Tạp chí Khoa học Công nghệ Xây dựng, ĐHXDHN, 2026, 20 (5V): 90–103

ĐỀ XUẤT PHƯƠNG PHÁP HỌC MÁY CẢI THIỆN ĐỘ CHÍNH XÁC ĐẾM LƯU LƯỢNG XE TẠI NÚT GIAO THÔNG

Vũ Minh Tâm[a,*], Phạm Ngọc Việt[a], Nguyễn Minh Quân[a], Trần Văn Hiếu[b], Thái Hồng Nam[a]

[a]*Khoa Cầu Đường, Trường Đại học Xây dựng Hà Nội, số 55 đường Giải Phóng, phường Bạch Mai, Hà Nội, Việt Nam*
[b]*Công ty cổ phần Lapinta, Tòa nhà The Rox Center, 136 Hồ Tùng Mậu, phường Phú Diễn, Hà Nội*

Nhận ngày 25/5/2026, Sửa xong 04/8/2026, Chấp nhận đăng 04/9/2026

Tóm tắt

Lưu lượng xe tại các nút giao là số liệu đầu vào quan trọng cho thiết kế và vận hành nút giao thông, đặc biệt trong đô thị. Tuy nhiên, trong điều kiện giao thông hỗn hợp có xe máy chiếm ưu thế tại Việt Nam, việc nhận diện và đếm xe từ video bằng mô hình AI có tỷ lệ chính xác cao, nhưng vẫn không đạt được tuyệt đối do phương tiện bị che khuất và di chuyển không theo làn. Bài báo này đề xuất một cách tiếp cận mới để cải thiện hơn nữa sự chính xác của việc đếm xe bằng mô hình AI hiện tại ở Việt Nam bằng việc sử dụng các thuật toán học máy. Nghiên cứu tình huống được thực hiện tại một nút giao ngã tư điển hình nút Tố Hữu - Vạn Phúc, Hà Nội. Kết quả cho thấy phương án đề xuất giúp cải thiện rõ rệt các sai số so với phương pháp đối chứng. Từ đó, khẳng định tính khả thi của hướng tiếp cận kết hợp AI và học máy trong nâng cao độ chính xác của hệ thống đếm xe tự động tại nút giao thông.

Từ khoá: đếm lưu lượng xe; giao thông hỗn hợp; AI; YOLO; học máy.

A MACHINE LEARNING APPROACH TO IMPROVING THE ACCURACY OF TRAFFIC VOLUME COUNTING AT INTERSECTIONS

Abstract

Traffic volume at intersections is an important input for the design and operation of intersections, especially in urban areas. However, under motorcycle-dominated mixed traffic conditions in Vietnam, vehicle detection and counting from video using AI models can achieve high accuracy but still cannot be completely accurate due to vehicle occlusion and non-lane-based movements. This paper proposes a new approach to further improve the accuracy of vehicle counting by existing AI models in Vietnam through the use of machine learning algorithms. A case study is conducted at a typical four-leg intersection, the To Huu - Van Phuc intersection in Hanoi. The results show that the proposed approach significantly reduces counting errors compared with the baseline method. These findings confirm the feasibility of combining AI and machine learning to improve the accuracy of automatic vehicle counting systems at intersections.

Keywords: traffic volume counting; mixed traffic; AI; YOLO; machine learning.

https://doi.org/10.31814/stce.huce2026-20(5V)-07 © 2026 Trường Đại học Xây dựng Hà Nội (ĐHXDHN)

1. Giới thiệu

Việc thu thập chính xác dữ liệu lưu lượng giao thông tại các nút giao đóng vai trò rất quan trọng đối với phân tích giao thông, đánh giá và vận hành nút giao thông sử dụng đèn tín hiệu. Đặc biệt, tại các đô thị lớn tại Việt Nam, nơi giao thông hỗn hợp chiếm ưu thế với tỷ lệ xe máy rất lớn, lưu lượng phương tiện biến động mạnh theo thời gian và theo hướng, dẫn đến yêu cầu cao hơn đối với các phương pháp đo đếm và xử lý dữ liệu giao thông [1]. Ngoài ra, đếm lưu lượng theo từng loại phương tiện còn là đầu vào trực tiếp cho các bài toán tối ưu chu kỳ đèn và xây dựng các giải pháp giao thông thông minh tại nút giao. Trong những năm gần đây, cùng với sự phát triển của trí tuệ nhân tạo và thị giác máy tính, nhiều nghiên cứu đã sử dụng các mô hình phát hiện đối tượng để nhận diện, phân loại và đếm phương tiện từ video giao thông. Các mô hình như YOLO được sử dụng phổ biến nhờ khả năng phát hiện nhanh, tương đối chính xác và thuận lợi cho triển khai trong thời gian thực [2, 3]. Tuy

*Tác giả đại diện. *Địa chỉ e-mail:* tamvm@huce.edu.vn (Tâm, V. M.)

nhiên, độ chính xác của các mô hình này thường phụ thuộc mạnh vào điều kiện dữ liệu đầu vào, chất lượng camera, góc quan sát, hiện tượng che khuất và đặc điểm tổ chức giao thông tại khu vực nghiên cứu. Vì vậy, sai số nhận diện và sai số đếm vẫn là vấn đề đáng quan tâm [4, 5]. Ví dụ, tại các nút giao đông đúc, xe máy thường len lỏi, dừng chờ thành cụm và thay đổi vị trí liên tục, làm cho việc phát hiện và theo vết đối tượng trở nên phức tạp hơn so với điều kiện giao thông thuần ô tô [5]. Vì vậy, mặc dù các mô hình AI hiện đại có thể cho kết quả chính nhưng nếu chỉ dựa vào mô hình AI hiện có vẫn chưa đủ để bảo đảm độ chính xác cao trong mọi điều kiện giao thông đô thị.

Từ đó, nghiên cứu này đề xuất một phương pháp kết hợp gồm hai phần. Ở phần thứ nhất, mô hình AI nền trong nghiên cứu [4] được sử dụng để phát hiện, phân loại và đếm 5 loại phương tiện phổ biến tại nút giao, gồm xe máy, xe đạp, xe con, xe tải và xe buýt. Kết quả đếm ban đầu của mô hình này được ký hiệu thống nhất là AI_baseline và được sử dụng làm phương án đối chứng trong toàn bài. Ở phần thứ hai, các thuật toán học máy được sử dụng để học quy luật sai số của AI_baseline, từ đó hiệu chỉnh lại lưu lượng ước lượng sao cho gần hơn với giá trị thực đo. Bài báo hướng tới hai mục tiêu chính: thứ nhất, đánh giá mức độ sai số của AI_baseline trong điều kiện giao thông hỗn hợp tại nút giao đô thị; thứ hai, đề xuất và kiểm chứng một lớp học máy hậu xử lý nhằm nâng cao độ chính xác của AI_baseline theo từng loại phương tiện.

Trong thời gian gần đây, nhận diện và đếm phương tiện từ video giao thông là một hướng nghiên cứu được quan tâm mạnh mẽ nhờ sự phát triển của trí tuệ nhân tạo và thị giác máy tính. Nhiều mô hình phát hiện đối tượng, đặc biệt là họ YOLO, đã được áp dụng cho bài toán này nhờ tốc độ xử lý nhanh, khả năng phát hiện tương đối chính xác và tính phù hợp với các ứng dụng thời gian thực [2, 3]. Các nghiên cứu này cho thấy việc khai thác video để tự động thu thập dữ liệu giao thông có tiềm năng lớn trong thay thế hoặc hỗ trợ các phương pháp đếm thủ công truyền thống. Tuy nhiên, kết quả của các mô hình phát hiện và đếm phương tiện vẫn chịu ảnh hưởng rõ rệt bởi chất lượng video, góc đặt camera, ánh sáng, mật độ phương tiện và hiện tượng che khuất [6]. Trong môi trường giao thông thực tế, sai số có thể phát sinh ở nhiều khâu khác nhau như phát hiện thiếu, phát hiện nhầm, mất vết đối tượng hoặc đếm lặp [4, 5]. Ngoài ra, trong điều kiện dòng xe hỗn hợp nhiều xe máy, các phương tiện có kích thước rất khác nhau nhưng cùng chia sẻ không gian lưu thông, dẫn đến sự đan xen liên tục, mức độ che khuất cao và hành vi dừng chờ phức tạp [5]. Đối với Việt Nam, nghiên cứu của Vu và cs. [1] về đếm lưu lượng giao thông hỗn hợp tại các nút giao có tỷ lệ xe máy lớn cho thấy rằng, mặc dù các mô hình thị giác máy tính hiện đại có thể đạt kết quả tốt, bài toán đếm chính xác trong điều kiện thực tế vẫn còn nhiều thách thức và cần các bước xử lý bổ sung để tăng độ tin cậy. Kết quả này có ý nghĩa quan trọng đối với nghiên cứu hiện tại, vì với việc chỉ sử dụng một mô hình AI hiện có chưa chắc đã đủ để tạo ra dữ liệu có độ chính xác gần tuyệt đối trong mọi trạng thái giao thông.

Bên cạnh hướng nghiên cứu tập trung vào phát hiện và đếm trực tiếp từ video, nhiều công trình khác đã khai thác các thuật toán học máy để phân tích, dự báo và hiệu chỉnh dữ liệu giao thông theo chuỗi thời gian ngắn. Các mô hình như Linear Regression, Random Forest, Support Vector Regression, XGBoost hay mạng nơ-ron đã được áp dụng cho các bài toán dự báo lưu lượng theo các khoảng thời gian rời rạc và cho thấy khả năng học được quy luật biến động của dòng xe theo thời gian [7, 8]. So với các mô hình phát hiện đối tượng, các thuật toán học máy loại này không làm việc trực tiếp trên ảnh hoặc video mà hoạt động trên chuỗi dữ liệu đã được trích xuất, do đó phù hợp để sử dụng như một lớp hậu xử lý nhằm hiệu chỉnh kết quả đếm ban đầu. Qua tổng quan các nghiên cứu đã công bố có thể thấy rằng phần lớn các công trình hiện nay đi theo một trong hai hướng chính. Hướng thứ nhất tập trung cải thiện chất lượng phát hiện, theo vết và đếm phương tiện trực tiếp từ video thông qua thay đổi kiến trúc mô hình, tăng cường dữ liệu huấn luyện hoặc điều chỉnh quy trình xử lý ảnh [4]. Hướng thứ hai tập trung dự báo lưu lượng giao thông ngắn hạn bằng các mô hình học máy và học sâu

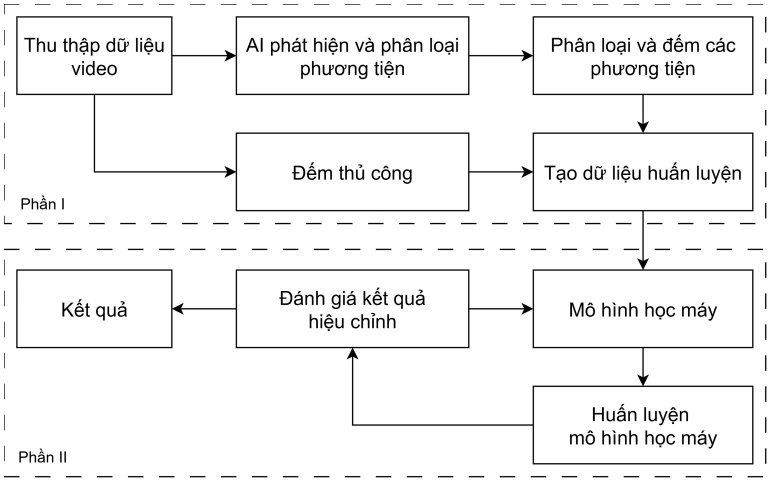
trên chuỗi số liệu theo thời gian [7]. Rất ít nghiên cứu khai thác các mô hình học máy như một lớp hậu xử lý để hiệu chỉnh sai số có tính hệ thống của kết quả đếm từ mô hình AI. Vì vậy, điểm mới của bài báo không nằm ở việc phát triển một mô hình nhận diện phương tiện mới, mà ở việc đề xuất và kiểm chứng lớp học máy hậu xử lý, được lựa chọn theo từng tổ hợp hướng - loại xe, nhằm cải thiện độ chính xác đếm trong điều kiện giao thông hỗn hợp nhiều xe máy.

2. Phương pháp nghiên cứu

2.1. Phương pháp tổng quát

Nghiên cứu đề xuất một quy trình xử lý gồm nhiều bước, bắt đầu từ dữ liệu video giao thông tại nút giao và kết thúc bằng bộ kết quả đếm lưu lượng đã được cải thiện bằng phương pháp học máy. Phương pháp được xây dựng theo cấu trúc hai phần chính. Phần thứ nhất thực hiện phát hiện, phân loại và đếm phương tiện từ video bằng mô hình AI [4]. Phần thứ hai khai thác chuỗi kết quả đếm ban đầu này, kết hợp với dữ liệu tham chiếu thực đo, để huấn luyện các mô hình học máy nhằm học quy luật sai số và hiệu chỉnh lại kết quả đếm.

Toàn bộ quy trình nghiên cứu được trình bày dưới dạng sơ đồ tuần tự xử lý như ở Hình 1, gồm hai phần liên tiếp. Phần 1 bao gồm thu thập dữ liệu video, AI phát hiện và phân loại phương tiện, phân loại và đếm các phương tiện, đếm thủ công, và tạo dữ liệu huấn luyện [4]. Phần 2 bao gồm xây dựng mô hình học máy, huấn luyện mô hình học máy, đánh giá kết quả hiệu chỉnh và cuối cùng là chọn lọc kết quả tốt nhất. Cấu trúc này cho phép tách biệt rõ hai lớp xử lý: lớp thị giác máy tính để tạo ra số đếm ban đầu, và lớp học máy để hiệu chỉnh sai số của số đếm đó. Cách tổ chức này phù hợp với định hướng trong các nghiên cứu về đếm hỗn hợp tại nút giao và dự báo lưu lượng ngắn hạn. Phương pháp này không thay thế hoàn toàn hệ thống đếm bằng AI, mà coi AI là tầng xử lý đầu tiên để tạo ra số đếm thô theo từng loại phương tiện. Sau đó, tầng học máy đóng vai trò như một mô-đun hiệu chỉnh hậu xử lý, giúp giảm sai số giữa giá trị đếm của AI và giá trị thực đo. Nhờ cách tiếp cận này, nghiên cứu vừa khai thác được ưu điểm của mô hình AI trong nhận diện đối tượng từ video, vừa tận dụng được khả năng học quy luật biến động dữ liệu của học máy để cải thiện độ chính xác cuối cùng.



Hình 1. Sơ đồ tuần tự xử lý của phương pháp nghiên cứu

2.2. Thu thập dữ liệu video

Dữ liệu video được thu thập tại một nút giao ngã tư có lưu lượng lớn và thành phần phương tiện hỗn hợp. Dữ liệu đầu vào là các đoạn video giao thông được ghi nhận từ camera quan sát có khả năng bao quát rõ hướng phương tiện đi vào và đi ra khỏi nút giao. Phạm vi phân tích tập trung vào các

hướng xe đi vào nút giao, nơi có thể quan sát được quá trình phương tiện tiến tới, dừng chờ và đi qua khu vực giao cắt. Để phản ánh sự khác biệt về trạng thái giao thông, dữ liệu được lựa chọn trong hai khung giờ đại diện, gồm một giờ bình thường và một giờ cao điểm. Từ các video ban đầu, quá trình chuẩn bị dữ liệu bao gồm cắt đoạn thời gian cần phân tích, đồng bộ mốc thời gian, kiểm tra chất lượng hình ảnh và xác định vùng quan tâm đường đếm. Việc chuẩn hóa phạm vi quan sát là cần thiết để bảo đảm rằng AI_baseline và kết quả đếm thủ công được thực hiện trên cùng một không gian và cùng một nguyên tắc đếm. Cách tổ chức dữ liệu dạng chuỗi thời gian ngắn như vậy cũng phù hợp với các nghiên cứu về dự báo lưu lượng theo chu kỳ và theo khoảng thời gian rời rạc.

2.3. AI phát hiện và phân loại phương tiện

Sau khi dữ liệu video được chuẩn hóa, bước tiếp theo là sử dụng mô hình AI để phát hiện và phân loại phương tiện trên từng khung hình. Trong nghiên cứu này, bước phát hiện - phân loại kế thừa từ khung nghiên cứu do Vũ và cs. đề xuất cho bài toán đếm giao thông hỗn hợp tại các nút giao có tỷ lệ xe máy lớn [4]. Khung này được xây dựng theo chuỗi nhận diện – theo dõi – đếm, trong đó mô hình nhận diện phương tiện, mô hình theo dõi giúp duy trì danh tính đối tượng qua nhiều khung hình, và mô hình đếm xác định phương tiện đã đi qua vùng đếm theo từng hướng chuyển động. Kết quả đầu ra của bước này là tập hợp các đối tượng phương tiện đã được gán nhãn lớp, vị trí không gian và thời điểm xuất hiện trong video. Đây là dữ liệu đầu vào trực tiếp cho bước đếm phương tiện theo từng hướng giao thông và theo từng khoảng thời gian 5 phút.

2.4. Phân loại và đếm các phương tiện

Trên cơ sở kết quả phát hiện - phân loại ở bước trước, nghiên cứu tiếp tục thực hiện bước đếm các phương tiện theo loại và hướng tiếp cận của nút giao. Bước này bám theo phương pháp đếm của Vu và cs., tức là không chỉ dựa vào phát hiện đối tượng đơn lẻ trên từng khung hình, mà dựa vào chuỗi chuyển động của phương tiện trong không gian quan sát để xác định thời điểm phương tiện thực sự đi qua vùng đếm [4]. Trong nghiên cứu này, mặc dù hệ thống AI phát hiện ở mức 15 lớp chi tiết, kết quả cuối cùng được gộp lại thành 5 lớp chính để phù hợp với mục tiêu phân tích và với dữ liệu đếm thủ công. Cụ thể, các lớp chi tiết tương ứng với xe máy được gộp thành nhóm xe máy; lớp xe đạp được giữ thành nhóm xe đạp; các lớp ô tô con được gộp thành nhóm xe con; các lớp xe tải, xe tải trung bình, xe tải nặng hoặc container được gộp thành nhóm tải; và các lớp xe buýt, minibus hoặc xe khách cỡ lớn được gộp thành nhóm buýt. Việc gộp lớp theo cách này giúp vừa giữ được ưu điểm của mô hình phát hiện đa lớp ở đầu vào, vừa bảo đảm tính nhất quán với mục tiêu nghiên cứu là đánh giá sai số trên 5 loại phương tiện chính.

2.5. Kết hợp với đếm thủ công để tạo dữ liệu huấn luyện

Song song với nhánh AI, cùng trên các đoạn video đã chọn, nghiên cứu tiến hành đếm thủ công để tạo dữ liệu tham chiếu. Việc đếm thủ công được thực hiện trên cùng vùng quan sát, cùng hướng đếm và cùng đơn vị thời gian 5 phút như bước đếm AI, nhằm bảo đảm rằng hai nguồn dữ liệu có thể đối sánh trực tiếp với nhau.

2.6. Mô hình học máy sử dụng để hiệu chỉnh sai số

Sau khi tạo bộ dữ liệu huấn luyện, nghiên cứu tiến hành thử nghiệm nhiều mô hình học máy khác nhau để xác định mô hình phù hợp nhất cho từng tổ hợp hướng - loại xe. Các mô hình được lựa chọn gồm LinearRegression [9], MLPRegressor [10], RandomForest [11], DecisionTree [12], GradientBoosting [13], SVR [14]; ngoài ra AI_baseline [4] được giữ lại như một phương án đối chứng, chứ không phải là một mô hình học máy hậu xử lý.

Mô hình tuyến tính, LinearRegression được sử dụng như mô hình hồi quy cơ sở có khả năng diễn giải tốt, phù hợp để kiểm tra xem sai số của AI có tuân theo quan hệ gần tuyến tính với dữ liệu đầu vào hay không. Trong các nghiên cứu giao thông, hồi quy tuyến tính hoặc đa biến vẫn thường được dùng như một chuẩn đối sánh hoặc như một thành phần trong các mô hình lai, chẳng hạn mô hình MLR-LSTM cho dự báo lưu lượng nhiều nút giao [9]. Tiếp theo là các mô hình cây quyết định. Thứ nhất DecisionTree là mô hình phân hoạch dữ liệu theo các điều kiện rẽ nhánh, có ưu điểm là dễ diễn giải và có khả năng nắm bắt các quan hệ phi tuyến cơ bản. Bài toán dự báo giao thông tại nút giao cũng đã được nghiên cứu bằng các mô hình cây quyết định và cây tổ hợp, cho thấy nhóm mô hình này phù hợp với dữ liệu có nhiều yếu tố ngữ cảnh và quan hệ phi tuyến. Về nền tảng phương pháp, cây quyết định được xây dựng trên cơ sở kinh điển của Quinlan [15]. Thứ hai RandomForest là mô hình tổ hợp nhiều cây quyết định, trong đó mỗi cây được huấn luyện trên một tập con dữ liệu và tập con đặc trưng ngẫu nhiên. Breiman cho thấy random forest có khả năng giảm phương sai và tăng độ ổn định của dự báo nhờ cơ chế tổ hợp nhiều cây; trong nghiên cứu giao thông gần đây, Random Forest cũng thường được dùng như một baseline mạnh cho bài toán dự báo số xe hoặc lưu lượng ngắn hạn [16]. Cuối cùng GradientBoosting là mô hình tăng cường dần các bộ học yếu theo hướng tối thiểu hóa sai số còn lại của mô hình trước đó. Phương pháp gradient boosting của Friedman là nền tảng quan trọng cho nhiều thuật toán boosting hiện đại; trong bài toán giao thông tại nút giao, các mô hình cây tăng cường như GBRT/GBM cũng đã được sử dụng để nâng cao độ chính xác dự báo [17]. Về nhóm mô hình học máy nâng cao hơn thì có SVR là dạng hồi quy của support vector machine, phù hợp với các bài toán có quan hệ phi tuyến và số mẫu không quá lớn. Nền tảng của mô hình này xuất phát từ công trình support-vector networks của Cortes và Vapnik; trong lĩnh vực dự báo lưu lượng, SVR đã được dùng cho bài toán dự báo giao thông ngắn hạn và cho thấy khả năng xử lý tốt khi dữ liệu có cấu trúc phi tuyến [18]. Mô hình tiếp sau là MLPRegressor, đại diện cho nhóm mạng nơ-ron truyền thẳng nhiều lớp, phù hợp để học các quan hệ phi tuyến phức tạp giữa đầu vào và đầu ra. Nền tảng của cách học lan truyền ngược được đặt bởi Rumelhart, Hinton và Williams; trong giao thông, các kiến trúc neural network, kể cả MLP và các biến thể sâu hơn, đã được sử dụng rộng rãi trong các bài toán dự báo lưu lượng và trạng thái giao thông [19].

2.7. Huấn luyện mô hình, đánh giá hiệu quả hiệu chỉnh và chọn lọc kết quả

Sau khi xác định được các mô hình cần thử nghiệm, bước tiếp theo là huấn luyện mô hình học máy trên bộ dữ liệu đã tạo. Với mỗi tổ hợp hướng và loại phương tiện, dữ liệu được chia thành tập huấn luyện và tập kiểm tra theo trình tự thời gian. Trong quá trình huấn luyện, nghiên cứu tiến hành điều chỉnh siêu tham số của từng mô hình trong phạm vi phù hợp với đặc trưng dữ liệu. DecisionTree, RandomForest và GradientBoosting, các tham số như độ sâu cây, số lượng, số mẫu tối thiểu để tách nút, số mẫu tối thiểu ở lá và learning rate được thử nghiệm; với SVR, các tham số như kernel được điều chỉnh; với MLPRegressor, các tham số như số lớp ẩn, số neuron mỗi lớp, hàm kích hoạt, hệ số điều chuẩn và tốc độ học được thay đổi; còn với LinearRegression, mô hình được dùng như một chuẩn tuyến tính để đối chiếu mức độ cải thiện. Việc tinh chỉnh này nhằm tìm ra cấu hình giúp giảm sai số hiệu chỉnh thay vì chỉ tối ưu trên dữ liệu huấn luyện.

Hiệu quả của bước hiệu chỉnh được đánh giá bằng các chỉ tiêu MAE, RMSE, R^2 và MAPE, đồng thời so sánh trực tiếp với AI_baseline. Trong đó, MAE được sử dụng làm tiêu chí chính để lựa chọn mô hình tốt nhất cho từng tổ hợp hướng - loại xe, vì chỉ tiêu này phản ánh trực tiếp mức sai số tuyệt đối trung bình của số đếm. RMSE được dùng để kiểm tra mức nhạy với các sai số lớn; MAPE phản ánh sai số tương đối; còn R^2 cho biết mức độ bám theo xu hướng biến động của số liệu thực. Cách đánh giá bằng nhiều chỉ tiêu như vậy phù hợp với thông lệ trong các nghiên cứu dự báo lưu lượng và dự báo theo chu kỳ tại nút giao. Giá trị R^2 âm cho thấy dự báo của mô hình kém hơn phương án tham

chiếu chỉ sử dụng giá trị trung bình của số liệu thực trên tập kiểm tra. Vì vậy, giá trị này là dấu hiệu mô hình chưa mô tả tốt biến động của dữ liệu.

Bước cuối cùng là chọn lọc kết quả. Cụ thể, đối với mỗi tổ hợp hướng - loại xe, nghiên cứu so sánh tất cả các mô hình đã huấn luyện với AI_baseline. Nếu một mô hình học máy cho giá trị MAE nhỏ hơn AI_baseline và đồng thời không làm suy giảm nghiêm trọng các chỉ tiêu RMSE, MAPE và R^2, mô hình đó được giữ lại như phương án hiệu chỉnh cuối cùng cho tổ hợp dữ liệu tương ứng. Ngược lại, nếu tất cả các mô hình học máy đều không cải thiện được kết quả so với AI_baseline, nghiên cứu giữ nguyên AI_baseline. Cơ chế chọn lọc này giúp hệ thống cuối cùng không bị ép phải sử dụng học máy trong những trường hợp mà việc hiệu chỉnh không đem lại lợi ích thực sự, đồng thời bảo đảm rằng kết quả đầu ra cuối cùng là phương án tốt nhất đã được kiểm chứng trên dữ liệu thực đo.

3. Ứng dụng cụ thể

Để kiểm chứng tính khả thi và hiệu quả của phương pháp đề xuất, ứng dụng cụ thể được thực hiện tại nút giao Tố Hữu - Vạn Phúc, là một nút giao ngã tư điển hình trong khu vực đô thị tại đây thường xuyên xuất hiện các trạng thái giao thông biến động mạnh theo thời gian, từ đó tạo điều kiện phù hợp để đánh giá mức độ ổn định của phương pháp trong các trường hợp lưu lượng khác nhau.

Nghiên cứu được triển khai trên hai kịch bản quan sát, gồm giờ bình thường và giờ cao điểm. Hai kịch bản này được lựa chọn nhằm phản ánh sự khác biệt về mật độ dòng xe, mức độ che khuất, tính phức tạp trong chuyển động. Việc đồng thời xem xét hai kịch bản này cho phép đánh giá phương pháp không chỉ ở điều kiện thuận lợi mà còn trong trạng thái giao thông bất lợi hơn. Toàn bộ quá trình xử lý trong nghiên cứu tình huống được triển khai theo đúng sơ đồ tuần tự của phương pháp nghiên cứu ở Hình 1. Cụ thể, quá trình này được chia thành hai phần liên tiếp. Ở Phần 1, dữ liệu video giao thông được thu thập và đưa vào mô hình AI để thực hiện phát hiện, phân loại và đếm phương tiện. Song song với đó, cùng trên bộ dữ liệu video này, quá trình đếm thủ công được tiến hành để xây dựng dữ liệu tham chiếu.

Kết quả của hai nhánh xử lý này sau đó được kết hợp để tạo thành bộ dữ liệu huấn luyện cho giai đoạn tiếp theo. Ở Phần 2, bộ dữ liệu huấn luyện được sử dụng để xây dựng và huấn luyện các mô hình học máy, sau đó tiến hành đánh giá mức độ hiệu chỉnh sai số và tạo ra kết quả đếm đã được cải thiện. Cách tổ chức như vậy bảo đảm rằng từng bước trong quy trình đều có quan hệ logic chặt chẽ, đồng thời cho phép đánh giá rõ vai trò của lớp học máy hậu xử lý đối với kết quả đếm ban đầu từ AI.

3.1. Trường hợp giờ bình thường

a. Thiết lập dữ liệu đầu vào

Khung giờ bình thường từ 09 giờ 55 phút đến 11 giờ 15 phút sáng ngày 17 tháng 11 năm 2025 được lựa chọn để đại diện cho trạng thái giao thông ít bão hòa hơn, trong đó tốc độ dòng xe và mức độ che khuất thường thấp hơn so với giờ cao điểm. Video trong khung giờ này được chia thành 14 khoảng thời gian liên tiếp, mỗi khoảng 5 phút, để tạo chuỗi dữ liệu lưu lượng cho năm loại phương tiện nghiên cứu, gồm xe máy, xe đạp, xe con, xe tải và xe buýt. Góc camera này hướng thẳng trực tiếp ra nút giao được thể hiện rõ qua Hình 2.

Việc lựa chọn đơn vị thời gian 5 phút có ý nghĩa quan trọng về mặt phương pháp. Thời gian này là khoảng thời gian đủ ngắn để phản ánh được sự biến động của dòng xe trong môi trường giao thông đô thị, đặc biệt tại các nút giao có lưu lượng thay đổi nhanh. Thứ hai, khoảng thời gian này vẫn đủ dài để tổng hợp được số lượng phương tiện theo từng loại một cách ổn định, hạn chế nhiễu ngẫu nhiên phát sinh nếu chia quá nhỏ. Thứ ba, dữ liệu theo từng khoảng 5 phút phù hợp với mục tiêu tiếp theo của nghiên cứu là sử dụng chuỗi số liệu đã hiệu chỉnh để hỗ trợ đánh giá hoặc đề xuất chu kỳ đèn tín hiệu theo các giai đoạn vận hành ngắn. Dữ liệu đếm tay mỗi 5 phút còn có ý nghĩa như một nền tham chiếu

để nhận diện dạng sai số cơ bản của mô hình AI trong điều kiện lưu lượng trung bình. Nếu phương pháp học máy hậu xử lý vẫn tạo ra mức cải thiện đáng kể trong bối cảnh này, điều đó cho thấy khả năng ứng dụng của phương pháp không chỉ giới hạn ở các thời điểm giao thông phức tạp mà còn có thể phát huy hiệu quả trong điều kiện vận hành thông thường.



Hình 2. Nút giao Tố Hữu – Vạn Phúc giờ bình thường

b. Tổ chức dữ liệu theo quy trình xử lý

Video giao thông được thu thập và làm đầu vào cho mô hình AI. Từ đây, hệ thống AI thực hiện phát hiện và phân loại phương tiện, sau đó chuyển sang bước phân loại và đếm các phương tiện để thu được số lượng của từng loại xe trong từng khoảng thời gian 5 phút. Đồng thời, cùng trên bộ video này, tiến hành đếm thủ công nhằm tạo ra dữ liệu thực đo tương ứng. Sau khi có đồng thời hai chuỗi số liệu, bước tiếp theo là tạo dữ liệu huấn luyện. Tại bước này, AI_baseline không được sử dụng một cách độc lập, mà được ghép nối với kết quả đếm thủ công để xây dựng bộ dữ liệu có thể phản ánh mối quan hệ giữa AI_baseline, số đếm thực và phần sai số giữa chúng. Từ bộ dữ liệu huấn luyện đã tạo, nghiên cứu tiếp tục xây dựng mô hình học máy phù hợp và thực hiện huấn luyện mô hình học máy để học quy luật sai lệch của kết quả đếm. Sau khi quá trình huấn luyện hoàn thành, mô hình được sử dụng để hiệu chỉnh AI_baseline. Bước cuối cùng trong chuỗi xử lý là đánh giá kết quả hiệu chỉnh, trong đó sai số sau hiệu chỉnh được so sánh với sai số ban đầu của AI nhằm xác định mức độ cải thiện đạt được. Kết quả thu được từ bước này là đầu ra cuối cùng của kịch bản nghiên cứu giờ bình thường.

Điểm quan trọng của kịch bản này là nó giúp làm rõ xem lớp học máy hậu xử lý có hoạt động ổn định ngay cả khi mức sai số ban đầu chưa quá lớn hay không. Nếu mô hình vẫn có thể học được và điều chỉnh tốt các sai lệch nhỏ nhưng có tính hệ thống, thì điều đó cho thấy phương pháp đề xuất có khả năng tổng quát hóa tốt hơn và không chỉ hữu ích trong các tình huống giao thông cực đoan.

3.2. Trường hợp giờ cao điểm

a. Thiết lập dữ liệu đầu vào

Khung giờ cao điểm được lựa chọn để kiểm tra phương pháp là từ 07 giờ 20 phút đến 08 giờ 30 phút sáng ngày 17 tháng 11 năm 2025. Khác với kịch bản giờ bình thường, kịch bản giờ cao điểm được lựa chọn nhằm kiểm tra phương pháp trong điều kiện giao thông phức tạp hơn, khi mật độ phương tiện tăng cao, trạng thái dừng chờ xuất hiện thường xuyên và mức độ che khuất giữa các phương tiện lớn hơn. Kịch bản giờ cao điểm này cũng sẽ có một góc camera hướng ra nút được thể hiện ở Hình 3.

Tương tự như kịch bản giờ bình thường, video giao thông của giờ cao điểm được chia thành các khoảng thời gian liên tiếp, mỗi khoảng 5 phút. Với từng khoảng thời gian, nghiên cứu xác định song

song hai tập dữ liệu gồm AI_baseline và số đếm thực đo từ đếm thủ công cho năm loại phương tiện. Việc giữ thống nhất cấu trúc dữ liệu giữa hai kịch bản là cần thiết để bảo đảm tính so sánh trong quá trình đánh giá.

b. Tổ chức dữ liệu theo quy trình xử lý

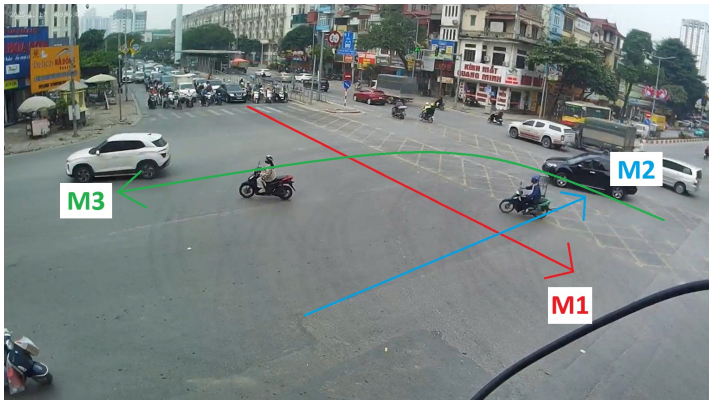
Toàn bộ các bước xử lý của giờ cao điểm vẫn bám theo Hình 1 tương tự như tại giờ bình thường, nhưng trọng tâm phân tích được đặt vào khả năng học sai số trong các điều kiện giao thông bất lợi. Cụ thể, nghiên cứu xem xét liệu mô hình học máy có bù được phần sai số phát sinh do che khuất, nhận diện nhầm hoặc đếm thiếu ở các khoảng có lưu lượng đỉnh hay không. Việc so sánh giữa hai kịch bản giờ bình thường và giờ cao điểm cho phép đánh giá mức độ ổn định của phương pháp đề xuất. Nếu sai số được cải thiện rõ ở cả hai trường hợp, đặc biệt là trong giờ cao điểm, thì điều đó cho thấy lớp học máy có tiềm năng ứng dụng thực tế cao hơn trong các hệ thống quan trắc giao thông đô thị.



Hình 3. Nút giao Tố Hữu – Vạn Phúc giờ cao điểm

4. Kết quả

Kết quả nghiên cứu được trình bày theo hai cấp độ. Trước hết, nghiên cứu đánh giá mức độ sai lệch giữa số liệu đếm thủ công và AI_baseline theo từng hướng giao thông và theo từng loại phương tiện. Trên cơ sở đó, các mô hình học máy được xây dựng và kiểm định nhằm xác định khả năng hiệu chỉnh sai số của AI_baseline. Cuối cùng, một số trường hợp cải thiện tiêu biểu được phân tích chi tiết để làm rõ cơ chế và mức độ cải thiện của phương pháp đề xuất.



Hình 4. Các hướng đếm chính tại nút giao Tố Hữu – Vạn Phúc

Kết quả đếm tay ban đầu được xác định thông qua quan sát video, trong đó ba hướng đếm chính tại nút giao được ký hiệu là M1, M2 và M3, như thể hiện trong Hình 4. Ba hướng này là cơ sở để tổ chức dữ liệu và phân tích sai số trong toàn bộ nghiên cứu.

4.1. So sánh số liệu đếm tay và AI_baseline theo từng hướng

Trước khi tiến hành hiệu chỉnh bằng học máy, cần đánh giá mức độ sai số ban đầu của mô hình AI so với số liệu thực đo. Việc đánh giá này được thực hiện theo hai cấp: theo hướng giao thông và theo loại phương tiện. Cách tiếp cận này cho phép nhận diện rõ hơn liệu sai số chủ yếu xuất phát từ đặc điểm hình học quan sát của từng hướng hay từ đặc trưng nhận diện của từng loại xe.

Bảng 1. Tổng hợp số lượng đếm thủ công và AI_baseline theo hướng tại 2 khung giờ

Giờ	Hướng	Đếm tay	AI_baseline	Chênh lệch AI_baseline thực tế	AI_baseline /Thực tế (%)
07:20-08:30	M1	8706	5229	−3477	60,06
07:20-08:30	M2	3574	1476	−2098	41,30
07:20-08:30	M3	1087	742	−345	68,26
09:55-11:15	M1	2971	2699	−272	90,84
09:55-11:15	M2	1925	1281	−644	66,55
09:55-11:15	M3	937	728	−209	77,69

Bảng 1 cho thấy mô hình AI có xu hướng đếm thiếu so với số liệu thực tế ở cả ba hướng giao thông trong khung giờ bình thường. Trong đó, hướng M1 thời gian từ 09:55-11:15 có kết quả tốt nhất khi AI ghi nhận 2699 xe so với 2971 xe thực tế, tương ứng đạt 90,84%. Ngược lại, hướng M2 thời gian từ 07:20-08:30 là hướng có sai số lớn nhất khi AI chỉ ghi nhận 1476 xe so với 3574 xe thực tế, tương ứng 41,30%. Hướng M3 của cả 2 khung giờ đạt mức trung gian với tỷ lệ khoảng 74%. Kết quả này cho thấy sai số của AI không phân bố đồng đều giữa các hướng giao thông và theo khung giờ khác nhau. Sự khác biệt này có thể liên quan đến nhiều yếu tố như góc quay camera, mức độ che khuất, mật độ phương tiện và hành vi chuyển động đặc trưng theo từng hướng. Đặc biệt, cả 2 khung giờ M2 có sai số lớn nhất cho thấy rằng đây là hướng có điều kiện quan sát bất lợi hơn và có cấu trúc dòng xe phức tạp hơn. Tuy nhiên, phân tích theo hướng mới chỉ cho thấy mức độ sai lệch ở quy mô tổng hợp. Để hiểu rõ hơn bản chất sai số của AI, cần tiếp tục xem xét kết quả theo từng loại phương tiện, bởi mỗi nhóm xe có đặc trưng hình học và hành vi chuyển động khác nhau, từ đó dẫn đến mức độ nhận diện khác nhau.

Bảng 2 cho thấy sai số của AI phụ thuộc khá rõ vào từng loại phương tiện. Trong số năm nhóm xe được xem xét, xe máy là nhóm có chênh lệch tuyệt đối lớn nhất, khi AI đếm thiếu 866 xe giờ thường và 5499 xe giờ cao điểm. Điều này là phù hợp với thực tế giao thông hỗn hợp tại Việt Nam, nơi xe máy thường có mật độ cao, di chuyển linh hoạt và dễ che khuất lẫn nhau. Đối với xe con, AI đạt mức chính xác khá hơn so với thực tế (68,74% ở giờ cao điểm và 85,20% ở giờ thường). Trong khi đó, nhóm xe tải có mức nhận diện thấp hơn đáng kể, riêng xe buýt ở giờ thường có xu hướng đếm dư nhẹ, với tỷ lệ 106,76%, cho thấy sai số không chỉ tồn tại dưới dạng đếm thiếu mà còn có thể xuất hiện dưới dạng đếm thừa trong một số trường hợp. Nhóm xe đạp có số lượng nhỏ nhưng tỷ lệ nhận diện cũng chưa cao, đạt 76,47% ở giờ thường và 61,67% ở giờ cao điểm.

Bảng 1 cho thấy sai số biến thiên theo hướng giao thông thì Bảng 2 cho thấy sai số còn phụ thuộc mạnh vào từng loại phương tiện. Hai kết quả này kết hợp lại cho thấy việc sử dụng một mô hình hiệu chỉnh chung cho toàn bộ dữ liệu có thể không phải là lựa chọn tối ưu. Thay vào đó, cần xem xét khả năng lựa chọn mô hình học máy theo từng tổ hợp hướng - loại xe, nhằm phản ánh tốt hơn quy luật sai

số cụ thể của từng trường hợp. Trên cơ sở nhận diện sự khác biệt về sai số giữa các hướng và các loại phương tiện, nghiên cứu tiếp tục kiểm tra các mô hình học máy khác nhau để tìm ra phương án hiệu chỉnh phù hợp nhất cho từng tổ hợp dữ liệu. Kết quả tổng hợp được trình bày trong Bảng 3.

Bảng 2. Tổng hợp số lượng đếm thủ công và AI_baseline theo loại phương tiện

Thời gian	Loại xe	Đếm tay	AI_baseline	Chênh lệch AI_baseline − Thực tế	AI_baseline /Thực tế (%)
07:20-08:30	Xe máy	12046	6547	−5499	54,35
07:20-08:30	Xe con	1075	739	−336	68,74
07:20-08:30	Tải	127	62	−65	48,82
07:20-08:30	Buýt	85	78	−7	91,76
07:20-08:30	Xe đạp	34	21	−13	61,76
09:55-11:15	Xe máy	4382	3516	−866	80,24
09:55-11:15	Xe con	993	846	−147	85,20
09:55-11:15	Tải	367	254	−113	69,21
09:55-11:15	Buýt	74	79	5	106,76
09:55-11:15	Xe đạp	17	13	−4	76,47

Bảng 3. Mô hình học máy có MAE nhỏ nhất cho từng hướng và từng loại xe

Hướng	Loại xe	Mô hình có MAE nhỏ nhất	MAE tốt nhất	MAE AI_baseline	Cải thiện MAE (%)	RMSE	R^2	MAPE (%)
M1	Buýt	Linear Regression	0,71	1	28,75	0,85	−0,43	44,67
M1	Tải	Linear Regression	3,38	2	−68,75	4,62	−1,85	41,59
M1	Xe con	SVR	7,14	3,50	−104,14	8,29	−0,83	19,56
M1	Xe máy	Gradient Boosting	5,51	10,50	47,50	6,41	0,94	4,17
M1	Xe đạp	SVR	0,30	0,50	40	0,46	−0,12	30
M2	Buýt	Random Forest	1,48	1,25	−18,20	2,13	−8,07	143
M2	Tải	Random Forest	1,41	3	53,17	1,84	0,03	19,42
M2	Xe con	Decision Tree	4,12	3,50	−17,86	7,05	−1,14	41,96
M2	Xe máy	SVR	12,41	27,75	55,29	16,44	−1,59	14,54
M2	Xe đạp	SVR	0,30	0,25	−20	0,46	−0,12	30
M3	Buýt	SVR	0,61	0,75	19,33	0,73	−1,13	60,50
M3	Tải	Linear Regression	1,25	1,25	0	1,30	0,47	52,58
M3	Xe con	Linear Regression	0,98	2,25	56,56	1,41	0,81	7,62
M3	Xe máy	Linear Regression	2,00	10,75	81,37	2,08	0,78	3,61
M3	Xe đạp	MLP Regressor	0,42	0,25	−67	0,62	0	41,75

Bảng 3 cho thấy trong tổng số 15 tổ hợp hướng - loại xe, có 9 tổ hợp mà mô hình học máy đạt giá trị MAE nhỏ hơn so với AI_baseline. Ở 6 tổ hợp còn lại, mô hình học máy có mức cải thiện MAE ≤ 0 nên không được lựa chọn; phương án cuối cùng là giữ nguyên AI_baseline. Như vậy, Bảng 3 vừa trình bày mô hình học máy có MAE nhỏ nhất trong nhóm thử nghiệm, vừa làm rõ quyết định lựa chọn cuối cùng theo nguyên tắc tại Mục 2.7. Kết quả cho thấy bước hiệu chỉnh bằng học máy có hiệu quả trong hơn một nửa số tổ hợp, nhưng mức độ cải thiện không đồng đều giữa các nhóm dữ liệu.

Các trường hợp cải thiện rõ nhất tập trung ở nhóm xe máy và xe con, đặc biệt tại các hướng M1 và M3. Ví dụ, đối với xe máy tại M3, MAE giảm từ 10,75 xuống còn 2,00, tương ứng mức cải thiện

81,37%. Tương tự, đối với xe con tại M3, MAE giảm từ 2,25 xuống còn 0,98, tương ứng mức cải thiện 56,56%. Ngược lại, ở một số nhóm dữ liệu có kích thước mẫu nhỏ hoặc biến động không ổn định, chẳng hạn xe đạp hoặc buýt, hiệu quả cải thiện chưa nhất quán, thậm chí có trường hợp mô hình học máy cho kết quả kém hơn AI_baseline.

Kết quả từ Bảng 3 là cơ sở để lựa chọn các trường hợp tiêu biểu cho phân tích sâu hơn ở phần tiếp theo. Trong số các tổ hợp đã khảo sát, hai trường hợp nổi bật nhất là xe máy tại hướng M3 và xe con tại hướng M3, bởi đây là những trường hợp vừa có mức cải thiện sai số rõ rệt, vừa cho thấy mô hình sau hiệu chỉnh bám sát xu hướng thực tế tốt hơn. Vì vậy, hai trường hợp này được lựa chọn để phân tích chi tiết nhằm làm rõ hơn cơ chế cải thiện của phương pháp đề xuất.

4.2. Các trường hợp cải thiện tiêu biểu

a. Trường hợp Xe máy tại hướng M3

Đối với xe máy tại hướng M3, kết quả tổng hợp ở Bảng 3 cho thấy đây là trường hợp có mức cải thiện lớn nhất theo chỉ tiêu MAE. Để làm rõ hơn sự khác biệt giữa các thuật toán học máy, Bảng 4 trình bày kết quả so sánh chi tiết giữa các mô hình cho riêng tổ hợp dữ liệu này.

Bảng 4. So sánh các mô hình cho Xe máy tại M3

Thời gian	Model	MAE	RMSE	R^2	MAPE(%)
07:20-08:30	LinearRegression	14,31	19,72	−0,12	38,64
07:20-08:30	RandomForest	12,71	19,36	−0,08	39,06
07:20-08:30	MLPRegressor	27,49	28,20	−1,29	59,54
07:20-08:30	GradientBoosting	11,15	19,34	−0,08	36,43
07:20-08:30	SVR	18,57	21,78	−0,36	47,83
07:20-08:30	DecisionTree	14,00	19,30	−0,07	37,66
07:20-08:30	AI_baseline	31,25	34,03	−2,33	51,67
09:55-11:15	LinearRegression	2,00	2,08	0,78	3,61
09:55 -11:15	RandomForest	2,48	3,18	0,49	4,51
09:55-11:15	MLPRegressor	3,05	3,66	0,32	5,35
09:55-11:15	GradientBoosting	3,31	4,41	0,01	5,83
09:55-11:15	SVR	3,41	3,80	0,27	6,21
09:55-11:15	DecisionTree	4,75	5,63	−0,61	8,54
09:55-11:15	AI_baseline	10,75	10,85	−4,98	19,29

Kết quả ở Bảng 4 cho thấy Linear Regression là mô hình hiệu chỉnh tốt nhất đối với xe máy tại hướng M3. So với AI_baseline, MAE giảm rất mạnh từ 10,75 xe xuống còn 2,00 xe, trong khi RMSE giảm từ 10,85 xuống 2,08 ở khung giờ 09:55-11:15. Đặc biệt, hệ số R^2 tăng từ −4,98 lên 0,78, cho thấy mô hình sau hiệu chỉnh đã mô tả xu hướng biến động của số liệu thực tế tốt hơn rất nhiều. Đồng thời, MAPE cũng giảm mạnh từ 19,29% xuống 3,61%, phản ánh sự cải thiện đáng kể về sai số tương đối. Trong khung giờ 07:20-08:30 Gradient Boosting là mô hình tốt nhất cho Xe máy tại M3 với MAE = 11,15 xe, RMSE = 19,34 xe và MAPE = 36,43%. So với AI_baseline có MAE = 31,25 xe và MAPE = 51,67%, sai số đã giảm đáng kể sau hiệu chỉnh. Từ kết quả này có thể thấy rằng đối với nhóm xe máy tại hướng M3, mối quan hệ giữa AI_baseline và số liệu thực tế có tính quy luật khá rõ, đủ để một mô hình tuyến tính đơn giản có thể học và hiệu chỉnh hiệu quả. Để minh họa cụ thể hơn cho kết quả này, Bảng 5 trình bày một số mẫu dự đoán xác thực của mô hình tốt nhất.

Bảng 5 cho thấy trong nhiều mẫu xác thực, mô hình sau hiệu chỉnh đã đưa kết quả dự đoán tiến rất gần tới số liệu thực tế. Khi AI đếm 38 xe máy trong khi thực tế là 51 xe máy, sai số ban đầu của

AI là 13 xe, còn sau hiệu chỉnh sai số chỉ còn khoảng 2 xe. Tương tự, tại mẫu AI đếm 52 xe máy và thực tế là 63 xe máy, sai số giảm từ 11 xe xuống còn khoảng 1 xe. Những ví dụ này củng cố nhận định rằng với dữ liệu xe máy tại M3, sai số của AI mang tính hệ thống tương đối rõ ràng, nhờ đó mô hình học máy có thể học được quy luật sai lệch và hiệu chỉnh hiệu quả. Có thể thấy hiệu quả của phương pháp đề xuất không chỉ dừng lại ở nhóm phương tiện có lưu lượng lớn nhất. Để kiểm tra khả năng cải thiện trên một nhóm phương tiện khác, nghiên cứu tiếp tục xem xét trường hợp xe con tại hướng M3, là trường hợp cũng cho kết quả cải thiện lớn trong Bảng 3.

Bảng 5. Kết quả dự đoán của mô hình Gradient Boosting (GB) cho Xe máy tại M3

Thời gian	AI_baseline	Thực tế	Sai số AI_baseline	Dự đoán GB	Sai số GB	Cải thiện so với AI_baseline
10:55-11:00	52	63	11	64	1	9
11:00-11:05	47	57	10	59	2	7
11:05-11:10	45	54	9	56	2	7
11:10-11:15	38	51	13	49	2	11

b. Trường hợp Xe con tại hướng M3

Bảng 6 tiếp tục cho thấy Linear Regression là mô hình tốt nhất đối với xe con tại hướng M3. Cụ thể, MAE giảm từ 2,25 xe của AI_baseline xuống còn 0,98 xe, trong khi RMSE giảm từ 2,87 xuống 1,41. Đồng thời, hệ số R^2 tăng từ 0,20 lên 0,81, phản ánh việc mô hình sau hiệu chỉnh mô tả tốt hơn xu hướng của số liệu thực. MAPE cũng giảm mạnh từ 26,74% xuống 7,62%, cho thấy sai số tương đối đã được cải thiện đáng kể.

Bảng 6. So sánh các mô hình cho Xe con tại M3 giờ thường

Model	MAE	RMSE	R^2	MAPE(%)
LinearRegression	0,98	1,41	0,81	7,62
MLPRegressor	1,78	2,18	0,54	19,75
RandomForest	2,14	2,56	0,36	18,61
AI_baseline	2,25	2,87	0,20	26,74
DecisionTree	2,75	2,96	0,15	26,04
GradientBoosting	2,79	3,02	0,11	26,24
SVR	2,90	3,05	0,09	27,87

So với trường hợp xe máy tại M3, mức sai số tuyệt đối của xe con vốn đã thấp hơn từ ban đầu, nhưng việc hiệu chỉnh bằng học máy vẫn mang lại giá trị rõ rệt. Điều này cho thấy lớp hậu xử lý không chỉ hữu ích đối với các nhóm phương tiện có lưu lượng lớn và sai số cao, mà còn có thể cải thiện cả các nhóm phương tiện có quy mô nhỏ hơn nhưng vẫn tồn tại sai lệch có hệ thống. Để minh họa rõ hơn, Bảng 7 trình bày một số mẫu dự đoán xác thực của mô hình tốt nhất cho trường hợp này.

Bảng 7 cho thấy trong nhiều mẫu, mô hình sau hiệu chỉnh đưa ra kết quả gần với số liệu thực tế hơn so với AI ban đầu. Tại mẫu AI đếm 3 xe con trong khi thực tế là 8 xe con, sai số ban đầu là 5 xe, còn sau hiệu chỉnh không có sai số. Ở các mẫu AI đếm 7 xe con và thực tế 9 xe con, sai số của mô hình chỉ còn khoảng 1 xe, thấp hơn rõ rệt so với sai số ban đầu.

Tuy nhiên, Bảng 7 cũng cho thấy không phải mọi mẫu dự đoán đều được cải thiện. Chẳng hạn, tại mẫu AI đếm 16 xe con và thực tế cũng là 16 xe con, AI_baseline không có sai số, trong khi mô hình lại dự đoán 13 xe, làm phát sinh sai số mới. Trường hợp này cho thấy rằng dù mô hình học máy có

thể cải thiện xu hướng tổng thể, nhưng ở cấp độ từng mẫu riêng lẻ vẫn có thể xảy ra hiện tượng hiệu chỉnh quá mức. Đây cũng là một kết quả quan trọng, vì nó nhấn mạnh rằng lớp học máy hậu xử lý không phải lúc nào cũng cải thiện tuyệt đối mọi quan sát, mà hiệu quả của nó cần được đánh giá trên toàn bộ tập dữ liệu thông qua các chỉ tiêu tổng hợp như MAE, RMSE, R^2 và MAPE.

Bảng 7. Kết quả dự đoán của mô hình Linear Regression (LR) cho Xe con tại M3

Thời gian	AI_baseline	Thực tế	Sai số AI_baseline	Dự đoán LR	Sai số LR	Cải thiện so với AI_baseline
10:55-11:00	3	8	5	8	0	5
11:00-11:05	16	16	0	13	3	−3
11:05-11:10	7	9	2	10	1	1
11:10-11:15	7	9	2	10	1	1

Tổng hợp toàn bộ kết quả học máy tổng quan đã cải thiện được tốt hơn khi so với AI_baseline theo chỉ số MAE. Các trường hợp cải thiện nổi bật nhất thuộc về xe máy tại M1, xe máy tại M3 và xe con tại M3. Ở những trường hợp này, MAE, RMSE và MAPE đều giảm, trong khi R^2 tăng rõ rệt, chứng minh rằng mô hình sau hiệu chỉnh không chỉ giảm sai số trung bình mà còn mô tả tốt hơn xu hướng biến động thực tế. Tuy nhiên, kết quả cũng cho thấy không tồn tại một mô hình duy nhất tốt nhất cho mọi loại xe. Mỗi nhóm phương tiện có thể cần một mô hình phù hợp riêng, phụ thuộc vào đặc tính lưu lượng và kiểu sai số của AI_baseline. Vì vậy, hướng triển khai phù hợp trong thực tế là lựa chọn mô hình tốt nhất theo từng loại xe, thậm chí theo từng hướng giao thông và theo các khung giờ cụ thể. Các bảng kết quả đã chứng minh rằng việc bổ sung bước hiệu chỉnh bằng mô hình học máy là cần thiết và có khả năng nâng cao đáng kể độ chính xác của hệ thống đếm xe tự động.

5. Kết luận

Bài báo đã đề xuất một phương pháp kết hợp giữa mô hình AI [4] và học máy hậu xử lý nhằm nâng cao độ chính xác đếm lưu lượng phương tiện tại nút giao trong điều kiện giao thông hỗn hợp. Phương pháp được xây dựng theo hai tầng xử lý liên tiếp. Ở tầng thứ nhất, mô hình AI được sử dụng để phát hiện, phân loại và đếm phương tiện từ dữ liệu video [4]. Ở tầng thứ hai, các mô hình học máy được sử dụng để học quy luật sai số của AI_baseline theo từng khoảng thời gian 5 phút, từ đó hiệu chỉnh lại số đếm ban đầu theo từng hướng giao thông và từng loại phương tiện.

Kết quả nghiên cứu cụ thể tại nút giao Tố Hữu - Vạn Phúc cho thấy mô hình AI có xu hướng đếm thiếu ở phần lớn các trường hợp, tuy nhiên mức sai số không giống nhau giữa các hướng giao thông và giữa các loại phương tiện. Điều này cho thấy sai số của hệ thống đếm tự động không mang tính đồng nhất, mà phụ thuộc vào đặc trưng lưu lượng, mức độ che khuất, góc quan sát và đặc tính di chuyển của từng nhóm phương tiện trong dòng giao thông hỗn hợp. Trên cơ sở dữ liệu đối sánh giữa số đếm AI và số đếm thủ công, nghiên cứu đã thử nghiệm nhiều mô hình học máy khác nhau để thực hiện hiệu chỉnh sai số. Kết quả cho thấy học máy có khả năng cải thiện độ chính xác trong phần lớn các tổ hợp hướng - loại xe, trong đó các trường hợp cải thiện rõ nhất tập trung ở nhóm xe máy và xe con. Ở các trường hợp này, các chỉ tiêu MAE, RMSE và MAPE đều giảm, trong khi hệ số R^2 tăng lên, cho thấy mô hình sau hiệu chỉnh không chỉ giảm sai số trung bình mà còn mô tả tốt hơn xu hướng biến động thực tế của lưu lượng.

Nghiên cứu đã chứng minh rằng việc kết hợp AI với học máy hậu xử lý là một hướng tiếp cận khả thi nhằm cải thiện chất lượng đếm xe tự động tại nút giao thông. Tuy nhiên, nghiên cứu hiện mới được kiểm chứng trên một nút giao và trong số lượng khung thời gian còn hạn chế. Trong các nghiên cứu tiếp theo, cần mở rộng tập dữ liệu cho nhiều nút giao, nhiều điều kiện giao thông và nhiều thời

điểm quan sát khác nhau để đánh giá đầy đủ hơn tính ổn định của phương pháp. Đồng thời, chuỗi lưu lượng sau hiệu chỉnh cũng có thể được tiếp tục khai thác như đầu vào cho các bài toán phân tích giao thông nâng cao, đặc biệt là đánh giá nhu cầu theo hướng và hỗ trợ xác định chu kỳ đèn tín hiệu theo thời gian ngắn.

Lời cảm ơn

Thu thập số liệu lưu lượng giao thông trong nghiên cứu được thực hiện bởi các sinh viên Khoa Cầu đường, Trường Đại học Xây dựng Hà Nội.

Tuyên bố về việc sử dụng trí tuệ nhân tạo tạo sinh và công nghệ hỗ trợ bởi AI

Các tác giả xác nhận không sử dụng bất kỳ công cụ trí tuệ nhân tạo tạo sinh hoặc công nghệ hỗ trợ bởi AI nào trong quá trình chuẩn bị và hoàn thiện bản thảo.

Tài liệu tham khảo

[1] Vu, T., Preston, J. (2023). Microscopic simulation model for motorcycle dominated networks: A case study of a VISSIM simulation model for a mixed traffic corridor. *IOP Conference Series: Materials Science and Engineering*, IOP Publishing, 1289(1):012045.
[2] Ultralytics (2024). *Ultralytics YOLO11*.
[3] Chen, W.-C., Deng, M.-J., Liu, P.-Y., Lai, C.-C., Lin, Y.-H. (2023). A framework for real-time vehicle counting and velocity estimation using deep learning. *Sustainable Computing: Informatics and Systems*, 40:100927.
[4] Vu, T., Thai, H. N., Pham, V. N., Vu, H. T., Luong, A. T., Van Luong, T. (2025). Counting mixed traffic volumes at motorcycle-dominated intersections by using computer vision. *International Journal of Intelligent Transportation Systems Research*, 23(1):146–164.
[5] Tan, D. M., Kieu, L.-M. (2023). TRAMON: An automated traffic monitoring system for high density, mixed and lane-free traffic. *IATSS Research*, 47(4):468–481.
[6] Vu, T. (2025). Pedestrian flow counting at urban intersections using a retrained YOLOv8 model. *Journal of Science and Technology in Civil Engineering (JSTCE) - HUCE*, 19(2):107–118.
[7] Razali, N. A. M., Shamsaimon, N., Ishak, K. K., Ramli, S., Amran, M. F. M., Sukardi, S. (2021). Gap, techniques and evaluation: Traffic flow prediction using machine learning and deep learning. *Journal of Big Data*, 8(1):152.
[8] Mahmoud, N., Abdel-Aty, M., Cai, Q., Yuan, J. (2021). Predicting cycle-level traffic movements at signalized intersections using machine learning models. *Transportation Research Part C: Emerging Technologies*, 124:102930.
[9] Su, X., Yan, X., Tsai, C.-L. (2012). Linear regression. *Wiley Interdisciplinary Reviews: Computational Statistics*, 4(3):275–294.
[10] Yadav, A. (2019). *Artificial neural network in Python using SKLearn (MLP regression)*.
[11] Louppe, G. (2014). *Understanding random forests: From theory to practice*. Ph.d. thesis, Université de Liège.
[12] Quinlan, J. R. (1996). Learning decision tree classifiers. *ACM Computing Surveys*, 28(1):71–72.
[13] Natekin, A., Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in Neurorobotics*, 7:21.
[14] Awad, M., Khanna, R. (2015). Support vector regression. *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers*, Berkeley, CA, Apress, 67–80.
[15] Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, 1(1):81–106.
[16] Breiman, L. (2001). Random forests. *Machine Learning*, 45(1):5–32.
[17] Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5):1189–1232.
[18] Cortes, C., Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3):273–297.
[19] Rumelhart, D. E., Hinton, G. E., Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088):533–536.