

Nghiên cứu phân tích và trích xuất đặc trưng dữ liệu giao thông từ camera giám sát phục vụ cho mô hình dự báo lưu lượng

Research on analyzing and extracting traffic data features from surveillance cameras for traffic forecasting model

> TS. PHẠM THỊ LÝ

Trường Đại học Giao thông vận tải

Email: ptlydk@utc.edu.vn

TÓM TẮT

Nội dung bài báo đưa ra chương trình và kết quả của việc phân tích bộ dữ liệu được thu thập từ camera giao thông bao gồm 2.976 bản ghi dưới định dạng tệp CSV, bao gồm 9 trường thông tin. Kết quả của nghiên cứu đã phân tích và tìm ra được loại phương tiện chi phối tổng thể của hệ thống; phân tích được lưu lượng giao thông theo thời gian với hành vi đi lại hàng ngày của người tham gia giao thông, bao gồm việc di chuyển đến và rời khỏi nơi làm việc; phân tích được sự phân bố các tình huống giao thông, cho thấy trạng thái lưu thông phổ biến trong tập dữ liệu giúp cho việc đánh giá mức độ thách thức của bài toán dự báo lưu lượng giao thông và hiệu suất của mô hình. Ngoài ra, nghiên cứu cũng trích chọn được đặc trưng của dữ liệu giúp giảm độ phức tạp, cải thiện độ chính xác, giảm rủi ro overfitting, biết feature nào ảnh hưởng mạnh nhất đến kết quả, giúp phân tích sâu hơn cho mô hình dự báo lưu lượng giao thông sẽ triển khai.

Từ khóa: Lưu lượng giao thông, mô hình dự báo, phân tích dữ liệu, dữ liệu lớn, trí tuệ nhân tạo.

ABSTRACT

The paper presents the program and results of the analysis of a data set collected from traffic cameras including 2976 records in CSV file format, including 9 information fields. The results of the study analyzed and found the type of vehicle that is the majority at the intersection; analyzed real-time traffic flow with daily travel behavior of traffic participants including moving to and from work; analyzed the distribution of traffic situations, showing common traffic states in the data set to help assess the level of challenge of the traffic forecasting problem and the performance of the model. In addition, the study also extracted data features to reduce complexity, improve accuracy, reduce the risk of overfitting, know which features have the strongest influence on the results, helping to further analyze the traffic forecasting model to be deployed.

Keywords: Traffic flow, forecasting model, data analysis, Big data, artificial intelligence.

1. ĐẶT VẤN ĐỀ

Những năm gần đây, cùng với sự phát triển của khoa học công nghệ và đặc biệt là kỹ thuật trí tuệ nhân tạo đã giúp mọi mặt trong đời sống trở nên dễ dàng hơn. Trong đó, lĩnh vực GTVT cũng không ngoại lệ. Để áp dụng các thuật toán trí tuệ nhân tạo vào việc điều khiển luồng tín hiệu giao thông tại các nút giao thì rất cần thiết phải thu thập bộ dữ liệu lớn và phân tích, lựa chọn đặc tính phù hợp cho việc triển khai các thuật toán [1-12]. Việc phân tích dữ liệu đóng vai trò quan trọng, biến dữ liệu "thô" được thu thập, phân tích thành

thông tin có giá trị. Với hàng triệu bản ghi giao thông, sau khi được phân tích dữ liệu sẽ phát hiện được thời điểm và địa điểm hay tắc đường để từ đó có phương án điều chỉnh phù hợp. Dựa trên việc phân tích dữ liệu từ bộ dữ liệu lớn, các quyết định sẽ không còn cảm tính mà dựa trên bằng chứng rõ ràng giúp giảm thiểu rủi ro, nâng cao độ tin cậy cho các chiến lược. Dữ liệu lịch sử kết hợp với các mô hình phân tích có thể cho phép dự báo xu hướng, giúp chuẩn bị trước kế hoạch, tránh bị động (ví dụ dự đoán lưu lượng xe mùa lễ, tết để điều tiết giao thông trước). Phân tích dữ liệu sẽ giúp phát

hiện những điểm bất cập cần phải cải thiện giúp doanh nghiệp vận tải tổ chức hoạt động hiệu quả hơn, chi phí thấp hơn (ví dụ phân tích hành trình xe buýt để tối ưu hóa lịch trình, tiết kiệm nhiên liệu). Phân tích dữ liệu thu thập từ hệ thống camera giao thông giúp giám sát giao thông theo thời gian thực nhằm phát hiện kịp thời các sự cố như tai nạn, tắc đường, xe vi phạm giao thông; dự đoán tắc nghẽn từ đó đưa ra điều chỉnh đèn tín hiệu, phân luồng giao thông hợp lý và quản lý ùn tắc giao thông. Ngoài ra, khi phân tích dữ liệu từ camera giao thông có thể xác định mật độ xe theo từng tuyến, từng khung giờ, giúp cơ quan quản lý lên kế hoạch tổ chức giao thông tốt hơn... Bài báo đưa ra một nghiên cứu xây dựng hệ thống phân tích dữ liệu cho bộ dữ liệu thu thập từ camera giám sát giao thông, có định dạng CSV, 2976 bản ghi, 9 trường thông tin phục vụ cho mô hình dự báo.

2. NỘI DUNG

2.1. Mô tả dữ liệu

Tập dữ liệu được sử dụng trong nghiên cứu có nguồn gốc từ camera giám sát giao thông có ứng dụng mô hình thị giác máy tính [3]. Bộ dữ liệu được lưu trữ trong 2.976 bản ghi dưới định dạng tệp CSV, bao gồm 9 trường thông tin. Các cột bổ sung như thời gian tính theo giờ, ngày, ngày trong tuần và số lượng cho từng loại phương tiện (CarCount, BikeCount, BusCount, TruckCount). Cột "Tổng" biểu thị tổng số lượng của tất cả các loại phương tiện được phát hiện trong khoảng thời gian 15 phút. Bộ dữ liệu được cập nhật sau mỗi 15 phút, cung cấp chế độ xem toàn diện về các mô hình giao thông trong suốt một tháng. Ngoài ra, bộ dữ liệu bao gồm một cột chỉ ra tình hình giao thông được phân loại thành bốn loại: 1 - Heavy, 2 - High, 3 - Normal và 4 - Low. Thông tin này có thể giúp đánh giá mức độ nghiêm trọng của tình trạng tắc nghẽn và theo dõi tình trạng giao thông tại các thời điểm và ngày khác nhau trong tuần.

Time	Date	Day of the week	CarCount	BikeCount	BusCount	TruckCount	Total	Traffic Situation	
0	12:00:00 AM	10	Tuesday	31	0	4	4	39	low
1	12:15:00 AM	10	Tuesday	49	0	3	3	55	low
2	12:30:00 AM	10	Tuesday	46	0	3	6	55	low
3	12:45:00 AM	10	Tuesday	51	0	2	5	58	low
4	1:00:00 AM	10	Tuesday	57	6	15	16	94	normal
...
2971	10:45:00 PM	9	Thursday	16	3	1	36	56	normal
2972	11:00:00 PM	9	Thursday	11	0	1	30	42	normal
2973	11:15:00 PM	9	Thursday	15	4	1	25	45	normal
2974	11:30:00 PM	9	Thursday	16	5	0	27	48	normal
2975	11:45:00 PM	9	Thursday	14	3	1	15	33	normal

2976 rows x 9 columns

Hình 1. Bộ dữ liệu giao thông dùng cho hệ thống phân tích dữ liệu

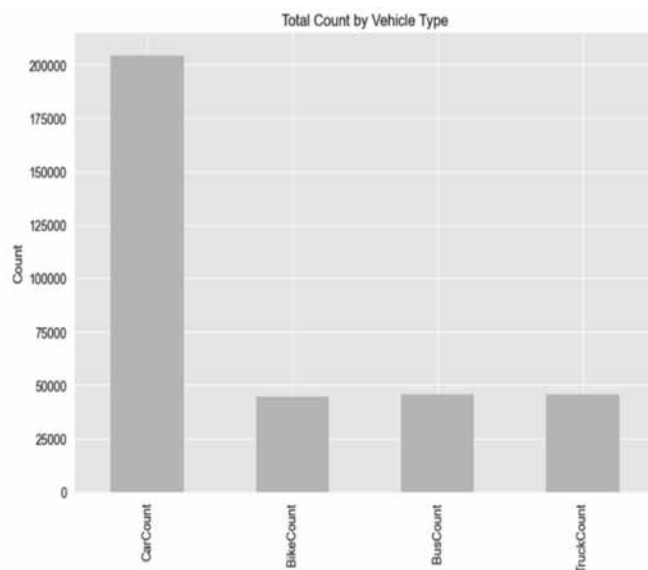
2.2. Phân tích dữ liệu

1. Thống kê số lượng phương tiện

Chương trình:

```
import seaborn as sns
import matplotlib.pyplot as plt
%matplotlib inline
# Set the style for better aesthetics
plt.style.use('seaborn-v0_8')
fig, axes = plt.subplots(2, 2, figsize=(16, 12))
# 1. Distribution of vehicle types// Loại phương tiện giao thông
vehicle_data = traffic_data[['CarCount', 'BikeCount', 'BusCount', 'TruckCount']].sum()
```

```
vehicle_data.plot(kind='bar', ax=axes[0, 0], color='skyblue')
axes[0, 0].set_title('Total Count by Vehicle Type')
axes[0, 0].set_ylabel('Count')
```



Hình 2. Tổng số lượng theo loại phương tiện

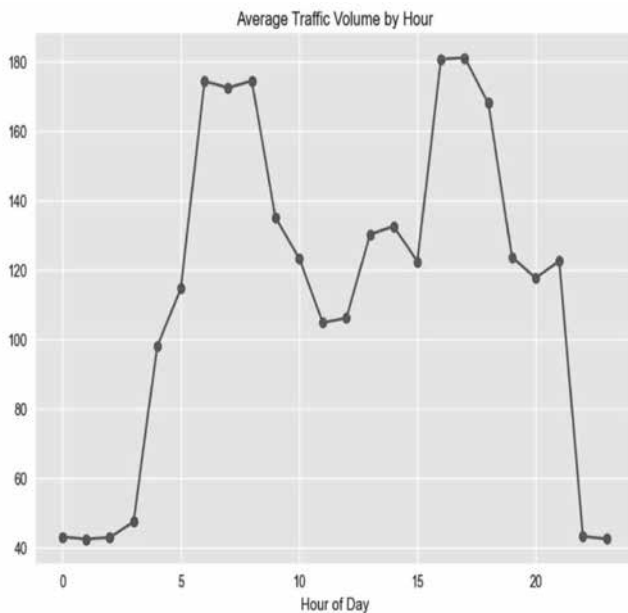
Trên biểu đồ kết quả "Tổng số lượng theo loại phương tiện", chỉ ra thành phần của dòng giao thông dựa trên phân loại phương tiện. Trong đó, loại phương tiện "Car" (ô tô con) chiếm số lượng lớn hơn so với các loại phương tiện khác như "Bike" (xe máy/xe đạp), "Bus" (xe buýt) và "Truck" (xe tải). Sự phân bố không đồng đều này cho thấy ô tô con là thành phần chính chi phối lưu lượng tổng thể, điều này có thể ảnh hưởng đến đặc điểm của dòng giao thông và cần được xem xét khi phân tích hoặc mô hình hóa, đặc biệt nếu mô hình có khả năng phân biệt các loại phương tiện.

2. Lưu lượng giao thông trung bình theo giờ

Chương trình:

```
traffic_data['Hour'] = pd.to_datetime(traffic_data['Time']).dt.hour
hourly_traffic = traffic_data.groupby('Hour')['Total'].mean()
hourly_traffic.plot(kind='line', ax=axes[0, 1], marker='o', color='green')
axes[0, 1].set_title('Average Traffic Volume by Hour')
axes[0, 1].set_xlabel('Hour of Day')
axes[0, 1].set_ylabel('Average Vehicle Count')
```

Phân tích lưu lượng giao thông theo thời gian là yếu tố cốt lõi trong dự báo. Biểu đồ "Lưu lượng giao thông trung bình theo giờ" thể hiện rõ ràng tính chu kỳ hàng ngày đặc trưng của giao thông đô thị. Đường biểu diễn cho thấy lưu lượng thấp nhất vào ban đêm, bắt đầu tăng dần từ sáng sớm và đạt đỉnh điểm đầu tiên vào khoảng giờ đi làm buổi sáng (khoảng 7 - 9 giờ). Sau đó, lưu lượng giảm xuống vào giữa ngày và tăng trở lại, đạt đỉnh điểm thứ hai và thường là cao nhất vào giờ tan tầm buổi chiều/tối (khoảng 16 - 18 giờ), trước khi giảm nhanh chóng vào cuối ngày. Mẫu hình này phản ánh hành vi đi lại hàng ngày của người dân, bao gồm việc di chuyển đến và rời khỏi nơi làm việc, là đặc điểm quan trọng cần được nắm bắt bởi mô hình dự báo.



Hình 3. Lưu lượng giao thông trung bình theo giờ

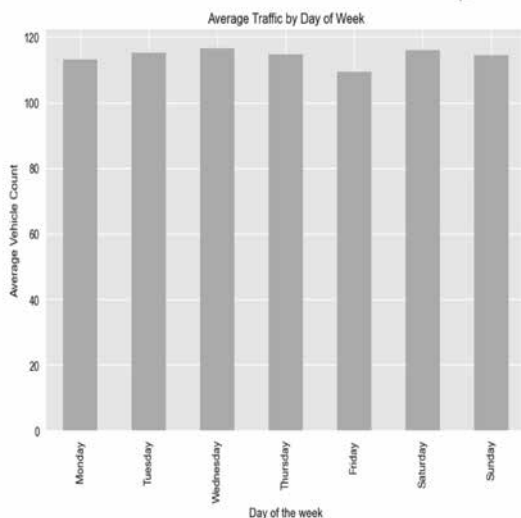
3. Lưu lượng giao thông trung bình theo ngày trong tuần

Chương trình:

```
day_order = ['Monday', 'Tuesday', 'Wednesday', 'Thursday',
'Friday', 'Saturday', 'Sunday']
day_traffic = traffic_data.groupby('Day of the week')['Total'].
mean()
day_traffic = day_traffic.reindex(index=[d for d in day_order if
d in day_traffic.index])
```

```
day_traffic.plot(kind='bar', ax=axes[1, 0], color='orange')
axes[1, 0].set_title('Average Traffic by Day of Week')
axes[1, 0].set_ylabel('Average Vehicle Count')
```

Kết quả đạt được như trên Hình 3:



Hình 4. Lưu lượng giao thông trung bình theo ngày trong tuần

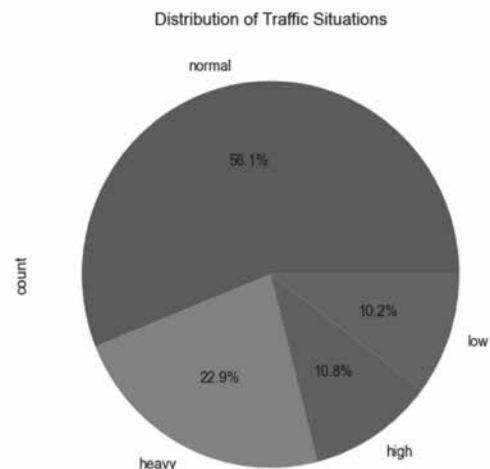
Ngoài biến động hàng ngày, lưu lượng giao thông còn thể hiện sự khác biệt giữa các ngày trong tuần. Biểu đồ “Lưu lượng giao thông trung bình theo ngày trong tuần” cho thấy sự biến động của lưu lượng trung bình từ thứ hai đến chủ nhật. Thông thường, các ngày trong tuần (thứ hai đến thứ sáu) có xu hướng có lưu lượng

trung bình cao hơn do hoạt động đi lại phục vụ công việc và học tập. Cuối tuần (thứ bảy và chủ nhật) có thể có lưu lượng khác biệt, tùy thuộc vào mục đích của các chuyến đi (mua sắm, giải trí...). Phân tích này giúp xác định liệu có cần xử lý riêng dữ liệu ngày thường và cuối tuần hay không trong quá trình dự báo.

4. Phân bố tình trạng giao thông

Chương trình:

```
traffic_data['Traffic Situation'].value_counts().plot(kind='pie',
ax=axes[1, 1], autopct='%1.1f%%')
axes[1, 1].set_title('Distribution of Traffic Situations')
plt.tight_layout()
plt.show()
```



Hình 5. Phân bố các tình huống giao thông

Kết quả cho ra biểu đồ “Phân bố các tình huống giao thông” cung cấp cái nhìn tổng quan về trạng thái lưu thông phổ biến trong tập dữ liệu. Biểu đồ tròn này phân loại lưu lượng thành các tình huống như “normal” (bình thường), “low” (thấp), “high” (cao) và “heavy” (rất cao/ùn tắc nặng). Tỷ lệ phần trăm của mỗi lát cắt cho biết tần suất xuất hiện của từng tình huống. Ví dụ, nếu tình huống “normal” chiếm tỷ lệ lớn nhất, điều này cho thấy phần lớn thời gian giao thông diễn ra ở mức bình thường. Ngược lại, tỷ lệ cao của “high” hoặc “heavy” có thể chỉ ra rằng dữ liệu bao gồm nhiều trường hợp ùn tắc. Thông tin này hữu ích cho việc đánh giá mức độ thách thức của bài toán dự báo và có thể ảnh hưởng đến việc lựa chọn tiêu chí đánh giá hiệu suất mô hình.

Các biểu đồ phân tích dữ liệu ban đầu này cung cấp những hiểu biết sâu sắc về đặc điểm của lưu lượng giao thông nền, bao gồm thành phần phương tiện, tính chu kỳ theo giờ và ngày và phân bố các mức độ tắc nghẽn. Những thông tin này là nền tảng quan trọng để hiểu rõ dữ liệu, xác định các yếu tố ảnh hưởng chính đến lưu lượng và xây dựng/đánh giá các mô hình dự báo lưu lượng giao thông một cách hiệu quả.

2.3. Trích chọn đặc trưng dữ liệu

```
# Create a correlation matrix for the vehicle counts and total
traffic
corr_matrix = traffic_data[['CarCount', 'BikeCount', 'BusCount',
'TruckCount', 'Total']].corr()
# Plot the correlation heatmap
```

```


plt.figure(figsize=(10, 8))
heatmap = sns.heatmap(corr_matrix, annot=True,
cmap='coolwarm', vmin=-1, vmax=1)
plt.title('Correlation Between Vehicle Types and Total Traffic')
plt.tight_layout()
# Create a composite traffic pattern analysis
fig, axes = plt.subplots(1, 2, figsize=(16, 6))
# 1. Stacked area chart of vehicle composition over the day
hourly_composition = traffic_data.groupby('Hour')
[['CarCount', 'BikeCount', 'BusCount', 'TruckCount']].mean()
hourly_composition.plot.area(stacked=True, ax=axes[0],
color=['#4e79a7', '#f28e2c', '#e15759', '#7b7b21'])
axes[0].set_title('Vehicle Composition by Hour of Day')
axes[0].set_xlabel('Hour')
axes[0].set_ylabel('Average Count')
axes[0].legend(loc='upper right')
# 2. Traffic situation by hour
traffic_situation_hour = traffic_data.groupby(['Hour', 'Traffic
Situation']).size().unstack().fillna(0)
traffic_situation_hour.plot(kind='bar', stacked=True,
ax=axes[1],
color=['#59a14f', '#f1ce63', '#e15759'])
axes[1].set_title('Traffic Situation Distribution by Hour')
axes[1].set_xlabel('Hour of Day')
axes[1].set_ylabel('Count')
plt.tight_layout()
plt.show()
# Calculate percentage of each vehicle type in total traffic
traffic_data['CarPercent'] = traffic_data['CarCount'] / traffic_
data['Total'] * 100
traffic_data['BikePercent'] = traffic_data['BikeCount'] / traffic_
data['Total'] * 100
traffic_data['BusPercent'] = traffic_data['BusCount'] / traffic_
data['Total'] * 100
traffic_data['TruckPercent'] = traffic_data['TruckCount'] /
traffic_data['Total'] * 100
# Show summary statistics of vehicle percentages
vehicle_percentage_summary = traffic_data[['CarPercent',
'BikePercent', 'BusPercent', 'TruckPercent']].describe()
display(vehicle_percentage_summary)

```

Trích chọn đặc trưng dữ liệu để đánh giá mối quan hệ giữa các biến thông qua biểu đồ ma trận tương quan, được trình bày dưới dạng heatmap (Hình 5). Biểu đồ này hiển thị hệ số tương quan Pearson giữa tất cả các cặp biến trong tập dữ liệu, bao gồm Time (giờ trong ngày), Date (ngày tháng), Day of the week (ngày trong tuần), số lượng của từng loại phương tiện (ô tô, xe máy/xe đạp, xe buýt, xe tải), tổng số lượng phương tiện và tình huống giao thông. Giá trị trong mỗi ô của ma trận thể hiện cường độ và chiều của mối quan hệ tuyến tính giữa hai biến tương ứng.

Từ Hình 5, phân tích mối tương quan giữa các loại phương tiện riêng lẻ với tổng số lượng phương tiện cho thấy được cấu trúc của dòng giao thông. Hệ số tương quan rất cao giữa Car Count và Total (0,97) cho thấy ô tô con là thành phần chiếm tỷ trọng lớn nhất và có sự biến động gần gũi nhất với tổng lưu lượng. Bike Count cũng cho thấy tương quan mạnh với Total (0,89), trong khi Bus Count (0,79)

và Truck Count (0,73) có mức độ tương quan với Total thấp hơn một chút. Điều này củng cố nhận định từ biểu đồ tổng số lượng theo loại phương tiện và chỉ ra rằng các mô hình dự báo lưu lượng tổng thể có thể được chi phối chủ yếu bởi hành vi của ô tô con và xe máy/xe đạp. Mỗi tương quan thuận mạnh nhưng không quá cao giữa các loại phương tiện với nhau (ví dụ: Car Count với Bike Count là 0,72) cho thấy mặc dù chúng có xu hướng biến động cùng chiều, nhưng mức độ đồng bộ không hoàn toàn tuyệt đối, phản ánh sự khác biệt trong mục đích và thời gian di chuyển của từng loại phương tiện.



Hình 6. Biểu đồ nhiệt phục vụ trích chọn đặc trưng

Tiếp theo, xem xét mối quan hệ của các yếu tố thời gian với lưu lượng. Biến Time (giờ trong ngày) có mối tương quan thuận ở mức trung bình với các biến đếm số lượng phương tiện (khoảng 0,30 đến 0,45) và với tổng số lượng phương tiện (0,48). Mặc dù không phải là tương quan rất mạnh (gần 1), giá trị tương quan này cho thấy có một xu hướng tăng lưu lượng tuyến tính chung trong ngày (ví dụ: từ sáng đến chiều tối). Tuy nhiên, hệ số tương quan này có thể không hoàn toàn phản ánh đúng bản chất phi tuyến tính của biến động lưu lượng theo giờ (với các đỉnh và đáy rõ rệt), mà chủ yếu bắt giữ xu hướng tổng thể. Điều này ngụ ý rằng các mô hình dự báo cần có khả năng nắm bắt các mẫu hình phi tuyến tính và tính chu kỳ theo giờ chứ không chỉ dựa vào mối quan hệ tuyến tính đơn giản với biến "Time". Mặt khác, biến Day of the week cho thấy mối tương quan rất yếu hoặc gần như không có với tất cả các biến đếm số lượng và Tổng lưu lượng (hệ số rất gần 0). Điều này khá bất ngờ nếu chúng ta kỳ vọng lưu lượng ngày thường và cuối tuần khác biệt rõ rệt. Một khả năng là biến "Day of the week" trong tập dữ liệu được mã hóa theo cách không tạo ra mối quan hệ tuyến tính mạnh với lưu lượng, hoặc ảnh hưởng của ngày trong tuần là làm thay đổi mức lưu lượng trung bình tổng thể chứ không phải là một tương quan tuyến tính trực tiếp với các biến đếm trong toàn bộ tập dữ liệu. Việc này cần được làm rõ thêm thông qua phân tích các biểu đồ trung bình theo ngày đã trình bày trước đó, vốn đã chỉ ra sự khác biệt.

Cuối cùng, mối quan hệ giữa Tình huống giao thông (Traffic Situation) và các biến khác là cực kỳ quan trọng. Biến Traffic Situation cho thấy mối tương quan thuận mạnh mẽ với Tổng số lượng phương tiện (0,88). Điều này khẳng định một cách định lượng rằng khi số lượng phương tiện trên đường tăng lên, tình trạng giao thông có xu hướng xấu đi (chuyển sang “high” hoặc “heavy”). Mối tương quan này cũng mạnh với Car Count (0,87), Bike Count (0,75), Bus Count (0,61) và Truck Count (0,62), lần lượt theo thứ tự đóng góp vào tổng lưu lượng. Mối tương quan dương nhưng ở mức thấp hơn với Time (0,29) và gần như không có với Day of the week (-0,02) ngụ ý rằng mặc dù giờ cao điểm có xu hướng xảy ra ùn tắc hơn, bản thân biến thời gian và ngày trong tuần không có mối quan hệ tuyến tính mạnh với mức độ nghiêm trọng của tình huống giao thông khi xem xét toàn bộ tập dữ liệu. Điều này nhấn mạnh rằng chính lượng phương tiện trên đường tại một thời điểm mới là yếu tố quyết định chính đến tình huống giao thông. Phân tích ma trận tương quan đã cung cấp bằng chứng định lượng về mối quan hệ giữa các biến. Nó xác nhận tầm quan trọng của các loại phương tiện, đặc biệt là ô tô con, đối với tổng lưu lượng, làm nổi bật sự phụ thuộc của lưu lượng vào yếu tố thời gian trong ngày (dù không hoàn toàn tuyến tính) và chứng minh mối liên hệ chặt chẽ giữa tổng số lượng phương tiện và tình trạng giao thông. Mặc dù mối quan hệ với ngày trong tuần có vẻ yếu về mặt tuyến tính, các phân tích khác (như biểu đồ trung bình theo ngày) có thể tiết lộ những khác biệt phi tuyến tính hoặc ảnh hưởng gián tiếp. Những phát hiện này là nền tảng vững chắc cho việc lựa chọn các biến đầu vào cho mô hình dự báo và hiểu rõ hơn về các yếu tố chi phối lưu lượng giao thông.

3. KẾT LUẬN

Nội dung bài báo này chỉ tập trung nghiên cứu phân tích bộ dữ liệu được thu thập từ camera giao thông gồm 2.976 bản ghi dưới định dạng tệp CSV, bao gồm 9 trường thông tin phục vụ cho mô hình dự báo lưu lượng giao thông. Nghiên cứu đã phân tích và tìm ra được loại phương tiện chi phối tổng thể của hệ thống; phân tích được lưu lượng giao thông theo thời gian với hành vi đi lại hàng ngày của người tham gia giao thông bao gồm việc di chuyển đến rời khỏi nơi làm việc; phân tích được sự phân bố các tình huống giao thông, cho thấy trạng thái lưu thông phổ biến trong tập dữ liệu giúp cho việc đánh giá mức độ thách thức của bài toán dự báo lưu lượng giao thông và hiệu suất của mô hình. Ngoài ra, nghiên cứu này cũng đã trích chọn được các đặc trưng phục vụ cho mô hình dự báo lưu lượng giao thông từ bộ dữ liệu thu được từ camera giám sát giao thông. Tuy nhiên, nội dung bài báo này mới chỉ dừng lại ở phạm vi phân tích dữ liệu mà chưa đưa ra mô hình dự báo lưu lượng giao thông. Việc nghiên cứu xây dựng mô hình dự báo lưu lượng giao thông dựa trên bộ dữ liệu hiện có và các phân tích dữ liệu thu được từ nghiên cứu này sẽ được nhóm tác giả công bố ở những nghiên cứu tiếp theo.

TÀI LIỆU THAM KHẢO

- [1]. D'Alconzo, I. Drago, A. Morichetta (Sep., 2019), M. Mellia and P. Casas, A Survey on Big Data for Network Traffic Monitoring and Analysis, IEEE Transactions on Network and Service Management, vol.16, no.3, pp.909-923, doi: 10.1109/TNSM.2019.2933358.
- [2]. Y. Miao, Z. Ruan, L. Pan, J. Zhang and Y. Xiang (2018), Comprehensive analysis of network traffic data, Concurrency and Computation: Practice and Experience, vol.30, no.22,

doi: 10.1002/cpe.4181.

- [3]. S. Park, S. Kim and Y. Ha (Dec., 2018), Highway traffic accident prediction using VDS big data analysis, The Journal of Supercomputing, vol.74, no.12, pp.6261-6280, doi: 10.1007/s11227-016-1624-z.
- [4]. B. Shamo, E. Asa and J. Membah (2014), Linear Spatial Interpolation and Analysis of Annual Average Daily Traffic Data, Journal of Computing in Civil Engineering, vol.28, no.4, doi: 10.1061/(ASCE)CP.1943-5487.0000281.
- [5]. J. Han, Z. Li, and L. A. Tang (2010), Mining Moving Object, Trajectory and Traffic Data, in Database Systems for Advanced Applications (DASFAA), Part II, LNCS 5982, Springer, pp 485-486.
- [6]. V. D. Sharma, R. R. Sharma, B. D. Pandey and N. Gupta (1989), Non-linear analysis of a traffic flow, Zeitschrift für Angewandte Mathematik und Physik (ZAMP), vol.40, no.6, pp.828-837.
- [7]. M. Abbasi, A. Shahraki and A. Taherkordi (Apr., 2021), Deep Learning for Network Traffic Monitoring and Analysis (NTMA): A Survey, Computer Communications, vol.170, pp.19-41, doi: 10.1016/j.comcom.2021.01.021.
- [8]. H. Zhang, Y. Zhang, Z. Li and D. Hu (Dec., 2004), Spatial-Temporal Traffic Data Analysis Based on Global Data Management Using MAS, IEEE Transactions on Intelligent Transportation Systems, vol.5, no.4, pp.267-274, doi: 10.1109/TITS.2004.837816.
- [9]. D. E. Duffy, A. A. McIntosh, M. Rosenstein and W. Willinger (Apr., 1994), Statistical Analysis of CCSN/SS7 Traffic Data from Working CCS Subnetworks, IEEE Journal on Selected Areas in Communications, vol.12, no.3, pp.544-551.
- [10]. I. Alam, D. M. Farid, and R. J. F. Rossetti (2019), The Prediction of Traffic Flow with Regression Analysis, in Emerging Technologies in Data Mining and Information Security, A. Abraham et al., Eds., Springer, pp.661-670, doi: 10.1007/978-981-13-1498-8_58.
- [11]. I. Alam, D. Md. Farid and R. J. F. Rossetti (2019), The Prediction of Traffic Flow with Regression Analysis, in Emerging Technologies in Data Mining and Information Security, A. Abraham et al., Eds. Singapore: Springer Nature, pp.661-671, doi: 10.1007/978-981-13-1498-8_58.
- [12]. R. Ling, T. F. Bertel and P. R. Sundsøy (2011), The socio-demographics of texting: An analysis of traffic data, New Media & Society, vol.14, no.2, pp.281-298, doi: 10.1177/1461444811412711.