *arXiv:2004.08955*, 2020. URL: <https://arxiv.org/abs/2004.08955> (дата звернення: 08.09.2025).
18. Li S., Zhang H., Wang B., та ін. A Small Object Detection Algorithm for Traffic Signs Based on the Improved YOLOv7. *Sensors*, 2023. URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10459082/> (дата звернення: 08.09.2025).
19. Huang X., та ін. Adaptive colour calibration for traffic-sign inspection. *IET Intelligent Transport Systems*, 2023.

20. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. arXiv:1505.04597, 2015. URL: <https://arxiv.org/abs/1505.04597> (дата звернення: 08.09.2025).
21. ДСТУ 4100:2021. Знаки дорожні. Загальні технічні умови. Київ: ДП «УкрНДНЦ», 2021.
22. Zhang F., та ін. Extracting Traffic Signage by Combining Point Clouds and Images. Remote Sensing, 2023. URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC9964076/> (дата звернення: 08.09.2025).
23. Ahn Y., Munjy R., Li Z. Traffic Sign Extraction from Mobile LiDAR Point Cloud. ROSA P / NTL, 2024. URL: <https://rosap.ntl.bts.gov/view/dot/75693> (дата звернення: 08.09.2025).
24. Cheng Y.-T., та ін. Image-Aided LiDAR Extraction, Classification, and Mapping. Remote Sensing, 2024. URL: <https://www.mdpi.com/2072-4292/16/10/1668> (дата звернення: 08.09.2025).
25. Müller S., та ін. Multimodal damage detection for road-side assets. ITS World Congress, 2024.
26. Tomita K., та ін. A Review of Infrared Thermography for Delamination Detection. Sensors, 2022. URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8779359/> (дата звернення: 08.09.2025).

References

1. FHWA. Sign Retroreflectivity – Definitions and Units (R_A, cd/lux/m²). URL: <https://highways.dot.gov/safety/other/visibility/workshops-nighttime-visibility-traffic-signs-summary-workshop-findings-7> (Last accessed: 08.09.2025) [in English].
2. Khalilikhah M., et al. Using Stationary Image-Based Method for Evaluation of Traffic Sign Condition. Case Studies in Transport Policy, 2016. URL: <https://www.sciencedirect.com/science/article/pii/S2046043016300429> (Last accessed: 08.09.2025) [in English].
3. Balali V., et al. Image-Based Remote Measurement of Retro-Reflectivity of Traffic Signs (Daytime HDR → Nighttime). Mineta Transportation Institute Report 1878, 2021. URL: <https://transweb.sjsu.edu/sites/default/files/1878-Balili-Remote-Measurement-Road-Reflectivity.pdf> (Last accessed: 08.09.2025) [in English].
4. Oregon DOT (ODOT). Retroreflective Signs — Final Report. 2018. URL: <https://www.oregon.gov/odot/Programs/ResearchDocuments/SPR799LidarRetroFinalReport.pdf> (Last accessed: 08.09.2025) [in English].
5. Maerz N. H., et al. Automated Mobile Highway Sign Visibility Measurement Using Nighttime Video. TRB, 2002. URL: https://www.mst.edu/~norbert/pdf/trb02_maerz_sign.pdf (Last accessed: 08.09.2025) [in English].
6. Cai H. Y., Li L. J. Measuring Light and Geometry Data of Roadway Environments using HDR Photogrammetry. Journal of Transportation Technologies, 2012. URL: <https://scispace.com/pdf/measuring-light-and-geometry-data-of-roadway-environments-laxhsejfv.pdf> (Last accessed: 08.09.2025) [in English].
7. Finlayson G.D., Trezzi E. Shades of Gray and Colour Constancy. IS&T Color Imaging Conference, 2004. URL: <https://library.imaging.org/admin/apis/public/api/ist/website/downloadArticle/cic/12/1/art00008> (Last accessed: 08.09.2025) [in English].
8. van de Weijer J., Gevers T., Gijsenij A. Grey-Edge Hypothesis and Color Constancy. Technical Report CR-2542, INRIA/LEAR, 2007. URL: <https://lear.inrialpes.fr/people/vandeweijer/papers/cr2542.pdf> (Last accessed: 08.09.2025) [in English].
9. Sharma G., Wu W., Dalal E. N. The CIEDE2000 color-difference formula: Implementation notes... *Color Research & Application*, 2005, 30 (1). 21–30. DOI: <https://doi.org/10.1002/col.20070>. URL: <https://onlinelibrary.wiley.com/doi/10.1002/col.20070> (Last accessed: 08.09.2025) [in English].
10. State Agency for Restoration and Development of Infrastructure of Ukraine. Report on the Execution of the Passport of the Budget Program for 2023 (KPKVK 3111020) [in Ukrainian]. Kyiv, 2024. URL: https://restoration.gov.ua/4489/finansovo-ekonomichna_diialnist/59452/59540.pdf (Last accessed: 09.10.2025) [in English].
11. Lim X. R., Lee C. P., Lim K. M., Ong T. S., Alqahtani A., Ali M. Recent Advances in Traffic Sign Recognition: Approaches and Datasets. *Sensors*. 2023. 23(10):4674. DOI: <https://doi.org/10.3390/s23104674>. URL: <https://www.mdpi.com/1424-8220/23/10/4674> (Last accessed: 08.10.2025) [in English].

12. Chen H., Li X., Zhou W., et al. Computational methods for automatic traffic signs detection and recognition: a review. *Array*, 2024. URL: <https://www.sciencedirect.com/science/article/pii/S2590123024017961> (Last accessed: 08.09.2025) [in English].
13. Houben S., Stallkamp J., Salmen J., Schlipsing M., Igel C. Detection of Traffic Signs in Real-World Images: The German Traffic Sign Detection Benchmark. *Proc. IJCNN*, 2013. 715–722. DOI: <https://doi.org/10.1109/IJCNN.2013.6706807> [in English].
14. Neuhold G., Ollmann T., Rota Bulò S., Kotschieder P. The Mapillary Vistas Dataset for Semantic Understanding of Street Scenes. *ICCV*, 2017. URL: https://openaccess.thecvf.com/content_ICCV_2017/papers/Neuhold_The_Mapillary_Vistas_ICCV_2017_paper.pdf (Last accessed: 08.09.2025) [in English].
15. Lin T.-Y., Dollár P., Girshick R., He K., Hariharan B., Belongie S. Feature Pyramid Networks for Object Detection. *CVPR*, 2017. URL: https://openaccess.thecvf.com/content_cvpr_2017/papers/Lin_Feature_Pyramid_Networks_CVPR_2017_paper.pdf (Last accessed: 08.10.2025) [in English].
16. He K., Gkioxari G., Dollár P., Girshick R. Mask R-CNN. *arXiv:1703.06870*, 2017. URL: <https://arxiv.org/pdf/1703.06870> (Last accessed: 08.09.2025) [in English].
17. Zhang H., Wu C., Zhang Z., et al. ResNeSt: Split-Attention Networks. *arXiv:2004.08955*, 2020. URL: <https://arxiv.org/abs/2004.08955> (Last accessed: 08.09.2025) [in English].
18. Li S., Zhang H., Wang B., et al. A Small Object Detection Algorithm for Traffic Signs Based on the Improved YOLOv7. *Sensors*, 2023. URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10459082/> (Last accessed: 08.09.2025) [in English].
19. Huang X., et al. Adaptive colour calibration for traffic-sign inspection. *IET Intelligent Transport Systems*, 2023 [in English].
20. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *arXiv:1505.04597*, 2015. URL: <https://arxiv.org/abs/1505.04597> (Last accessed: 08.09.2025).
21. DSTU 4100:2021. Road signs. General technical conditions. Kyiv: SE «UkrNDNC», 2021 [in Ukrainian].
22. Zhang F., et al. Extracting Traffic Signage by Combining Point Clouds and Images. *Remote Sensing*, 2023. URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC9964076/> (Last accessed: 08.10.2025) [in English].
23. Ahn Y., Munjy R., Li Z. Traffic Sign Extraction from Mobile LiDAR Point Cloud. *ROSA P / NTL*, 2024. URL: <https://rosap.ntl.bts.gov/view/dot/75693> (Last accessed: 08.09.2025) [in English].
24. Cheng Y.-T., et al. Image-Aided LiDAR Extraction, Classification, and Mapping. *Remote Sensing*, 2024. URL: <https://www.mdpi.com/2072-4292/16/10/1668> (Last accessed: 08.09.2025) [in English].
25. Müller S., et al. Multimodal damage detection for road-side assets. *ITS World Congress*, 2024 [in English].
26. Tomita K., et al. A Review of Infrared Thermography for Delamination Detection. *Sensors*, 2022. URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8779359/> (Last accessed: 08.09.2025) [in English].

Roman Smolyanyuk, Ph.D., Sciences Professor, <https://orcid.org/0000-0001-7087-7834>
Serhii Khalin, <https://orcid.org/0009-0009-6061-8498>

Kharkiv National Automobile and Highway University (KHNADU), Kharkiv, Ukraine

ARTIFICIAL INTELLIGENCE FOR AUTOMATED IDENTIFICATION AND CONDITION ASSESSMENT OF TRAFFIC CONTROL DEVICES

Abstract

Introduction. Traffic control devices, primarily traffic signs and road markings make the roadway environment intelligible to drivers and have a major impact on safety. Manual inspections remain the benchmark for compliance, but they are labour-intensive, costly, and episodic, which creates long lag times

between deterioration and remediation. Recent advances in computer vision and deep learning enable automated pipelines that detect, classify and assess the condition of signs using video and images, optionally supported by photometric measurements of retroreflectivity.

Problem statement. Despite high accuracy on public benchmarks, deep models degrade in real-world edge cases: fading, dirt, graffiti, occlusions by foliage, snow or fog, and strong off-axis viewpoints. Moreover, condition assessment requires quantified metrics — colour difference, glyph legibility and contrast, geometric deformation and retroreflectivity — rather than a coarse «good / damaged» label.

Purpose. To consolidate approaches for automated inspection, compare their strengths and limitations under realistic constraints, and outline an edge–cloud architecture that minimizes manual effort while meeting regulatory tolerances.

Materials and methods. We consider a spectrum of methods — from color/shape rules and classical hand-crafted features (HOG-SVM, SIFT-SVM) to single-stage object detectors (YOLOv8, SSD), two-stage detectors (Faster R-CNN, Mask R-CNN), and multi-task as well as multimodal approaches that incorporate depth maps (LiDAR/stereo). For quantitative condition assessment, we describe conversion to the CIELAB color space after Gray-World or Shades-of-Grey white balancing, the use of physics-guided networks to estimate retroreflectivity, and the evaluation metrics employed (mAP for recognition, RMSE for condition regression, FPS on Jetson-NX).

Results. Based on aggregated data, single- and two-stage deep detectors deliver mAP of 0.95 – 0.97, while multi-task/multimodal pipelines achieve the lowest error in condition estimation (RMSE 0.05 – 0.08). On edge devices, 18 – 35 fps is attainable (architecture-dependent), enabling on-device processing with subsequent offloading of candidate frames for heavy segmentation in the cloud. The proposed architecture combines a lightweight on-board YOLOv8-Nano detector (~28 fps) with cloud modules for segmentation and photometric analysis; contrastive pretraining on 20,000 unlabeled patches reduces labeling needs by ~60%, and an inexpensive solid-state LiDAR improves damage-class accuracy and enables tilt/roll measurement with $\pm 2^\circ$ precision.

Conclusions. AI-assisted inspection substantially increases the frequency and objectivity of assessments, shortens maintenance cycles and creates the basis for data-driven asset management. Future priorities include expanding open datasets with authentic degradation patterns, improving physics-guided networks for direct retroreflectivity estimation, and conducting longitudinal studies to quantify safety and economic benefits.

Keywords: road, traffic sign inspection; computer vision; deep learning; condition assessment; intelligent transportation systems; asset management.