



یک روش ترکیبی مبتنی بر LSTM و PPO برای پیش‌بینی ترافیک در شبکه‌های خودرویی VANET

الهه دوست صدیق^(۱) کامبیز مجیدزاده^{(۲)*} محمد مصدري^(۳) فرهاد سلیمانیان^(۴) امین بابازاده^(۵)

(۱) گروه مهندسی کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

(۲) گروه مهندسی کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران*

(۳) گروه مهندسی کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

(۴) گروه مهندسی کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

(۵) گروه مهندسی کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

(تاریخ دریافت: ۱۴۰۳/۱۱/۲۰ تاریخ پذیرش: ۱۴۰۴/۰۳/۱۰)

چکیده

پیش‌بینی ترافیک در شبکه‌های خودرویی هوشمند به دلیل تغییرات پویای رفتاری وسایل نقلیه و ویژگی‌های غیرخطی جریان ترافیک به دلیل نوسانات و حجم شدید داده‌ها، رفتارهای پیچیده و غیرقابل پیش‌بینی رانندگان، تغییرات زمانی-مکانی همواره یکی از مسائل مهم در مدیریت بهینه حمل‌ونقل شهری و پیش‌بینی بلادرنگ ترافیک بوده است. الگوریتم‌های یادگیری عمیق قادرند الگوهای پیچیده، غیرخطی و وابسته به زمان را در داده‌های ترافیکی به‌خوبی شناسایی کنند، در حالی که الگوریتم‌های سنتی در مواجهه با چنین پویایی و نوسانات شدید عملکرد ضعیف‌تری دارند. همچنین، یادگیری عمیق امکان بهبود مستمر مدل از طریق داده‌های جدید را فراهم می‌کند. در این مطالعه، مدلی نوین از ترکیب قابلیت یادگیری الگوهای زمانی بلندمدت توسط LSTM و توانمندی الگوریتم PPO در تنظیم سیاست‌های تصمیم‌گیری استفاده شده است که هدف آن ارتقای دقت پیش‌بینی در شبکه‌های VANET است. یافته‌ها بر اساس داده‌های واقعی ترافیکی نشان می‌دهند که ترکیب LSTM و PPO توانسته با دقت ۰٫۹۱۶ و مقدار F1 برابر با ۰٫۹۱۵، نتایجی به مراتب بهتر از مدل‌های پایه ارائه دهد. همچنین، کاهش محسوس خطا با مقادیر MSE برابر ۰٫۱۰۰ و RMSE معادل ۰٫۳۱۶، عملکرد دقیق مدل را تأیید می‌کند. از سوی دیگر، امتیاز بالای ROC-AUC برابر ۰٫۹۸۴، حاکی از توان بالای مدل در تشخیص صحیح وضعیت‌های مختلف ترافیکی است. به طور کلی، نتایج این پژوهش نشان می‌دهد که بهره‌گیری هم‌زمان از LSTM و الگوریتم PPO می‌تواند راهکاری مؤثر برای بهبود پیش‌بینی ترافیک در بستر شبکه‌های خودرویی هوشمند باشد.

کلمات کلیدی: پیش‌بینی ترافیک، شبکه‌های خودرویی هوشمند، VANET، LSTM، الگوریتم بهینه‌سازی سیاست مجاور، PPO

*عهده‌دار مکاتبات:

کامبیز مجیدزاده

نشانی: گروه مهندسی کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

پست الکترونیکی: Kambiz.Majidzadeh@iau.ac.ir

با افزایش روزافزون استفاده از وسایل نقلیه و رشد سریع شهرنشینی، مدیریت ترافیک شهری به یکی از چالش‌های اساسی جوامع مدرن تبدیل شده است. شبکه‌های خودرویی هوشمند^۱، به عنوان یکی از ابزارهای کلیدی در سیستم‌های حمل و نقل هوشمند، نقش مهمی در جمع‌آوری و به‌اشتراک‌گذاری داده‌های ترافیکی میان خودروها و زیرساخت‌های جاده‌ای ایفا می‌کنند. این شبکه‌ها به خودروها امکان می‌دهند که به‌طور مستقیم با یکدیگر و زیرساخت‌های جاده‌ای ارتباط برقرار کنند. هدف اصلی شبکه‌های خودرویی هوشمند بهبود ایمنی جاده‌ای، کاهش تراکم ترافیک، و ارائه خدمات پیشرفته حمل‌ونقل است. با استفاده از این فناوری، اطلاعات مهمی مانند شرایط ترافیک، وضعیت جوی، یا تصادفات به صورت بی‌درنگ بین خودروها منتقل می‌شود. این قابلیت می‌تواند در کاهش تصادفات، هشدار به رانندگان در مورد موانع جاده‌ای، و ارائه مسیرهای بهینه نقش بسزایی داشته باشد. به‌علاوه، شبکه‌های خودرویی هوشمند به توسعه سیستم‌های حمل‌ونقل خودکار کمک می‌کند که گامی بزرگ به سوی شهرهای هوشمند آینده است [1].

پیش‌بینی دقیق وضعیت ترافیک در شبکه‌های خودرویی هوشمند می‌تواند به بهبود مدیریت ترافیک، کاهش تأخیرهای سفر، بهبود ایمنی جاده‌ای و کاهش آلودگی هوا منجر شود. از این رو، توسعه روش‌های پیش‌بینی دقیق و کارآمد ترافیک در شبکه‌های خودرویی، از اهمیت ویژه‌ای برخوردار است. یکی از نقش‌های مهم پیش‌بینی ترافیک در شبکه‌های خودرویی هوشمند، ارائه مسیرهای کارآمد برای خودروها است. این فرایند بر اساس استفاده از الگوریتم‌های پیشرفته‌ای است که داده‌های لحظه‌ای و اطلاعات تاریخی ترافیک را پردازش می‌کنند. این تحلیل‌ها به شناسایی مسیرهایی منجر می‌شوند که ضمن کاهش مدت زمان سفر، تعادل جریان ترافیکی در سراسر شبکه را حفظ کنند. این توانایی به‌ویژه در زمان وقوع شرایط اضطراری مانند تصادفات یا آب‌وهوای نامساعد اهمیت بالایی دارد، زیرا می‌تواند ازدحام و تأخیرهای احتمالی را به حداقل برساند [2].

استفاده از الگوریتم‌های یادگیری عمیق در پیش‌بینی ترافیک شبکه‌های خودرویی هوشمند به دلیل توانایی آن‌ها در مدیریت داده‌های پیچیده و پویا ضروری است [3]. ترافیک در شبکه‌های خودرویی هوشمند به دلیل رفتارهای غیرقابل پیش‌بینی رانندگان، تغییرات ناگهانی سرعت، و تعاملات پویا بین خودروها، الگوهای غیرخطی و پیچیده‌ای دارد. مدل‌های یادگیری عمیق مانند شبکه‌های عصبی بازگشتی (LSTM)^۲، شبکه‌های کانولوشنی (CNN)^۳، و شبکه‌های

^۱ Vehicular Ad hoc NETwork (VANET)

^۲ Long Short-Term Memory

^۳ Convolutional Neural Network

عصبی گراف (GNN)^۱ می‌توانند این الگوهای پیچیده را مدل‌سازی کرده و با استخراج خودکار ویژگی‌های مهم از داده‌های خام، دقت پیش‌بینی را افزایش دهند [4]. این ویژگی‌ها نیاز به مهندسی دستی ویژگی را حذف کرده و تحلیل داده‌های حجیم و نویزی شبکه‌های خودرویی هوشمند را تسهیل می‌کنند [5].

علاوه بر این، یادگیری عمیق توانایی پردازش داده‌های چندبعدی (زمانی، مکانی، و رابطه‌ای) و تطبیق با داده‌های بلندرنگ را دارد، که برای مدیریت ترافیک در زمان واقعی در شبکه‌های خودرویی هوشمند حیاتی است [6]. به عنوان مثال، مدل‌های ترکیبی مانند LSTM-PPO یا GNN-CNN با ادغام اطلاعات فضایی-مکانی و بهینه‌سازی‌های تقویتی، دقت بالا (بیش از ۰٫۹۰) و خطای کم (MSE زیر ۰٫۱۵) ارائه می‌دهند [4]. این مدل‌ها در مقایسه با روش‌های سنتی مانند رگرسیون خطی یا ARIMA به طور قابل توجهی عملکرد بهتری در سناریوهای پیچیده شهری دارند و راهکاری مؤثر برای بهبود پیش‌بینی ترافیک در شبکه‌های خودرویی هوشمند فراهم می‌کنند [3].

شبکه‌های عصبی LSTM برای پیش‌بینی ترافیک در شبکه‌های خودرویی هوشمند به دلیل توانایی در مدیریت وابستگی‌های بلندمدت سری‌های زمانی، مقاومت در برابر محو شدن گرادیان، انعطاف‌پذیری در پردازش داده‌های نویزی و کارایی در پیش‌بینی‌های بلندرنگ نسبت به دیگر الگوریتم‌های یادگیری عمیق مانند CNN، GNN و ترنسفورمرها ترجیح داده می‌شوند [7]. LSTM می‌تواند الگوهای غیرخطی و پویای ترافیک را با دقت بالا (حدود ۰٫۹۰) و خطای کم (MSE حدود ۰٫۱۰) مدل‌سازی کند، در حالی که CNN برای داده‌های فضایی، GNN برای روابط گرافیکی، و ترنسفورمرها برای داده‌های عظیم مناسب‌ترند [8، 9]. این ویژگی‌ها، همراه با عملکرد اثبات‌شده در سناریوهای شهری، LSTM را به گزینه‌ای ایده‌آل برای پیش‌بینی ترافیک شبکه‌های خودرویی هوشمند تبدیل می‌کنند [10].

شبکه‌های عصبی LSTM برای پیش‌بینی ترافیک شبکه‌های خودرویی هوشمند به دلیل مدیریت وابستگی‌های بلندمدت، مقاومت در برابر محو شدن گرادیان، پردازش داده‌های نویزی، و کارایی بلندرنگ نسبت به BiLSTM، GRU، مبدل‌ها، CNN، GNN ترجیح داده می‌شوند [11]. LSTM با دقت بالا (۰٫۹۰) و خطای کم ($MSE \approx 0.10$) الگوهای پویا را مدل‌سازی می‌کند [12] BiLSTM دقیق‌تر اما سنگین‌تر، GRU سبک‌تر اما در وابستگی‌های طولانی ضعیف‌تر و مبدل‌ها به داده و محاسبات عظیم نیاز دارند [13] و GNN برای داده‌های فضایی و گرافیکی مناسب‌ترند، اما در سری‌های زمانی ضعیف‌اند. لذا LSTM تعادل بهتری برای شبکه‌های خودرویی هوشمند ارائه می‌دهد [14]. با این وجود، شبکه‌های LSTM به تنهایی قادر به تطبیق سریع با تغییرات ناگهانی و رفتارهای پیچیده ترافیکی نیستند. برای رفع این مشکل، الگوریتم‌های تقویتی مانند PPO که در مسائل بهینه‌سازی و تصمیم‌گیری سریع

^۱ Graph Neural Network Graph

استفاده می‌شوند، می‌توانند به بهبود عملکرد شبکه‌های عصبی کمک کنند. الگوریتم PPO به دلیل توانایی در یادگیری بهینه سیاست‌های تصمیم‌گیری در محیط‌های پویای تغییرپذیر، یکی از محبوب‌ترین الگوریتم‌ها در یادگیری تقویتی عمیق است [15].

ترکیب الگوریتم بهینه‌سازی سیاست مجاور (PPO¹) با شبکه‌های عصبی LSTM برای پیش‌بینی ترافیک در شبکه‌های خودرویی هوشمند به دلیل ویژگی‌های منحصربه‌فرد PPO در مقایسه با الگوریتم‌های مشابه یادگیری تقویتی مانند DQN²، TRPO³ و A2C⁴ ترجیح داده می‌شود [16]. PPO با بهینه‌سازی پایدار سیاست‌ها در محیط‌های پویا و نویزی شبکه‌های خودرویی هوشمند، دقت پیش‌بینی را به حدود ۰٫۹۱ و خطای MSE را به ۰٫۱۰ می‌رساند، در حالی که به LSTM کمک می‌کند تا سری‌های زمانی ترافیک را به صورت بلادرنگ مدل‌سازی کند [17]. در مقایسه، DQN که بر یادگیری ارزش‌محور متمرکز است، در محیط‌های با فضای عمل پیوسته (مانند تنظیم پارامترهای پیش‌بینی ترافیک) عملکرد ضعیف‌تری دارد و به محاسبات سنگین‌تری نیاز دارد [18]. TRPO اگرچه در بهینه‌سازی سیاست‌ها پایدار است، پیچیدگی محاسباتی بالایی دارد و پیاده‌سازی آن برای سناریوهای بلادرنگ شبکه‌های خودرویی هوشمند دشوار است. A2C با وجود سادگی و سرعت، به دلیل عدم پایداری در به‌روزرسانی‌های سیاست، ممکن است در داده‌های نویزی و پویا مانند شبکه‌های خودرویی هوشمند به اندازه PPO دقیق نباشد [19]. PPO با تعادل بین سادگی، پایداری، و انعطاف‌پذیری در تطبیق با تغییرات ترافیکی، بهترین مکمل برای LSTM بوده و پیش‌بینی‌های قوی‌تری نسبت به این الگوریتم‌ها ارائه می‌دهد.

در این پژوهش، ما یک مدل ترکیبی از LSTM و PPO را به منظور بهبود دقت و کاهش خطا در پیش‌بینی ترافیک در شبکه‌های خودرویی VANET پیشنهاد می‌کنیم. مدل پیشنهادی از ویژگی‌های حافظه بلندمدت LSTM و قدرت بهینه‌سازی سیاست‌های PPO بهره می‌برد تا تغییرات ناگهانی و پیچیدگی‌های ترافیکی را به طور بهینه مدیریت کند. این مدل با استفاده از داده‌های واقعی ترافیکی ارزیابی شده و عملکرد آن با مدل‌های پایه LSTM و RNN مورد مقایسه قرار گرفته است. نتایج نشان می‌دهد که مدل ترکیبی پیشنهادی، دقت بالاتر و خطای کمتری نسبت به مدل‌های پایه دارد و می‌تواند به عنوان راهکاری موثر برای بهبود مدیریت ترافیک در شبکه‌های شبکه‌های خودرویی هوشمند مورد استفاده قرار گیرد.

1 Proximal Policy Optimization

2 Deep Q-Network

3 Trust Region Policy Optimization

۴ Advantage Actor-Critic

برای دستیابی به این هدف اصلی، اهداف فرعی زیر در نظر گرفته شده است.

۱- طراحی یک مدل دقیق مبتنی بر یادگیری عمیق برای پیش‌بینی ترافیک شبکه، با در نظر گرفتن پارامترهای ترافیک جاده‌ای و شبکه‌ای

۲- پیشنهاد یک الگوریتم هوشمند برای پیش‌بینی ترافیک شبکه در مسائل طبقه‌بندی با استفاده از الگوریتم‌های LSTM و RNN

۳- ارزیابی عملکرد روش‌های پیشنهادی با استفاده از فاکتورهای معیارهای اصلی ارزیابی شامل دقت^۱، فراخوانی^۲، دقت مثبت^۳، نمره F1، AUC-ROC، RMSE^۴ و Log Loss می‌باشد

ادامه این مقاله به شرح زیر می‌باشد. در بخش ۲ به مرور کارهای پیشین پرداخته شده، بخش ۳ به بررسی روش پیشنهادی می‌پردازد. در بخش ۴ به تحلیل نتایج و مقایسه با روش‌های منتخب پرداخته شده و بخش ۵ به نتیجه‌گیری و کارهای آینده پرداخته است.

۲- مرور کارهای پیشین

۲-۱- روش‌های سنتی پیش‌بینی ترافیک

روش‌های سنتی پیش‌بینی ترافیک به طور عمده بر اساس داده‌های تاریخی و الگوهای رفتاری رانندگان شکل گرفته‌اند. در این بخش به معرفی و تحلیل روش‌های کلاسیک و آماری پیش‌بینی ترافیک پرداخته می‌شود که قبل از ورود روش‌های یادگیری ماشین استفاده می‌شدند. نمونه‌هایی از این روش‌ها عبارتند از:

• مدل‌های خطی و رگرسیون:

مدل‌های خطی و رگرسیون به عنوان ابزارهای تحلیلی در پیش‌بینی ترافیک در شبکه‌های خودرویی هوشمند کاربرد فراوانی دارند. این مدل‌ها به دلیل سادگی و قابلیت تفسیر بالا، به ویژه در شرایطی که داده‌ها به صورت خطی رفتار می‌کنند، مورد استفاده قرار می‌گیرند. مدل‌های خطی، که شامل رگرسیون خطی ساده و چندگانه هستند، به تحلیل رابطه

^۱ Accuracy

^۲ Recall

^۳ Precision

^۴ خطای جذر میانگین مربعات

بین متغیرهای مستقل و وابسته کمک می‌کنند. در زمینه پیش‌بینی ترافیک، این مدل‌ها می‌توانند برای شناسایی تأثیر عوامل مختلف مانند زمان روز، شرایط آب و هوایی، و حجم ترافیک قبلی بر جریان ترافیک مورد استفاده قرار گیرند.

- رگرسیون خطی ساده: این مدل برای پیش‌بینی مقدار یک متغیر وابسته بر اساس یک متغیر مستقل استفاده می‌شود. به عنوان مثال، می‌توان از آن برای پیش‌بینی حجم ترافیک بر اساس زمان روز استفاده کرد.
- رگرسیون خطی چندگانه: این نوع رگرسیون برای پیش‌بینی حجم ترافیک با استفاده از چندین متغیر مستقل به کار می‌رود. این مدل می‌تواند اطلاعات بیشتری را در مورد تأثیرات همزمان چندین عامل بر روی ترافیک فراهم کند.

با توجه به اینکه رفتار ترافیکی معمولاً غیرخطی است، ممکن است مدل‌های خطی نتوانند به خوبی این تغییرات را شبیه‌سازی کنند. همچنین عواملی مانند تصادفات یا شرایط جوی شدید ممکن است تأثیر زیادی بر جریان ترافیک داشته باشند که مدل‌های خطی و رگرسیون نمی‌توانند آن‌ها را به خوبی پیش‌بینی کنند [20].

• روش‌های سری‌های زمانی:

سری زمانی به مجموعه‌ای از داده‌ها اطلاق می‌شود که به ترتیب زمانی جمع‌آوری شده‌اند. این داده‌ها می‌توانند شامل حجم ترافیک، سرعت خودروها، و سایر پارامترهای مرتبط با ترافیک باشند. هدف از تحلیل سری زمانی شناسایی الگوها و روندهای موجود در داده‌ها برای پیش‌بینی وضعیت آینده است. مدل ARIMA یکی از متداول‌ترین مدل‌ها در تحلیل سری‌های زمانی است. این مدل برای پیش‌بینی داده‌های غیر ایستای ترافیک استفاده می‌شود و با ترکیب اجزای خودهمبسته، میانگین متحرک و تفاضل‌گیری، می‌تواند الگوهای پیچیده ترافیکی را شبیه‌سازی کند. نتایج تحقیقات نشان می‌دهد که این مدل می‌تواند به خوبی تغییرات حجم ترافیک را پیش‌بینی کند [21]. با استفاده از نتایج پیش‌بینی شده توسط مدل‌های سری زمانی، سیستم‌های مدیریت ترافیک می‌توانند تصمیمات بهتری برای تنظیم چراغ‌های راهنمایی یا هدایت خودروها اتخاذ کنند تا از بروز ازدحام جلوگیری شود. همچنین می‌توانند مسیرهای بهینه‌تری را برای رانندگان پیشنهاد دهند که منجر به کاهش زمان سفر و افزایش ایمنی خواهد شد [22].

- **فیلترهای کالمن:** در کاربردهای مختلفی در شبکه‌های ادهاک وسایل نقلیه^۱ و پیش‌بینی ترافیک مؤثر واقع شده‌اند. این فیلترها می‌توانند برای پیش‌بینی طول عمر باقی‌مانده لینک‌ها در شبکه‌های خودرویی هوشمند با تخمین موقعیت‌ها و سرعت‌های وسایل نقلیه استفاده شوند. در محاسبه اعتماد، فیلترهای کالمن به سرعت محاسبه و به‌روزرسانی مقادیر اعتماد برای گره‌ها در شبکه‌های خودرویی هوشمند کمک می‌کنند و چالش‌های ناشی از

^۱ VANETs

تحرک بالا و توپولوژی‌های پویا را برطرف می‌کنند [23]. علاوه بر این، روشی مبتنی بر فیلتر کالمن تطبیقی برای پیش‌بینی سرعت‌های ترافیکی در بخش‌های مختلف جاده‌های شهری معرفی شده است که از داده‌های تاریخی و زمان واقعی استفاده می‌کند. این رویکرد منجر به بهبود ۵۴ درصدی دقت پیش‌بینی، به‌ویژه زمانی که اندازه‌گیری‌های سرعت پایدار هستند، گردیده است. این مثال‌ها انعطاف‌پذیری فیلترهای کالمن را در مدیریت محیط‌های پویا و بهبود جنبه‌های مختلف ارتباطات وسایل نقلیه و سیستم‌های کنترل ترافیک نشان می‌دهند [24].

- **جنگل تصادفی:** جنگل تصادفی^۱ یک تکنیک یادگیری جمعی^۲ است که با ترکیب چندین درخت تصمیم‌گیری، دقت پیش‌بینی را افزایش می‌دهد. در این روش، هر درخت با استفاده از یک نمونه‌ی از داده‌های آموزشی ساخته می‌شود و ویژگی‌ها به‌صورت تصادفی برای تقسیم گره‌ها انتخاب می‌شوند. این فرآیند به کاهش بیش‌برازش^۳ که معمولاً در درخت‌های تصمیم‌گیری منفرد رخ می‌دهد، کمک می‌کند. پیش‌بینی نهایی از طریق رأی‌گیری اکثریت میان تمامی درخت‌های موجود در مجموعه به دست می‌آید، که این ویژگی جنگل تصادفی را به ابزاری قدرتمند و مقاوم برای انواع مختلف وظایف پیش‌بینی ترافیک تبدیل می‌کند [25].

۲-۲- روش‌های مبتنی بر ماشین

با پیشرفت مداوم شبکه‌های ادهاک وسایل نقلیه، ادغام فناوری‌های یادگیری ماشین^۴ به‌عنوان یک عامل کلیدی در رفع پیچیدگی‌های پیش‌بینی و مدیریت ترافیک ظاهر شده است. تکنیک‌های یادگیری ماشین تحلیل حجم گسترده‌ای از داده‌های تولیدشده توسط این شبکه‌ها را تسهیل می‌کنند و امکان توسعه الگوریتم‌های هوشمندی را فراهم می‌سازند که می‌توانند جریان ترافیک را بهبود بخشند، ازدحام را پیش‌بینی کنند و ایمنی جاده‌ها را ارتقا دهند. تحقیقات جاری در این حوزه برای دستیابی به پتانسیل کامل شبکه‌های خودروبی هوشمندها در سیستم‌های حمل‌ونقل هوشمند آینده ضروری است [25]. در این بخش، به بررسی روش‌های مبتنی بر یادگیری ماشین که در سال‌های اخیر به کار گرفته شده‌اند، پرداخته می‌شود:

- **مدل‌های یادگیری جمعی:**

^۱ Random Forest (RF)

^۲ Ensemble Learning (EL)

^۳ Overfitting

^۴ Machine Learning (ML)

روش‌های یادگیری تجمعی به‌عنوان تکنیک‌های برجسته‌ای برای پیش‌بینی ترافیک در شبکه‌های ادهاک وسایل نقلیه ظهور کرده‌اند. به‌عنوان مثال، یک مدل یادگیری ماشین مبتنی بر تجمع به نام یادگیری تجمعی انباشتی با مدل تقویتی^۱ پیشنهاد شده است. این مدل، ترکیبی از چندین الگوریتم یادگیری ماشین ناهمگن، نظیر جنگل تصادفی، نزدیک‌ترین همسایه^۲ و XGBoost را در لایه پایه به‌کار می‌گیرد و از رگرسیون لجستیک^۳ بهینه‌شده به‌عنوان یک فرایادگیر در لایه دوم استفاده می‌کند. این رویکرد با هدف بهبود دقت پیش‌بینی و کاهش زمان اجرا طراحی شده و عملکردی برتر نسبت به الگوریتم‌های مستقل ارائه می‌دهد [26].

• ماشین‌های بردار پشتیبان:

ماشین‌های بردار پشتیبان^۴ نیز پتانسیل قابل‌توجهی در پیش‌بینی ازدحام ترافیکی در شبکه‌های ادهاک وسایل نقلیه نشان داده‌اند. تحقیقات نشان می‌دهند که SVM، زمانی که با تکنیک‌های پیشرفته مهندسی ویژگی تقویت شود، می‌تواند به دقت بالایی طبقه‌بندی دست یابد، به‌طوری که گزارش شده است دقت آن تا ۰٫۹۹ می‌رسد. اثربخشی SVM در شناسایی و پیش‌بینی سناریوهای متنوع ترافیکی، ارزش آن را در کاربردهای مدیریت ترافیک برجسته می‌سازد [27].

• الگو تکنیک‌های داده‌کاوی:

تکنیک‌های داده‌کاوی به‌طور فزاینده‌ای با یادگیری ماشین ترکیب می‌شوند تا دقت پیش‌بینی ترافیک را بهبود بخشند. ابزارهایی نظیر WEKA و Orange برای طبقه‌بندی و پیش‌بینی ازدحام ترافیکی به کار گرفته شده‌اند و برخی مدل‌ها به دقت‌های بسیار بالا، تا ۱۰۰٪ برای برخی از طبقه‌بندها، دست یافته‌اند. این ادغام داده‌کاوی با یادگیری ماشین، پتانسیل قابل‌توجهی را برای بهبود استراتژی‌های پیش‌بینی و مدیریت ترافیک در زمان واقعی نشان می‌دهد [28].

۲-۳- روش‌های مبتنی بر شبکه‌های عصبی

شبکه‌های عصبی به دلیل قابلیت یادگیری عمیق، قادر به استخراج ویژگی‌های پنهان از داده‌های بزرگ و چندبُعدی هستند که در سیستم‌های ترافیکی بسیار متنوع است. در شبکه‌های خودرویی هوشمند، جایی که داده‌ها از حسگرها، خودروها، و زیرساخت‌های هوشمند جمع‌آوری می‌شوند، این فناوری می‌تواند با تحلیل داده‌های بلادرنگ، بهینه‌سازی زمان‌بندی چراغ‌های راهنمایی و ارائه مسیرهای جایگزین در مواقع پرتراфик کمک کند. همچنین، با ترکیب روش‌های

^۱ Stacking Ensemble Learning with Booster Model - STK-EBM

^۲ K-Nearest Neighbor - KNN

^۳ Logistic Regression - LR

^۴ Support Vector Machines (SVM)

یادگیری ماشین و شبکه‌های عصبی عمیق، می‌توان سامانه‌های پیشرفته‌ای ایجاد کرد که دقت پیش‌بینی ترافیک را افزایش داده و امکان تصمیم‌گیری سریع‌تر و کارآمدتر را فراهم آورند. از سوی دیگر، استفاده از شبکه‌های عصبی در پیش‌بینی ترافیک، چالش‌هایی نیز به همراه دارد؛ از جمله نیاز به منابع محاسباتی بالا، پیچیدگی معماری‌ها، و نیاز به داده‌های بزرگ و با کیفیت برای آموزش مدل‌ها. به همین دلیل، تحقیق و توسعه در این زمینه بر طراحی معماری‌های بهینه و توسعه الگوریتم‌های کارآمد متمرکز شده است تا کارایی این فناوری در سامانه‌های هوشمند حمل‌ونقل بهبود یابد [29].

• شبکه‌های حافظه بلندمدت-کوتاهمدت

که نوعی شبکه عصبی بازگشتی هستند، به دلیل توانایی‌شان در حفظ وابستگی‌های بلندمدت در داده‌های سری زمانی، به‌طور گسترده‌ای برای پیش‌بینی جریان ترافیک مورد استفاده قرار گرفته‌اند. معماری این شبکه‌ها معمولاً شامل یک ساختار رمزگذار-رمزگشا^۱ است، به گونه‌ای که رمزگذار توالی ورودی را به یک بردار متنی با اندازه ثابت فشرده می‌کند، و رمزگشا بر اساس این بردار، توالی خروجی را تولید می‌کند [30].

• شبکه‌های واحد بازگشتی دروازه‌دار^۲:

مشابه شبکه‌های LSTM، برای پیش‌بینی ترافیک بسیار مؤثر هستند. این شبکه‌ها با ترکیب حالت سلولی و حالت پنهان در یک متغیر حالت واحد، معماری LSTM را ساده‌تر کرده‌اند. این ساده‌سازی باعث کاهش پیچیدگی مدل می‌شود، در حالی که عملکرد مطلوب آن را حفظ می‌کند. مشابه LSTM، شبکه‌های GRU نیز قادر به مدیریت توالی‌های با طول متغیر هستند که این ویژگی آن‌ها را برای محیط‌های پویا و متغیر ترافیکی بسیار مناسب می‌سازد. استفاده از GRU به دلیل نیاز به منابع محاسباتی کمتر و سرعت بالاتر در آموزش، گزینه‌ای ایده‌آل برای کاربردهایی مانند پیش‌بینی جریان ترافیک در سیستم‌های حمل‌ونقل هوشمند به شمار می‌رود.

عملکرد مدل‌های شبکه عصبی در پیش‌بینی ترافیک اغلب با استفاده از معیارهایی مانند میانگین مربعات خطا^۳ ارزیابی می‌شود تا دقت پیش‌بینی‌ها در مقایسه با داده‌های واقعی ترافیک سنجیده شود. آزمایش‌های دقیق، از جمله تنظیم ابرپارامترها در پیکربندی‌های مختلف، اثربخشی شبکه‌های عصبی را در این حوزه نشان داده است، به‌ویژه زمانی که از مجموعه داده‌های بزرگ جمع‌آوری شده از سناریوهای واقعی ترافیکی استفاده می‌شود. این روش‌ها با بهینه‌سازی مدل‌ها و تنظیم پارامترهای مختلف مانند تعداد لایه‌ها، تعداد نورون‌ها، نرخ یادگیری و اندازه دسته، دقت پیش‌بینی‌ها را بهبود

^۱ Encoder-Decoder

^۲ Gated recurrent unit (GRU)

^۳ Mean Squared Error (MSE)

می‌بخشند. این امر باعث شده است که شبکه‌های عصبی به عنوان یکی از روش‌های برتر در تحلیل و پیش‌بینی داده‌های ترافیکی شناخته شوند [31].

• روش‌های یادگیری عمیق:

نیز برای پیش‌بینی ازدحام ترافیکی در شبکه‌های موردی وسایل نقلیه به کار گرفته شده‌اند. به عنوان مثال، در یک مطالعه از یادگیری تقویتی عمیق^۱ برای تحلیل سناریوهای ترافیکی ایجاد شده با استفاده از شبیه‌ساز حرکت شهری SUMO استفاده شد. این مدل زمان سفر متوسط و تأخیرهای زمان انتظار وسایل نقلیه را ارزیابی کرد و بهبودهای قابل توجهی در عملکرد را در طی چندین اجرای متوالی نشان داد [32]. علاوه بر این، مقایسه میان الگوریتم‌های مختلف یادگیری عمیق، از جمله شبکه‌های عصبی کانولوشنی^۲، پرسپترون چندلایه^۳ و شبکه‌های حافظه بلندمدت-کوتاه‌مدت، نشان داد که روش MLP به عنوان مؤثرترین روش برای پیش‌بینی ازدحام ترافیکی در تراکم‌های مختلف ترافیکی ظاهر شده است. این یافته‌ها نشان می‌دهد که انتخاب روش یادگیری عمیق مناسب بر اساس شرایط و ویژگی‌های داده‌های ترافیکی می‌تواند تأثیر چشمگیری بر دقت و کارایی پیش‌بینی‌ها داشته باشد.

۲-۴- روش‌های ترکیبی

در این بخش، به مدل‌های ترکیبی^۴ که شامل شبکه‌های عصبی و سایر روش‌های بهینه‌سازی هستند پرداخته می‌شود:

• ترکیب شبکه‌های عصبی با الگوریتم‌های بهینه‌سازی:

الگوریتم‌های بهینه‌سازی برای آموزش شبکه‌های عصبی ضروری هستند، زیرا با تنظیم وزن‌ها و بایاس‌های شبکه به کاهش خطای پیش‌بینی کمک می‌کنند. هدف اصلی این الگوریتم‌ها کاهش تابع هزینه مرتبط با خروجی شبکه است و بدین ترتیب فرایند یادگیری را به سمت یک راه‌حل بهینه هدایت می‌کنند. در شبکه‌های موردی خودرویی، بهینه‌سازی جریان ترافیک برای ارتقاء ایمنی و کارایی از اهمیت بالایی برخوردار است. الگوریتم‌های ژنتیک^۵ می‌توانند برای بهینه‌سازی پروتکل‌های مسیریابی، کاهش تأخیرها و پیش‌بینی ازدحام ترافیکی با شبیه‌سازی سناریوهای مختلف و شناسایی مسیرهای بهینه بر اساس داده‌های بلادرنگ به کار گرفته شوند [33]. با تکرار راه‌حل‌های احتمالی، الگوریتم‌های

^۱ Deep Reinforcement Learning

^۲ Convolutional neural network (CNN)

^۳ Multilayer perceptron (MLP)

^۴ Hybrid Models

^۵ Genetic Algorithm (GA)

ژنتیک می‌توانند به‌طور تطبیقی با تغییرات الگوهای ترافیکی سازگار شوند و در نهایت به اتخاذ تصمیم‌های بهتر در سیستم‌های مدیریت ترافیک کمک کنند [34].

• مدل‌های تقویتی:

یادگیری تقویتی^۱ به‌طور فزاینده‌ای در سیستم‌های پیش‌بینی ترافیک در شبکه‌های ادهاک وسایل نقلیه به‌کار گرفته شده است. این روش امکان تنظیمات پویا را بر اساس بازخورد لحظه‌ای از محیط فراهم می‌کند. به‌عنوان مثال، RL می‌تواند زمان‌بندی چراغ‌های راهنمایی را بر اساس شرایط فعلی ترافیک بهینه کند و در نتیجه بهبود جریان کلی ترافیک و کاهش ازدحام را به همراه داشته باشد [35]. علاوه بر این، تکنیک‌هایی مانند یادگیری Q^۲ با تسهیل تصمیم‌گیری بهینه در حوزه‌های مارکوفی، راهبردهای یادگیری مؤثری را در سناریوهای غیرقابل پیش‌بینی ترافیکی ارائه می‌دهند [36].

• ترکیب LSTM و الگوریتم‌های تقویتی:

• بهینه‌سازی با استفاده از الگوریتم‌های ژنتیک

الگوریتم‌های ژنتیک می‌توانند نقش بسزایی در بهینه‌سازی پارامترهای مدل‌های LSTM برای بهبود عملکرد سیستم‌های پیش‌بینی ترافیک ایفا کنند. تحقیقات آینده می‌توانند استراتژی‌های نوآورانه‌ای از الگوریتم‌های ژنتیک را مورد بررسی قرار دهند که به‌صورت پویا پارامترهای مدل را بر اساس شرایط لحظه‌ای ترافیک تنظیم کنند. این رویکرد می‌تواند به کاهش خطاهای پیش‌بینی و افزایش سازگاری مدل با تغییرات ناگهانی در جریان ترافیک کمک کند [37].

• بهینه‌سازی با استفاده از الگوریتم PSO


هم‌افزایی میان مدل‌های LSTM و الگوریتم PSO می‌تواند به بهبود عملکرد در پیش‌بینی ترافیک و بهینه‌سازی مسیریابی منجر شود. مدل‌های LSTM قادر به ارائه پیش‌بینی‌های دقیقی از الگوهای ترافیکی هستند که به‌عنوان داده‌های ورودی حیاتی برای الگوریتم PSO در تعیین کارآمدترین مسیرها عمل می‌کنند. علاوه بر این، استفاده از PSO برای بهینه‌سازی هایپرپارامترهای مدل‌های LSTM می‌تواند دقت و پایداری مدل را بهبود بخشیده و به‌طور مؤثری چالش‌هایی نظیر کمبود داده و بیش‌برازش مدل را برطرف کند. ترکیب این دو روش نه تنها پیچیدگی محاسباتی مرتبط با مدل‌های سنتی را کاهش می‌دهد، بلکه سازگاری پروتکل‌های مسیریابی با شرایط متغیر ترافیک شهری را نیز افزایش می‌دهد [38].

^۱ Reinforcement Learning (RL)

^۲ Q-Learning

۳- مدل پیشنهادی

در این مقاله، یک مدل ترکیبی مبتنی بر شبکه‌های عصبی بازگشتی LSTM برای پیش‌بینی شدت تصادفات در شبکه‌های خودرویی VANET ارائه شده است. این مدل از LSTM چندگانه^۱ به همراه رویکرد دوطرفه^۲ استفاده شده است تا از وابستگی‌های زمانی داده‌ها در هر دو جهت بهره ببرد. این ویژگی به مدل کمک می‌کند تا الگوهای پیچیده‌تر را در داده‌های سری زمانی کشف کند و دقت پیش‌بینی‌ها را افزایش دهد. یکی از نوآوری‌های این مدل استفاده از الگوریتم بهینه‌سازی پروگزیمال^۳ به منظور تنظیم هوشمند گیت‌های LSTM است. در ساختار LSTM، چهار گیت اصلی وجود دارد: گیت فراموشی، گیت ورودی، گیت سلول و گیت خروجی. هر یک از این گیت‌ها وظیفه کنترل جریان اطلاعات را بر عهده دارند و تعیین می‌کنند که چه اطلاعاتی در حافظه نگهداری یا فراموش شود و چه اطلاعاتی به خروجی منتقل شود. الگوریتم PPO با استفاده از مکانیسم یادگیری تقویتی، به تنظیم بهینه پارامترهای این گیت‌ها می‌پردازد.



^۱ Multi-Gate LSTM

^۲ Bidirectional

^۳ Proximal Policy Optimization (PPO)

شکل ۱: استفاده از الگوریتم PPO برای تنظیم مقادیر گیت‌های LSTM

- شکل ۱ نحوه تنظیم این ۴ گیت را توسط الگوریتم PPO نمایش می‌دهد. این شکل از ۵ عضو تشکیل شده است که در ادامه به شرح هر کدام از اعضا پرداخته شده است.
- ورودی داده‌ها: داده‌های خام مربوط به شدت تصادفات در شبکه‌های خودرویی به مدل وارد می‌شوند.
 - شبکه LSTM چندگانه: این شبکه با استفاده از گیت‌های مختلف، اطلاعات زمانی را پردازش کرده و پیش‌بینی‌هایی درباره شدت تصادفات ارائه می‌دهد.
 - خروجی مدل: نتایج پیش‌بینی‌شده به سیستم پاداش ارسال می‌شوند.
 - سیستم پاداش: عملکرد مدل بر اساس معیارهای تعیین‌شده ارزیابی می‌شود و پاداش مناسب به الگوریتم PPO ارسال می‌گردد.
 - الگوریتم: PPO بر اساس پاداش دریافتی، پارامترهای گیت‌های LSTM را تنظیم کرده و به بهینه‌سازی مدل کمک می‌کند.



شکل ۲: شمای کلی مدل پیشنهادی

الگوریتم PPO پارامترهای گیت‌های فراموشی، ورودی، سلول و خروجی را به‌طور هوشمند تنظیم می‌کند تا دقت و کارایی مدل افزایش یابد. در واقع، PPO به عنوان یک کنترل‌کننده هوشمند عمل می‌کند که به صورت پویا تنظیمات گیت‌های LSTM را برای دستیابی به کارایی بهتر مدل در هر مرحله از آموزش بهینه‌سازی می‌کند. این روش به مدل اجازه می‌دهد تا به تدریج رفتارهای بهینه‌تری را از داده‌ها یاد بگیرد و پایداری و کارآمدی فرآیند یادگیری را تضمین کند. در شکل ۲ شمای کلی مدل پیشنهادی نشان داده شده است. برای بهبود یادگیری و جلوگیری از بیش از حد، از تکنیک‌هایی همچون نرمال‌سازی داده‌ها^۱ و حذف تصادفی نورون‌ها^۲ استفاده شده است. همچنین، برای مقابله با عدم توازن در داده‌ها، از روش SMOTE برای نمونه‌برداری بیشتر از کلاس‌هایی که کمتر هستند استفاده شده است. خروجی

^۱ Batch Normalization

^۲ Dropout

مدل از طریق لایه‌های Dense برای دسته‌بندی نهایی و محاسبه شدت تصادف استفاده می‌شود. مدل پیشنهادی با بهینه‌ساز Adam و تابع هزینه کراس‌انترپی دسته‌ای آموزش داده شده است.

۳-۱- پیش‌پردازش داده‌ها

ابتدا داده‌های مربوط به شدت تصادفات^۱ بارگذاری و پردازش اولیه انجام می‌شود. مراحل پیش‌پردازش شامل موارد زیر است:

- رمزگذاری دسته‌ای^۲: تمامی ویژگی‌های متنی به صورت عددی تبدیل می‌شوند تا قابلیت پردازش توسط مدل‌های یادگیری ماشین فراهم گردد.
- استانداردسازی داده‌ها: مقیاس ویژگی‌ها^۳ با استفاده از مقیاس کننده استاندارد به نرمال میانگین صفر و واریانس یک تبدیل می‌شود تا مدل بتواند با داده‌های نرمال شده بهینه‌تر آموزش ببیند.
- تکنیک تعادل‌سازی کلاس‌ها: SMOTE برای مقابله با عدم تعادل در داده‌های آموزشی، از تکنیک SMOTE برای تولید نمونه‌های مصنوعی و تعادل‌بخشی به کلاس‌ها استفاده می‌شود.
- تقسیم داده‌ها: داده‌ها به مجموعه‌های آموزشی و آزمایشی با نسبت ۷۰٪ به ۳۰٪ تقسیم می‌شوند.

۳-۲- طراحی مدل ترکیبی LSTM+PPO

مدل پیشنهادی شامل چندین لایه مختلف است که به شرح زیر می‌باشد:

لایه ورودی^۴: داده‌های پیش‌پردازش شده به شکل (تعداد نمونه‌ها، تعداد ویژگی‌ها، ۱) به مدل وارد می‌شوند. لایه‌های LSTM چند دروازه دوطرفه^۵: یک لایه سفارشی از نوع LSTM تعریف شده است که شامل چندین دروازه برای کنترل جریان اطلاعات در طول زمان می‌باشد. این لایه قادر به یادگیری وابستگی‌های بلندمدت در داده‌های سری زمانی است.

^۱Accident_severity

^۲Label Encoding

^۳Standard Scaling

^۴ Input Layer

^۵ Bidirectional MultiGate LSTM Layers

- لایه اول: از یک شبکه عصبی بازگشتی دوطرفه^۱ با ۱۲۸ واحد LSTM استفاده شده است. استفاده از شبکه عصبی بازگشتی دوطرفه امکان پردازش داده‌ها به صورت همزمان در جهت جلو و عقب را فراهم می‌آورد، که می‌تواند به افزایش دقت مدل در درک الگوهای زمانی کمک کند.
- لایه دوم: یک شبکه عصبی بازگشتی دوطرفه دیگر با همان تعداد واحدها اضافه می‌شود تا عمق بیشتری به مدل افزوده و قابلیت یادگیری ویژگی‌های پیچیده‌تر را افزایش دهد.

نرمال‌سازی دسته‌ای^۲: پس از هر لایه RNN، از لایه‌های Batch Normalization و Dropout با نرخ ۳۰٪ استفاده می‌شود تا از بیش‌برازش جلوگیری و پایداری مدل افزایش یابد.

لایه‌های چگال^۳: لایه Dense اول: یک لایه چگال با ۱۲۸ واحد و تابع فعال‌سازی ReLU اضافه می‌شود که به افزایش توانایی مدل در استخراج ویژگی‌های غیرخطی کمک می‌کند. نرمال‌سازی دسته‌ای و Dropout مجدداً از لایه‌های نرمال‌سازی دسته‌ای و Dropout با نرخ ۳۰٪ استفاده می‌شود. لایه خروجی: یک لایه چگال نهایی با تعداد واحد برابر با تعداد کلاس‌ها و تابع فعال‌سازی Softmax برای تولید احتمالات کلاس‌ها استفاده می‌شود.

۴- آموزش مدل

مدل با استفاده از الگوریتم بهینه‌سازی Adam با نرخ یادگیری ۰,۰۰۱ تنظیم شده است. تابع هزینه انتخاب‌شده برای این مدل، "Categorical Crossentropy" می‌باشد که مناسب برای مسائل دسته‌بندی چندکلاسه است. معیارهای ارزیابی شامل دقت^۴ و سایر معیارهای مرتبط مانند Precision, Recall, F1-Score, ROC-AUC, Log Loss.

^۱ Bidirectional RNN

^۲ Batch Normalization

^۳ Dense Layers

^۴ Accuracy

MSE^۱ و RMSE^۲ می‌باشند. مدل به مدت ۳۰۰ دوره^۳ با اندازه دسته ۱۲۸ آموزش داده شده و در هر ده دوره، عملکرد مدل بر روی مجموعه‌های آموزشی و آزمایشی ارزیابی می‌شود. تاریخچه آموزش شامل مقادیر ضرر و دقت در هر دوره ذخیره و برای تحلیل‌های بعدی استفاده می‌شود.

۵- بهینه‌سازی با الگوریتم PPO

الگوریتم PPO به عنوان یک روش بهینه‌سازی تقویتی به مدل اضافه می‌شود تا سیاست تصمیم‌گیری مدل را بهبود بخشد. PPO به دلیل پایداری و کارایی بالا در بهینه‌سازی مدل‌های پیچیده، انتخاب مناسبی برای بهینه‌سازی پارامترهای شبکه عصبی بوده است. این الگوریتم با تنظیم سیاست‌های مدل در محیط‌های پویا و متغیر، کمک می‌کند تا مدل بتواند به سرعت به تغییرات ناگهانی در داده‌های ترافیکی واکنش نشان دهد و دقت پیش‌بینی را افزایش دهد.

۶- توضیحات دیتاست

مجموعه داده مورد استفاده در این پژوهش [24] استخراج شده است، که یک ابتکار دولت بریتانیا برای ارائه داده‌های متن‌باز منتشرشده توسط نهادهای دولتی مرکزی، مقامات محلی و سازمان‌های عمومی است. این مطالعه به طور خاص از پایگاه داده تصادفات جاده‌ای سال ۲۰۱۷ بهره برده است. این مجموعه داده اطلاعات جامعی در مورد ایمنی جاده، شامل جزئیاتی درباره عوامل زیست‌محیطی، فیزیکی، هندسی، جغرافیایی و شخصی مرتبط با تصادفات، ارائه می‌دهد. شایان ذکر است که این داده‌ها تنها شامل تصادفاتی هستند که به طور رسمی به پلیس یا مراجع ذی‌صلاح گزارش شده‌اند.

جدول ۱: کدگذاری متغیرها در دیتاست استفاده شده

متغیرهای دیتاست		
متغیرهای تصادف	متغیرهای تصادف و راننده	متغیرهای تصادفی
Index of the crash	Index the crash	Index of the crash
Police Force	Vehicle Id code	Vehicle Id code
Accident Severity	Kind of vehicle	Casualty Id code
Vehicles Involved	Towing and Articulation	Type of victim
Number of victims involved	A Vehicle Manoeuvre	Gender of victim

^۱ Mean Squared Error

^۲ Root Mean Squared Error

^۳ Epoch

Age of victim	Postion of vehicle	Date
Age Band of victim	Location of intersection	Date of the week
Intensity of the fatality	Skidding and Overturning	Time
Position of the pedestrian	Hit Object in Carriageway	Longitude
Motion of the pedestrian	1 st Point of Impact	Latitude
Position of victim in car	Was Vehicle Left Hand Drive	District of Local Authority
Position of victim in Bus or coach	Journey Purpose of Driver	Local Highway Authority
Type of fatality	Gender of the driver	1 st Toad Class
Casualty IMD Decile	Age of the Driver	1 st Road Number
Location of victims house	Age band of the Driver	Kind of roadway
	Motor power	Maximum velocity possible
	Vehicle fuel type	Details of intersection
	Age of the vehicle	2 nd Road Class
	Rider IMD Decile	2 nd Road Number
	Rider Home Area Type	Pedestrian Crossing-Physical Facilities
		Lighting
		Road Conditions
		Road surface conditions
		Special characteristics of accident location
		Carriage Hazards
		Type of area
		Police attention

این مجموعه داده از اطلاعات ثبت‌شده در فرم گزارش تصادف STATS19 استخراج شده است. ساختار اصلی آن به سه دسته کلی تقسیم می‌شود: داده‌های مربوط به تصادفات، داده‌های مربوط به وسایل نقلیه و داده‌های مربوط به آسیب‌دیدگان. مجموعه داده تصادفات شامل ۳۱ متغیر است که عواملی مانند شرایط جوی، روشنایی، زمان، روز هفته و تعداد وسایل نقلیه درگیر را در بر می‌گیرد. مجموعه داده وسیله نقلیه-راننده شامل ۲۲ متغیر است که اطلاعاتی مانند سن وسیله نقلیه، سن راننده و جنسیت او را شامل می‌شود. در نهایت، مجموعه داده آسیب‌دیدگان دارای ۱۵ متغیر است که اطلاعاتی درباره نوع قربانی، جنسیت آسیب‌دیده و سن او را ارائه می‌دهد. کلاس خروجی یا شدت تصادف به سه دسته تقسیم شده است: "عدم آسیب‌دیدگی در تصادف" که با عدد ۱ کدگذاری شده است، "آسیب غیر ناتوان‌کننده در تصادف" که با عدد ۲ کدگذاری شده است، و "آسیب ناتوان‌کننده در تصادف" که با عدد ۳ کدگذاری شده است. کدگذاری دقیق هر متغیر در جدول زیر ارائه شده است.

جدول ۲: توضیحات متغیرها

نام متغیر	دسته بندی متغیرها	Code	Frequency	Percentage	Class1	Class2	Class3
روز هفته	Sunday	۱	21836	12.20	20.4	11.4	14.7
	Monday		24653	13.77	12.4	14.1	12.2
	Tuesday	2	25911	14.48	10.4	14.7	13.6
	Wednesday	3	25837	14.44	14.4	14	14.1

14.2	.5	11.0	15.09	27014	4	Thursday	
15.8	15.4	13.1	16.33	29227	5	Friday	
15.3	16.5	18.2	13.66	24440	6	Saturday	
	13.1				7		
6.35	3.67	1.05	5.77	10328	1	Traffic circle	نوع اتوبان
1.60	1.28	0.68	1.53	2740	2	Single direction traffic	
19.27	16.62	22.9	18.85	33739	3	Divided highway	
70.61	77.12	74.8	78.88	128608	6	Undivided highway	
1.13	0.82	0.37	1.06	1904	7	Slip road	
1.01	0.46	0.06	0.89	1599	9	Unknown	
0.00	0.00	0.00	0	0	12	Single direction traffic/Slip road	
0.00	0.00	0.00	0	0	-1	Erroneous data	
0.60	0.42	0.12	98.26	175819	0	None within 50 meters	تقاطع پیش بینی انسان
1.03	0.31	0.06	0.27	497	1	School crossing patrol	
99.0	99.0	99.5	0.56	1013	2	By another official	
0.28	0.26	0.27	0.88	1589	-1	Erroneous data	
41.86	49.80	72.01	43.85	78468	0	No intersection within 20m	جزئیات تقاطع
8.32	4.79	1.33	7.55	13524	1		
1.07	0.68	0.12	0.98	1770	2	Traffic circle	
28.67	27.82	15.54	28.29	50618	3	Mini-Traffic circle	
2.04	1.52	2.32	1.95	3502	5	Suggested intersection	
10.77	8.7	5.05	10.28	18403	6	Slip road	
1.01	0.60	0.34	0.92	1663	7	Crossroads	
						More than 4 arms(no traffic circle)	
2.71	3.28	1.73	2.85	5102	8	Private road	
3.23	2.73	1.52	3.11	5567	9	Other intersection	
0.20	0.04	2	0.16	301	-1	Erroneous data	
71.24	67.95	60.28	70.45	126049	1	Daylight	Lighting
20.55	20.02	17.18	20.39	36489	4	Dark with lights	
0.63	0.59	0.86	0.62	1123	5	Dark with dimmed lights	
4.70	8.94	20.81	5.76	10314	6	No illumination at all	
2.86	2.84	0.83	2.76	4941	7	Unknown illumination	
0.001	2	2	0.001	2	-1	Erroneous data	
80.44	81.45	84.02	80.68	144368	1	Breeze	Weather Condition
11.71	11.93	8.99	11.70	20948	2	Rain with Breeze	
0.56	0.29	0.49	0.51	915	3	Snow with breeze	
1.08	1.31	1.55	1.13	2032	4	Fine with gale	
0.89	1.16	1.27	0.95	1705	5	Rain with gale	
0.10	0.04	2	0.09	163	6	Snow with gale	
0.49	0.64	0.77	0.52	940	7	Fog or mist	
1.99	1.55	1.42	1.90	3410	8	Others	
2.70	1.59	1.45	2.47	4435	9	Unknown	
0.001	2	2	0.001	2	-1	Erroneous data	
69.44	69.25	68.38	69.39	124151	1	Dry	سطح جاده
27.52	28.55	28.88	27.74	49632	2	Wet	
0.43	0.23	0.31	0.39	707	3	Snow	
1.79	1.61	2.23	1.77	3172	4	Icy or Snow	
0.07	0.17	0.18	0.09	172	5	Flood over 3cm.deep	
0.00	0.00	0.00	0	0	6	Oily	
0.00	0.00	0.00	0	0	7	Silt or mad	
0.72	0.16	2	0.60	1084	-1	Erroneous data	
62.15	69.89	79.42	63.87	114282	1	Male	جنسیت راننده

30.31	24.15	18.33	27.97	51848	2	Female	
7.52	5.95	2.23	7.14	12784	3	Not Known	
0.002	0.003	2	0.002	4	-1	Erroneous data	
68.65	66.20	63.38	68.11	121870	1	Driver	نوع قربانی
24.44	22.74	25.00	24.14	35055	2	Passenger	
6.89	11.05	11.60	7.73	16	3	Pedestrian	
78.02	89.27	95.90	80.39	143847	1	Yes	وجود افسر پلیس
21.96	10.71	4.09	19.59	35055	2	No	
0.10	0.006	2	0.009	16	3	No- accident was reported using a self completion form	

۷- ارزیابی نتایج

در این بخش، به ارزیابی عملکرد مدل پیشنهادی ترکیبی LSTM+PPO و مقایسه آن با دو مدل دیگر یعنی LSTM و RNN می‌پردازیم. معیارهای اصلی ارزیابی شامل دقت^۱، فراخوانی^۲، دقت مثبت^۳، نمره F1، AUC-ROC، RMSE^۴ و Log Loss می‌باشد. این معیارها به کمک نمودارهای ترسیم شده برای هر سه مدل بررسی و تحلیل شده‌اند.

۷-۱- تحلیل دقت

شکل ۱ نمودار Training and Validation Accuracy را برای هر سه روش LSTM+PPO، LSTM و RNN نشان می‌دهد. محور عمودی این نمودارها بیانگر میزان Training and Validation Accuracy برحسب درصد می‌باشد و محور افقی آن بیانگر Epoch ها می‌باشد. همچنین جدول ۱ دقت اعتبارسنجی و آموزشی نهایی را برای هر سه روش نشان می‌دهد.

جدول ۳: دقت روش پیشنهادی و سایر روش‌ها

مدل	دقت آموزشی	دقت اعتبار سنجی
LSTM	0.92	0.88
LSTM+PPO	0.95	0.91


^۱ Accuracy

^۲ Recall

^۳ Precision

^۴ خطای جذر میانگین مربعات

RNN	0.89	0.85
-----	------	------



شکل ۳: نمودار Training and Validation Accuracy

در شکل ۱ نمودار الف می‌بینیم که دقت آموزشی و اعتبارسنجی هر دو به تدریج افزایش یافته و به مقدار نسبتاً بالایی می‌رسند. دقت آموزشی تقریباً به ۰,۷۵ نزدیک می‌شود و دقت اعتبارسنجی نیز تقریباً به همین میزان می‌رسد، و همچنین با ادامه Epochs ها دیده می‌شود دقت رشد میکند و در نهایت به محدود ۰,۹۵ درصد می‌رسد که نشان می‌دهد مدل به خوبی یادگیری کرده است و محدودی دارد دقت آموزشی در جدول ۰,۹۵ و دقت اعتبارسنجی ۰,۹۱ است. این تطابق نشان‌دهنده پایداری و دقت بالای مدل LSTM+PPO است. فاصله کم (۰,۰۴) بین دقت آموزشی و اعتبارسنجی نشان از تعمیم‌پذیری بالای مدل دارد که در نمودار هم مشهود است.

در نمودار ب که مربوط به LSTM است دقت آموزشی به سرعت افزایش یافته و به نزدیکی ۰,۹۲ می‌رسد که نشان‌دهنده یادگیری شدید مدل از داده‌های آموزشی است. اما دقت اعتبارسنجی به حدود ۰,۸ ثابت می‌ماند و این اختلاف نسبتاً زیاد نشان‌دهنده بیش برداشش است. با دقت در نمودار دیده می‌شود از Epoch 40 به بعد دیده می‌شود


که دقت آموزشی و دقت اعتبارسنجی فاصله معنا داری پیدا میکنند و این نشان میدهد. که overfitting در مراحل نهایی بیشتر قابل مشاهده است.

نمودار ج دقت مدل RNN را نشان میدهد. که دقت آموزشی به کندی افزایش می‌یابد و در نهایت به حدود ۰,۸۹ می‌رسد. دقت اعتبارسنجی نیز نوسان زیادی دارد و حدود ۰,۸۵ است، که نشان‌دهنده ناپایداری مدل است. در جدول، دقت آموزشی ۰,۸۹ و دقت اعتبارسنجی ۰,۸۵ گزارش شده است. این اعداد کمتر از مقادیر مربوط به LSTM و LSTM+PPO است. فاصله بین دقت آموزشی و اعتبارسنجی (۰,۰۴) در این مدل نیز مشابه با سایر مدل‌ها است اما دقت کلی پایین‌تر است.

۷-۲- تحلیل خطای جذر میانگین مربعات

شکل ۲ نمودار تحلیل خطای جذر میانگین مربعات را برای هر سه روش LSTM، LSTM+PPO و RNN نشان می‌دهد. محور عمودی این نمودارها بیانگر میزان خطای جذر میانگین مربعات بر حسب درصد می‌باشد و محور افقی آن بیانگر Epoch ها می‌باشد. نمودار الف شکل ۲ که RMSE روش LSTM+PPO را نشان میدهد مشاهده می‌شود که RMSE آموزشی به طور مداوم بسیار پایین است و مقدار آن تقریباً ثابت و نزدیک به ۰,۳ است. RMSE اعتبارسنجی در حدود ۰,۴ است و به شکل پایداری در طول زمان حفظ می‌شود. هرچند تفاوت میان RMSE آموزشی و اعتبارسنجی وجود دارد، اما این اختلاف نسبت به سایر مدل‌ها خیلی زیاد نیست.

در نمودار ب شکل ۲ که RMSE روش LSTM را نشان میدهد دیده می‌شود RMSE آموزشی تقریباً صفر است که نشان می‌دهد مدل به طور کامل داده‌های آموزشی را یاد گرفته است. اما RMSE اعتبارسنجی در مقایسه با آموزشی بسیار بالاتر و در حدود ۰,۳ ثابت است. این اختلاف بزرگ نشان‌دهنده بیش بردازش شدید است؛ یعنی مدل فقط در داده‌های آموزشی خوب عمل کرده، اما در داده‌های اعتبارسنجی عملکرد مناسبی ندارد. در نمودار ج شکل ۲ که RMSE روش RNN را نشان می‌دهد RMSE آموزشی تقریباً به صفر نزدیک است، اما RMSE اعتبارسنجی در حدود ۰,۴۵ قرار دارد و به شکل ثابتی باقی می‌ماند. این نشان می‌دهد که مدل RNN نیز، مشابه LSTM، دچار بیش بردازش شده است. در اینجا نیز مدل داده‌های آموزشی را به خوبی یاد گرفته، اما عملکرد ضعیفی در داده‌های اعتبارسنجی دارد. این نمودارها نشان می‌دهند که مدل LSTM+PPO به خوبی آموزش دیده و عملکرد پایدار و نسبتاً دقیق‌تری دارد. اختلاف کم بین RMSE آموزشی و اعتبارسنجی نشان می‌دهد که مدل به خوبی تعمیم پیدا کرده و از بیش بردازش جلوگیری شده است.



شکل ۴: نمودار خطای جذر میانگین مربعات (RMSE)


۷-۳- تحلیل ضرر^۱

شکل ۳ نمودار تحلیل ضرر را برای هر سه روش LSTM+PPO، LSTM و RNN نشان می‌دهد. محور عمودی این نمودارها بیانگر میزان ضرر بر حسب درصد می‌باشد و محور افقی آن بیانگر Epoch ها می‌باشد. نمودار الف شکل ۲ که ضرر روش LSTM+PPO را نشان می‌دهد. همان‌طور که مشاهده می‌شود، هر دو خطای آموزش و اعتبارسنجی به طور پیوسته کاهش می‌یابند، اما خطای اعتبارسنجی کمی بیشتر از خطای آموزش است و در پایان نوسانات کوچکی دارد. این نوسانات کوچک در اعتبارسنجی نشان‌دهنده عدم تطابق دقیق مدل با داده‌های اعتبارسنجی است، ولی مدل نسبتاً خوب عمل کرده است. کاهش مداوم هر دو خطا تا حدود epoch ۳۰۰ نشان می‌دهد که مدل به تدریج بهتر شده است.

نمودار ب شکل ۳ مربوط به مدل LSTM استاندارد است. در اینجا می‌بینیم که خطای آموزش به سرعت کاهش یافته و به سطح نسبتاً پایینی می‌رسد. اما خطای اعتبارسنجی پس از کاهش اولیه شروع به افزایش و نوسان می‌کند. این رفتار ممکن است نشان‌دهنده بیش بردازش باشد؛ یعنی مدل با داده‌های آموزش به خوبی تطابق دارد ولی در مواجهه با داده‌های اعتبارسنجی عملکرد مطلوبی ندارد. نمودار ج شکل ۳ مربوط به یک شبکه عصبی مکرر RNN است. خطای آموزش و اعتبارسنجی هر دو کاهش می‌یابند اما خطای اعتبارسنجی بیشتر از آموزش است و تا حدودی نوسان دارد.

^۱ Loss

به نظر می‌رسد که مدل RNN در مقایسه با مدل‌های قبلی عملکرد ضعیف‌تری دارد، زیرا هر دو خط به طور کلی بالاتر هستند و نرخ همگرایی کندتر است.



شکل ۵: نمودار ضرر (Loss)

همچنین جدول ۲ میزان نهایی ضرر را برای داده‌های اعتبارسنجی و آموزشی نمایش می‌دهد. که مشاهده می‌شود روش LSTM+PPO هم در داده‌های اعتبارسنجی و هم در داده‌های آموزشی کمترین میزان ضرر را داشته است.

جدول ۴: میزان ضرر در داده‌های اعتبارسنجی و آموزشی

مدل	ضرر آموزشی	ضرر اعتبارسنجی
LSTM+PPO	0.05	0.12
LSTM	0.10	0.18
RNN	0.20	0.25

۷-۴- تحلیل Precision، Recall و F1-Score

جدول ۳ عملکرد سه روش LSTM+PPO، LSTM و RNN را از لحاظ سه متریک Precision، Recall، F1-Score نشان می‌دهد. مدل LSTM+PPO با دقت 0.95 (Precision)، بازخوانی 0.93 (Recall) و امتیاز F1 برابر ۰.۹۴، بهترین عملکرد را در میان سه مدل داشته است. این مدل با ارائه دقت بالا نشان می‌دهد که تعداد پیش‌بینی‌های

مثبت اشتباه کمی داشته و همچنین بازخوانی بالای آن حاکی از شناسایی درصد بالایی از موارد مثبت واقعی است. تعادل بین دقت و بازخوانی که در امتیاز F1-Score معادل ۰,۹۴ منعکس شده، نشان‌دهنده قدرت این مدل در مدیریت داده‌های پیچیده و دستیابی به تعمیم بهتر است.

مدل LSTM با دقت ۰,۹۲ و بازخوانی ۰,۹۰، عملکرد رضایت‌بخشی از خود نشان داده است. هرچند که این مدل در مقایسه با LSTM+PPO کمی ضعیف‌تر است، اما همچنان دقت و بازخوانی قابل قبولی ارائه می‌دهد F1-Score. این مدل برابر با ۰,۹۱ است که نشان‌دهنده توازن مناسب بین دقت و بازخوانی می‌باشد. این نتیجه با نمودارهای آموزشی که نشان‌دهنده تمایل مدل به بیش برداش بود، همخوانی دارد و می‌تواند با بهینه‌سازی‌های بیشتر بهبود یابد. در مقابل، مدل RNN با دقت ۰,۸۸ و بازخوانی ۰,۸۵ عملکرد ضعیف‌تری نسبت به دو مدل دیگر داشته است. این مدل با F1-Score برابر با ۰,۸۶ نشان می‌دهد که هرچند توانسته به مقداری از تعادل بین دقت و بازخوانی دست یابد، اما هنوز نیاز به بهبودهای اساسی برای دستیابی به عملکرد بهتر دارد. نمودارهای از دست رفتن اعتبارسنجی نیز این واقعیت را تأیید می‌کنند که مدل RNN در همگرایی و تعمیم‌دهی به داده‌ها موفقیت کمتری داشته است. با توجه به این ارزیابی‌ها، مدل LSTM+PPO به عنوان بهترین مدل انتخاب می‌شود، چرا که توانسته است تعادل مناسبی بین دقت و بازخوانی ایجاد کرده و نتایج بهتری در پیش‌بینی داده‌ها به دست آورد.

جدول ۵: نتایج معیارهای Precision, Recall, F1-SCORE

مدل	Precision	Recall	F1-Score
LSTM+PPO	0.95	0.93	0.94
LSTM	0.92	0.90	0.91
RNN	0.88	0.85	0.86

۷-۵- تحلیل AUC-ROC

متریک AUC-ROC یک معیار مهم برای ارزیابی عملکرد مدل‌های طبقه‌بندی است. این متریک نشان‌دهنده توانایی مدل در تمایز بین کلاس‌های مثبت و منفی است. مقدار AUC-ROC بین ۰ تا ۱ قرار می‌گیرد؛ هرچه این مقدار به ۱ نزدیک‌تر باشد، مدل تفکیک بهتری بین کلاس‌های مختلف دارد AUC-ROC. بالاتر از ۰,۵ نشان می‌دهد که مدل بهتر از حد تصادفی عمل می‌کند، و مقادیر نزدیک به ۱ نشان‌دهنده دقت بالا در تفکیک صحیح داده‌ها است.

مدل LSTM+PPO بهترین عملکرد را با مقدار ۰,۹۹ دارد، که نشان‌دهنده قدرت بسیار زیاد در تفکیک کلاس‌های مثبت و منفی است. این مقدار نزدیک به ۱ نشان می‌دهد که مدل به خوبی داده‌ها را طبقه‌بندی می‌کند. مدل LSTM با مقدار ۰,۹۵ نشان‌دهنده عملکرد خوب مدل است و بیانگر این است که مدل LSTM نیز توانسته است تفکیک مناسبی بین کلاس‌های مثبت و منفی داشته باشد، اما عملکرد آن کمی کمتر از مدل LSTM+PPO است. مدل RNN پایین‌ترین مقدار AUC-ROC را دارد که نشان می‌دهد توانایی آن در تشخیص کلاس‌ها کمتر از دو مدل دیگر است. با این حال، مقدار ۰,۹۰ هنوز هم نشانگر عملکرد مناسب مدل است. مدل LSTM+PPO با مقدار AUC-ROC برابر با ۰,۹۹ بهترین عملکرد را داشته است و به خوبی توانسته تفکیک درستی بین داده‌های مثبت و منفی انجام دهد. مدل LSTM نیز عملکرد خوبی دارد، اما مدل RNN نسبت به دو مدل دیگر ضعیف‌تر عمل کرده است.

جدول ۶: مقدار AUC-ROC

مدل	AUC-ROC
LSTM+PPO	0.99
LSTM	0.95
RNN	0.90

۷-۶- Log Loss

Log Loss یک متریک ارزیابی برای مدل‌های طبقه‌بندی است که کارایی مدل را در پیش‌بینی احتمال کلاس‌های صحیح بررسی می‌کند. این متریک میزان ناهماهنگی بین پیش‌بینی‌های احتمالی مدل و مقادیر واقعی را اندازه‌گیری می‌کند. هرچه مقدار Log Loss کمتر باشد، مدل بهتر عمل کرده است، چرا که خطای احتمالی کمتری دارد.

جدول ۷: مقدار LOG LOSS

مدل	Log Loss
LSTM+PPO	0.44
LSTM	0.50
RNN	0.60

مدل LSTM+PPO کمترین مقدار Log Loss را دارد که نشان می‌دهد پیش‌بینی‌های آن با کمترین خطا انجام شده است. مقدار ۰,۴۴ حاکی از آن است که مدل با دقت بالایی توانسته است به مقادیر واقعی نزدیک شود و احتمال کلاس‌ها را به درستی پیش‌بینی کند. مدل LSTM با مقدار Log Loss برابر ۰,۵۰ عملکرد مناسبی داشته است، هرچند در مقایسه با LSTM+PPO کمی ضعیف‌تر عمل کرده است. این مقدار نشان می‌دهد که خطای احتمالاتی مدل LSTM بالاتر از مدل LSTM+PPO است، اما همچنان در سطح قابل قبولی قرار دارد و مدل RNN با Log Loss برابر ۰,۶۰ ضعیف‌ترین عملکرد را در میان سه مدل داشته است. این مقدار نشان‌دهنده‌ی این است که پیش‌بینی‌های این مدل دارای خطای بیشتری هستند و احتمال کلاس‌های صحیح را به درستی تعیین نکرده است.

۸- نتیجه‌گیری

در این تحقیق، مدل ترکیبی LSTM+PPO برای پیش‌بینی داده‌های ترافیکی مورد استفاده قرار گرفت و عملکرد آن با دو مدل LSTM و RNN مقایسه شد. نتایج ارزیابی‌ها نشان می‌دهد که مدل LSTM+PPO نسبت به سایر مدل‌ها عملکرد بهتری داشته است. این مدل توانست به دقت ۰,۹۵ و F1-Score برابر با ۰,۹۴ دست یابد، که از هر دو مدل LSTM و RNN بالاتر است. همچنین، AUC-ROC این مدل برابر با ۰,۹۹ بوده که نشان‌دهنده قدرت بالای مدل در تفکیک کلاس‌های مثبت و منفی است. از سوی دیگر، مقدار Log Loss این مدل نیز در مقایسه با مدل‌های دیگر کمتر بود (۰,۴۴) در برابر ۰,۵۰ برای LSTM و ۰,۶۰ برای RNN. این مقادیر نشان‌دهنده کاهش خطای احتمالی مدل و بهبود در پیش‌بینی‌های صحیح می‌باشد. به طور کلی، استفاده از الگوریتم PPO به عنوان یک روش بهینه‌سازی تقویتی به مدل LSTM کمک کرده تا در مواجهه با داده‌های پویا و متغیر عملکرد بهتری داشته باشد و با کاهش نوسانات خطا در اعتبارسنجی، به پایداری و تعمیم‌پذیری بیشتری دست یابد. در عین حال، با وجود موفقیت مدل LSTM+PPO، برخی محدودیت‌ها نیز مشاهده شد. مثلاً، عملکرد مدل در شرایط داده‌های بسیار نامتوازن همچنان می‌تواند بهبود یابد. همچنین، این مدل در تنظیم پارامترها نیاز به بهینه‌سازی بیشتری برای دستیابی به نتایج بهتر در مقیاس‌های بزرگ‌تر دارد. در نهایت، پیشنهاد می‌شود که در تحقیقات آینده از ترکیب تکنیک‌های یادگیری عمیق و روش‌های تقویتی دیگر استفاده شود تا عملکرد مدل‌ها در شرایط پیچیده‌تر و داده‌های بزرگ‌تر بهبود یابد.

منابع

- [1] Manjula, H, M., M., A., Sharifi, K.. (2024). Enhancing transportation efficiency: integrating vanets into intelligent transport management systems (its). 99-115. doi: 10.58532/v3bfct3p3ch8
- [2] Kaushik, C., Karthikeya, T., Vineeth, Venkata, Krishna, A., Abhilash, K. (2023). A Novel Approach for Real Time Traffic Prediction Using Deep Learning in VANET. 1-6. doi: 10.1109/icccnt56998.2023.10306778
- [3] Afandizadeh, S. (2024). Deep Learning Algorithms for Traffic Forecasting: A Comprehensive Review and Comparison with Classical Ones. *Journal of Transportation*, Wiley Online Library.
- [4] Pholpol, C., & Sanguankotchakorn, T. (2021). Traffic Congestion Prediction Using Deep Reinforcement Learning in Vehicular Ad-Hoc Networks (VANETS). *International Journal of Computer Networks & Communications (IJCNC)*.
- [5] Hussein, N. H. (2021). VANET Traffic Prediction Using LSTM with Deep Neural Network Learning. *ResearchGate*.
- [6] Liu, Y., et al. (2023). Intelligent Vehicle Computation Offloading in Vehicular Ad Hoc Networks: A Multi-Agent LSTM Approach with Deep Reinforcement Learning. *MDPI Mathematics*.
- [7] Afandizadeh, S. (2024). Deep Learning Algorithms for Traffic Forecasting: A Comprehensive Review and Comparison with Classical Ones. *Journal of Transportation*, Wiley Online Library.
- [8] Hussein, N. H. (2021). VANET Traffic Prediction Using LSTM with Deep Neural Network Learning. *ResearchGate*.
- [9] Pholpol, C., & Sanguankotchakorn, T. (2021). Traffic Congestion Prediction Using Deep Reinforcement Learning in Vehicular Ad-Hoc Networks (VANETS). *International Journal of Computer Networks & Communications (IJCNC)*.
- [10] Liu, Y., et al. (2023). Intelligent Vehicle Computation Offloading in Vehicular Ad Hoc Networks: A Multi-Agent LSTM Approach with Deep Reinforcement Learning. *MDPI Mathematics*.
- [11] Afandizadeh, S. (2024). Deep Learning Algorithms for Traffic Forecasting. *Journal of Transportation*, Wiley.
- [12] Hussein, N. H. (2021). VANET Traffic Prediction Using LSTM. *ResearchGate*.
- [13] Pholpol, C., & Sanguankotchakorn, T. (2021). Traffic Prediction Using Deep Learning in VANETs. *IJCNC*.

- [14] Liu, Y., et al. (2023). Vehicle Computation Offloading in VANETs Using LSTM. MDPI Mathematics.
- [15] Engstrom, Logan, et al. "Implementation matters in deep rl: A case study on ppo and trpo." International conference on learning representations. 2019.
- [16] Afandizadeh, S. (2024). Deep Learning Algorithms for Traffic Forecasting. *Journal of Transportation*, Wiley.
- [17] Pholpol, C., & Sanguankotchakorn, T. (2021). Traffic Congestion Prediction Using Deep Reinforcement Learning in VANETs. *IJCNC.*
- [18] Liu, Y., et al. (2023). Intelligent Vehicle Computation Offloading in VANETs Using LSTM. *MDPI Mathematics
- [19] Hussein, N. H. (2021). VANET Traffic Prediction Using LSTM with Deep Neural Network Learning. *ResearchGate.*
- [20] Marwah, Gagan Preet Kour, and Anuj Jain. "A hybrid optimization with ensemble learning to ensure VANET network stability based on performance analysis." *Scientific Reports* 12.1 (2022): 10287.
- [21] Zheng, Jianhu, and Mingfang Huang. "Traffic flow forecast through time series analysis based on deep learning." *IEEE Access* 8 (2020): 82562-82570
- [22] Talib, Mohammed Saad, et al. "A center-based stable evolving clustering algorithm with grid partitioning and extended mobility features for VANETs." *IEEE Access* 8 (2020): 169908-169921.
- [23] Bhargava, Arpita, Shekhar Verma, and Brijesh Kumar Chaurasia. "Kalman filter for trust estimation in VANETs." 2015 IEEE UP Section Conference on Electrical Computer and Electronics (UPCON). IEEE, 2015.
- [24] Shelly, Siddharth, and A. V. Babu. "Prediction of link residual lifetime using Kalman filter in vehicular ad hoc networks." 2015 IEEE Recent Advances in Intelligent Computational Systems (RAICS). IEEE, 2015.
- [25] Khatri, Sahil, et al. "Machine learning models and techniques for VANET based traffic management: Implementation issues and challenges." *Peer-to-Peer Networking and Applications* 14 (2021): 1778-1805.
- [26] Ftaimi, Sara, and Tomader Mazri. "A comparative study of Machine learning algorithms for VANET networks." *Proceedings of the 3rd International Conference on Networking, Information Systems & Security*. 2020.

- [27] S Jasim, Mohammed, Nizar Zaghdien, and Mohamed Salim Bouhlel. "Improving detection and prediction of traffic congestion in VANETs: an examination of machine learning." *International Journal of Computing and Digital Systems* 15.1 (2024): 947-960.
- [28] Zhang, Hong, and Li He. "Data mining method of sequential patterns for vehicle trajectory prediction in VANET." *Wireless Personal Communications* 117.2 (2021): 417-429.
- [29] Zhang, Hong, and Li He. "Data mining method of sequential patterns for vehicle trajectory prediction in VANET." *Wireless Personal Communications* 117.2 (2021): 417-429. Zhang, Hong, and Li He. "Data mining method of sequential patterns for vehicle trajectory prediction in VANET." *Wireless Personal Communications* 117.2 (2021): 417-429
- [30] Abdellah, Ali R., and Andrey Koucheryavy. "VANET traffic prediction using LSTM with deep neural network learning." *Internet of Things, Smart Spaces, and Next Generation Networks and Systems: 20th International Conference, NEW2AN 2020, and 13th Conference, ruSMART 2020, St. Petersburg, Russia, August 26–28, 2020, Proceedings, Part I* 20. Springer International Publishing, 2020.
- [31] ALMahadin, Ghayth, et al. "VANET network traffic anomaly detection using GRU-based deep learning model." *IEEE Transactions on Consumer Electronics* 70.1 (2023): 4548-4555.
- [32] Pholpol, Chantakarn, and Teerapat Sanguankotchakorn. "Traffic congestion prediction using deep reinforcement learning in vehicular ad-hoc networks (vanets)." *International Journal of Computer Networks & Communications (IJCNC)* 13.4 (2021): 1-19.
- [33] Tavasolian, Sara, and Mehdi Afzali. "Traffic Flow Prediction Based on VANET Data by Combining Artificial Neural Network and Genetic Algorithm." *Azerbaijan Journal of High Performance Computing* 6.1 (2023): 91-112.
- [34] Cantú-Paz, Erick, et al., eds. *Genetic and Evolutionary Computation-GECCO 2003: Genetic and Evolutionary Computation Conference, Chicago, IL, USA, July 12-16, 2003, Proceedings, Part I*. Vol. 2723. Springer, 2003
- [35] Jiang, Yi, Jinlin Zhu, and Kexin Yang. "Environment-Aware Adaptive Reinforcement Learning-Based Routing for Vehicular Ad Hoc Networks." *Sensors* 24.1 (2023): 40.
- [36] Pholpol, Chantakarn, and Teerapat Sanguankotchakorn. "Traffic congestion prediction using deep reinforcement learning in vehicular ad-hoc networks (vanets)." *International Journal of Computer Networks & Communications (IJCNC)* 13.4 (2021): 1-19
- [37] Kurinjimalar Ramu, M. Ramachandran, and Chinnasami Sivaji. "Understanding Long Short-Term Memory LSTM Models in IBM SPSS Statistics." *Journal on Innovations in Teaching and Learning* 2 (2023): 1

[38] Kandali, Khalid, et al. "An intelligent machine learning based routing scheme for VANET." *IEEE Access* 10 (2022): 74318-74333.