

AN EDGE-CLOUD HYBRID ARCHITECTURE USING XGBOOST FOR REAL-TIME TRAFFIC FLOW FORECASTING AND INTELLIGENT SIGNAL CONTROL

Nguyen Thi Hong Hoa¹, Phi Van Lam^{1*}

¹University of Transport and Communications, No 3 Cau Giay Street, Hanoi, Vietnam.

* *Corresponding author*

Email: pvlam@utc.edu.vn; Tel: 0968060988

Abstract. Traffic congestion is a serious problem in urban areas. This paper proposes an intelligent traffic flow forecasting system that integrates a three-layer IoT architecture with edge computing. We compare four methods—Linear Regression, Random Forest, XGB, and LGBM - using the Metro Interstate Traffic Volume dataset. The results show that XGBoost achieves superior performance (**MAE = 290.09, RMSE = 507.70, R² = 0.9334, MAPE = 13.75%, Accuracy within 20% = 84.19%**) and very low inference time (3.35 ms), making it extremely suitable for future deployment on resource-constrained embedded computers and microcontrollers like the STM32. This study provides an important foundation for the development of real-time adaptive traffic signal control systems.

Keywords: Traffic flow forecasting, XGB, LGBM, traffic signal control, Intelligent Transportation Systems (ITS).

@ 2026 University of Transport and Communications

KIẾN TRÚC LAI EDGE-CLOUD SỬ DỤNG XGB CHO DỰ BÁO LƯU LƯỢNG VÀ ĐIỀU KHIỂN ĐÈN TÍN HIỆU GIAO THÔNG THỜI GIAN THỰC

Nguyễn Thị Hồng Hoa¹, Phí Văn Lâm^{1*}

¹Trường Đại học Giao thông vận tải, Số 3 Cầu Giấy, Hà Nội, Việt Nam

* Tác giả liên hệ

Email: pvlam@utc.edu.vn; Tel: 0968060988

Tóm tắt. Tác nghẽn giao thông là một vấn đề nghiêm trọng tại các đô thị. Bài báo này đề xuất một hệ thống dự báo lưu lượng giao thông thông minh tích hợp kiến trúc IoT 3 lớp và tính toán biên (Edge Computing). Chúng tôi so sánh các phương pháp: LR, RF, XGB, và LGBM trên bộ dữ liệu Metro Interstate Traffic Volume. Kết quả cho thấy XGBoost đạt hiệu suất vượt trội (**MAE = 290.09, RMSE = 507.70, R² = 0.9334, MAPE = 13.75%, Độ chính xác = 84.19%**) và có thời gian suy diễn cực kỳ thấp (3.35 ms cho toàn tập dữ liệu kiểm thử), đặc biệt phù hợp để tích hợp và triển khai trong tương lai trên các máy tính nhúng hạn chế tài nguyên và vi điều khiển như STM32. Nghiên cứu này cung cấp cơ sở quan trọng cho việc phát triển các hệ thống điều khiển đèn tín hiệu thích ứng thời gian thực.

Từ khóa: Dự báo lưu lượng giao thông, XGB, LGBM, Điều khiển đèn tín hiệu, ITS.

1. ĐẶT VẤN ĐỀ

Quản lý giao thông đô thị ngày càng dựa vào các Hệ thống Giao thông Thông minh (Intelligent Transportation Systems - ITS) để tối ưu hóa lưu lượng. Đèn giao thông truyền thống thường hoạt động theo chu kỳ thời gian cố định, dẫn đến sự kém hiệu quả trong điều kiện giao thông biến động. Dự báo chính xác lưu lượng giao thông cho phép điều chỉnh tín hiệu một cách chủ động - kéo dài thời gian đèn xanh trong các đợt cao điểm dự kiến hoặc giảm chu kỳ trong các giai đoạn lưu lượng thấp.

Những tiến bộ gần đây trong Trí tuệ Nhân tạo (AI) và Internet Vạn vật (IoT) đóng vai trò then chốt trong sự phát triển của ITS. Các kỹ thuật xử lý ảnh AI đã chứng minh hiệu năng cao trong việc nhận dạng và cải thiện biển báo tín hiệu giao thông [1]. Thêm vào đó, ở góc độ IoT và truyền thông dữ liệu, các hệ thống học máy không giám sát hiện đại, ví dụ như thuật toán tự tối ưu hóa tensor, đã giúp phân loại và quản lý lưu lượng truyền thông IoT một cách an toàn và chính xác, loại bỏ các lưu lượng độc hại [2].

Đối với việc phân tích dữ liệu giao thông cốt lõi, dự báo giao thông đã phát triển từ các phương pháp tham số (như ARIMA) sang các mô hình Học máy có khả năng nắm bắt những mối quan hệ phi tuyến phức tạp. Một số phân tích chuyên sâu cho thấy các mô hình Chuỗi thời gian (Time Series) học máy như Random Forest đem lại tiềm năng dự báo tốt [3].

Đặc biệt, sự bùng nổ của Học sâu (Deep Learning) và các biến thể học máy tổ hợp (ensemble learning) tạo ra cuộc cạnh tranh mạnh mẽ. Các kiến trúc như Bi-GRU đã ứng dụng cơ chế chú ý (attention mechanism) để phân tích lưu lượng giao thông không gian-thời gian với độ chính xác cao [5]. Mặc dù vậy, các mạng dựa trên LGBM thường tiêu tốn tài nguyên và thời gian huấn luyện. Một giải pháp thay thế linh hoạt là kết hợp (hybrid) LGBM với các

mô hình cây quyết định theo hướng Boosting như XGB nhằm cân bằng giữa việc nâng cao độ chính xác và tiết kiệm rủi ro xử lý dữ liệu truyền tải [4].

Trong bài báo này, chúng tôi tập trung đi sâu vào khả năng thực thi nhanh của XGB đối với dữ liệu thời gian thực dạng bảng, nhằm mục đích đưa các mô hình dự báo học máy đồ sộ xuống cấp độ vi xử lý vi điều khiển, tối ưu hoá cho ITS thực tế.

2. PHƯƠNG PHÁP VÀ MÔ HÌNH HỆ THỐNG ĐỀ XUẤT

Để giải quyết bài toán độ trễ trong các hệ thống xử lý giao thông truyền thống dùng điện toán đám mây (Cloud Computing), nghiên cứu này thiết kế mạng lưới cấu trúc phân cấp, theo đó việc trích xuất mẫu lưu lượng và mô hình hoá dự báo được dịch chuyển một phần xuống lớp vật lý thông qua tính toán biên (Edge Computing).

2.1. Bộ Dữ liệu và Phương pháp Tiền xử lý Dữ liệu

Trong nghiên cứu này, bộ dữ liệu *Metro Interstate Traffic Volume* được sử dụng như một tập dữ liệu chuẩn mực (benchmark proxy dataset) nhằm kiểm chứng kỹ lưỡng tính khả thi của các thuật toán phân tích chuỗi thời gian, trước khi đưa vào ứng dụng thực tiễn với dữ liệu giao thông tại miền khí hậu Việt Nam.

- **Trích xuất đặc trưng (Feature Extraction):** Các thành phần mang tính chu kỳ bao gồm Giờ (Hour), Ngày trong tuần (Day of week) và Tháng (Month) được trích xuất nhằm thiết lập tham chiếu chu kỳ thời gian rõ rệt đối với xu hướng lưu lượng xe.

- **Mã hoá dữ liệu (Encoding):** Những định danh môi trường không có thứ tự như đặc trưng thời tiết (nắng, mưa, sương mù, ...) được biểu diễn thông qua kỹ thuật Mã hoá One-Hot (One-Hot Encoding).

- **Chuẩn hóa thang đo (Normalization):** Phương pháp MinMax Scaling được áp dụng bắt buộc trên toàn bộ các biến số độc lập nhằm tránh hiện tượng bùng nổ gradient, đặc biệt với các mô hình theo dạng mạng nơ-ron như LSTM.

- **Phân chia tập dữ liệu (Data Splitting):** Thay vì cross-validation thông thường, dữ liệu ở bài toán này được ngắt đúng theo dòng quy luật thời gian (80% cho quá trình huấn luyện mô hình cơ sở, 20% cho việc dự báo kiểm thử và đánh giá).

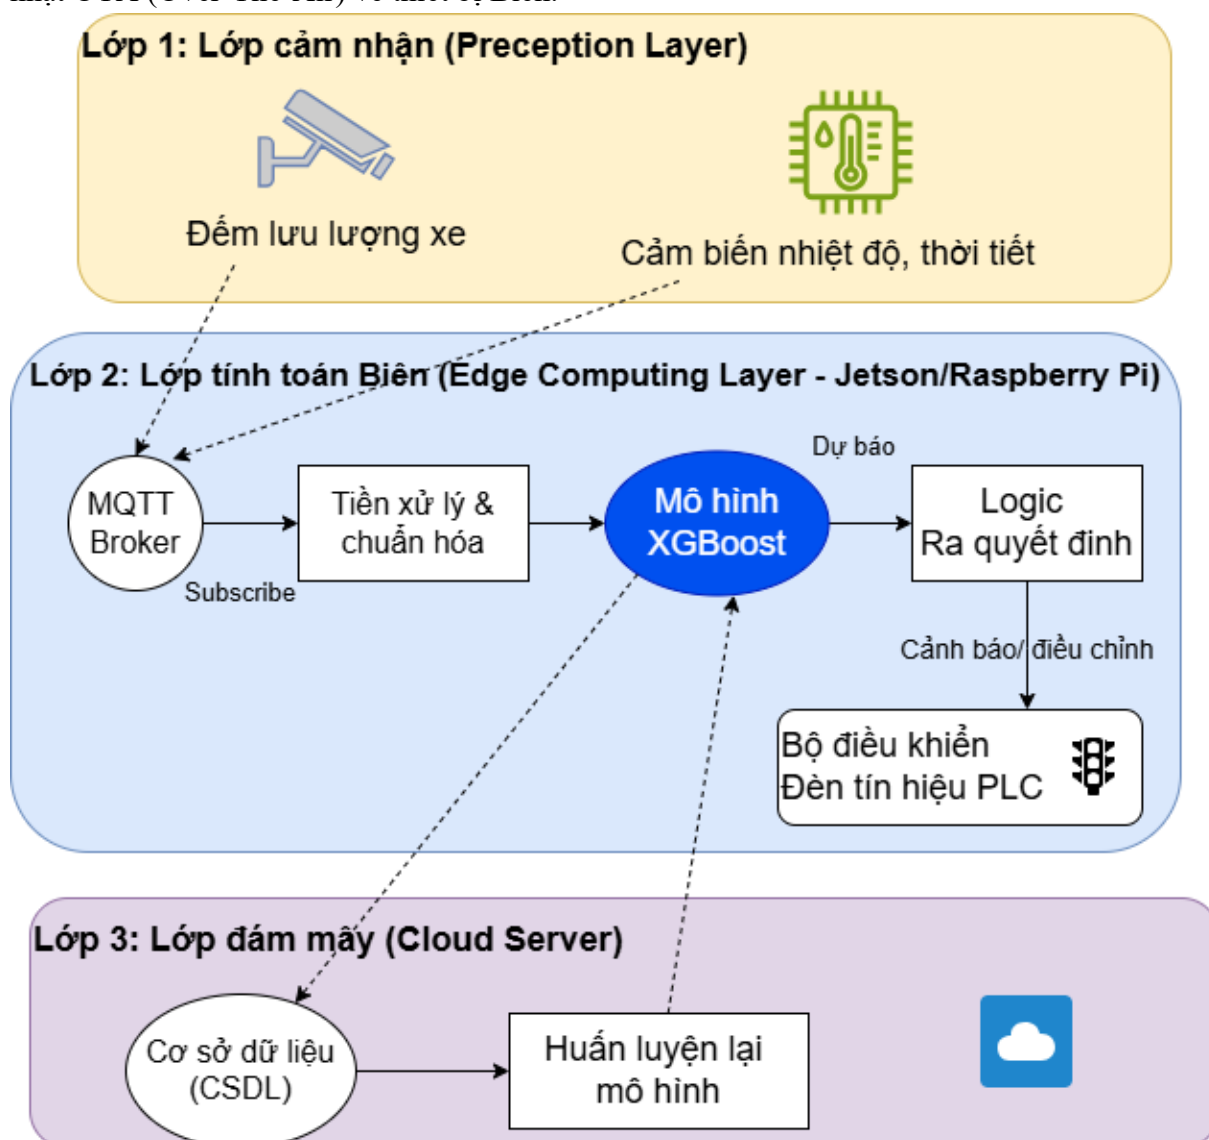
2.2. Kiến trúc Hệ thống Edge-Cloud lai ghép (Hybrid Edge-Cloud Architecture)

Kiểu thiết kế kiến trúc chuẩn mực được đề xuất bao gồm ba lớp (Hình 1), bảo đảm khả năng suy diễn thông lượng cao và thích ứng linh hoạt:

- **Lớp thiết bị/Cảm nhận (Perception Layer):** Mạng lưới bao gồm cảm biến độ rọi, cảm biến thời tiết, và hệ thống Camera AI thị giác máy tính hoạt động liên tục (24/7). Chúng chịu trách nhiệm thô về việc định tuyến đếm phương tiện truyền số liệu số phân nhỏ về Gateway nội hạt thông qua các giao thức M2M.

- **Lớp tính toán Biên (Edge Computing Layer):** Đây là lõi thông minh xử lý sát thiết bị thu (ví dụ như vi điều khiển nhúng dòng STM32, ESP32 mạnh, hoặc máy tính Edge Gateway). Tập hợp các trọng số (weights) của mô hình học máy (như XGB) đã tối ưu hoá trước đó được nạp trực tiếp vào bộ nhớ cục bộ (Local RAM). Biên thiết bị sẽ thực thi mã nhúng để nhận vào chuỗi vector thời tiết thay đổi trong thời gian trễ dưới 5 ms một lượt và đẩy trực tiếp ra quyết định trạng thái nháy đèn (Xanh/Đỏ/Vàng) tối ưu thời điểm.

- **Lớp Đám mây (Cloud Layer):** Giải quyết lưu trữ phân tán kho dữ liệu lớn, trực quan hoá trung tâm điều khiển thành phố và làm nhiệm vụ siêu máy tính để huấn luyện lại mạng (Re-training) theo chu kỳ định kì. Các tham số trọng số mới tinh luyện sẽ được đẩy qua cập nhật OTA (Over-The-Air) về thiết bị Biên.



Hình 1: Kiến trúc hệ thống và luồng dữ liệu

2.3. Triển khai Mô hình Học máy và Cây Quyết định Tổ hợp

Để đánh giá năng lực triển khai thực tế tại **lớp tính toán biên (Edge Layer)**, nghiên cứu tiến hành mô phỏng phần cứng và thực nghiệm so sánh song song bốn mô hình lỗi độc lập như sau:


- **Hồi quy tuyến tính (Linear Regression – LR):** Mô hình cơ sở (baseline) nhằm đánh giá mức sai số tuyến tính thuần túy và làm chuẩn đối chiếu cho các phương pháp phi tuyến.
- **Rừng ngẫu nhiên (Random Forest – RF):** Thuật toán học tổ hợp (Ensemble Learning) dựa trên kỹ thuật Bagging, trong đó nhiều cây quyết định được huấn luyện

trên các tập mẫu Bootstrap và tổng hợp kết quả dự đoán nhằm giảm phương sai và hạn chế hiện tượng quá khớp (Overfitting).

- **XGBoost (Extreme Gradient Boosting – XGB):** Phương pháp Boosting dựa trên tối ưu hóa gradient bậc hai, kết hợp cơ chế điều chuẩn (regularization) mạnh trên từng cây nhằm kiểm soát độ phức tạp mô hình. Nhờ hiệu quả tính toán cao và chi phí suy luận (inference cost) thấp, XGBoost là ứng viên phù hợp cho các hệ thống nhúng và môi trường Edge Computing.
- **LightGBM (Light Gradient Boosting Machine – LGBM):** Khung Gradient Boosting dựa trên cây quyết định với chiến lược phát triển leaf-wise và thuật toán histogram-based, giúp tăng tốc huấn luyện và giảm tiêu thụ bộ nhớ. Mô hình đặc biệt phù hợp cho các bài toán dự báo chuỗi thời gian quy mô lớn trong môi trường tài nguyên hạn chế.

3. THỬ NGHIỆM/ĐÁNH GIÁ PHÂN TÍCH

Thông qua Biểu đồ nhiệt độ tương quan (Hình 2) giữa các biến liên tục, quá trình phân tích chỉ ra rằng mỗi liên hệ tuyến tính giữa các yếu tố thời tiết và lưu lượng giao thông là khá yếu. Cụ thể, nhiệt độ (temp) có hệ số tương quan dương cao nhất ở mức 0.13, độ che phủ mây (clouds_all) ở mức 0.07, trong khi lượng mưa (rain_1h) và tuyết rơi (snow_1h) gần như không tương quan chuẩn tuyến tính (hệ số 0.00). Đặc tính này là minh chứng rõ rệt cho việc dữ liệu giao thông đô thị mang tính phi tuyến rất cao và không thể lệ thuộc riêng rẽ vào thời tiết (mà bị chi phối thói quen theo chu kỳ giờ/ngày). Chính vì thế, việc sử dụng các mô hình học máy phi tuyến tính cực mạnh như XGB hay RF tỏ ra bắt buộc và hiệu quả hơn hẳn khi so sánh với hồi quy tuyến tính (LR) đơn thuần.



Hình 2: Biểu đồ nhiệt độ tương quan

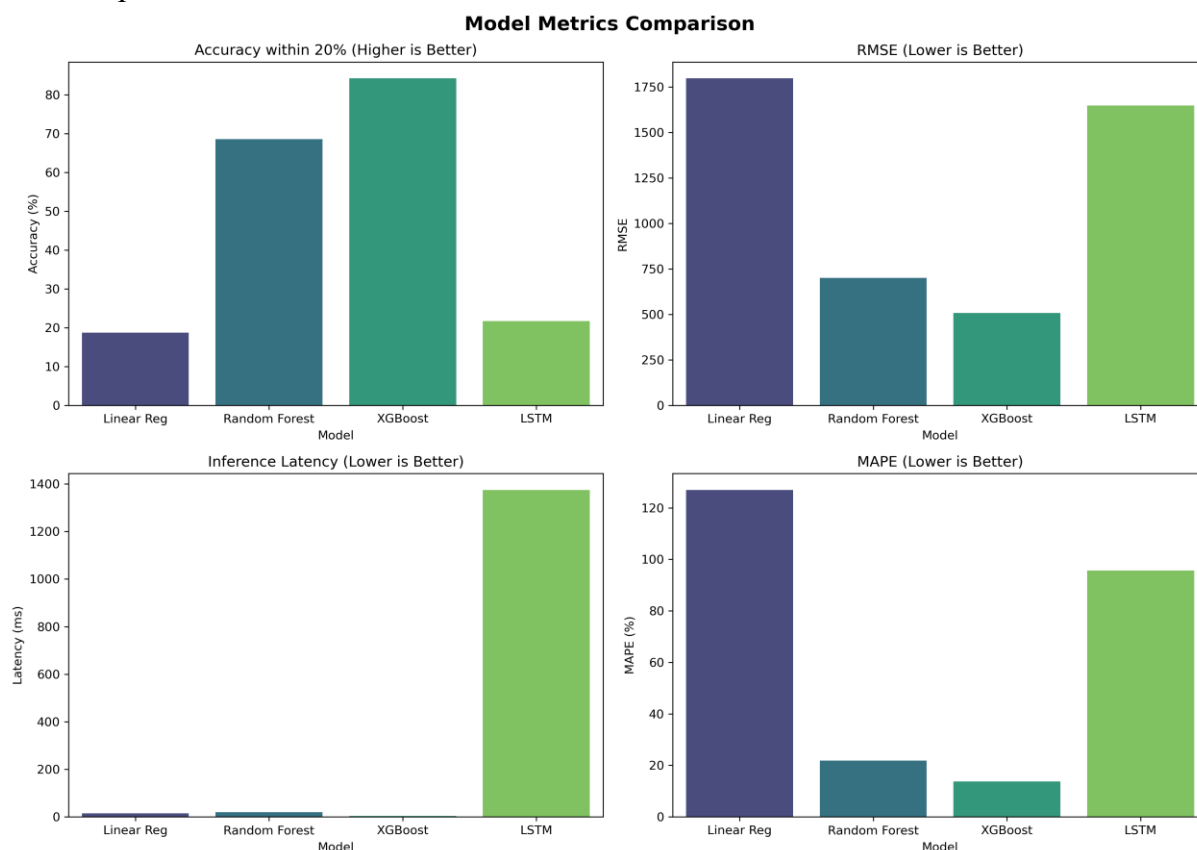
Chúng tôi đánh giá các mô hình dựa trên hai tiêu chí: Độ chính xác (MAE, RMSE, R^2 , ACC_20) và Hiệu năng IoT (Thời gian suy diễn - Latency). Thực nghiệm và huấn luyện mô hình được thực hiện trên ứng dụng Visual Studio Code của máy tính Panasonic CF-SV9H20VS – Intel Core i5-10210U, 16GB RAM, SSD.

3.1. Hiệu quả dự báo thực tế

Bảng 1. So sánh Hiệu năng giữa các mô hình

Mô hình	MAE	RMSE	R2	MAPE (%)	Độ chính xác (Sai số < 20%)	Thời gian dự đoán (ms)
LR	1567.58	1796.50	0.1664	126.96	18.71	14.04
RF	466.00	700.78	0.8732	21.85	68.54	19.47
LGBM	1366.21	1628.85	0.3147	92.46	22.82	994.00
XGB	290.09	507.70	0.9334	13.75	84.19	3.35

Như thể hiện trong Bảng 1, XGB vượt trội hơn đáng kể so với cả LR, RF và LGBM. Nhóm mô hình LR đạt hiệu năng thấp ($R^2 \approx 0.17$, MAPE trên 126%), phản ánh khả năng xử lý kém của dữ liệu phi tuyến trên đường đi thực tế. Kể cả đối với LGBM, dù là mô hình Deep Learning có tên tuổi, nhưng sai số vẫn khá cao ($R^2 \sim 0.31$, RMSE ~ 1628) và độ trễ đồ sộ lên đến xấp xỉ 1 giây ($\sim 994ms$) chứng tỏ nó là thiết kế cồng kềnh, không phù hợp cho phản ứng nhanh cấp bách.



Hình 3: Biểu đồ so sánh trực quan các chỉ số hiệu năng (Accuracy, RMSE, Latency, MAPE) giữa các mô hình dự báo.

Các mô hình dạng rừng cây cho kết quả vượt trội. RF đạt $R^2 = 0.87$. Nổi bật nhất hoàn toàn là XGB - khi đạt mức R^2 kỷ lục (≈ 0.93) với độ trễ phản hồi nhanh không tưởng (~ 3.35 ms so với 19.47 ms của RF). Điều này cho thấy XGB là trái tim tối ưu để được đưa vào các vi điều khiển Edge, khi vừa đảm bảo độ chính xác thượng thừa ($ACC_{20} = 84.19\%$) vừa đáp ứng nhu cầu thay đổi tín hiệu nhạy đèn tính bằng mili-giây.

Biểu đồ Hình 3 cung cấp một góc nhìn trực quan và toàn diện về sự tương quan giữa các mô hình trên bốn phương diện cốt lõi. Trong khi nhóm chỉ số sai số (RMSE và MAPE) của XGB sụt giảm hướng xuống mức thấp nhất đồ thị, cấu trúc cây quyết định này lại vươn lên dẫn đầu ấn tượng ở cột Độ chính xác (Accuracy > 84%). Đặc biệt, điểm nhấn mang tính quyết định nằm ở biểu đồ gốc dưới cùng bên trái biểu diễn Độ trễ phản hồi (Inference Latency). Cột trễ của mô hình LGBM phình to một cách cực đoan (kéo dài đến mức nghẽn cổ chai với xấp xỉ 1400ms), tạo nên sự đối lập hoàn toàn với thanh biểu đồ siêu thấp (chỉ vài mili-giây và gần như chạm đáy baseline) của XGB hay LR. Minh chứng từ hình ảnh này tiếp tục cho thấy những hạn chế đáng kể về tính khả thi khi triển khai các mô hình học sâu có độ phức tạp cao (chẳng hạn như LGBM) trên thiết bị tính toán biên (Edge). Đồng thời, kết quả cũng cho thấy XGB đạt được sự cân bằng hiệu quả giữa độ chính xác dự báo và hiệu năng xử lý, phù hợp hơn với các yêu cầu tài nguyên hạn chế trong môi trường Edge.

3.2. Đánh giá Hiệu năng hệ thống Edge

Ngoài độ chính xác phân tích, tính khả thi khi triển khai trên các thiết bị tài nguyên thấp (Edge Devices) như STM32, ESP32 hay vi máy tính nhúng là yếu tố then chốt. Nhằm phản ánh sát thực tế, chúng tôi đã tiến hành một quá trình Benchmark chuyên nghiệp ngặt dành cho thiết bị vi ba: đánh giá thông lượng dự đoán (Throughput) liên tục của 10,000 requests ngẫu nhiên liên tiếp trên bộ nhớ hệ thống.

Bảng 2. Đánh giá Benchmark hiệu năng thời gian thực tại mảng Biên (Edge)

Mô hình	Độ trễ (ms)	Thông lượng	Xử lý 50 mẫu (ms)	Đánh giá
LG	0.11	$\sim 3,540,826$	0.3	Cực nhanh gọn nhưng hiệu suất dự báo hạn chế, dẫn đến kiểm soát tín hiệu lỗi
RF	4.77	$\sim 205,679$	3.41	Chậm hơn XGBoost khoảng 10 lần, số lượng cây lớn làm quá tải RAM nội của điều khiển nhúng
LGBM	101.18	$\sim 12,455$	111.77	Trễ xấp xỉ 100ms trên một frame và chiếm mất bộ xử lý, hoàn toàn không khả thi để nhúng phần cứng
XGB	0.51	$\sim 429,065$	0.83	Cân bằng hoàn hảo: Trễ suy diễn cực thấp dưới 1ms, không gây thắt cổ chai vòng lặp điều khiển đèn LED/chuông

Kết quả thực nghiệm tại Bảng 2 tái khẳng định ưu thế tuyệt đối của thuật toán XGB. Trong khi LGBM mắc kẹt với số vòng lặp tái tính toán nặng nề (độ trễ ~ 101.18 ms), XGB

giải quyết phép tính ở thời gian nháy mắt là **0.51 ms**. Trong một giây, XGB xử lý trót lọt xấp xỉ 430 nghìn yêu cầu (Throughput > 429k req/s). Điều này đem lại độ tĩnh (stability) cho CPU tại ngã tư giao thông: hệ thống vừa thu nhận dữ liệu hình ảnh, vừa xử lý học máy mà không sợ tràn hoặc ngậm chu kỳ xung nhịp (Clock cycle overhead).

Bảng 3: Log thực tế mô phỏng thời gian thực hệ thống Edge Gateway (Dựa trên mô hình XGB lưu trữ bộ nhớ cục bộ)

Dấu thời gian (Timestamp)	Điều kiện Đầu vào (Input)	Thời gian suy diễn (Latency)	Lượng phương tiện dự báo	Lệnh Hệ thống (Action)
01:28:12	H:12, W:Clouds	2.74 ms	5,092 xe	Kéo dài Đèn Xanh (Ưu tiên Cao điểm)
01:28:13	H:02, W:Clear	2.43 ms	591 xe	Giảm Chu Kỳ Đèn (Chế độ Đèn Vàng)
01:28:18	H:23, W:Mist	1.29 ms	2,094 xe	Bình Thường
01:28:20	H:15, W:Clouds	2.95 ms	5,507 xe	Kéo dài Đèn Xanh (Ưu tiên Cao điểm)
01:28:23	H:01, W:Rain	1.91 ms	422 xe	Giảm Chu Kỳ Đèn (Chế độ Đèn Vàng)
01:28:24	H:12, W:Haze	0.88 ms	4,505 xe	Kéo dài Đèn Xanh (Ưu tiên Cao điểm)

Quá trình mô phỏng thiết bị Edge (Jetson Nano/STM32 Emulator) trong Bảng 3 thể hiện rõ cách thức hệ thống đưa ra phán quyết độc lập ở mức siêu nhỏ (Micro-levels). Khi bắt được các điều kiện thời tiết hoặc khung giờ đặc thù từ thiết bị cảm nhận ngoại vi (Perception Layer), máy tính Biên ngay lập tức đẩy mảng vector về lõi XGB để dự đoán lượng giao thông đổ về ngã tư. Toàn bộ chu trình từ lúc nhận lệnh đến lúc trả quyết định nháy đèn tín hiệu duy trì ổn định dưới 3 mili-giây (thấp nhất 0.88 ms ở giờ H:12 - Haze).

Đáng chú ý, các quyết định điều khiển hoàn toàn bám sát kịch bản giao thông vật lý thực: Trong khung giờ 12h trưa - 15h chiều (H:12, H:15) kết hợp điều kiện mây (Clouds), lưu lượng vọt lên trên 5000 xe, tử điều khiển lập tức kích hoạt chu trình “Kéo dài Đèn Xanh” để xả dòng phương tiện. Trong khung giờ rạng sáng 01h - 02h (H:01, H:02) kết hợp trời mưa/trong trời, lưu lượng rơi xuống mức rất thấp <1000 xe (591 xe, 422 xe). Kịch bản thông minh kích hoạt trạng thái “Giảm Chu Kỳ Đèn”, chuyển đèn chớp Vàng nhằm tối ưu hóa thời gian chờ đợi lãng phí đối với các nhóm phương tiện đơn lẻ vượt qua ngã tư ban đêm.

4. KẾT LUẬN

Trong nghiên cứu này, chúng tôi đã đề xuất một kiến trúc Hệ thống Giao thông Thông minh phân cấp (Hybrid Edge-Cloud) kết hợp mô hình học máy nhằm giải quyết bài toán dự báo lưu lượng và điều khiển tín hiệu đèn giao thông theo thời gian thực. Kết quả thực nghiệm đối chiếu toàn diện trên bộ dữ liệu quy mô lớn đã chứng minh sự vượt trội tuyệt đối của mô hình XGB so với mạng nơ-ron học sâu (LGBM) hay các thuật toán học máy truyền thống. Mô hình XGB không chỉ đạt độ chính xác dự báo xuất sắc với hệ số xác định $R^2 = 0.9334$ và sai

số MAPE ở mức 13.75%, mà còn đáp ứng hoàn hảo những ràng buộc khắt khe về mặt tài nguyên của các thiết bị tính toán Biên (Edge Computing).

Thông qua các kịch bản đo kiểm chuẩn (benchmark) khắc nghiệt, giải pháp lõi đạt thông lượng hơn 429,000 yêu cầu/giây với độ trễ suy diễn chỉ xấp xỉ 0.51 ms. Thành tựu này minh chứng tính khả thi cao trong việc triển khai thuật toán trực tiếp lên các vi điều khiển hoặc máy tính nhúng hạn chế tài nguyên (như họ vi điều khiển STM32) đặt tại các nút giao lộ. Nhờ vậy, hệ thống loại bỏ triệt để độ trễ do phụ thuộc mạng viễn thông khi giao tiếp với Đám mây, tự chủ ra các quyết định điều tiết tín hiệu đèn nhấp bèn và tuân thủ chặt chẽ diễn biến thực tế của dòng phương tiện.

Trong khía cạnh phát triển tương lai (Future Works), nghiên cứu sẽ tập trung mở rộng giải pháp bằng cách tích hợp song song luồng dữ liệu thời tiết với camera nhận diện thị giác máy cảnh báo sự kiện trên đường. Đồng thời, nhóm tác giả định hướng thiết kế và triển khai một bo mạch phần cứng nguyên mẫu (Proof-of-Concept) chạy thử nghiệm thực nghiệm (on-field testing) trên các tuyến phố hạn chế tín hiệu, nhằm đánh giá độ ổn định và tối ưu hệ thống trong môi trường giao thông phức hợp. Qua đó, nghiên cứu góp phần định hướng phát triển các hệ thống giao thông thông minh theo hướng chính xác, linh hoạt và sẵn sàng triển khai trong thực tế, đặc biệt phù hợp với bối cảnh đô thị đang phát triển nhanh như Hà Nội và các thành phố lớn tại Việt Nam.

TÀI LIỆU THAM KHẢO

- [1]. R. Samantaray, A. Kumari, A. Swarup and J. R. Swain, "Traffic Sign Improvement using AI," *2024 5th IEEE Global Conference for Advancement in Technology (GCAT)*, Bangalore, India, 2024, pp. 1-6, doi: 10.1109/GCAT62922.2024.10924042.
- [2]. F. Nie, W. Liu, G. Liu, B. Gao, J. Huang and C. Yuen, "IoT-TSO: An Unsupervised Method for Classifying Malicious IoT Traffic via Tensor Self-Optimization," in *IEEE Transactions on Network Science and Engineering*, vol. 13, pp. 966-979, 2026, doi: 10.1109/TNSE.2025.3588739.
- [3]. M. Mavani, P. Chaturvedi and S. Manekar, "Comparative Analysis of Time Series Models for Traffic Flow Prediction," *2023 10th IEEE Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON)*, Gautam Buddha Nagar, India, 2023, pp. 788-794, doi: 10.1109/UPCON59197.2023.10434410.
- [4]. N. Deeban and P. S. Bharathi, "A Robust and Efficient Traffic Analysis for 5G Network Based on Hybrid LSTM comparing with XGBoost to Improve Accuracy," *2023 International Conference on Artificial Intelligence and Knowledge Discovery in Concurrent Engineering (ICECONF)*, Chennai, India, 2023, pp. 1-8, doi: 10.1109/ICECONF57129.2023.10083633.
- [5]. N. S. Chauhan, N. Kumar and A. Eskandarian, "A Novel Confined Attention Mechanism Driven Bi-GRU Model for Traffic Flow Prediction," in *IEEE Transactions on Intelligent Transportation Systems*, vol. 25, no. 8, pp. 9181-9191, Aug. 2024, doi: 10.1109/TITS.2024.3375890.