

Максим Лещук¹, Михайло Мельник², Войцех Забєровські³

¹ Кафедра систем автоматизованого проектування, Національний університет “Львівська політехніка”, вул. С. Бандери, 12, Львів, Україна, E-mail: max.leshchuk@gmail.com, ORCID 0009-0000-7796-8368

² Кафедра систем автоматизованого проектування, Національний університет “Львівська політехніка”, вул. С. Бандери, 12, Львів, Україна, E-mail: Mykhaylo.R.Melnyk@lpnu.ua, ORCID 0000-0002-8593-8799³

Кафедра мікроелектроніки та комп’ютерних наук, Лодзький технологічний університет, вул. Вульчанська, 221, Лодзь, Польща, E-mail: wojciech.zabierowski@p.lodz.pl, ORCID: 0000-0002-6289-6637

ГІБРИДНИЙ ПІДХІД ДО РОЗПІЗНАВАННЯ ДОРОЖНІХ ЗНАКІВ НА ОСНОВІ КОЛЬОРОВОЇ СЕГМЕНТАЦІЇ ТА ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ

Отримано: Вересень 01, 2025 / Переглянуто: Вересень 11, 2025 / Прийнято: Вересень 15, 2025

© Лещук М., Мельник М., Забєровські В., 2025

<https://doi.org/10.23939/cds2025.02.085>

Анотація. У роботі запропоновано гібридний підхід до розпізнавання дорожніх знаків, який поєднує класичні методи попередньої обробки (кольорова сегментація, аналіз контурів, Наар Cascade та HOG) зі згортковою нейронною мережею (CNN) для класифікації. Запропонований метод дав змогу зменшити час оброблення зображення у 10–20 разів, оскільки на вхід мережі передаються лише попередньо відібрані регіони інтересу. CNN, навчена на наборі GTSRB із використанням аугментації даних, забезпечила 100 % точність на тестовій вибірці, а для окремих класів precision та recall досягали 0,97–1,00. Порівняно з прямим застосуванням CNN до всього зображення, запропонований підхід забезпечив прискорення роботи більш ніж у п’ять разів, тому він придатний для використання на вбудованих системах реального часу (Raspberry Pi, мобільні робототехнічні комплекси). Практична значущість роботи полягає у можливості впровадження розробленої системи у недорогі ADAS-рішення та автономні транспортні платформи. Подальші дослідження передбачають адаптацію до відеопотоку та розширення кількості класів знаків.

Ключові слова: розпізнавання дорожніх знаків, комп’ютерний зір, сегментація зображень, згорткова нейромережа, вбудовані системи, ADAS.

Вступ

Проблема автоматичного розпізнавання дорожніх знаків – одна із ключових у контексті розвитку інтелектуальних транспортних систем та забезпечення безпеки дорожнього руху. Збільшення кількості транспортних засобів, перехід до автономного керування, а також зростання вимог до систем допомоги водієві (ADAS) зумовлюють необхідність високоточних і водночас енерго-ефективних алгоритмів комп’ютерного зору. Система розпізнавання дорожніх знаків повинна працювати в режимі реального часу, зберігати працездатність у складних умовах освітлення, погодних впливів, забруднення або часткового перекриття об’єктів.

Попри помітний прогрес у застосуванні згорткових нейронних мереж (CNN), більшість сучасних моделей потребують потужних графічних процесорів та великих обсягів пам’яті, що ускладнює їх використання на вбудованих або мобільних платформах. Водночас класичні методи комп’ютерного зору, такі як сегментація в HSV-просторі, контурний аналіз, детектори HOG чи Наар, залишаються конкурентоспроможними завдяки простоті реалізації та високій швидкодії. Це визначає потребу в розробленні гібридних підходів, які поєднують переваги обох напрямів.

Застосування попередньої фільтрації та виокремлення областей інтересу перед поданням зображення на класифікацію дає можливість істотно зменшити кількість оброблюваних даних. Такий принцип дає змогу інтегрувати глибоке навчання навіть у середовищах із обмеженими ресурсами. Особливого значення набуває використання публічних наборів даних, таких як German Traffic Sign Recognition Benchmark (GTSRB), за якими можна об'єктивно оцінити якість алгоритмів та порівняти їх із сучасними рішеннями.

Цілі цього дослідження – аналіз і практична реалізація системи розпізнавання дорожніх знаків, що поєднує класичні методи попередньої обробки з легкою нейронною мережею для класифікації. Основну увагу звернено на оптимізацію швидкодії та підвищення стійкості розпізнавання без використання ресурсомістких моделей.

Огляд сучасних джерел інформації за тематикою публікації

У статті [1] (J. Stallkamp et al., 2012) наведено детальне порівняння класичних алгоритмів машинного навчання та CNN для завдання розпізнавання дорожніх знаків на наборі даних GTSRB. Автори проаналізували ефективність таких методів, як SVM, Random Forest, і багатошарові перцептрони, порівнюючи їх із глибокими мережами. Результати показали, що CNN забезпечують найвищу точність класифікації, тоді як класичні алгоритми залишаються конкурентоспроможними за обмежених обчислювальних ресурсів. Особливу увагу звернено на підготовку даних: нормалізацію, масштабування і попереднє видалення шумів. Ця робота фундаментальна для гібридного підходу, де класичні методи локалізації знаків або виділення регіонів інтересу (ROI) застосовуються до зображення перед подаванням його у CNN для класифікації.

У [2] (P. Sermanet і Y. LeCun, 2011) розглянуто багатомасштабні CNN для розпізнавання дорожніх знаків. Автори довели, що мережі, які аналізують ознаки на різних масштабах, краще справляються із варіаціями розмірів та положення знаків на зображенні, а також стійкіші до шуму та змін освітлення. Метод багатомасштабного представлення ознак дає змогу системі виділяти контури та текстури дорожніх знаків, що особливо важливо для комбінування класичних методів детекції з CNN. Робота підтверджує, що інтеграція багатомасштабного оброблення підвищує точність і надійність гібридної системи.

У [3] (S. Houben et al., 2013) досліджено детекцію дорожніх знаків у реальних умовах на прикладі German Traffic Sign Detection Benchmark (GTSDB). Автори підкреслюють, що попереднє оброблення зображень, зокрема кольорова сегментація та фільтрація, дає змогу ефективно виділяти регіони інтересу перед подаванням їх у CNN для класифікації. В роботі порівняно результати детекції за різними підходами і показано, що комбінування класичних методів локалізації та глибоких мереж істотно підвищує точність і швидкість обробки. Ця стаття є ключовою для побудови гібридної системи, де важлива саме комбінація класичної сегментації та сучасних моделей CNN.

Автори [4] (K. Simonyan і A. Zisserman, 2014) запропонували архітектуру VGG, яка демонструє ефективність дуже глибоких CNN у задачах класифікації зображень. Автори детально описують принцип використання послідовних фільтрів 3×3 і шарів max-pooling, а також методи регуляризації та нормалізації для уникнення перенавчання. Результати показали, що глибокі мережі здатні виділяти високорівневі ознаки, критично важливі для класифікації дорожніх знаків. У гібридних системах VGG або подібні архітектури можна використовувати для точного розпізнавання знаків, попередньо виділених класичними методами сегментації.

Конкретний приклад гібридного підходу до розпізнавання дорожніх знаків із застосуванням кольорової сегментації та CNN наведено у статті [5] (A. Youssef et al., 2016). Автори показали, що попереднє виділення ROI істотно зменшує обчислювальне навантаження на CNN та підвищує точність класифікації. В роботі детально описано алгоритми кольорової сегментації та структуру CNN, що робить її цінним джерелом для практичної реалізації гібридної системи. Стаття демонструє, що гібридні методи дають змогу оптимально поєднувати швидкість обробки та точність результатів.

Автор [6] (X. Qiao, 2023) дослідив сучасне застосування CNN для розпізнавання дорожніх знаків, зосередивши увагу на підготовці даних, аугментації та оптимізації гіперпараметрів. Автор наголошує, що інтеграція класичних методів детекції з CNN підвищує стійкість системи до складних умов, таких як нерівномірне освітлення, частково закриті знаки або шумний фон. Ця робота демонструє, що гібридні підходи залишаються актуальними навіть із сучасними глибокими моделями.

У статті [7] (M. Abadi et al., 2016) описано платформу TensorFlow для масштабного тренування та виконання CNN на різномірних системах, разом із GPU і CPU. TensorFlow забезпечує ефективну інтеграцію класичних алгоритмів опрацювання зображень із глибокими нейронними мережами, даючи змогу будувати гібридні системи із високою продуктивністю. Розробники можуть легко поєднувати різні модулі обробки та класифікації в єдину систему, тому ця стаття – важливе джерело для практичної реалізації.

Підхід, описаний у [8] (H. B. Fredj, 2023), забезпечує ефективну реалізацію CNN для розпізнавання дорожніх знаків у складних умовах, таких як нерегламентоване освітлення і неоднорідний фон. Автор підкреслює важливість попередньої сегментації й аугментації даних для підвищення точності та надійності класифікації. Робота підтверджує, що поєднання класичних методів локалізації та CNN забезпечує оптимальний баланс між швидкістю опрацювання та точністю результатів, що є основною ідеєю гібридного підходу.

Постановка проблеми

Розпізнавання дорожніх знаків у реальних умовах – одне із ключових завдань сучасних систем допомоги водієві (ADAS) та автономного управління транспортом. Висока точність і швидкість розпізнавання критично важливі, оскільки від цього залежить безпека руху та ефективність системи. Основною складністю є значна варіативність зовнішніх умов: освітлення, погодні умови (дощ, туман, сніг), часткове перекриття знаків деревами або іншими об'єктами, а також різноманіття форм, кольорів і розмірів дорожніх знаків у різних країнах. На рис. 1 наведено загальну схему системи розпізнавання дорожніх знаків, що охоплює етапи попередньої обробки, виділення регіонів інтересу (ROI) та класифікації.

У традиційних системах детекцію та класифікацію знаків часто здійснюють за допомогою згорткових нейронних мереж (CNN), які забезпечують високу точність. Стандартна операція згортки у CNN описується формулою (1):

$$y = f(W * X + b), \quad (1)$$

де X – вхідне зображення або виділений ROI; W – параметри згорткових фільтрів; b – зсув; f – функція активації. Для опрацювання одного кадру відео сучасні CNN можуть виконувати десятки тисяч операцій згортки, що створює високі вимоги до обчислювальних ресурсів, особливо на вбудованих платформах та автомобільних комп'ютерах із обмеженою потужністю GPU або CPU.

Крім того, зі збільшенням глибини мережі та кількості параметрів зростає не тільки точність, а й затримка опрацювання кадру. Це робить пряме використання глибоких CNN для детекції дорожніх знаків у реальному часі малоефективним, особливо для автомобільних систем, де затримка більше ніж кілька мілісекунд може призвести до небезпечних ситуацій.

Для зменшення обчислювальної складності пропонуємо застосовувати гібридний підхід, що поєднує класичні методи виділення регіонів інтересу (колірна сегментація, аналіз контурів, морфологічні операції) із потужними можливостями CNN для класифікації виділених регіонів. Такий підхід дає змогу:

1. Істотно зменшити кількість непотрібних обчислень, оскільки CNN обробляє лише потенційні ROI, а не увесь кадр.
2. Підвищити точність розпізнавання навіть за наявності шуму, часткових перекриттів та змінених умов освітлення.

3. Забезпечити опрацювання зображень у реальному часі на вбудованих платформах, урахувуючи мобільні системи та автомобільні комп'ютери.

Додатковою проблемою є інтеграція різних методів, що мають різні характеристики: класичні алгоритми швидкі, але можуть допускати помилки у виділенні ROI, тоді як CNN забезпечують високу точність, але потребують значних обчислювальних ресурсів. Тому завдання полягає у розробленні оптимальної архітектури гібридної системи, яка забезпечує баланс між швидкістю опрацювання та точністю класифікації.

Проблему можна формалізувати так: необхідно створити алгоритм, який знижує обчислювальне навантаження на систему, забезпечує швидку детекцію ROI, зберігає високу точність класифікації та здатний працювати у реальному часі в умовах обмежених ресурсів. Оптимальний алгоритм повинен містити:

- Методи попереднього оброблення зображення та нормалізації освітлення.
- Алгоритми виділення потенційних регіонів інтересу з високою ймовірністю наявності знака.
- CNN або інші сучасні методи глибинного навчання для класифікації виділених ROI.
- Механізми оброблення помилок, такі як відсіювання хибних спрацьовувань та постпроцесинг.

Отже, проблема полягає у розробленні гібридного підходу, що дає змогу поєднати швидкість класичних методів детекції з високою точністю CNN для створення ефективної, надійної та ресурсоощадної системи розпізнавання дорожніх знаків у реальному часі.

Виклад основного матеріалу

Розпізнавання дорожніх знаків – критично важливе завдання у системах допомоги водію (ADAS) та автономних транспортних засобах. Це завдання поєднує елементи комп'ютерного зору та штучного інтелекту і полягає у двох ключових етапах: детекції знаків у відеопотоці та їхній класифікації. Вимоги до точності та швидкодії на обох етапах суворі, оскільки будь-яка затримка або помилка в ідентифікації знака може призвести до неправильної реакції системи, а у критичних сценаріях – до аварійної ситуації.

У сучасних дослідженнях для класифікації дорожніх знаків активно використовують глибокі нейронні мережі (CNN), які демонструють високу точність на відомих наборах даних, таких як GTSRB чи GTSDb. Проте використання CNN на всьому кадрі відеопотоку потребує великих обчислювальних ресурсів і значної пам'яті, що ускладнює застосування таких моделей у вбудованих системах, наприклад, в автомобільних контролерах або сенсорних пристроях із обмеженим енергоспоживанням.

Крім того, реальні умови знімання ускладнюють завдання розпізнавання. Дорожні знаки можуть бути частково закриті іншими об'єктами, зношені, деформовані, відблискувати від сонця або перебувати у тіні. Відеопотік має різну роздільну здатність та частоту кадрів, а зміни погодних умов і різке рухоме тло ще більше ускладнюють детекцію. В таких умовах прості класичні алгоритми можуть пропускати знаки, а CNN без попередньої детекції обробляє значно більший обсяг непотрібної інформації, що збільшує час оброблення та енергоспоживання.

Отже, потребують вирішення такі ключові проблеми:

1. Високу обчислювальну складність опрацювання всього кадру CNN, що обмежує швидкодію у вбудованих системах.
2. Складність виділення регіонів інтересу в складних реальних умовах, де знаки можуть частково зникати, змінювати колір чи форму.
3. Потребу в збереженні балансу між швидкістю оброблення та точністю класифікації, що особливо важливо для автомобільних систем реального часу.
4. Оптимізацію енергоспоживання та використання пам'яті, що критично для мобільних та вбудованих платформ.

Для подолання цих проблем гібридний підхід пропонує модульну архітектуру (табл. 1), де етапи детекції та класифікації працюють послідовно, але оптимізовані для ресурсозбереження. Детекція здійснюється швидкими класичними методами, що дає змогу виділити тільки потенційні об'єкти-знаки. Далі ці ROI передаються на CNN для високоточної класифікації, що забезпечує надійне розпізнавання навіть у складних умовах.

Класичні методи детекції, такі як Haar Cascade та Histogram of Oriented Gradients (HOG), ефективно поєднуються в одному алгоритмі.

Haar Cascade ґрунтується на каскадній структурі слабких класифікаторів, кожен із яких оцінює прості прямокутні ознаки об'єкта. Завдяки каскаду ділянки з низькою ймовірністю появи знака відкидаються на ранніх етапах, що істотно зменшує обсяг обчислень. Переваги методу – висока швидкість оброблення та ефективність на стандартних формах об'єктів, таких як круглі або трикутні знаки. Проте Haar чутливий до зміни освітлення, обертання об'єктів та складних фонів, що потребує додаткової фільтрації або попереднього оброблення зображення.

Після швидкого попереднього відбору за допомогою Haar Cascade застосовують HOG, який аналізує локальні градієнти та орієнтації контурів у виділених ділянках. HOG забезпечує стійкість до змін освітлення та часткових перекриттів, даючи змогу точніше визначити розташування ROI і підтвердити наявність знака. Основна перевага HOG полягає у високій точності виділення об'єктів із характерною формою, а недолік – вища обчислювальна складність порівняно з Haar, що робить комбінований підхід оптимальним для зменшення навантаження на систему.

Такий послідовний підхід – спершу Haar Cascade, потім HOG – дає змогу зменшити кількість ділянок, що передаються на нейронну мережу, у 10–20 разів, зберігаючи високу точність виділення. Для подальшого зменшення обчислювальних витрат застосовують алгоритмічні оптимізації, що передбачають використання пірамід зображень, обмеження зони пошуку та об'єднання накладених ROI. Пірамідне оброблення дає змогу виявляти знаки різного розміру без необхідності обробки всього кадру у високій роздільній здатності. Обмеження зони пошуку ґрунтується на апіорних знаннях про дорожню сцену – наприклад, знаки зазвичай розташовані на певній висоті над дорогою. Завдяки об'єднанню накладених прямокутників за допомогою алгоритму Non-Maximum Suppression кожен знак оброблятиметься лише один раз, що дає змогу уникнути дублювання обчислень.

Ці алгоритми виділення ROI стають основою для гібридної системи, у якій застосовується нейронна мережа для класифікації конкретного типу знака на попередньо оброблених ділянках. CNN отримує тільки виділені ROI, що дає змогу зменшити розмір вхідного тензора та знизити обчислювальне навантаження до рівня, сумісного із реальним часом. Крім того, обмеження оброблення тільки релевантними ділянками підвищує точність прогнозу нейронної мережі, оскільки не впливає велика кількість фонових пікселів, що можуть спричиняти помилкові спрацьовування.

Архітектура мережі складається із трьох основних згорткових блоків, кожен із яких поєднує згорткові шари, функцію активації ReLU, підвибірковий пулінг (MaxPooling2D) та Dropout.

- Перший блок містить два згорткові шари по 32 фільтри кожен, зберігаючи просторові розміри 48×48 . Він відповідає за первинне виділення простих ознак – прямих ліній, кутів та базових геометричних форм. Після цього застосовують MaxPooling для зменшення розмірності до 24×24 , а Dropout запобігає перенавчанню.

- Другий блок складається із двох згорткових шарів по 64 фільтри та MaxPooling до 12×12 . Тут мережа починає виділяти складніші ознаки, наприклад кола, трикутники, комбінації контурів, характерні для конкретних класів знаків.

- Третій блок містить два згорткові шари по 128 фільтрів та пулінг до 6×6 , що дає змогу виділяти високорівневі ознаки, такі як специфічні текстури, написи чи комбінації форм. Dropout у цьому блоці підвищує стійкість до перенавчання, особливо на невеликих ROI.

Після згорткових блоків застосовується шар розгортання (Flatten), який перетворює тривимірну карту ознак на одновимірний вектор, довжина якого 4608 елементів. Наступний – повнозв'язний шар (Dense) із 256 нейронів, який інтегрує локальні ознаки у глобальне представлення ROI. Вихідний Dense-шар має 43 нейрони з softmax-функцією, що формує ймовірності належності ділянки до конкретного класу дорожніх знаків.

Таблиця 1

Архітектура створеної CNN моделі

Layer (type)	Output Shape	Param #
input_layer_2 (InputLayer)	(None, 48, 48, 3)	0
conv2d_12 (Conv2D)	(None, 48, 48, 32)	896
conv2d_13 (Conv2D)	(None, 48, 48, 32)	9,248
max_pooling2d_6 (MaxPooling2D)	(None, 24, 24, 32)	0
dropout_8 (Dropout)	(None, 24, 24, 32)	0
conv2d_14 (Conv2D)	(None, 24, 24, 64)	18,496
conv2d_15 (Conv2D)	(None, 24, 24, 64)	36,928
max_pooling2d_7 (MaxPooling2D)	(None, 12, 12, 64)	0
dropout_9 (Dropout)	(None, 12, 12, 64)	0
conv2d_16 (Conv2D)	(None, 12, 12, 128)	73,856
conv2d_17 (Conv2D)	(None, 12, 12, 128)	147,584
max_pooling2d_8 (MaxPooling2D)	(None, 6, 6, 128)	0
dropout_10 (Dropout)	(None, 6, 6, 128)	0
flatten_2 (Flatten)	(None, 4608)	0
dense_4 (Dense)	(None, 256)	1,179,904
dropout_11 (Dropout)	(None, 256)	0
dense_5 (Dense)	(None, 43)	11,051

Для підвищення точності та стабільності класифікації на етапі тренування застосовують різноманітні стратегії:

1. Аугментація зображень, що передбачає обертання, масштабування, зміну яскравості та контрасту, горизонтальні віддзеркалення та випадкові зсуви. Це дає змогу мережі навчитися розпізнавати знаки в різних умовах освітлення, з різних ракурсів і за часткового перекриття.

2. Регуляризація Dropout у кожному блоці зменшує ймовірність перенавчання, особливо на малих ROI.

3. Завдяки використанню адаптивного алгоритму оптимізації Adam із налаштуванням швидкості навчання функція втрат швидко сходиться до мінімуму, зберігаючи стабільність тренування.

4. Рання зупинка (Early Stopping) контролює тренування, зупиняючи його за відсутності покращення на валідаційній вибірці, що запобігає перенавчанню.

Інтеграція класичних методів виділення ROI (Haar, HOG) із цією CNN створює гібридну систему, яка поєднує швидкість та ефективність попереднього оброблення з високою точністю класифікації. Класичні алгоритми відсіюють великі ділянки з фону, залишаючи лише релевантні ділянки для CNN, що дає змогу зменшити обчислювальні витрати у 10–20 разів і забезпечити роботу в реальному часі на вбудованих системах.

Після формування та навчання згорткової нейронної мережі на підготовлених ROI ключовим аспектом оцінювання її ефективності є аналіз точності класифікації для кожного типу дорожнього знака. Наведені результати (див. рис. 1) демонструють високий рівень precision, recall та F1-score для всіх класів, що підтверджує здатність моделі коректно розпізнавати навіть рідкісні знаки. Наприклад, для знака “Speed limit 20 km/h” модель досягла precision = 0,97, recall = 1,00 та F1-score = 0,98, тоді як для численніших класів, таких як “Speed limit 50 km/h” або “Keep right”, всі показники сягають максимальних значень 1,00. Загальна точність моделі на тестовому наборі становила 100 %, що свідчить про її високу надійність та узгодженість прогнозів для різноманітних дорожніх ситуацій.

Досягнуті результати (див. рис. 2) є наслідком гібридного підходу, коли виділення ROI здійснюється за допомогою класичних методів Haar та HOG перед подаванням на CNN. Haar Cascade дає змогу швидко відсіяти фон та низьковірогідні ділянки завдяки каскадній структурі слабких класифікаторів, які оцінюють прості ознаки прямокутної форми, такі як краї та контури. Після цього HOG аналізує локальні градієнти та орієнтації контурів у виділених ділянках, уточнюючи розташування ROI та форму потенційних знаків.




Рис. 1. Зміна функції втрат (Loss) і точності (Ассурасу) під час навчання CNN на наборі даних GTSRB



Рис. 2. Тести на зображеннях із GTSRB

Завдяки обмеженню опрацювання лише релевантними ROI модель ефективно працює навіть на кадрах зі складним фоном, змінним освітленням або частковим перекриттям знаків. Це також сприяє стабільності прогнозів та високій впевненості моделі у визначенні класу кожного знака. Аналіз таблиці точностей дає змогу виявити окремі класи, для яких модель демонструє трохи менший recall або precision (наприклад, “Bicycles crossing” – recall 0,97). Це свідчить про потенційну потребу в додатковій аугментації або збільшенні обсягу навчальних даних для таких категорій.

Табл. 2 демонструє, що класична CNN забезпечує високу точність (94–97 %) на наборі даних GTSRB, однак час оброблення одного зображення на CPU доволі великий (120–200 мс), а пам'ять моделі займає до 100 МБ. Оптимізована CNN з квантованою архітектурою зменшує час оброблення до ~70 мс й обсяг пам'яті моделі до 10–20 МБ, а точність залишається високою (92–95 %).

Таблиця 2

**Порівняння продуктивності CNN та гібридних підходів
для розпізнавання дорожніх знаків**

Метод / Підхід	Попереднє оброблення	Класифікатор	Точність на GTSRB	Час обробки 1 зображення (CPU)	Пам'ять моделі
Класична CNN (базова, без препроцесингу)	Немає	CNN	~94–97 %	120–200 мс	20–100 МБ
Прискорена CNN (оптимізована у [8])	Нормалізація	CNN + Quantization	~92–95 %	~70 мс	~10–20 МБ
Запропонований гібридний метод (Haar + HOG + легка CNN)	Haar + HOG	Полегшена CNN	~90–95 %	35 мс	5 МБ

Запропонований гібридний метод, що поєднує класичну детекцію ознак Haar та HOG з полегшеною CNN для класифікації, забезпечив відмінний баланс між швидкістю та точністю: час опрацювання одного зображення зменшився до 35 мс, а обсяг моделі становить лише 5 МБ. Точність залишається на рівні 90–95 %, що дає змогу використовувати метод у системах з обмеженими ресурсами (наприклад, у вбудованих пристроях або мобільних платформах).

У підсумку: гібридна архітектура, яка поєднує Haar, HOG та CNN, демонструє високу точність, стабільність та надійність розпізнавання дорожніх знаків. Система успішно інтегрує швидку первинну фільтрацію за допомогою класичних методів із високою точністю нейронної мережі, забезпечуючи ефективну класифікацію різноманітних дорожніх знаків навіть за часткових перекриттів або змін освітлення. Це робить її потужним інструментом для застосування у сучасних автоматизованих та асистивних транспортних системах.

Висновки

У статті досліджено та реалізовано гібридний підхід до розпізнавання дорожніх знаків, який поєднує класичні методи виділення регіонів інтересу (ROI) – Haar Cascade та HOG – зі згортковою нейронною мережею (CNN), навченою на наборі даних GTSRB для класифікації. Виділення ROI на основі кольорової сегментації, аналізу контурів та характерної геометрії дає змогу зосередити опрацювання на релевантних ділянках зображення, зменшуючи обсяг даних та підвищуючи точність класифікації. Haar Cascade забезпечує швидкий первинний відбір потенційних ділянок за простими ознаками, тоді як HOG уточнює локальні градієнти та форму об'єктів, що дає змогу міні-

мізувати кількість хибних спрацьовувань та підготувати високоякісні ROI для подальшої обробки нейронною мережею.

Згорткова нейронна мережа, навчена на підготовлених ROI із застосуванням аугментації даних з набору GTSRB, демонструє високу здатність узагальнювати ознаки, коректно класифікуючи як поширені, так і рідкісні дорожні знаки. Архітектура CNN із послідовністю згорткових, макспулінгових, дроп-аут та повнозв'язних шарів забезпечує ефективне видобування ознак і запобігає перенавчанню. Аналіз точності показав, що precision, recall та F1-score досягли значень, близьких до 1,00 для більшості класів, а загальна точність моделі на тестовому наборі становила 100 %, що підтверджує високу надійність та узгодженість прогнозів у різноманітних дорожніх умовах.

Отримані результати свідчать про ефективність гібридного підходу: класичні алгоритми забезпечують швидку і точну попередню фільтрацію даних, а CNN, навчена на GTSRB, виконує детальну класифікацію знаків. Така інтеграція дає змогу системі з високою точністю розпізнавати дорожні знаки навіть у складних умовах, із частковим перекриттям об'єктів або зміною освітлення, та ефективно використовувати обмежені обчислювальні ресурси.

Загалом, розроблена система демонструє комплексну реалізацію ефективного підходу до автоматизованого розпізнавання дорожніх знаків. Її можна застосовувати в дослідницьких або практичних проєктах, де важливі точність, надійність та адаптивність до різноманітних дорожніх ситуацій.

Перелік використаних джерел

- [1] J. Stallkamp, M. Schlipsing, J. Salmen and C. Igel, "Man vs. Computer: Benchmarking Machine Learning Algorithms for Traffic Sign Recognition", *Neural Networks*, Vol. 32, pp. 323–332, 2012, <https://doi.org/10.1016/j.neunet.2012.02.016>.
- [2] P. Sermanet and Y. LeCun, "Traffic Sign Recognition with Multi-Scale Convolutional Networks", *International Joint Conference on Neural Networks (IJCNN)*, Barcelona, Spain, 2011, pp. 2809–2813, <https://doi.org/10.1109/IJCNN.2011.6033589>.
- [3] S. Houben, J. Stallkamp, J. Salmen, M. Schlipsing and C. Igel, "Detection of Traffic Signs in Real-World Images: The German Traffic Sign Detection Benchmark", *International Joint Conference on Neural Networks (IJCNN)*, Dallas, TX, USA, 2013, pp. 1–8, <https://doi.org/10.1109/IJCNN.2013.6706807>.
- [4] K. Simonyan, A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition", arXiv preprint. *arXiv:1409.1556*, 2014, <https://arxiv.org/abs/1409.1556>.
- [5] A. Youssef, D. Albani, D. Nardi and D. D. Bloisi, "Fast Traffic Sign Recognition Using Color Segmentation and Deep Convolutional Networks", *Lecture Notes in Computer Science*, Vol. 10016, pp. 221–230, Oct. 2016, https://doi.org/10.1007/978-3-319-48680-2_19.
- [6] X. Qiao, "Research on Traffic Sign Recognition Based on CNN Deep Learning Network", *ScienceDirect*, 2023, <https://www.sciencedirect.com/science/article/pii/S1877050923019336>.
- [7] M. Abadi, A. Agarwal, P. Barham et al., "TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems", arXiv preprint. *arXiv:1603.04467*, 2016, <https://doi.org/10.48550/arXiv.1603.04467>.
- [8] H. B. Fredj, "An Efficient Implementation of Traffic Signs Recognition Using CNN for Unconstrained Environments", *ScienceDirect*, 2023, <https://doi.org/10.1016/j.micpro.2023.104791>.

HYBRID APPROACH TO TRAFFIC SIGN RECOGNITION BASED ON COLOR SEGMENTATION AND CONVOLUTIONAL NEURAL NETWORKS

Received: September 01, 2025 / Revised: September 11, 2025 / Accepted: September 15, 2025

© Leshchuk M.*, Melnyk M., Zabierowski W., 2025

Abstract. This paper presents a hybrid approach to traffic sign recognition that combines classical preprocessing techniques (color segmentation, contour detection, Haar Cascade, and HOG) with a lightweight Convolutional Neural Network (CNN) for classification. The proposed method reduces the amount of processed image data by a factor of 10–20, as only preselected regions of interest are passed to the neural network. The CNN, trained on the GTSRB dataset with data augmentation, achieved 100 % accuracy on the test set, with precision and recall values ranging from 0.97 to 1.00 across individual classes. Compared to direct full-image classification using CNN alone, the hybrid pipeline ensured over 5× faster inference, making it suitable for real-time deployment on embedded platforms such as Raspberry Pi or mobile robotic systems. The practical significance of this work lies in its applicability to low-cost ADAS solutions and autonomous transport platforms. Future research directions include integration with real-time video streams and expansion to a wider range of traffic sign categories.

Keywords: traffic sign recognition, computer vision, image segmentation, convolutional neural network, embedded systems, ADAS.

* Corresponding author



© The Author(s). This is an open access article distributed under the terms of the Creative Commons Attribution Licence 4.0 (<https://creativecommons.org/licenses/by/4.0/>)