

XÂY DỰNG MÔ HÌNH DỰ ĐOÁN NHẬN DIỆN BIỂN BÁO GIAO THÔNG TẠI VIỆT NAM HỖ TRỢ LÁI XE AN TOÀN

Huỳnh Thị Kim Chi, Trần Công Cẩn

Trường Đại học Khánh Hòa

Thông tin chung:

Ngày nhận bài: 25/3/2025

Ngày phản biện: 27/3/2025

Ngày duyệt đăng: 14/5/2025

*Tác giả chính:

huynhthikimchi@ukh.edu.vn

DOI:

<https://doi.org/10.70879/nhxhkMk6K>

6K

Title:

Building a Predictive Model for Traffic Sign Recognition in Vietnam for Safe Driving Assistance.

Từ khóa:

Mạng đối kháng sinh mẫu tích chập đa lớp; Mạng nơ-ron tích chập; Nhận diện biển báo giao thông.

Keywords:

DCGANs; CNN; Traffic sign recognition..

TÓM TẮT: Trước tình trạng giao thông ngày càng đông đúc và ùn tắc thường xuyên trên các tuyến đường ở Việt Nam, việc nhận biết chính xác các biển báo giao thông trở nên vô cùng quan trọng để tăng cường an toàn và giảm thiểu tai nạn. Nghiên cứu này giới thiệu một cách tiếp cận mới, xây dựng một mô hình dự đoán để nhận diện biển báo giao thông tại Việt Nam bằng cách sử dụng các kỹ thuật học máy hiện đại, kết hợp với học sâu, đặc biệt là mạng nơ-ron tích chập (CNN). Mô hình này được thiết kế để phân loại và nhận biết các biển báo một cách hiệu quả. Kết quả thử nghiệm cho thấy mô hình đạt độ chính xác cao, mở ra triển vọng ứng dụng trong các hệ thống hỗ trợ lái xe an toàn, góp phần cải thiện an toàn giao thông. Bài viết cũng đề cập đến những thách thức khi áp dụng mô hình trong điều kiện giao thông thực tế tại Việt Nam và đưa ra các giải pháp để nâng cao hiệu quả nhận diện.

ABSTRACT: With the increasingly crowded and frequent traffic jams on roads in Vietnam, the accurate recognition of traffic signs has become extremely important to enhance safety and reduce accidents. This study introduces a new approach, building a predictive model to recognize traffic signs in Vietnam by using modern machine learning techniques, combined with deep learning, especially convolutional neural networks (CNN). This model is designed to classify and recognize signs effectively. The experimental results show that the model achieves high accuracy, opening up the prospect of application in safe driving assistance systems, contributing to improving traffic safety. The article also mentions the challenges when applying the model in real traffic conditions in Vietnam and proposes solutions to improve recognition efficiency.

1. Giới thiệu vấn đề nghiên cứu

Giao thông tại Việt Nam ngày càng trở nên đông đúc với mật độ phương tiện tăng nhanh và nhiều tình huống giao thông phức tạp đã đặt ra bài toán lớn về an toàn giao thông cho cơ quan quản lý và người tham gia giao thông. Trong bối cảnh đó, việc nhận diện chính xác các biển báo giao thông đóng vai trò then chốt giúp người tham gia giao thông tuân thủ luật lệ và hạn chế nguy cơ xảy ra tai

nạn. Tuy nhiên, môi trường giao thông đa dạng và luôn thay đổi ở Việt Nam là thách thức không nhỏ khi phát triển các hệ thống nhận diện biển báo hiệu quả.

Hiện nay, sự phát triển nhanh chóng của trí tuệ nhân tạo (AI - Artificial Intelligence) đã tạo điều kiện thuận lợi cho việc xây dựng và triển khai các hệ thống thông minh trong lĩnh vực giao thông. Trên cơ sở công nghệ AI, nghiên cứu và đề xuất mô hình dự đoán nhận

diện biển báo giao thông tại Việt Nam hỗ trợ phương tiện tự hành là một hướng đi đầy tiềm năng, góp phần giải quyết bài toán an toàn giao thông đô thị.

Trong nghiên cứu này, chúng tôi phân tích mô hình học sâu CNN và DCGANs, từ đó đề xuất mô hình kết hợp nhằm tận dụng ưu điểm của từng mô hình. Bước tiếp theo, chúng tôi xây dựng tập dữ liệu biển báo giao thông Việt Nam, sử dụng nền tảng Google Colab để huấn luyện mô hình và đánh giá hiệu quả dựa trên độ chính xác. Kết quả nhận được cho thấy mô hình chúng tôi đề xuất có khả năng ứng dụng cao trong thực tiễn, đặc biệt trong các hệ thống hỗ trợ lái xe an toàn và tự động hóa phương tiện giao thông trong tương lai.

2. Cơ sở lý thuyết và phương pháp nghiên cứu

2.1. Nghiên cứu một số mô hình về nhận diện biển báo giao thông đường bộ

Nhận diện biển báo giao thông hỗ trợ lái xe an toàn là lĩnh vực nghiên cứu đang phát triển mạnh mẽ nhờ vào những tiến bộ vượt bậc trong các kỹ thuật học sâu (*deep learning*), thu hút nhiều sự quan tâm trong lĩnh vực thị giác máy tính. Nhiều nghiên cứu gần đây đã đề xuất các phương pháp cải tiến nhằm nâng cao độ chính xác, cải thiện hiệu suất nhận diện biển báo giao thông trong các điều kiện môi trường giao thông đa dạng nhằm tăng độ tin cậy và khả năng ứng dụng cho hệ thống hỗ trợ lái xe. Chúng tôi nghiên cứu một số mô hình và tóm lược các thông tin về mô hình được sử dụng, kỹ thuật phát triển, môi trường đánh giá và độ chính xác:

- Năm 2023: **Kumar et al.** [1] đã áp dụng kỹ thuật tăng cường dữ liệu nhằm xử lý các trường hợp biển báo bị mờ hoặc che khuất, thu được độ chính xác 95,3% trong môi trường đô thị thực tế. **Zhang et al.** [2] phát triển mô hình CNN tích hợp các phương pháp tăng cường ngẫu nhiên, đạt độ chính xác 94,2% trên dữ liệu giao thông đô thị có nhiều yếu tố gây nhiễu. **Lee et al.** [3] sử dụng

YOLOv4 trong bối cảnh ánh sáng yếu và tầm nhìn hạn chế như đường hầm hoặc điều kiện ban đêm và ghi nhận độ chính xác đạt 96,1%. **Park et al.** [4] đã khai thác học chuyển giao kết hợp mạng nơ-ron sâu để cải thiện hiệu suất trên các tập dữ liệu hạn chế, đạt độ chính xác 92,8% với quy mô dưới 2.000 ảnh. **Zhang et al.** [5] tối ưu hóa mô hình nhận diện trong môi trường đô thị phức tạp, bao gồm nhiều yếu tố gây nhiễu như cây cối, biển quảng cáo và đạt độ chính xác 93,5%.

- Năm 2024: **Liu et al.** [6] đề xuất mô hình tích hợp Transformer và YOLOv5, chú trọng vào việc duy trì hiệu năng trong điều kiện ánh sáng thay đổi trên các tuyến đường nông thôn, đạt độ chính xác 95,6%. **Lee et al.** [7] tiếp tục nâng cao hiệu suất mô hình qua việc áp dụng tăng cường hình ảnh trong các tình huống thời tiết bất lợi như mưa, sương mù, nắng gắt, đạt độ chính xác 94,8%. **Jang et al.** [8] khai thác dữ liệu từ đa cảm biến (camera và radar) để tăng khả năng nhận diện trong môi trường giao thông đông đúc, đạt độ chính xác 95,9%. **Li et al.** [9] hướng đến khả năng tổng quát hóa mô hình bằng cách sử dụng tập dữ liệu lớn, bao phủ nhiều khu vực và điều kiện giao thông, đạt độ chính xác 96,0% trên tập dữ liệu hơn 50.000 ảnh.

Những kết quả nêu trên góp phần khẳng định tiềm năng ứng dụng của các mô hình học sâu trong lĩnh vực nhận diện biển báo giao thông, đồng thời làm rõ các yếu tố ảnh hưởng đến hiệu suất nhận diện như điều kiện ánh sáng, môi trường thử nghiệm và giới hạn dữ liệu huấn luyện. Đó là những yếu tố cần được cân nhắc kỹ lưỡng khi phát triển mô hình phù hợp với thực tiễn tại Việt Nam.

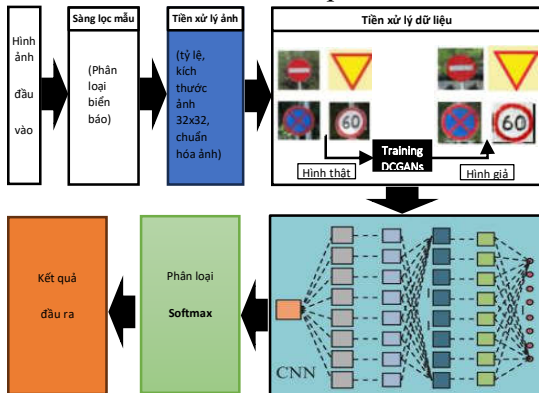
2.2. Đề xuất mô hình

Qua phân tích các nghiên cứu liên quan tại Mục 2.1 cho thấy nhiều phương pháp hiện đại như CNN, YOLOv4/v5, Transformer và học chuyển giao đã đạt được độ chính xác cao trong nhận diện biển báo giao thông. Tuy nhiên, các nghiên cứu đó quan tâm thử

nghiệm trong môi trường đô thị ổn định, điều kiện ánh sáng thuận lợi hoặc dữ liệu được xử lý trước; các tình huống như ánh sáng yếu, biển báo bị che khuất hoặc ảnh hưởng bởi điều kiện thời tiết chưa được quan tâm toàn diện dẫn đến khả năng tổng quát hóa của mô hình trong thực tế còn hạn chế.

Trong bối cảnh của nghiên cứu này, chúng tôi đối mặt với những thách thức từ thực tiễn như tập dữ liệu thu thập được còn hạn chế về số lượng, thiếu đa dạng về điều kiện ánh sáng, thời tiết và môi trường đặc thù của Việt Nam. Tiêu chí lựa chọn mô hình không chỉ dựa trên độ chính xác nhận diện mà cần cân nhắc đến khả năng mở rộng và tăng cường dữ liệu huấn luyện một cách hiệu quả. Từ đó, chúng tôi chọn mô hình Deep Convolutional Generative Adversarial Networks (DCGANs) [10] đưa vào nghiên cứu này vì DCGANs cho phép tạo ra các hình ảnh biển báo giả mô phỏng nhiều điều kiện môi trường khác nhau giúp mở rộng tập dữ liệu huấn luyện mà không phụ thuộc hoàn toàn vào dữ liệu từ môi trường thực tế.

Để tăng độ chính xác nhận diện, chúng tôi đề xuất mô hình kết hợp DCGANs với CNN (Convolutional Neural Networks) [11] được trình bày trong Hình 1. Trong đó, dữ liệu được huấn luyện qua hai giai đoạn tương ứng với 2 mô hình được kết hợp.



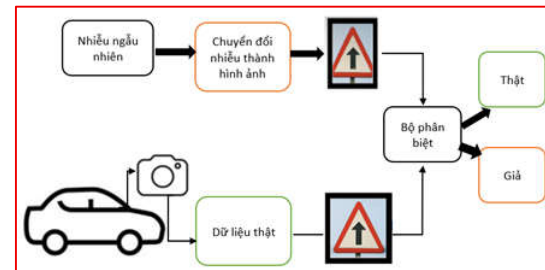
Hình 1. Mô hình kết hợp DCGANs với CNN.

Trong Hình 1, hình ảnh đầu vào sau khi qua bước sàng lọc để phân loại biển báo được

chuyển qua giai đoạn tiền xử lý để chuẩn hóa hình ảnh theo tỷ lệ, độ phân giải và kích thước phù hợp yêu cầu dữ liệu đầu vào của mô hình DCGANs. Sau đó, dữ liệu được chuyển đến giai đoạn huấn luyện 1.

Giai đoạn huấn luyện 1: DCGANs được sử dụng để sinh ảnh biển báo trong các điều kiện ánh sáng đa dạng, đặc biệt là trong môi trường ánh sáng yếu (điều kiện chưa được các mô hình hiện tại giải quyết triệt để). Sau đó, các ảnh này được chuyển sang giai đoạn huấn luyện 2.

Giai đoạn huấn luyện 2: các ảnh được đưa vào mạng nơ-ron tích chập (CNN) để thực hiện nhiệm vụ phân loại và nhận diện. Dữ liệu đầu ra của mô hình CNN sau đó được phân loại Softmax và trả về kết quả.



Hình 2. Mô hình DCGANs.

Mô hình DCGANs được sử dụng gồm bộ Chuyển đổi nhiễu thành hình ảnh (Generator) và Bộ Phân biệt (Discriminator) được mô tả trong Hình 2, trong đó:

- Generator nhận vector nhiễu 100 chiều, sử dụng các lớp transposed convolution với hàm ReLU và lớp cuối Tanh, sinh ảnh RGB $32 \times 32 \times 3$. Hàm mất mát:


$$L_G = -E_{z \sim P_z} [\log D(G(z))]$$

- Discriminator nhận ảnh đầu vào kích thước $32 \times 32 \times 3$, gồm các lớp convolution với LeakyReLU và sigmoid cuối cùng. Hàm mất mát:

$$L_D = -E_{x \sim P_{data}} [\log D(x)] - E_{z \sim P_z} [\log(1 - D(G(z)))]$$

- Quy trình thực hiện: cập nhật Discriminator rồi Generator xen kẽ. Chúng tôi đã lặp lại 20 epoch để huấn luyện dữ liệu.

- Đầu ra là xác suất ảnh thật.
- Cấu hình huấn luyện của DCGANs:
 - Số lượng epoch: 20.
 - Số bước cập nhật mỗi epoch: 2000.
 - Hàm mất mát: Binary Cross-Entropy (cho Discriminator) và Adversarial Loss (cho Generator).
 - Bộ tối ưu: Adam optimizer với tốc độ học 0.0002 và hệ số beta1 = 0.5.
 - Kích thước batch: 64.
 - Môi trường huấn luyện: Google Colab[13].



Hình 3. Mô hình CNN.

Mô hình CNN dùng huấn luyện dữ liệu được mô tả trong Hình 3. Để phân loại chính xác 43 loại biển báo giao thông từ ảnh đầu vào, bao gồm cả ảnh thật và ảnh tổng hợp từ DCGANs, cấu hình huấn luyện của mô hình CNN từ đầu vào đến đầu ra như sau:

- Lớp đầu vào: nhận ảnh RGB với kích thước chuẩn hóa là $32 \times 32 \times 1$.
- Các lớp tích chập (Convolutional layers): Mô hình có 4 lớp tích chập. Hai lớp đầu dùng 60 bộ lọc 5×5 , hai lớp sau dùng 30 bộ lọc 3×3 , tất cả đều dùng hàm kích hoạt ReLU. Mỗi lớp đều được áp dụng *Batch Normalization* nhằm ổn định quá trình huấn luyện và sử dụng hàm kích hoạt *ReLU*.
- Hai lớp gộp cực đại (MaxPooling2D) 2×2 được chèn sau lớp tích chập thứ hai và thứ tư nhằm giảm kích thước dữ liệu đầu ra trước khi chuyển sang lớp tiếp theo.
- Các lớp kết nối đầy đủ (Fully Connected layers) tổng hợp đặc trưng và thực hiện phân loại.
- Lớp đầu ra (Softmax) gồm 43 nút tương ứng với 43 lớp nhãn.
- Huấn luyện dữ bằng backpropagation với hàm mất mát categorical cross-entropy:

$$L = - \sum_{i=1}^{43} y_i \log(\hat{y}_i)$$

- Dùng bộ tối ưu Adam (lr=0.001), áp dụng dropout, data augmentation và early stopping để tránh overfitting.

Các kết quả thực nghiệm cần tính trung bình lỗi và trung bình độ chính xác. Chúng tôi sử dụng các công thức sau để tính chúng:

- Công thức tính trung bình: cho một tập hợp n giá trị $\{x_1, x_2, \dots, x_n\}$, giá trị trung bình được tính theo công thức:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

Trong đó:

- \bar{x} : là giá trị trung bình.
- n : là tổng số phần tử trong tập dữ liệu.
- x_i : là giá trị của phần tử thứ i .
- $\sum_{i=1}^n x_i$ là tổng tất cả các giá trị.
- Công thức tính trung bình độ chính xác (Accuracy):

$$\bar{A} = \frac{1}{n} \sum_{i=1}^n A_i$$

với A_i là độ chính xác trong epoch thứ i .

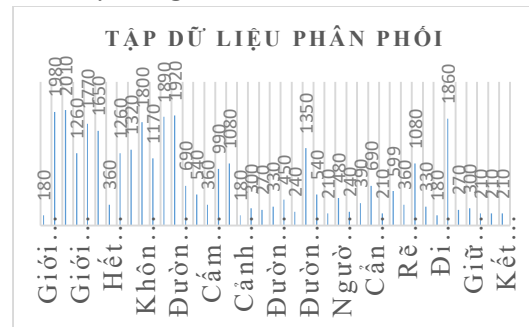
- Công thức tính trung bình độ lỗi (Loss):

$$\bar{L} = \frac{1}{n} \sum_{i=1}^n L_i$$

với L_i là giá trị lỗi trong epoch thứ i .

3. Kết quả nghiên cứu và thảo luận

3.1. Xây dựng dữ liệu



Hình 4. Số lượng dữ liệu phân phối.

Để xây dựng mô hình phân loại biển báo giao thông, việc phân loại chính xác các loại biển báo trong mọi điều kiện ánh sáng, môi

trường là điều kiện tiên quyết. Vào ban đêm, việc nhận diện biển báo gặp khó khăn do ánh sáng yếu và các hiệu ứng phản chiếu từ nguồn sáng có thể làm giảm độ chính xác của hệ thống nhận diện.

Chúng tôi sử dụng bộ dữ liệu Traffic Signs Preprocessed của Kaggle [12] áp dụng hệ thống phân loại được mô tả trong Biểu đồ 1 với 43 loại biển báo giao thông (Bảng 1: ví dụ một số biển báo giao thông). Các loại biển báo này bao gồm các nhóm như cảnh báo nguy hiểm, chỉ dẫn, hạn chế, hiệu lệnh, và các biển báo liên quan đến dịch vụ, khu vực đặc biệt. Dữ liệu hình ảnh này hỗ trợ hệ thống hoạt động hiệu quả trong môi trường giao thông thực tế, phục vụ các ứng dụng lái xe an toàn và giải pháp giao thông thông minh.

Bảng 1. Ví dụ một số biển báo giao thông

Mã biển báo	Tên biển báo	Hình ảnh minh họa
15	Dừng lại	
16	Cấm phương tiện	
18	Cấm đi ngược chiều	
19	Cảnh báo nguy hiểm	
33	Hết mọi lệnh cấm	

3.2. Huấn luyện dữ liệu

Trong nghiên cứu này, chúng tôi áp dụng mô hình DCGANs để tạo ra một bộ dữ liệu giả kết hợp CNN để phân loại nhận dạng dữ liệu. Sau đó, chúng tôi tiến hành đánh giá hiệu suất của hệ thống phân loại biển báo giao thông mà mình đã xây dựng. Kết quả từ các đánh giá này đã xác nhận tính khả thi của hệ thống được đề xuất.

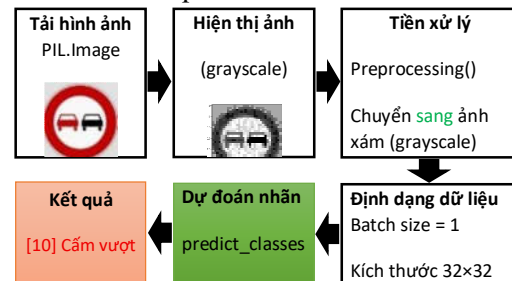
Trong quá trình thử nghiệm, mô hình DCGANs được triển khai để xử lý 43 loại

biển báo giao thông đường bộ từ bộ dữ liệu Traffic Signs Preprocessed của Kaggle, với tổng cộng 34799 hình ảnh.

3.3. Kiểm tra nhận diện biển báo

Các bước thực hiện một pha kiểm tra nhận diện biển báo trình bày trên Hình 4, bao gồm:

1. Tải hình ảnh.
2. Hiển thị hình ảnh ban đầu dưới dạng thang xám (grayscale). Chuyển hình ảnh thành mảng NumPy - Resize ảnh về kích thước 32×32 pixel.
3. Tiền xử lý preprocessing() + Chuyển sang ảnh xám (grayscale) + Chuẩn hóa dữ liệu.
4. Chuyển ảnh thành tensor 4 chiều: (1, 32, 32, 1), Batch size = 1, Kích thước ảnh 32×32, 1 (grayscale).
5. Dự đoán nhãn lớp.
6. Xuất kết quả.



Hình 5. Một pha kiểm tra nhận dạng.

3.4. Đánh giá kết quả nhận diện

Một số kết quả từ thí nghiệm thực tế được trình bày trong Bảng 2. Qua quá trình kiểm tra và phân tích, chúng tôi đã xác nhận mô hình có khả năng nhận diện biển báo giao thông đường bộ trong điều kiện ánh sáng khác nhau. Điều này chứng tỏ tính hiệu quả của mô hình trong việc xử lý hình ảnh biển báo giao thông trong các điều kiện ánh sáng khác nhau, giúp nâng cao độ tin cậy của hệ thống nhận diện biển báo trong môi trường thực tế.


Bảng 2. Hình ảnh kết quả nhận dạng và dự đoán biển báo giao thông đường bộ

Hình gốc	Hình xám	Mã và tên dự đoán biển báo đường bộ
----------	----------	-------------------------------------

		[10] Cấm vượt
		[35] rẽ trái phía trước
		[14] Giao với đường ưu tiên
		[18] Cấm đi ngược chiều
		[41] Chạy theo vòng xuyên
		[15] Dừng lại

Mô hình dự đoán nhận diện biển báo giao thông tại Việt Nam sử dụng DCGANs kết hợp CNN trên bộ dữ liệu Traffic Signs Preprocessed (43 loại, 34.799 ảnh), được huấn luyện trên nền tảng Google Colab, đạt độ chính xác trung bình 97% và độ lỗi 0,114%. Kết quả này tương đương hoặc vượt trội so với các nghiên cứu gần đây như **Kumar et al.** [1] có độ chính xác 95,3% sử dụng tăng cường dữ liệu, **Zhang et al.** [2] có độ chính xác 94,2% trên CNN tích hợp, và **Lee et al.** [3] có độ chính xác 96,1% với YOLOv4 trong điều kiện ánh sáng yếu. Ngoài ra, mô hình còn cạnh tranh với **Liu et al.** [6] có độ chính xác 95,6% sử dụng Transformer kết hợp YOLOv5 và **Li et al.** [9] có độ chính xác 96,0% trên tập dữ liệu lớn hơn. Kết quả chứng minh hiệu quả của mô hình trong việc nhận diện đa dạng biển báo giao thông, đồng thời phù hợp với điều kiện thực tiễn tại Việt Nam.

Độ chính xác trung bình đạt 97% đã chứng minh mô hình đề xuất của chúng tôi có hiệu suất nhận diện biển báo giao thông rất tốt. Kết quả này cho thấy khả năng tổng quát hóa của mô hình trên dữ liệu kiểm thử giúp đảm bảo tính chính xác trong các tình huống thực tế. Tuy nhiên, để nâng cao hiệu suất hơn nữa, cần tối ưu hóa mô hình nhằm giảm thiểu sai số và cải thiện độ chính xác trong những điều kiện môi trường phức tạp hơn.



Hình 6. Kết quả trung bình lỗi và trung bình độ chính xác.

4. Kết luận

Nghiên cứu này đã phát triển và triển khai một mô hình nhận diện biển báo giao thông dựa trên sự kết hợp của DCGANs và CNN, cho phép phân loại chính xác các loại biển báo giao thông trong nhiều điều kiện môi trường khác nhau. Kết quả thực nghiệm cho thấy mô hình đạt độ chính xác trung bình 97%, khẳng định hiệu quả trong việc nhận diện biển báo giao thông trong điều kiện ánh sáng khác nhau. Tuy nhiên, với trung bình lỗi ghi nhận ở mức 0.114 %, cần tăng dữ liệu huấn luyện để cải thiện hiệu suất của mô hình. Những kết quả này nhấn mạnh tiềm năng của phương pháp đề xuất trong việc tăng cường độ tin cậy cho các hệ thống nhận diện biển báo giao thông, từ đó hỗ trợ hiệu quả các ứng dụng thực tiễn như hệ thống lái xe an toàn và các giải pháp cảnh báo an toàn giao thông.

Trong các nghiên cứu tiếp theo, việc tối ưu hóa thuật toán, mở rộng quy mô và tính đa dạng của tập dữ liệu huấn luyện, cùng với nâng cao khả năng xử lý hình ảnh trong các điều kiện thời tiết xấu, sẽ là những hướng đi quan trọng để cải thiện độ chính xác và tính thực tiễn của mô hình. Ngoài ra, định hướng phát triển tương lai bao gồm việc bổ sung một tập dữ liệu mở rộng và xây dựng một mô hình tính toán khoảng cách giữa các phương tiện

nhằm đảm bảo khả năng vận hành an toàn trong môi trường thực tế.

Tài liệu tham khảo

1. Kumar, R., Sharma, A., & Singh, P. (2023). Data augmentation techniques for traffic sign recognition under occlusion. *Neural Computing and Applications*, 36(1), 81–89.
<https://doi.org/10.1007/s00542-023-07442-6>
2. Zhang, X., Li, S., & Liu, Y. (2023). Traffic sign recognition using CNN and data augmentation. *International Journal of Computer Vision*, 121(6), 1124–1135.
<https://doi.org/10.1007/s11263-023-01491-7>
3. Lee, J., Kim, H., & Choi, M. (2023). YOLOv4 for real-time traffic sign detection under various lighting conditions. *IEEE Transactions on Intelligent Transportation Systems*, 24(4), 1623–1631.
<https://doi.org/10.1109/TITS.2023.3056103>
4. Park, H., Kim, S., & Lee, J. (2023). Transfer learning for traffic sign recognition in challenging environments. *IEEE Transactions on Neural Networks and Learning Systems*, 35(7), 2550–2559.
<https://doi.org/10.1109/TNNLS.2023.3141805>
5. Zhang, Y., Liu, B., & Wang, X. (2023). Optimizing traffic sign recognition for urban autonomous vehicles. *Computer Vision Applications*, 45(6), 1101–1112.
<https://doi.org/10.1007/s00422-023-01478-y>
6. Liu, Y., Wang, L., & Zhang, T. (2024). Transformer and YOLOv5 based traffic sign recognition. *Computer Vision Applications*, 32(3), 345–356.
<https://doi.org/10.1007/s00422-024-01371-x>
7. Lee, S., Cho, H., & Yoon, H. (2024). Enhanced traffic sign detection using deep learning and image augmentation. *IEEE Transactions on Circuits and Systems for Video Technology*, 34(1), 132–140.
<https://doi.org/10.1109/TCSVT.2024.3154329>
8. Jang, J., Park, K., & Lee, D. (2024). Multi-sensor fusion for traffic sign recognition in autonomous vehicles. *IEEE Access*, 12, 3254–3262.
<https://doi.org/10.1109/ACCESS.2024.3045678>
9. Li, X., Chen, Y., & Zhang, Q. (2024). Large-scale traffic sign recognition using deep neural networks. *International Journal of Advanced Computer Science and Applications*, 11(2), 89–98.
<https://doi.org/10.14569/IJACSA.2024.0120243>
10. Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.
<https://arxiv.org/abs/1511.06434>
11. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
<https://doi.org/10.1038/nature14539>
12. Sichkar, V. (2019). Traffic Signs Preprocessed. Kaggle Dataset.
<https://www.kaggle.com/datasets/valentynsichkar/traffic-signs-preprocessed>
13. Google. (n.d.). Google Colaboratory. Google.
<https://colab.research.google.com>