Journal of Soft Computing and Information Technology (JSCIT)
Babol Noshirvani University of Technology, Babol, Iran
Journal Homepage: jscit.nit.ac.ir
DOI: 10.22034/jscit.2026.564785.2200
Volume 15, Number 2, Summer 2026, pp. 31-47
Received: 12/12/2025, Revised: 05/17/2026, Accepted: 05/18/2026

Predicting Accident Severity in Vehicular Ad Hoc Networks (VANETs) Using AOA-Optimized LSTM

Elahe Doostsadigh[1], Kambiz Majidzadeh*[2], Mohammad Masdari[3], Amin Babazadeh Sangar[4] and Farhad Soleimanian Gharehchopogh[5]
[1] Department of Computer Engineering, Ur.C., Islamic Azad University, Urmia, Iran
[2*,3, 4, 5] Department of Computer Engineering, Ur.C., Islamic Azad University, Urmia, Iran
[1]*e.doustsadigh@iau.ir*, [2*]*Kambiz.Majidzadeh@iau.ac.ir*

Corresponding author's address: Kambiz Majidzadeh, Faculty of Computer Engineering, Urmia Azad University of Technology, Urmia, Iran.

Abstract- Vehicular Ad Hoc Networks (VANETs), as a core component of intelligent transportation systems, play a crucial role in traffic safety analysis and traffic management. Accident severity prediction is one of the key applications of VANETs; however, due to the highly dynamic environment, diverse contributing factors, and complex patterns of road accidents, it remains a challenging problem. In this paper, an optimized Long Short-Term Memory (LSTM)–based approach is proposed for accident severity prediction, which can be employed as a decision-support tool in VANET-based environments and intelligent transportation systems. In the proposed method, the hyper-parameters of the LSTM model are automatically tuned using the Archimedes Optimization Algorithm (AOA) in order to enhance prediction accuracy, stability, and generalization capability. To evaluate the effectiveness of the proposed approach, the performance of the AOA-Optimized LSTM (LSTM+AOA) model is compared with baseline LSTM and RNN models, as well as a genetic algorithm–optimized model (GA+LSTM), using a comprehensive set of standard evaluation metrics. The experiments are conducted on the STATS19 UK road accident dataset from 2017, which contains information related to accident characteristics and traffic conditions. Experimental results demonstrate that the AOA-Optimized LSTM (LSTM+AOA) model outperforms the compared methods in accident severity prediction while exhibiting reduced overfitting and improved generalization performance. The findings indicate that employing the AOA for hyper-parameter optimization can significantly improve the performance and robustness of LSTM-based accident severity prediction models, highlighting the potential of the proposed approach as an effective decision-support tool for intelligent traffic management systems.

Keywords- Predicting Accident Severity, VANET, Deep Learning, Optimization, Hyper-parameter, LSTM, AOA.

مجله علمی رایانش نرم و فناوری اطلاعات
دانشگاه صنعتی نوشیروانی بابل
صفحه مجله: jscit.nit.ac.ir
شناسه دیجیتال: 10.22034/jscit.2026.564785.2200
جلد ۱۵، شماره ۲، تابستان ۱۴۰۵، صفحه ۳۱-۴۷
دریافت: ۱۴۰۴/۰۹/۲۱، بازنگری: ۱۴۰۵/۰۲/۲۷، پذیرش: ۱۴۰۵/۰۲/۲۸

پیش‌بینی شدت تصادفات در شبکه‌های سیار خودرویی (VANETs) با استفاده از LSTM بهینه‌شده توسط الگوریتمAOA

الهه دوست صدیق[۱]، کامبیز مجیدزاده*[۲]، محمد مصدری[۳]، امین بابازاده[۴] و فرهاد سلیمانیان[۵]
[۱] دانشجوی دکترا، گروه کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران.
*[۲و۳و۴و۵] استادیار، گروه کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران.
[1]e.doustsadigh@iau.ir, [2*]Kambiz.Majidzadeh@iau.ac.ir

* نشانی نویسنده مسئول: کامبیز مجیدزاده، ارومیه، کیلومتر دو جاده سلماس، دانشگاه آزاد ارومیه، مجتمع آیت‌الله رفسنجانی، دانشکده مهندسی کامپیوتر.

چکیده - شبکه‌های سیار خودرویی (VANET) به‌عنوان یکی از اجزای کلیدی سامانه‌های حمل‌ونقل هوشمند، نقش مهمی در تحلیل ایمنی جاده‌ها و مدیریت ترافیک ایفا می‌کنند. پیش‌بینی شدت تصادف یکی از کاربردهای مهم این شبکه‌ها محسوب می‌شود که به دلیل پویایی بالای محیط، تنوع عوامل مؤثر و پیچیدگی الگوهای حوادث جاده‌ای، یک مسئله چالش‌برانگیز به شمار می‌رود. در این مقاله، یک روش مبتنی بر شبکه عصبی حافظه بلندمدت کوتاه‌مدت (LSTM) بهینه‌سازی‌شده با استفاده از الگوریتم بهینه‌سازی ریاضی (AOA) برای پیش‌بینی شدت تصادف ارائه شده است که می‌تواند به‌عنوان یک ابزار تصمیم یار در محیط‌های مبتنی بر VANET و سامانه‌های حمل‌ونقل هوشمند مورداستفاده قرار گیرد. در روش پیشنهادی، ابرپارامترهای مدل LSTM به‌صورت خودکار توسط الگوریتم AOA تنظیم می‌شوند تا دقت، پایداری و قابلیت تعمیم مدل افزایش یابد. به‌منظور ارزیابی اثربخشی روش پیشنهادی، عملکرد مدل AOA-Optimized LSTM (LSTM+AOA)با مدل‌های پایه LSTM، RNN و همچنین روش بهینه‌سازی‌شده(GA+LSTM) ، بر اساس مجموعه‌ای از معیارهای ارزیابی استاندارد مقایسه شده است. داده‌های مورداستفاده از مجموعه‌داده تصادفات جاده‌ای بریتانیا (STATS19) مربوط به سال ۲۰۱۷ استخراج شده‌اند که شامل اطلاعات مرتبط با ویژگی‌های تصادفات و شرایط ترافیکی می‌باشند. نتایج تجربی نشان می‌دهد که مدل AOA-Optimized LSTM (LSTM+AOA) در مقایسه با سایر مدل‌های بررسی‌شده، عملکرد برتری در پیش‌بینی شدت تصادف ارائه داده و درعین‌حال شدت بیش برازش کمتری از خود نشان می‌دهد. یافته‌های این پژوهش بیانگر آن است که استفاده از الگوریتم AOA برای تنظیم ابرپارامترهای LSTM می‌تواند نقش مؤثری در بهبود دقت و پایداری مدل‌های پیش‌بینی شدت تصادف ایفا کند و این رویکرد قابلیت استفاده به‌عنوان یک ابزار پشتیبان تصمیم‌گیری در سامانه‌های مدیریت هوشمند ترافیک را دارا می‌باشد.

واژه‌های کلیدی: پیش‌بینی شدت تصادف، شبکه‌های سیار خودرویی، یادگیری عمیق، بهینه‌سازی، ابرپارامتر، LSTM، AOA.

۱- مقدمه

رشد سریع شهرنشینی و افزایش تعداد وسایل نقلیه در دهه‌های اخیر، مدیریت ترافیک شهری و ارتقای ایمنی جاده‌ای را به یکی از چالش‌های اساسی جوامع مدرن تبدیل کرده است [۱]. افزایش تراکم ترافیک نه‌تنها موجب اتلاف زمان و افزایش مصرف انرژی

می‌شود، بلکه پیامدهای جدی‌تری نظیر افزایش تصادفات جاده‌ای و تلفات انسانی را نیز به همراه دارد [۲]. در این راستا، سامانه‌های حمل‌ونقل هوشمند [۱]، به‌ویژه شبکه‌های سیار خودرویی [۲] به‌عنوان راهکارهایی نوین برای بهبود مدیریت ترافیک، افزایش ایمنی و کاهش اثرات منفی زیست‌محیطی موردتوجه قرار گرفته‌اند [۳]. شبکه‌های سیار خودرویی با فراهم‌سازی بستر تبادل اطلاعات میان وسایل نقلیه و زیرساخت‌های جاده‌ای، امکان تحلیل و پشتیبانی از تصمیم‌گیری در حوزه ایمنی ترافیک را فراهم می‌کند [۴]. بااین‌حال، پویایی بالای این شبکه‌ها و پیچیدگی عوامل مؤثر بر حوادث جاده‌ای، پیش‌بینی دقیق رخدادهایی نظیر شدت تصادفات را به یک مسئله چالش‌برانگیز تبدیل کرده است [۵].

در سال‌های اخیر، روش‌های یادگیری عمیق به دلیل توانایی بالا در استخراج الگوهای پیچیده از داده‌های حجیم و ناهمگن، به طور گسترده در مسائل مرتبط با ترافیک و ایمنی جاده‌ای به کار گرفته شده‌اند [۶]. در این میان، شبکه‌های عصبی حافظه بلندمدت کوتاه‌مدت [۳] به‌واسطه قابلیت مدل‌سازی وابستگی‌های زمانی و روندهای پنهان در داده‌ها، کاربرد گسترده‌ای در تحلیل پدیده‌های ترافیکی داشته‌اند [۷]. اگرچه شدت تصادف ذاتاً یک مسئله طبقه‌بندی محسوب می‌شود، اما الگوهای منجر به وقوع و شدت حوادث، متأثر از روندهای زمانی، شرایط پیشین ترافیک و هم‌بستگی میان رکوردهای متوالی هستند؛ امری که استفاده از مدل‌های دارای حافظه زمانی نظیر LSTM را توجیه‌پذیر می‌سازد. بااین‌وجود، عملکرد مدل‌های LSTM به‌شدت به تنظیم مناسب ابرپارامترهایی نظیر نرخ یادگیری، تعداد لایه‌ها و تعداد نورون‌ها وابسته است [۸]. تنظیم دستی این پارامترها علاوه بر زمان‌بر بودن، غالباً به راه‌حل‌های غیربهینه منجر می‌شود [۹].

به‌منظور غلبه بر این چالش، الگوریتم‌های بهینه‌سازی فراابتکاری به‌عنوان ابزارهایی کارآمد برای تنظیم خودکار ابرپارامترهای مدل‌های یادگیری عمیق معرفی شده‌اند [۱۰]. این الگوریتم‌ها با جست‌وجوی هوشمند در فضای پارامترها، امکان بهبود دقت و پایداری مدل‌ها را فراهم می‌کنند [۱۱]. باوجود این، بسیاری از مطالعات پیشین یا بر مدل‌های سنتی و ساده متکی بوده‌اند که توانایی محدودی در مواجهه با پویایی و پیچیدگی محیط‌های VANETدارند، یا از روش‌های بهینه‌سازی‌ای استفاده کرده‌اند که در تنظیم مدل‌های عمیق با فضای جست‌وجوی بزرگ، کارایی مطلوبی ارائه نمی‌دهند [۱۲]. علاوه بر این، بهره‌گیری از مجموعه‌داده‌های واقعی و جامع تصادفات جاده‌ای برای ارزیابی این روش‌ها کمتر موردتوجه قرار گرفته است.

این روش با بهره‌گیری AOA[۴] برای تنظیم خودکار ابرپارامترهای LSTM، دقت پیش‌بینی را افزایش داده و خطای مدل را کاهش می‌دهد. روش پیشنهادی روی مجموعه‌داده‌های تصادفات جاده‌ای ۲۰۱۷ بریتانیا ارزیابی شده است که اطلاعاتی جامع درباره شدت تصادفات و عوامل مرتبط ارائه می‌دهد [۱۳]. نتایج نشان‌دهنده برتری این روش نسبت به مدل‌های سنتی و مرجع در معیارهایی نظیر دقت، ROC-AUC[۵]، و خطای میانگین مربعات[۶] است.

در این پژوهش، برای تنظیم خودکار ابرپارامترهای مدل LSTM، از الگوریتم AOA استفاده شده است. الگوریتم AOA یک الگوریتم متا هیوریستیک جدید است که در سال ۲۰۲۱ توسط Abualigah و همکاران معرفی شد. ایده‌ی AOA بر پایه‌ی مدل‌سازی عملگرهای حسابی به‌عنوان قواعد جست‌وجو در فضای بهینه‌سازی است، به‌گونه‌ای که عملگرهای ضرب و تقسیم برای افزایش تنوع جست‌وجوی سراسری و عملگرهای جمع و تفریق برای تمرکز روی نواحی امیدبخش به کار می‌روند. این طراحی یک تعبیر محاسباتی برای کنترل هم‌زمان کاوش و بهره‌برداری است و در کار اصلی الگوریتم به‌صورت تجربی و تابعی تنظیم شده است [۱۴]. این الگوریتم با الهام از عملیات پایه حسابی (جمع، تفریق، ضرب و تقسیم)، ساختاری ساده ولی مؤثر دارد و توانایی بالایی در برقراری تعادل بین جستجوی محلی و جهانی دارد. عملکرد آن در بسیاری از مسائل بهینه‌سازی ترکیبی و پیوسته، نتایج قابل‌توجهی به همراه داشته است [۱۵].

نوآوری این پژوهش در به‌کارگیری AOA به‌عنوان بهینه‌ساز ابرپارامترهای LSTM در مسئله پیش‌بینی ترافیک VANET است. برخلاف GA[7] و PSO[8] که به پارامترهای کنترلی متعدد و تنظیمات حساس وابسته‌اند، AOA با تعداد پارامتر کمتر و انتقال تدریجی در فضای ابرپارامترها فراهم می‌کند. برخلاف روش‌های کلاسیک مانند جست‌وجوی شبکه‌ای یا جست‌وجوی تصادفی که از نظر زمان و منابع ناکارآمد هستند و حتی در مقایسه با الگوریتم‌های فراابتکاری قدیمی مانند PSO و GA که ممکن است به مینیمم‌های محلی همگرا شوند، AOA به دلیل طراحی ساده، تعداد پارامترهای کنترلی کم و نرخ همگرایی بالا، گزینه‌ای بسیار مناسب محسوب می‌شود [۱۶]. نتایج تجربی حاصل از ترکیب AOA با مدل LSTM نشان می‌دهد که این روش منجر به بهبود قابل‌توجهی در دقت پیش‌بینی، کاهش خطای RMSE و MAE[9] و افزایش پایداری در عملکرد مدل در داده‌های آزمایش‌شده می‌شود. این یافته‌ها مؤید پتانسیل بالای AOAدر مسائل بهینه‌سازی پارامترهای مدل‌های یادگیری عمیق است [۱۷]. این مقاله به‌صورت زیر سازمان‌دهی شده است: بخش دوم مرور کارهای پیشین را تشریح می‌کند، بخش سوم الگوریتم

بهینه‌سازی AOA را ارائه می‌دهد، بخش چهارم روش پیشنهادی را شرح می‌دهد. بخش پنجم ارزیابی نتایج و بخش ششم نتیجه‌گیری را ارائه می‌دهد.

۲- مرور کارهای پیشین

پیش‌بینی ترافیک در شبکه‌های خودرویی، به‌ویژه پیش‌بینی شدت تصادفات، به دلیل پویایی و پیچیدگی داده‌های بلادرنگ حاصل از ارتباطات خودرو به خودرو و خودرو به زیرساخت، چالشی کلیدی در سیستم‌های حمل‌ونقل هوشمند است. در ادامه پژوهش‌های پیشین با تأکید بر معیارهای ارزیابی، نوع داده‌ها، و محدودیت‌ها دسته‌بندی بررسی شده‌اند و شکاف‌های پژوهشی شناسایی می‌شوند.

۲-۱- روش‌های آماری و یادگیری ماشین سنتی

روش‌های آماری مانند رگرسیون خطی و مدل‌های سری زمانی از اولین روش‌های مورداستفاده برای پیش‌بینی ترافیک بوده‌اند. مدل‌هایی مانند ARIMA[10] در برخی پژوهش‌ها دقت قابل‌قبولی ارائه کرده‌اند، به‌طوری که در مطالعه‌ای دقت حدود ۷۰٪ برای پیش‌بینی جریان ترافیک شهری گزارش شده است [۱۹]. باوجود این، روش‌های آماری مبتنی بر فرض خطی‌بودن داده‌ها هستند و برای داده‌های غیرخطی و نویزی شبکه‌های VANET مناسب نیستند. این مدل‌ها به داده‌های منظم و ایستا وابسته‌اند و قادر به مدل‌سازی پویایی‌ها، رفتارهای تصادفی و تغییرات سریع شبکه نیستند. علاوه بر این، داده‌های واقعی مانند مجموعه STATS19 شامل نویز و داده‌های گمشده هستند که عملکرد مدل‌های آماری را کاهش می‌دهد [۱۳]. در نتیجه، روش‌های آماری برای کاربردهای بلادرنگ و پیچیده VANET محدودیت جدی دارند [۲۰]. با پیشرفت یادگیری ماشین، مدل‌هایی مانند SVM[11] و درخت تصمیم برای پیش‌بینی شدت تصادفات و ترافیک مورداستفاده قرار گرفتند. برای مثال، استفاده از SVM در برخی مطالعات منجر به‌دقت حدود ۷۵٪ شده است [۲۱]. بااین‌حال، روش‌های سنتی معمولاً به استخراج ویژگی‌های دستی وابسته‌اند و در مدل‌سازی وابستگی‌های زمانی بلندمدت عملکرد ضعیفی دارند. به‌طورکلی، اگرچه روش‌های یادگیری ماشین نسبت به روش‌های آماری عملکرد بهتری دارند، اما همچنان برای تحلیل پیچیدگی‌های زمانی و مکانی VANET کافی نیستند.

۲-۲- روش‌های یادگیری عمیق

ظهور روش‌های یادگیری عمیق مانند RNN[12] و LSTM تحول بزرگی در پیش‌بینی ترافیک ایجاد کرد. RNN ها، به دلیل توانایی در پردازش توالی‌ها، در برخی مطالعات مانند [۲۲] و [۲۳] عملکرد بهتری نسبت به روش‌های سنتی داشتند، اما مشکل بنیادی محوشدن گرادیان مانع یادگیری وابستگی‌های بلندمدت در آنها می‌شود [۲۴]. برای رفع این مشکل، شبکه‌های LSTM معرفی شدند و در مطالعات مختلف به‌عنوان یکی از قدرتمندترین ابزارها برای مدل‌سازی سری‌های زمانی شناخته شدند [۷]. باوجود این ظرفیت بالا، مدل‌های LSTM کاملاً به تنظیم دقیق ابرپارامترها وابسته‌اند و انتخاب نامناسب نرخ یادگیری، تعداد نورون‌ها، تعداد لایه‌ها یا حذف تصادفی نورون‌ها به‌صورت موقت [۱۳] می‌تواند منجر به بیش برازش، ناپایداری یا افت دقت شود [۲۵]؛ لذا برای بهره‌گیری مؤثر از LSTM در کاربردهای پیچیده‌ای مانند VANET، استفاده از روش‌های هوشمند و خودکار برای تنظیم ابرپارامترها ضروری است.

۲-۳- روش‌های بهینه‌سازی فراابتکاری برای LSTM

برای بهبود عملکرد LSTM، مطالعات زیادی به سمت استفاده از الگوریتم‌های فراابتکاری حرکت کرده‌اند. الگوریتم ژنتیک در برخی پژوهش‌ها مانند [۲۵] و [۲۷] یک روش مبتنی بر شبکه عصبی حافظه بلند عمیق برای پیش‌بینی سری‌های زمانی ارائه شده است. در این روش، چندین لایه LSTM به‌صورت پشته‌ای به کار گرفته می‌شوند تا وابستگی‌های زمانی بلندمدت و روابط غیرخطی داده‌ها به طور مؤثرتری مدل‌سازی شوند. هر لایه الگوهای زمانی را در مقیاس متفاوتی استخراج کرده و خروجی آن به لایه بعدی منتقل می‌شود. همچنین، پارامترهای اصلی شبکه با استفاده از الگوریتم ژنتیک بهینه‌سازی شده‌اند. روش‌های مبتنی بر مکانیزم توجه مانند مطالعه [۲۶] دقت را افزایش دادند؛ اما پیچیدگی محاسباتی بالایی دارند. مدل‌های تکاملی مبتنی بر توجه نیز نتایج خوبی ثبت کردند [۲۸]، ولی برای داده‌های بسیار غیرخطی پایداری کامل ندارند. در مطالعه [۲۹] یک روش ترکیبی برای پیش‌بینی کوتاه‌مدت ترافیک ارائه شده است که به‌منظور مدل‌سازی هم‌زمان الگوهای خطی و غیرخطی داده‌ها طراحی شده است. در این روش، ابتدا با استفاده از مدل تحلیل سری‌های زمانی [۱۴] مؤلفه‌های خطی شامل روند و فصلی بودن داده‌ها استخراج و حذف می‌شوند. سپس مؤلفه باقیمانده که شامل الگوهای غیرخطی است، به شبکه LSTM مجهز به مکانیزم توجه داده می‌شود تا وابستگی‌های زمانی مهم به طور مؤثر یاد گرفته شوند. در نهایت، برای تنظیم بهینه ابرپارامترهای مدل، از الگوریتم Bayesian Contextual Hyperband استفاده شده است. نتایج نشان می‌دهد که این ساختار ترکیبی نسبت به مدل‌های پایه، دقت پیش‌بینی بالاتری دارد، اما در فضاهای جستجوی بزرگ ناپایدار است. روش‌های مبتنی بر گرادیان مانند Adam، RMSprop و سایر

روش‌های وزن‌دهی تطبیقی نیز سرعت همگرایی بالایی دارند [۳۰] , [۳۳]، اما توانایی آنها برای پرهیز از بهینه‌های محلی محدود است. الگوریتم‌های پیشرفته‌تر مانند AutoML [۳۱] و ترکیب Transformer–LSTM [۳۴] دقت بالایی دارند؛ ولی به علت پیچیدگی زیاد و نیاز به منابع محاسباتی سنگین، برای محیط‌های بلادرنگ VANET مناسب نیستند. در این میان، الگوریتم AOA که یک الگوریتم نوظهور مبتنی بر عملیات حسابی است، در مطالعات [۱۰] و [۱۴] بهبود قابل‌توجهی در همگرایی و پایداری نشان داده است. این الگوریتم با تعداد پارامترهای کم و توانایی کنترل مؤثر تعادل بین کاوش و بهره‌برداری، پتانسیل بالایی برای تنظیم ابرپارامترهای مدل‌های یادگیری عمیق دارد.

۲-۴- جمع‌بندی و شناسایی شکاف‌های پژوهشی

بررسی انتقادی پژوهش‌های گذشته نشان می‌دهد که علی‌رغم تلاش‌های فراوان، چند شکاف اساسی همچنان باقی است. نخست اینکه روش‌های آماری و یادگیری ماشین سنتی در مدل‌سازی رفتارهای پیچیده و پویا در VANET ناکارآمد هستند. دوم اینکه روش‌های یادگیری عمیق مانند LSTM باوجود توانایی بالا، بدون تنظیم دقیق ابرپارامترها به‌سختی به عملکرد پایدار می‌رسند. سوم اینکه الگوریتم‌های فراابتکاری موجود یا سرعت کافی برای شرایط بلادرنگ را ندارند یا در فضای جستجوی پیچیده دچار ناپایداری می‌شوند. چهارم آنکه باوجود معرفی الگوریتم AOA در سال ۲۰۲۱ و اثربخشی آن در بسیاری از مسائل بهینه‌سازی، هیچ پژوهشی از AOAبرای تنظیم ابرپارامترهای LSTM در زمینه پیش‌بینی ترافیک VANET استفاده نکرده است. این خلأ پژوهشی نشان می‌دهد که روش پیشنهادی این مطالعه، یعنی ترکیب LSTM با الگوریتم AOA، می‌تواند پاسخی نوآورانه و مؤثر برای بهبود دقت، پایداری و سرعت پیش‌بینی در محیط‌های پویا و پیچیده VANET باشد.

۳- الگوریتم بهینه‌سازی AOA

الگوریتم بهینه‌سازی ریاضی یک روش متا هیوریستیک جدید است که از رفتار توزیع اپراتورهای اصلی ریاضی (ضرب، تقسیم، تفریق و جمع) الهام‌گرفته شده و برای حل مسائل بهینه‌سازی پیچیده طراحی شده است. این الگوریتم با ایجاد تعادل بین دوفاز کاوش [۱۵] و بهره‌برداری [۱۶] به جستجوی راه‌حل‌های بهینه در فضای جستجوی گسترده می‌پردازد. در ادامه، مراحل اصلی و عملکرد AOA به‌صورت خلاصه توضیح داده شده است.

جدول ۱: مقایسه تطبیقی روش‌های بهینه‌سازی ابرپارامترهای شبکه LSTM در مطالعات پیشین

مرجع	نقاط ضعف	نقاط قوت	نوع الگوریتم	روش بهینه سازی LSTM
[۲۶]	پیچیدگی محاسباتی بالا، نیاز به تنظیم دقیق وزن‌های توجه	LSTM+ مکانیزم توجه	تکاملی (جستجوی تصادفی رقابتی)	استفاده از مکانیزم توجه برای حفظ وابستگی‌های طولانی‌مدت، بهبود دقت پیش‌بینی
[۲۷]	زمان‌بر بودن بهینه‌سازی، نیاز به منابع محاسباتی زیاد	الگوریتم ژنتیک (GA)	تکاملی	بهینه‌سازی خودکار معماری و ابرپارامترها، انعطاف‌پذیری در مسائل پیچیده
[۲۸]	عدم توانایی در مدیریت داده‌های بسیار غیرخطی، وابستگی به کیفیت داده‌های ورودی	LSTM+ مکانیزم توجه	تکاملی (جستجوی تصادفی رقابتی)	انتخاب خودکار بهترین ترکیب ابرپارامترها و وزن‌های توجه
[۲۹]	وابستگی به مدل احتمالاتی اولیه، عملکرد ضعیف در فضاهای جستجوی بزرگ	بهینه‌سازی بیزی (Bayesian Optimization)	آماری	کارایی بالا در جستجوی فضای ابرپارامتر، کاهش تعداد آزمایش‌ها
[۳۰]	حساسیت به تنظیمات اولیه، احتمال گیر کردن در مینیمم محلی	الگوریتم گرادیان کاهشی(Adam)	سنتی	سرعت همگرایی بالا، مناسب برای داده‌های بزرگ
[۳۱]	پیچیدگی محاسباتی بالا، نیاز به داده‌های آموزشی زیاد	شبکه‌های خودکار تنظیم(AutoML)	یادگیری عمیق	اتوماسیون کامل فرآیند بهینه‌سازی، کاهش نیاز به دخالت انسانی
[۳۲]	کند بودن همگرایی در مسائل با ابعاد بالا	الگوریتم کلونی مورچه(ACO)	تکاملی	توانایی جستجوی جهانی، انعطاف‌پذیری در مسائل غیرخطی
[۳۳]	عدم توانایی در مدیریت وابستگی‌های بسیار طولانی	بهینه‌سازی مبتنی بر گرادیان (RMSprop)	سنتی	پایداری در بهینه‌سازی، مناسب برای سری‌های زمانی پویا
[۳۴]	نیاز به منابع محاسباتی بالا، پیچیدگی در پیاده‌سازی	شبکه‌های ترنسفورمر ترکیبی باLSTM	یادگیری عمیق	توانایی مدل‌سازی الگوهای پیچیده، دقت بالا در پیش‌بینی‌های پویا

۳-۱- مفهوم اصلی و مراحل الگوریتم

الگوریتم بهینه‌سازی ریاضی از اپراتورهای ریاضی (ضرب، تقسیم، تفریق و جمع) الهام‌گرفته است. این اپراتورها به‌عنوان ابزاری برای

مدل‌سازی رفتارهای جستجو در فضای بهینه‌سازی استفاده می‌شوند. ضرب و تقسیم به دلیل پراکندگی بالا برای کاوش در فضای جستجو مناسب‌اند، درحالی‌که تفریق و جمع به دلیل تراکم بالا برای بهره‌برداری و بهبود راه‌حل‌های محلی به کار می‌روند. الگوریتم AOA یک الگوریتم مبتنی بر جمعیت است که با مجموعه‌ای از راه‌حل‌های تصادفی آغاز می‌شود و به‌تدریج این راه‌حل‌ها را بهبود می‌دهد. مراحل اصلی آن عبارت‌اند از:

- **انتخاب فاز جستجو AOA:** با استفاده از تابع Math Optimizer Accelerated (MOA) بین فازهای کاوش و بهره‌برداری جابه‌جا می‌شود. این تابع با فرمول رابطه ۱ محاسبه می‌شود:

$$MOA(c_{Iter}) = min + C_{Iter} * \left(\frac{Max - Min}{Iter^{M}}\right) \quad (۱)$$

در رابطه ۱ C_{Iter} تکرار جاری، $Iter^{M}$ حداکثر تعداد تکرارها، Min و Max مقادیر حداقل و حداکثر تابع هستند. در هر تکرار، مقدار MOA طبق رابطه (۱) محاسبه می‌شود. سپس یک عدد تصادفی $r_1 \sim U(0,1)$ تولید می‌گردد. اگر $r_1 >$ MOA باشد الگوریتم وارد فاز کاوش می‌شود و در غیر این صورت فاز بهره‌برداری فعال خواهد شد. این سازوکار باعث تغییر تدریجی از جست‌وجوی سراسری به جست‌وجوی محلی در طول تکرارها می‌شود.

- **فاز اولیه‌سازی:** الگوریتم با تولید تصادفی مجموعه‌ای از راه‌حل‌های کاندید (جمعیت) شروع می‌شود. این راه‌حل‌ها به‌صورت ماتریسی نمایش داده می‌شوند که هر سطر نشان‌دهنده یک راه‌حل و هر ستون نشان‌دهنده یک متغیر تصمیم است

- **فاز کاوش:** در این فاز، اپراتورهای ضرب و تقسیم برای جستجوی گسترده در فضای جستجو استفاده می‌شوند.

این اپراتورها به دلیل پراکندگی بالا، به الگوریتم کمک می‌کنند تا از به دام افتادن در بهینه‌های محلی جلوگیری کند.

در الگوریتم AOA همه متغیرهای تصمیم در بازه‌های مجاز نرمال‌سازی و بی‌بعد در نظر گرفته می‌شوند؛ بنابراین عملگرهای حسابی روی بردار موقعیت‌ها کاملاً معتبر است. پس از به‌روزرسانی موقعیت‌ها در روابط (۳) و (۴)، هر بعد از بردار جدید در صورت خروج از قیود به‌صورت زیر برش می‌شود:

که در آن $best(x_j)$ بهترین موقعیت تاکنون، MOP احتمال بهینه‌ساز ریاضی، ϵ یک عدد کوچک، UB_j و LB_j کران‌های بالا و پایین، و پارامتر μ ضریب کنترل شدت جابه‌جایی در فضای جست‌وجو است. طبق پیشنهاد مقاله اصلی AOA ، مقدار μ =۰,۵ به‌عنوان مقدار پیش‌فرض استفاده می‌شود، اما در این پژوهش مقدار آن به‌صورت ثابت و مطابق مرجع در نظر گرفته شده تا اثر الگوریتم روی مسئله حفظ شود. در صورت نیاز می‌توان μ را نیز به‌عنوان پارامتر قابل‌تنظیم وارد فرایند بهینه‌سازی کرد.

$$X_{i,j} = min\left(max\left(X_{i,j}, LB_j\right), UB_j\right) \quad (۲)$$

$$X_{i,j}(c_{Iter}+1) = \begin{cases} best(x_j) \div (MOP+\epsilon) * \left(\left(UB_j - LB_j\right) * \mu + LB_j\right), r2 < 0.5 \\ best(x_j) * MOP * \left(\left(UB_j - LB_j\right) * \mu + LB_j\right), otherwise \end{cases} \quad (۳)$$

$$X_{i,j}(c_{Iter}+1) = \begin{cases} best(x_j) - (MOP+\epsilon) * \left(\left(UB_j - LB_j\right) * \mu + LB_j\right), & r3 < 0.5 \\ best(x_j) + MOP * \left(\left(UB_j - LB_j\right) * \mu + LB_j\right), & otherwise \end{cases} \quad (۴)$$

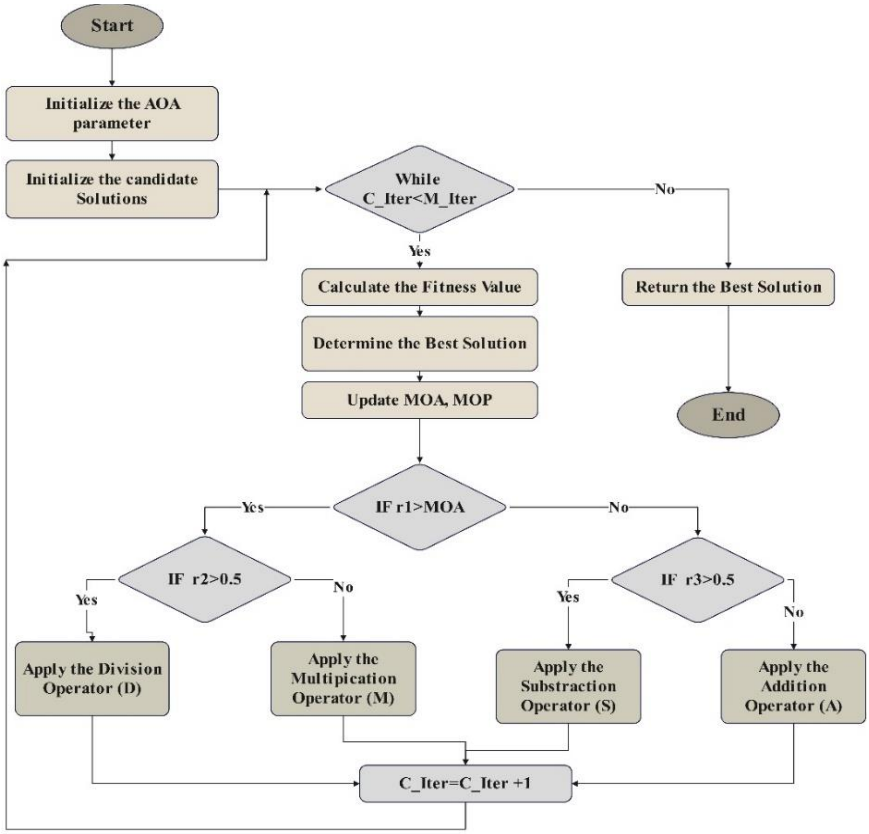
- **فاز بهره‌برداری:** در این فاز، اپراتورهای تفریق و جمع برای جستجوی عمیق در مناطق امیدوارکننده به کار می‌روند. این اپراتورها به دلیل تراکم بالا، دقت راه‌حل‌های محلی را افزایش می‌دهند.

- **پایان الگوریتم:** الگوریتم تا رسیدن به معیار توقف (مانند حداکثر تعداد تکرارها) ادامه می‌یابد و بهترین راه‌حل به‌دست‌آمده گزارش می‌شود.

با استفاده از تابع MOA و اپراتورهای ریاضی، تعادل مناسبی بین کاوش جهانی و بهره‌برداری محلی برقرار می‌کند. سادگی و انعطاف‌پذیری :این الگوریتم با حداقل پارامترهای قابل‌تنظیم (مانند μ=۰,۵ و α=۵) پیاده‌سازی آسانی دارد و برای مسائل مختلف بهینه‌سازی قابل‌استفاده است [۱۴]. نمودار شکل ۱ فلوچارت الگوریتم پیشنهادی را نشان می‌دهد.

۴- روش پیشنهادی

در این تحقیق، ما یک مدل پیش‌بینی شدت تصادفات جاده‌ای را با استفاده از شبکه‌های عصبی LSTM به‌منظور تحلیل داده‌های تصادفات جاده‌ای توسعه داده‌ایم. مدل پیشنهادی به طور خاص شامل مراحل مختلف پیش‌پردازش داده‌ها، بهینه‌سازی‌های ابرپارامتر و آموزش مدل LSTM برای بهبود دقت پیش‌بینی شدت تصادفات است. برای بهینه‌سازی ابرپارامترهای مدل، از الگوریتم بهینه‌سازی AOA استفاده کرده‌ایم. در این بخش، روش‌های



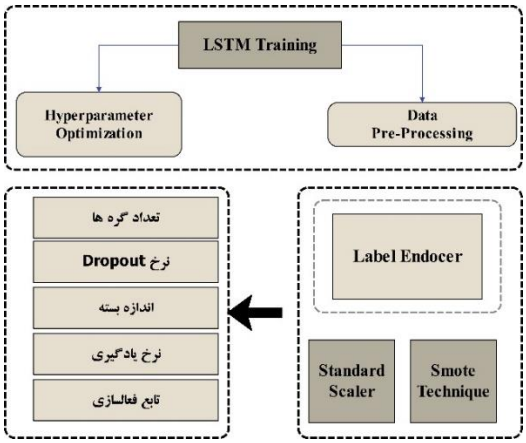
شکل ۱- فلوچارت الگوریتم بهینه‌سازی محاسبات ریاضی

استفاده‌شده در این تحقیق شرح داده می‌شود.

۴-۱- پیش‌پردازش داده‌ها

در این تحقیق داده‌ها پیش از استفاده در مدل، از طریق چندین مرحله پردازش پیشرفته تمیز و استانداردسازی شدند. در ابتدا، تمامی متغیرهای رشته‌ای با استفاده از کدگذارهای برچسب‌گذاری ۸ به مقادیر عددی تبدیل شدند. سپس داده‌ها به ویژگی‌ها و متغیر هدف (شدت تصادف) تقسیم شدند. ویژگی‌ها با استفاده از تکنیک استانداردسازی با استفاده از نرمال‌ساز استاندارد ۹ مقیاس‌بندی شدند تا الگوریتم‌های یادگیری به طور مؤثرتر به بهینه‌سازی بپردازند. به‌منظور جلوگیری از نشت داده، ابتدا داده‌ها به دو بخش آموزش (۷۰٪) و اعتبارسنجی (۳۰٪) تقسیم شدند. سپس تکنیک SMOTE تنها روی داده‌های بخش آموزش اعمال گردید تا نمونه‌های مصنوعی برای کلاس‌های اقلیت تولید شود. این رویکرد تضمین می‌کند که هیچ اطلاعاتی از داده‌های اعتبارسنجی در فرایند ایجاد نمونه‌های مصنوعی استفاده نشده و نتایج ارزیابی عاری از تورم ناشی از نشت داده باشند.

همچنین باتوجه‌به اینکه مسئله حاضر یک مسئله طبقه‌بندی بر اساس ویژگی‌های ایستا است و هر نمونه تصادف به‌صورت مستقل و بدون وابستگی زمانی مستقیم به نمونه‌های دیگر پیش‌بینی می‌شود، استفاده از SMOTE برای متوازن‌سازی توزیع کلاس‌ها بدون تخریب ساختار زمانی داده‌ها قابل‌توجیه است.



شکل ۲ معماری کلی روش پیشنهادی

۴-۲- بهینه‌سازی ابرپارامترها با استفاده از الگوریتم AOA

برای بهینه‌سازی ابرپارامترهای مدل LSTM، از الگوریتم بهینه‌سازی AOA استفاده کردیم که هدف آن به‌دست‌آوردن مجموعه بهترین

مقادیر ابرپارامترهای مدل است. الگوریتم AOA به‌عنوان یک روش مبتنی بر جمعیت در فضای جستجوی ابرپارامترها عمل می‌کند. در این الگوریتم، مجموعه‌ای از مقادیر اولیه برای ابرپارامترها به طور تصادفی تولید شده و در هر تکرار، عملکرد مدل با استفاده از یک تابع هدف محاسبه می‌شود. سپس، بهترین مقادیر ابرپارامترها بر اساس عملکرد ارزیابی می‌شوند و به طور مداوم با استفاده از تغییرات جمعیت و میانگین‌های حاصل از جمعیت فعلی به‌روز می‌شوند.

جدول ۲: فضای جستجوی ابرپارامترهای شبکه LSTM

اندیس	نوع	مقدار
۰	تعداد گره‌های LSTM	[۵۰،۱۵۰]
۱	نرخ حذف موقت	[۰،۱-۰،۵]
۲	اندازه بسته	[۳۲،۱۲۸]
۳	نرخ یادگیری	[$۱۰^{-۵}$،$۱۰^{-۳}$]
۴	نوع تابع فعال‌سازی	(کدگذاری ۰ تا ۴)
۵	تعداد لایه‌های LSTM	[۲،۴]
۶	تابع بهینه‌سازی	کدگذاری ۰ تا ۲

ابرپارامترهایی که در این تحقیق بهینه شده‌اند شامل تعداد واحدهای LSTM، نرخ دراپ اوت، اندازه دسته، تعداد لایه‌ها، نرخ یادگیری، تابع فعال‌سازی و انتخاب الگوریتم بهینه‌سازی هستند. این الگوریتم همچنین از معیار دقت اعتبارسنجی وزن‌دهی شده برای ارزیابی مدل استفاده می‌کند و در نهایت بهترین ترکیب از ابرپارامترها را انتخاب می‌کند. در این روش هر جواب کاندید توسط یک آرایه یک‌بعدی به طول ۷ مدل شده است که هر کدام از اندیس‌های این آرایه بیانگر یکی از ابرپارامترهای می‌باشد. جدول ۲ نحوه رمزگذاری جواب‌های کاندید را نشان می‌دهد. جدول ۲ سعی کرده یک آرایه یک‌بعدی را نشان دهد که اندیس اول (اندیس ۰) آن تعداد گره‌ها را نشان می‌دهد که یک عدد تصادفی بین ۵۰ الی ۱۵۰ به طور تصادفی انتخاب می‌شود. اندیس دوم (اندیس ۱) نرخ دراپ اوت را نشان می‌دهد که می‌تواند یک مقدار تصادفی بین ۰،۱ الی ۰،۵ داشته باشد، اندیس سوم (اندیس ۲) اندازه بسته‌ها را نشان می‌دهد که می‌تواند یک عدد تصادفی بین ۳۲ الی ۱۲۸ باشد، اندیس چهارم (اندیس ۳) به نرخ یادگیری اشاره دارد که می‌تواند بین ۰،۰۰۰۰۱ الی ۰،۰۰۱ باشد.

۴-۲-۱- تابع برازندگی

در این تحقیق، مسئله بهینه‌سازی ابرپارامترهای مدل به‌صورت یک مسئله تک‌هدفه فرموله شده است. تابع برازندگی مورداستفاده، دقت اعتبارسنجی وزن‌دهی شده می‌باشد که به‌عنوان معیار اصلی انتخاب ابرپارامترها در الگوریتم AOA در نظر گرفته شده است. رابطه ۵ تابع برازندگی مورداستفاده را نشان می‌دهد.

$$Fitness = ACC_W^{VAL} \quad (۵)$$

که در آن ACC_W^{VAL} دقت وزن‌دهی شده روی مجموعه اعتبارسنجی است و به‌صورت رابطه ۶ محاسبه می‌شود:

$$ACC_W^{VAL} = \sum_{C=1}^{3} ACC_c * w_C \quad (۶)$$

دراین‌رابطه، ACC_c دقت پیش‌بینی مربوط به کلاس c و w_c وزن متناظر با آن کلاس است که بر اساس نسبت تعداد نمونه‌های کلاس c به کل نمونه‌های مجموعه اعتبارسنجی محاسبه می‌شود. استفاده از این معیار به‌منظور درنظرگرفتن عدم توازن کلاس‌ها در داده‌های شدت تصادف صورت‌گرفته است. الگوریتم AOA باهدف بیشینه‌سازی مقدار تابع برازندگی، فضای جستجوی ابرپارامترها را کاوش کرده و بهترین پیکربندی مدل را انتخاب می‌کند. سایر معیارهای ارزیابی از جمله AUC-ROC ، RMSE و Log Loss صرفاً جهت تحلیل عملکرد نهایی مدل پس از فرایند آموزش به کار رفته‌اند و در فرایند بهینه‌سازی دخالتی ندارند. لازم به ذکر است که مجموعه‌داده آزمون (Test) در هیچ‌یک از مراحل بهینه‌سازی ابرپارامترها و محاسبه تابع برازندگی مورداستفاده قرار نگرفته و تنها پس از تثبیت بهترین پیکربندی مدل، برای ارزیابی نهایی عملکرد به کار گرفته شده است. این رویکرد به‌منظور جلوگیری از بیش برازش بر روی داده‌های اعتبارسنجی اتخاذ شده است. مدل LSTM پیشنهادی از چندین لایه LSTM استفاده می‌کند تعداد لایه‌ها توسط الگوریتم بهینه‌سازی AOA تعیین می‌شود که قادر به یادگیری وابستگی‌های طولانی‌مدت در داده‌های ورودی است. برای جلوگیری از بیش برازش، از لایه‌های دراپ اوت و نرمال‌سازی دسته استفاده شده است. همچنین، خروجی مدل در لایه آخر از تابع فعال‌سازی Soft-Max برای پیش‌بینی کلاس‌های شدت تصادف استفاده می‌کند. در نهایت، مدل با استفاده از یکی از الگوریتم‌های بهینه‌سازی ذکر شده آموزش داده می‌شود.

۴-۲-۲- ملاحظات محاسباتی و زمان اجرا

به دلیل استفاده از الگوریتم بهینه‌سازی AOA برای تنظیم ابرپارامترها، فرایند آموزش مدل پیشنهادی شامل اجرای مکرر مدل LSTM برای مجموعه‌های مختلفی از ابرپارامترها می‌باشد. در این چارچوب، هر ذره در الگوریتم AOA یک ترکیب از ابرپارامترها را نمایش می‌دهد و مقدار برازندگی آن از طریق آموزش مدل LSTM و ارزیابی عملکرد آن بر روی مجموعه اعتبارسنجی محاسبه می‌شود. پیاده‌سازی روش پیشنهادی بر روی یک سیستم با پردازنده گرافیکی RTX 3090i و حافظه Ram ۱۶ گیگ که از طریق سامانه Vast.ai

به‌صورت اجاره‌ای تامین شده در محیط Python و TensorFlow/Keras انجام شده است. برای الگوریتم AOA از ۳۰ ذره و ۲۵۰ تکرار استفاده شده است. بر اساس نتایج تجربی، میانگین زمان آموزش مدل LSTM برای هر epoch حدود ۲۰۰ ثانیه بوده و فرایند بهینه‌سازی ابرپارامترها به طور متوسط ۱۴۰ ساعت زمان برده است. اگرچه استفاده از AOA منجر به افزایش زمان محاسباتی نسبت به آموزش یک مدل منفرد می‌شود، اما این هزینه محاسباتی باتوجه‌به بهبود معنادار عملکرد و کاهش بیش برازش، قابل‌قبول و توجیه‌پذیر است.

۴-۳- آموزش مدل و ارزیابی عملکرد

مدل پس از انتخاب بهترین ابرپارامترها از طریق الگوریتم AOA، برای ۳۰۰ دوره آموزش داده می‌شود. در هر دوره، مدل بر اساس داده‌های آموزشی و ارزیابی روی داده‌های تست به‌روز می‌شود. برای ارزیابی عملکرد مدل از معیارهایی همچون دقت، دقت و یادآوری وزنی، F1-Score، AUC-ROC، Log Loss و RMSE استفاده شد. این معیارها به طور دوره‌ای در طول فرایند آموزش محاسبه شده و نتایج آن‌ها در گزارش‌ها و نمودارها ثبت می‌شود.

۴-۳-۱- معرفی مجموعه‌داده

مجموعه‌داده مورداستفاده در این پژوهش [۱۴] استخراج شده است که یک ابتکار دولت بریتانیا برای ارائه داده‌های متن متن‌باز منتشرشده توسط نهادهای دولتی مرکزی، مقامات محلی و سازمان‌های عمومی است. این مطالعه به طور خاص از پایگاه‌داده تصادفات جاده‌ای سال ۲۰۱۷ بهره برده است. این مجموعه‌داده اطلاعات جامعی در مورد ایمنی جاده، شامل جزئیاتی درباره عوامل زیست‌محیطی، فیزیکی، هندسی، جغرافیایی و شخصی مرتبط با تصادفات، ارائه می‌دهد. شایان‌ذکر است که این داده‌ها تنها شامل تصادفاتی هستند که به طور رسمی به پلیس یا مراجع ذی‌صلاح گزارش شده‌اند. این مجموعه‌داده 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

جدول ۳: شرح و طبقه‌بندی متغیرهای مورد استفاده در پایگاه داده تصادفات رانندگی

متغیرهای دادگان		
متغیرهای تصادف	متغیرهای تصادف و راننده	متغیرهای تصادفی
شناسه یکتای هر تصادف در پایگاه داده.	شاخص یکتای مربوط به تصادف	شناسه یکتای تصادف
نیروی انتظامی یا پلیس	موقعیت وسیله نقلیه	کد شناسایی وسیله نقلیه‌ای
شدت تصادف	نوع وسیله نقلیه	کد یکتای شناسایی قربانی
تعداد کل وسایل نقلیه	وضعیت یدک‌کش و مفاصل وسیله نقلیه	نوع قربانی
تعداد کل افراد آسیب‌دیده یا فوت‌شده در تصادف	حرکت یا مانور وسیله نقلیه در زمان تصادف	جنسیت فرد آسیب‌دیده.
تاریخ وقوع تصادف	موقعیت وسیله نقلیه	سن قربانی
روز هفته‌ای که تصادف در آن رخ داده است	محل تقاطع	گروه سنی قربانی
زمان وقوع تصادف	اطلاعات مربوط به سُرخوردن یا واژگون شدن	شدت آسیب یا جراحت وارده
طول جغرافیایی/ عرض جغرافیایی	اشیایی که وسیله نقلیه با آنها برخورد کرده است	موقعیت عابر پیاده در زمان تصادف
منطقه یا ناحیه تحت مدیریت شهرداری	نقطه نخست برخورد وسیله نقلیه	وضعیت حرکت عابر پیاده در لحظه حادثه
سازمان یا نهادی که مسئول نگهداری و مدیریت جاده محل تصادف است	آیا وسیله نقلیه فرمان به راست بوده یا فرمان به چپ.	محل نشستن قربانی در خودرو
رده‌بندی جاده اصلی(مانند بزرگراه، جاده اصلی، جاده فرعی)	هدف یا مقصد سفر راننده	محل قرارگیری قربانی در اتوبوس یا مینی‌بوس
شماره رسمی جاده اصلی	جنسیت راننده وسیله نقلیه.	نوع آسیب یا علت اصلی مرگ/جراحت
نوع فیزیکی راه	سن راننده	دهک شاخص محرومیت چندگانه(IMD)
حداکثر سرعت مجاز تعیین‌شده برای آن مسیر	گروه سنی	نوع یا موقعیت محل سکونت قربانی
جزئیات مربوط به تقاطع یا چهارراه	قدرت موتور	
رده‌بندی جاده دوم درگیر در تصادف	نوع سوخت مصرفی	
شماره رسمی جاده دوم	سن وسیله نقلیه	
وجود یا نوع امکانات فیزیکی عبور عابر پیاده	دهک شاخص محرومیت چندگانه (IMD) برای راننده	
وضعیت روشنایی در زمان تصادف	نوع منطقه محل زندگی راننده	
وضعیت کلی جاده/ شرایط سطح آسفالت		
ویژگی‌های خاص یا غیرعادی محل تصادف		
خطرات موجود در مسیر حرکت		
نوع منطقه(شهری و روستایی)		
حضور پلیس		

مجموعه‌داده تصادفات شامل ۳۱ متغیر است که عواملی مانند شرایط جوی، روشنایی، زمان، روز هفته و تعداد وسایل نقلیه درگیر را در بر می‌گیرد. مجموعه‌داده وسیله نقلیه - راننده شامل ۲۲ متغیر است که اطلاعاتی مانند سن وسیله نقلیه، سن راننده و جنسیت او را شامل می‌شود. در نهایت، مجموعه‌داده 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 ۳ ارائه شده است، و توضیحات متغیرها در جدول ۴ ارائه شده است. این مطالعه به طور خاص از پایگاه‌داده تصادفات جاده‌ای سال ۲۰۱۷ بهره برده است. این مجموعه‌داده اطلاعات جامعی در مورد ایمنی جاده، شامل جزئیاتی درباره عوامل زیست‌محیطی، فیزیکی، هندسی، جغرافیایی و شخصی مرتبط با تصادفات، ارائه می‌دهد.

جدول ۴-الف: تعاریف و شرح متغیرهای مورد استفاده

نام متغیر	دسته بندی متغیرها	کد	فرکانس	درصد	کلاس ۱	کلاس ۲	کلاس ۳
روز هفته	یکشنبه	۱	۲۱۸۳۶	۱۲,۲۰	۲۰,۴	۱۱,۴	۱۴,۷
	دوشنبه	۲	۲۴۵۶۳	۱۳,۷۷	۱۲,۴	۱۴,۱	۱۲,۲
	سه شنبه	۳	۲۵۹۱۱	۱۴,۴۸	۱۰,۴	۱۴,۷	۱۳,۶
	چهارشنبه	۴	۲۵۸۳۷	۱۴,۴۴	۱۴,۴	۱۴,۵	۱۴,۱
	پنج شنبه	۵	۲۷۰۱۴	۱۵,۰۹	۱۱,۰	۱۴,۷	۱۴,۲
	جمعه	۶	۲۹۲۲۷	۱۶,۳۳	۱۳,۰	۱۵,۴	۱۵,۸
	شنبه	۷	۲۴۴۴۰	۱۳,۶۶	۱۸,۲	۱۶,۵	۱۵,۳
نوع اتوبان	میدان ترافیکی	۱	۱۰۳۲۸	۵,۷۷	۱,۰۵	۱۳,۱	۶,۳۵
	ترافیک یک‌طرفه	۲	۲۷۴۰	۱,۵۳	۰,۶۸	۳,۶۷	۱,۶۰
	بزرگراه جداشده	۳	۳۳۷۳۹	۱۸,۸۵	۲۲,۹	۱,۲۸	۱۹,۲۷
	بزرگراه بدون جداکننده مرکزی	۷	۱۲۸۶۰۸	۷۸,۸۸	۷۴,۸	۱۶,۶۲	۷۰,۶۱
	رمپ ورودی یا خروجی بزرگراه	۹	۱۹۰۴	۱,۰۶	۰,۳۷	۷۷,۱۲	۱,۱۳
	داده گمشده	۱	۱۵۹۹	۰,۸۹	۰,۰۶	۰,۸۲	۱,۰۱
	ترافیک یک‌طرفه یا رمپ	۲	۰	۰	۰,۰۰	۰,۴۶	۰,۰۰
	ترافیک یک‌طرفه یا رمپ	۱-	۰	۰	۰,۰۰	۰,۰۰	۰,۰۰
	داده نادرست یا خطای ثبت‌شده						
تقاطع پیش بینی انسان	عدم وجود عامل کنترلی یا تسهیل‌گر در شعاع ۵۰ متری	۰	۱۷۵۸۱۹	۹۸,۲۶	۰,۱۲	۰,۴۲	۰,۶۰
	مامور عبور دانش‌آموزان	۱	۴۹۷	۰,۲۷	۰,۰۶	۰,۳۱	۱,۰۳
	تحت کنترل توسط مأمور رسمی دیگر	۲	۱۰۱۳	۰,۵۶	۹۹,۵	۹۹,۰	۹۹,۰
	داده نادرست / خطای ثبت اطلاعات	۱-	۱۵۸۹	۰,۸۸	۰,۲۷	۰,۲۶	۰,۲۸
جزئیات تقاطع	عدم وجود تقاطع در شعاع ۲۰ متری	۰	۷۸۴۶۸	۴۳,۸۵	۷۲,۰۱	۴۹,۸۰	۴۱,۸۶
	میدان ترافیکی	۱	۱۳۵۲۴	۷,۵۵	۱,۳۳	۴,۷۹	۸,۳۲
	میدان کوچک	۲	۱۷۷۰	۰,۹۸	۰,۱۲	۰,۶۸	۱,۰۷
	تقاطع پیشنهادی / تقاطع غیررسمی	۳	۵۰۶۱۸	۲۸,۲۹	۱۵,۵۴	۲۷,۸۰	۲۸,۶۷
	رمپ ورودی یا خروجی بزرگراه	۵	۳۵۰۲	۱,۹۵	۲,۳۲	۱,۵۲	۲,۰۴
	چهارراه	۶	۱۸۴۰۳	۱۰,۲۸	۵,۰۵	۸,۷	۱۰,۷۷
	تقاطع با بیش از چهار بازو (بدون میدان)	۷	۱۶۶۳	۰,۹۲	۰,۳۴	۰,۶۰	۱,۰۱
	جاده خصوصی						
	سایر انواع تقاطع	۸	۵۱۰۲	۲,۸۵	۱,۷۳	۳,۲۸	۲,۷۱
	داده نادرست / خطای ثبت‌شده	۹	۵۵۶۷	۳,۱۱	۱,۵۲	۲,۷۳	۳,۲۳
		۱-	۳۰۱	۰,۱۶	۲	۰,۰۴	۰,۲۰
وضعیت روشنایی	روشنایی روز	۱	۱۲۶۰۴۹	۷۰,۴۵	۶۰,۲۸	۶۷,۹۵	۷۱,۲۴
	تاریکی با چراغ‌های روشن	۴	۳۶۸۴۹	۲۰,۳۹	۱۷,۱۸	۲۰,۰۲	۲۰,۵۵
	تاریکی با چراغ‌های کم‌نور	۵	۱۱۲۳	۰,۶۲	۰,۸۶	۰,۵۹	۰,۶۳
	بدون هیچ‌گونه روشنایی	۶	۱۰۳۱۴	۵,۷۶	۲۰,۸۱	۸,۹۴	۴,۷۰
	نامشخص بودن وضعیت روشنایی	۷	۴۹۴۱	۲,۷۶	۰,۸۳	۲,۸۴	۲,۸۶
	داده نادرست / خطای ثبت	۱-	۲	۰,۰۰۱	۲	۲	۰,۰۰۱

جدول ۴-ب: تعاریف و شرح متغیرهای مورد استفاده در تحلیل

شرایط جوی	نسیم ملایم	۱	۱۴۴۳۶۸	۸۰,۶۸	۸۴,۰۲	۸۱,۴۵	۸۰,۴۴
	باران همراه با نسیم	۲	۲۰۹۴۸	۱۱,۷۰	۸,۹۹	۱۱,۹۳	۱۱,۷۱
	برف همراه با نسیم	۳	۹۱۵	۰,۵۱	۰,۴۹	۰,۲۹	۰,۵۶
	هوای صاف همراه با باد شدید	۴	۲۰۳۲	۱,۱۳	۱,۵۵	۱,۳۱	۱,۰۸
	باران همراه با باد شدید	۵	۱۷۰۵	۰,۹۵	۱,۲۷	۱,۱۶	۰,۸۹
	برف همراه با باد شدید	۶	۱۶۳	۰,۰۹	۲	۰,۰۴	۰,۱۰
	مه یا غبار	۷	۹۴۰	۰,۵۲	۰,۷۷	۰,۶۴	۰,۴۹
	سایر شرایط جوی	۸	۳۴۱۰	۱,۹۰	۱,۴۲	۱,۵۵	۱,۹۹
	وضعیت جوی نامشخص	۹	۴۴۳۵	۲,۴۷	۱,۴۵	۱,۵۹	۲,۷۰
	داده نادرست / خطای ثبت	-۱	۲	۰,۰۰۱	۲	۲	۰,۰۰۱
سطح جاده	سطح جاده خشک	۱	۱۲۴۱۵۱	۶۹,۳۹	۶۸,۳۸	۶۹,۲۵	۶۹,۴۴
	سطح جاده خیس	۲	۴۹۶۳۲	۲۷,۷۴	۲۸,۸۸	۲۸,۵۵	۲۷,۵۲
	سطح جاده برفی	۳	۷۰۷	۰,۳۹	۰,۳۱	۰,۲۳	۰,۴۳
	یخ‌زده یا برفی	۴	۳۱۷۲	۱,۷۷	۲,۲۳	۱,۶۱	۱,۷۹
	آب‌گرفتگی بیش از ۳ سانتی‌متر	۵	۱۷۲	۰,۰۹	۰,۱۸	۰,۱۷	۰,۰۷
	سطح جاده روغنی	۶	۰	۰	۰,۰۰	۰,۰۰	۰,۰۰
	سطح جاده گِلی یا دارای رسوبات داده	۷	۰	۰	۰,۰۰	۰,۰۰	۰,۰۰
	نادرست / خطای ثبت	-۱	۱۰۸۴	۰,۶۰	۲	۰,۱۶	۰,۷۲
جنسیت راننده	مرد	۱	۱۱۴۸۲	۶۳,۸۷	۷۹,۴۲	۶۹,۸۹	۶۲,۱۵
	زن	۲	۵۱۸۴۸	۲۹,۹۷	۱۸,۳۳	۲۴,۱۵	۳۰,۳۱
	نامشخص	۳	۱۲۷۸۴	۷,۱۴	۲,۲۳	۵,۹۵	۷,۵۲
	داده اشتباه	-	۴	۰,۰۰۲	۲	۰,۰۰۳	۰,۰۰۲
نوع قربانی	راننده	۱	۱۲۱۸۷۰	۶۸,۱۱	۶۳,۳۸	۶۶,۲۰	۶۸,۶۵
	مسافر	۲	۳۵۰۵۵	۲۴,۱۴	۲۵,۰۰	۲۲,۷۴	۲۴,۴۴
	عابر پیاده	۳	۱۶	۷,۷۳	۱۱,۶۰	۱۱,۰۵	۶,۸۹
وجود افسر پلیس	بله	۱	۱۴۳۸۴۷	۸۰,۳۹	۹۵,۹۰	۸۹,۲۷	۷۸,۰۲
	خیر	۲	۳۵۰۵۵	۱۹,۵۹	۴,۰۹	۱۰,۷۱	۲۱,۹۶
	خیر- تصادف توسط فرم خود-اظهاری گزارش شده است	۳	۱۶	۰,۰۰۹	۲	۰,۰۰۶	۰,۱۰

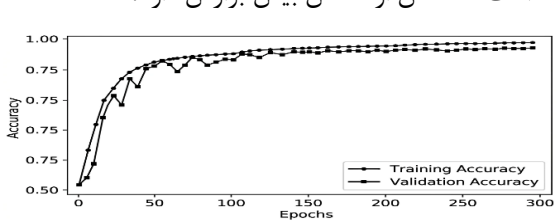
شایان‌ذکر است که این داده‌ها تنها شامل تصادفاتی هستند که به طور رسمی به پلیس یا مراجع ذی‌صلاح گزارش شده‌اند.

۵- ارزیابی نتایج

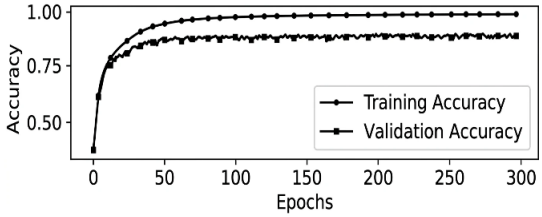
در این بخش، به ارزیابی عملکرد مدل پیشنهادی بهینه‌سازی شده LSTM به کمک AOA و مقایسه آن با دو مدل پایه‌ای یعنی LSTM ، RNN و GA-LST [۲۷]. می‌پردازیم. معیارهای اصلی ارزیابی شامل دقت، فراخوانی ۱۴، دقت مثبت ۱۵، نمره F1، AUC-ROC، RMSE[۱۶]، و Log Loss می‌باشد. این معیارها به کمک نمودارهای ترسیم‌شده برای هر سه مدل بررسی و تحلیل شده‌اند.

۵-۱- تحلیل دقت

نمودار شکل ۳ دقت اعتبارسنجی و دقت آموزشی را برای مدل پیشنهادی LSTM بهبودیافته توسط الگوریتم بهینه‌سازی (AOA) را نشان می‌دهد. این مدل با استفاده از الگوریتم بهینه‌سازی AOA آموزش‌داده‌شده است. در مقایسه با سایر مدل‌ها، مشاهده می‌شود که دقت آموزش و اعتبارسنجی در مراحل اولیه رشد سریعی دارد و پس از حدود ۲۰ دوره به یک‌روند پایدار می‌رسد. دقت اعتبارسنجی نیز به طور مداوم افزایش می‌یابد و نوسانات کمتری نسبت به سایر مدل‌ها دارد. این نشان می‌دهد که بهینه‌سازی AOA توانسته است تنظیمات مدل را بهینه کند و منجر به یک مدل با تعمیم‌پذیری بهتر شود. فاصله بین دقت آموزش و اعتبارسنجی نیز کمتر از سایر روش‌ها است که نشان از کاهش بیش برازش دارد.

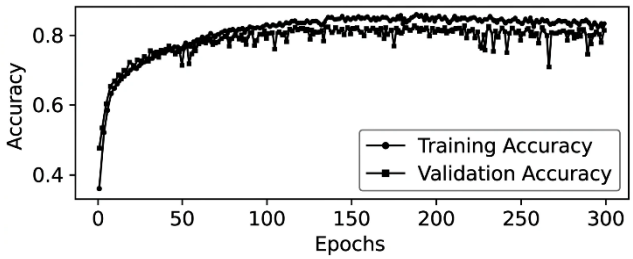


شکل ۳ نمودار دقت آموزش و اعتبارسنجی برای روشLSTM+AOA



شکل ۴ نمودار دقت آموزش و اعتبارسنجی برای روش LSTM

نمودار شکل ۴ دقت و اعتبارسنجی و دقت آموزشی را برای مدل LSTM استاندارد نشان می‌دهد. در این مدل، دقت آموزش نسبت به مدل LSTM+AOA سریع‌تر افزایش می‌یابد، اما دقت اعتبارسنجی در مقایسه با آموزش کمی پایین‌تر است و پس از حدود ۵۰ دوره به یک مقدار پایدار می‌رسد. یکی از نکات قابل‌توجه این است که اختلاف بین دقت آموزش و اعتبارسنجی بیشتر از مدل بهینه‌شده است که می‌تواند نشان‌دهنده بیش برازش جزئی باشد. این مدل عملکرد بهتری نسبت به RNN دارد، اما همچنان نسبت به نسخه بهینه‌شده نیاز به بهبود دارد.



شکل ۵ نمودار دقت آموزش و اعتبارسنجی برای روش RNN

نمودار شکل ۵ دقت اعتبارسنجی و دقت آموزشی را برای مدل RNN نشان می‌دهد. در این مدل، رشد دقت آموزش و اعتبارسنجی در مراحل اولیه کندتر از دو مدل دیگر است. دقت نهایی این مدل کمتر از LSTM و LSTM+AOA باقی می‌ماند، و نوسانات دقت اعتبارسنجی در مقایسه با مدل‌های دیگر بیشتر است.

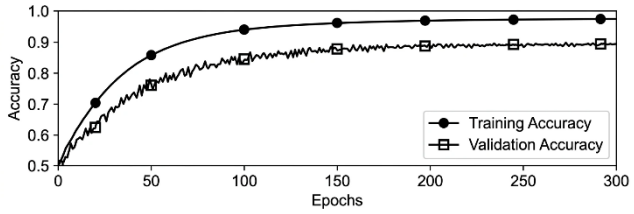
در این پژوهش، مجموعه‌داده به دو بخش آموزش و اعتبارسنجی تقسیم شد. فرایند انتخاب ابرپارامترها توسط الگوریتم AOA انجام گرفت. ازآنجاکه مجموعه‌آزمون مستقل در نظر گرفته نشده است، مقادیر گزارش‌شده در جدول ۵ مربوط به عملکرد نهایی مدل روی داده‌های آموزش و اعتبارسنجی می‌باشند. جدول ۵ دقت اعتبارسنجی و آموزشی نهایی را برای هر سه روش نشان می‌دهد. همان‌طور که مشاهده می‌شود، روش پیشنهادی LSTM+AOA بادقت اعتبارسنجی حدود ۰,۹۰۵ و دقت آموزشی حدود ۰,۹۸۲ بالاترین دقت را در میان مدل‌ها به دست آورده است. اختلاف مشاهده‌شده میان دقت آموزش و اعتبارسنجی در این مدل بیانگر گرایش محدود به بیش برازش است که باتوجه‌به ظرفیت بالای مدل‌های یادگیری عمیق امری قابل‌انتظار محسوب می‌شود.

دقت‌های گزارش‌شده در جدول ۵ مربوط به داده‌های آموزش و اعتبارسنجی هستند و انتخاب ابرپارامترها بر اساس ارزیابی عملکرد روی مجموعه اعتبارسنجی انجام شده است.

جدول ۵: مقایسه دقت آموزش و اعتبارسنجی مدل‌ها با استفاده از ابرپارامترهای بهینه‌شده

مدل	LSTM+AOA	LSTM	RNN	LSTM+GA
دقت آموزشی	۰,۹۸۲	۰,۹۲	۰,۸۹	۰,۹۶۵
دقت اعتبارسنجی	۰,۹۰۵	۰,۸۸	۰,۸۵	۰,۸۹

بااین‌حال، مقدار بالای دقت اعتبارسنجی و پایداری آن در طول فرایند آموزش نشان می‌دهد که این بیش برازش کنترل‌شده بوده و تأثیر منفی قابل‌توجهی بر توان تعمیم‌پذیری مدل نداشته است.

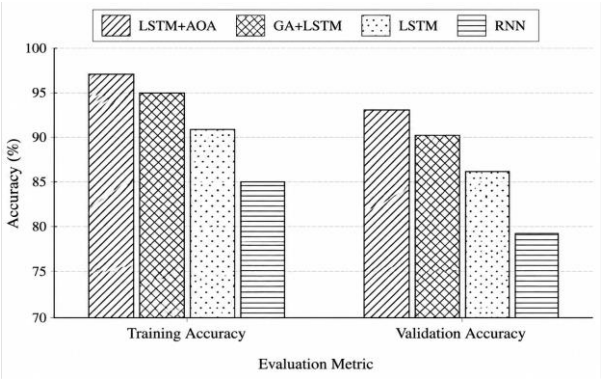


شکل ۶ نمودار دقت آموزش و اعتبارسنجی برای روش GA+LSTM

نمودار شکل ۶ دقت اعتبارسنجی و دقت آموزشی را برای مدل GA+LSTM نشان می‌دهد. دقت آموزش به‌سرعت افزایش‌یافته و به حدود ۹۷٪ می‌رسد، درحالی‌که دقت اعتبارسنجی روی حدود ۸۹٪ تثبیت می‌شود. فاصله‌ی ثابت بین دو منحنی نشان‌دهنده‌ی overfitting ملایم است. این موضوع نشان می‌دهد که RNN در استخراج وابستگی‌های طولانی‌مدت در داده‌ها عملکرد ضعیف‌تری دارد و پایداری کمتری در فرایند آموزش دارد. فاصله بین دقت آموزش و اعتبارسنجی نیز کمتر از LSTM اما بیشتر از مدل بهینه‌شده است که نشان‌دهنده عملکرد ضعیف‌تر این روش در تعمیم‌پذیری است.

نمودار شکل ۷ دقت اعتبارسنجی و دقت آموزشی هر چهار مدل را با نمودار میله‌ای نشان می‌دهد این نمودار مقایسه‌ای از دقت آموزش و دقت اعتبارسنجی برای چهار مدل LSTM+AOA، LSTMو

RNN و GA+LSTM ارائه می‌دهد. مدل LSTM+AOA این روش بالاترین دقت را در هر دو مرحله آموزش و اعتبارسنجی دارد.



شکل ۷ مقایسه دقت آموزش و اعتبارسنجی مدل پیشنهادی در برابر مدل‌های پایه

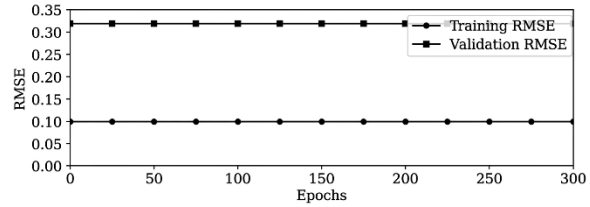
دقت آموزش نزدیک به ۹۸٪ و دقت اعتبارسنجی حدود ۹۲٪ است. این نشان‌دهنده‌ی بهبود قابل‌توجه یادگیری مدل و توانایی بهتر آن در تعمیم به داده‌های جدید است. مدل GA+LSTM رتبه دوم را به دست آورده نشان می‌دهد که بهینه‌سازی ابرپارامترها با الگوریتم ژنتیک نتیجه داشته؛ ولی عملکرد الگوریتم AOA بهتر بوده. مدل LSTMبدون بهینه‌سازی، دقت پایین‌تری نسبت به LSTM+AOA و GA+LSTM دارد. دقت آموزش این روش حدود ۹۲٪ و دقت اعتبارسنجی آن حدود ۸۹٪ است. این نشان می‌دهد که مدل همچنان عملکرد خوبی دارد؛ اما نسبت به نسخه‌ی بهینه شده توسط AOA، کارایی کمتری دارد. مدل RNN ضعیف‌ترین عملکرد را نشان می‌دهد. دقت آموزش و اعتبارسنجی آن هر دو پایین‌تر از روش‌های LSTM هستند (حدود ۸۹٪ و ۸۵٪ .(این نشان‌دهنده‌ی محدودیت‌های RNN در یادگیری وابستگی‌های طولانی‌مدت در داده‌ها است.

۵-۲- تحلیل خطای جذر میانگین مربعات(RMSE)

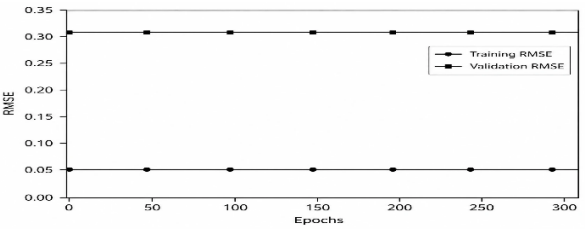
نمودار شکل ۸، ۹ و ۱۰ و ۱۱ نمودار تحلیل خطای جذر میانگین مربعات را برای هر چهار روش LSTM+AOA، GA+LSTM، LSTM و RNN نشان می‌دهد. محور عمودی این نمودارها بیانگر مقدار خطای جذر میانگین مربعات (RMSE) می‌باشد و محور افقی آن بیانگر Epochها می‌باشد. سه نمودار ارائه شده، تغییرات RMSE برای داده‌های آموزشی و اعتبارسنجی چهار مدل مختلف را در طول دوره‌های آموزشی نشان می‌دهند. در مدل LSTM+AOA (شکل ۸)، مقدار RMSE آموزش در سطح پایینی تثبیت شده و RMSE اعتبارسنجی نیز با اختلاف محدود نسبت به آن باقی‌مانده است.

این فاصله محدود نشان‌دهنده وجود بیش برازش خفیف اما کنترل‌شده در مدل پیشنهادی است که در مقایسه با مدل‌های پایه، تأثیر کمتری بر تعمیم‌پذیری دارد. در مقابل، نمودار شکل ۹ مربوط به مدل GA+LSTM نشان می‌دهد که مقدار RMSE آموزش حدود ۰,۰۶ می‌باشد، درحالی‌که RMSE اعتبارسنجی در حدود ۰,۳ ثابت باقی می‌ماند. در مقابل، نمودار شکل ۱۰ مربوط به مدل LSTM پایه نشان می‌دهد که مقدار RMSE آموزش به مقادیر بسیار کوچک (نزدیک به صفر) میل می‌کند، درحالی‌که RMSE اعتبارسنجی در حدود ۰,۳ ثابت باقی می‌ماند.

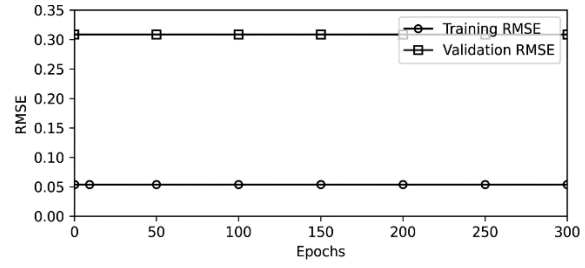
این رفتار بیانگر بیش برازش شدید مدل LSTM پایه است، به‌طوری که مدل به داده‌های آموزشی وابستگی زیادی پیدا کرده و توانایی تعمیم مناسب به داده‌های جدید را ازدست‌داده است. در مدل RNN (شکل ۱۱)، اگرچه فاصله بین RMSE آموزش و اعتبارسنجی کمتر از مدل LSTM است، اما مقادیر بالاتر RMSE و عدم بهبود در طول دوره‌های آموزشی نشان می‌دهد که این مدل در یادگیری الگوهای پیچیده و کاهش خطا با محدودیت مواجه است. به‌طورکلی، مقایسه نتایج RMSE نشان می‌دهد که استفاده از الگوریتم بهینه‌سازی AOA و ژنتیک بخصوص الگوریتم AOA برای تنظیم ابرپارامترهای LSTM نقش مؤثری در کاهش بیش برازش و بهبود تعادل بین یادگیری و تعمیم‌پذیری مدل ایفا کرده است.



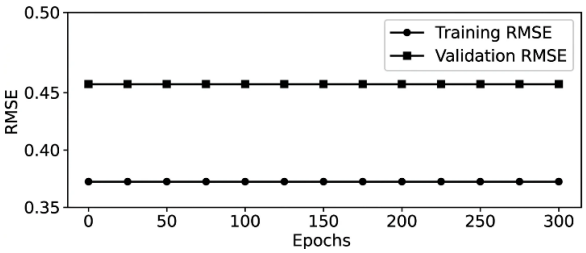
شکل ۸ نمودار RMSE آموزش و اعتبارسنجی برای روش LSTM+AOA



شکل ۹ نمودار RMSE آموزش و اعتبارسنجی برای روشGA+LSTM



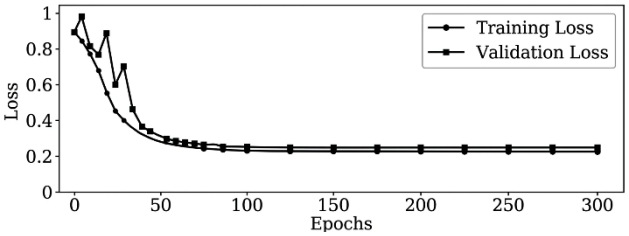
شکل ۱۰ مودار RMSE آموزش و اعتبارسنجی برای روشLSTM



شکل ۱۱ نمودار RMSE آموزش و اعتبارسنجی برای روشRNN

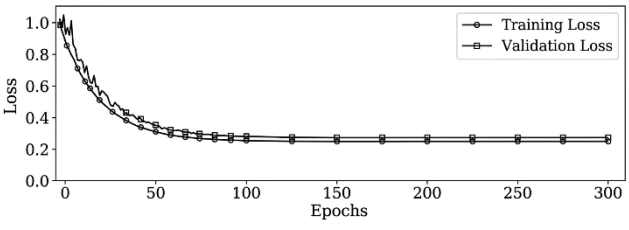
۵-۳- تحلیل ضرر (Loss)

نمودار شکل ۱۲،۱۳ و ۱۴ و ۱۵ تحلیل ضرر را برای هر چهار مدل LSTM+AOA، LSTM و RNN نشان می‌دهد. محور عمودی این نمودارها بیانگر مقدار تابع ضرر می‌باشد و محور افقی بیانگر تعداد Epochها می‌باشد. سه نمودار ارائه‌شده در شکل‌ها ۱۳، ۱۴،۱۲ و ۱۵ تغییرات Loss (تابع هزینه) برای داده‌های آموزشی و اعتبارسنجی چهار مدل را در طول دوره‌های آموزشی نشان می‌دهند. تحلیل این نمودارها نکات مهمی را در مورد عملکرد و چالش‌ها را روشن می‌کند.



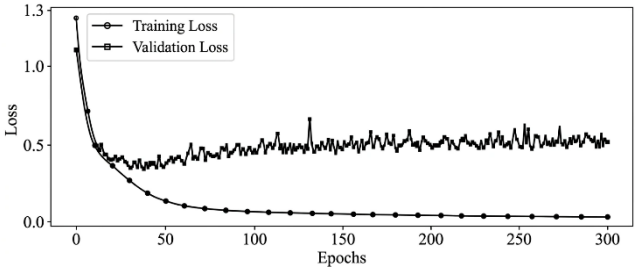
شکل ۱۲ نمودار زیان آموزش و اعتبارسنجی برای روشLSTM+AOA

در نمودار شکل ۱۲ LSTM+AOA با 300 دوره، Training Loss به حدود ۰,۲ تا ۰,۳ و Validation Loss به حدود ۰,۴ تا ۰,۵ کاهش می‌یابد. این نشان‌دهنده عملکرد نسبتاً بهتری نسبت به سه مدل دیگر است، اما همچنان فاصله بین Training و Validation Loss (۰,۱ تا ۰,۲ واحد) نشان‌دهنده کمی بیش برازش است. نوسانات Validation Lossدر این مدل ممکن است به ناپایداری داده‌ها یا مدل مربوط باشد.



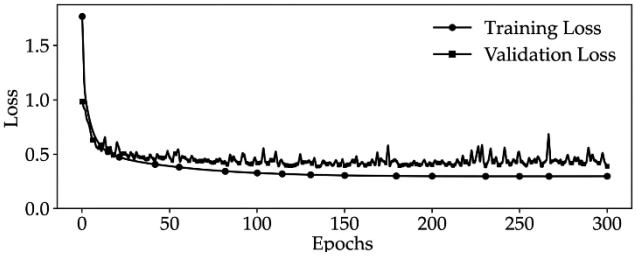
شکل ۱۳ نمودار زیان آموزش و اعتبارسنجی برای روشLSTM+AOA

نمودار شکل ۱۳ میزان ضرر را برای روش GA+LSTM نشان می‌دهد از حدود Epoch ۸۰ به بعد هر دو نمودار سرعت‌کاهشی خود را از دست میدن فاصله‌ی کم و تقریباً ثابت بین Training Lossو Validation Loss نشان می‌دهد overfittingشدید وجود ندارد، اما به دلیل توقف بهبود Validation Loss، بهینه‌ساز استفاده‌شده توان استخراج الگوی بهتر را نداشته و مدل در یک مینیمم نسبتاً ضعیف گیرکرده است.



شکل ۱۴ نمودار زیان آموزش و اعتبارسنجی برای روشLSTM

نمودار شکل ۱۴ LSTM با ۳۰۰ دوره نشان‌دهنده Training Loss در حدود ۰,۲ و Validation Loss در حدود ۰,۵ تا ۰,۶ است، با نوسانات قابل‌توجه در .Validation Loss فاصله بزرگ بین دو خط (حدود ۰,۳ تا ۰,۴ واحد) نشان‌دهنده بیش برازش شدید است که عملکرد ضعیفی در تعمیم‌دهی به داده‌های جدید دارد.



شکل ۱۵ نمودار زیان آموزش و اعتبارسنجی برای روشRNN

نمودار شکل ۱۵ RNN با ۳۰۰ دوره نیز مشابه LSTM عمل می‌کند، با Training Loss در حدود ۰,۲ و Validation Loss در حدود ۰,۵ تا ۰,۶، همراه با نوسانات زیاد در .Validation Loss این نیز نشان‌دهنده بیش برازش است، در کل، مدل LSTM+AOA با 300 دوره عملکرد بهتری نسبت به LSTM و RNN نشان می‌دهد، اما همه مدل‌ها نیاز به بهینه‌سازی دارند تا بیش برازش کاهش یابد و تعمیم‌دهی بهبود پیدا کند. اگرچه در مدل LSTM+AOA همچنان اختلاف محدودی بین Loss آموزش و اعتبارسنجی مشاهده می‌شود، این اختلاف در مقایسه با مدل‌هایLSTM ، GA+LSTM و RNN کمتر بوده و نشان می‌دهد که تنظیم مناسب ابرپارامترها توانسته است شدت بیش برازش را کاهش دهد، هرچند حذف کامل آن نیازمند راهکارهای تکمیلی است.

۵-۴- تحلیل Precision، Recall وF1-Score

جدول ۶ عملکرد چهار مدلLSTM+AOA ، GA+LSTM، LSTM و RNN را بر اساس معیارهای Precision، Recall و F1-Score

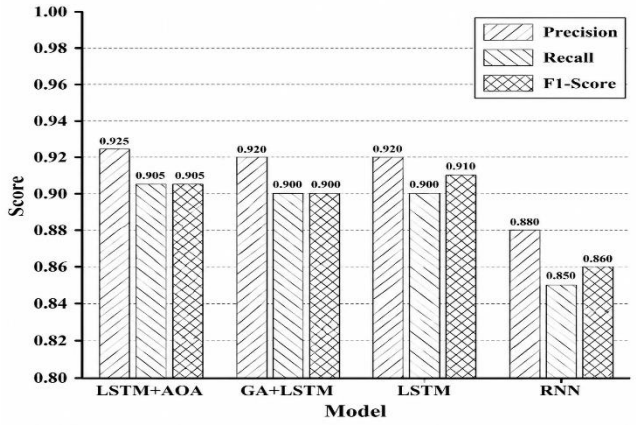
نشان می‌دهد مدل LSTM+AOA با مقادیر Precision برابر با ۰,۹۲۵، Recall برابر با ۰,۹۰۵ و F1-Score برابر با ۰,۹۰۵ بهترین عملکرد کلی را ارائه می‌دهد.

جدول ۶: مقایسه عملکرد مدل‌ها بر اساس Precision ، Recall **و** F1-Score

مدل	Precision	Recall	F1-Score
LSTM+AOA	۰,۹۲۵	۰,۹۰۵	۰,۹۰۵
GA+LSTM	۰,۹۲	۰,۹	۰,۹
LSTM	۰,۹۲	۰,۹	۰,۹۱
RNN	۰,۸۸	۰,۸۵	۰,۸۶

Precision بالای این مدل نشان‌دهنده کاهش قابل‌توجه پیش‌بینی‌های مثبت نادرست است، درحالی‌که Recall مناسب آن بیانگر توانایی مطلوب در شناسایی نمونه‌های مثبت واقعی می‌باشد. F1-Score این مدل نیز تعادل مؤثری بین Precision و Recall برقرار کرده و توانایی آن در تعمیم به داده‌های پیچیده را تأیید می‌کند. مدل GA+LSTM با Precision ۰,۹۲، Recall ۰,۹۰ و F1-Score ۰,۹۰ عملکرد قابل‌قبولی از خود نشان می‌دهد، اما در مقایسه با LSTM+AOA از نظر دقت کلی و تعادل بین معیارها ضعیف‌تر است. این نتایج نشان می‌دهد که استفاده از الگوریتم ژنتیک موجب بهبود عملکرد LSTM نسبت به حالت پایه شده، اما همچنان بهینه‌سازی مبتنی بر AOA اثربخشی بالاتری دارد. مدل LSTM با Precision ۰,۹۲، Recall ۰,۹۰ و F1-Score ۰,۹۱ عملکردی نزدیک به GA+LSTM دارد و از نظر F1-Score اندکی بهتر عمل کرده است که نشان‌دهنده تعادل مناسب بین Precision و Recall در این مدل می‌باشد. بااین‌حال، نبود یک روش بهینه‌سازی پیشرفته موجب شده است که این مدل نتواند به عملکرد مدل LSTM+AOA دست یابد. در نهایت، مدل RNN با مقادیر Precision ۰,۸۸، Recall ۰,۸۵ و F1-Score ۰,۸۶ ضعیف‌ترین عملکرد را در میان مدل‌ها دارد.

این نتایج، همراه با نمودارهای Loss اعتبارسنجی، نشان‌دهنده محدودیت این مدل در همگرایی مؤثر و تعمیم به داده‌های جدید است. در مجموع، باتوجه‌به نتایج ارائه‌شده در جدول ۶ و نمودار شکل ۱۶، مدل LSTM+AOA به‌عنوان بهترین مدل انتخاب می‌شود، زیرا بالاترین Precision را ارائه داده و تعادل مناسبی بین Recall و F1-Score برقرار کرده است.



شکل ۱۶ نمودار مقایسه عملکرد مدل‌های پیشنهادی بر اساس معیارهای Precision ، Recall **و** F1-Score

۵-۵- تحلیل AUC-ROC

معیار AUC-ROC یکی از شاخص‌های کلیدی برای ارزیابی عملکرد مدل‌های طبقه‌بندی است که توانایی مدل در تمایز بین کلاس‌های مثبت و منفی را اندازه‌گیری می‌کند. این معیار مقادیری بین ۰ و ۱ دارد؛ به‌طوری که مقادیر نزدیک‌تر به ۱ بیانگر قدرت تفکیک بالاتر مدل بوده و مقادیر بالاتر از ۰,۵ نشان‌دهنده عملکردی بهتر از حد تصادفی هستند.

جدول ۷: ارزیابی و مقایسه قدرت تفکیک‌پذیری مدل پیشنهادی با استفاده از معیار $AUC - ROC$

مدل	AUC-ROC
LSTM+AOA	۰,۹۷۴
GA+LSTM	۰,۹۵۳
LSTM	۰,۹۵
RNN	۰,۹۰

بر اساس جدول ۷، مدل LSTM+AOA با مقدار AUC-ROC برابر ۰,۹۷۴ بهترین عملکرد را در میان مدل‌های مورد بررسی ارائه داده و توانایی بسیار بالایی در تفکیک کلاس‌های مثبت و منفی نشان می‌دهد. پس از آن، مدل GA+LSTM با مقدار ۰,۹۵۳ عملکرد قابل‌توجهی از خود نشان داده است که بیانگر تأثیر مثبت به‌کارگیری الگوریتم ژنتیک در بهبود توان تمایز مدل LSTM می‌باشد.

مدل LSTM با مقدار AUC-ROC برابر ۰,۹۵ نیز عملکرد مناسبی دارد، اما نسبت به دو مدل بهینه‌سازی‌شده (LSTM+AOA) و (GA+LSTM) اندکی ضعیف‌تر عمل کرده است. در مقابل، مدل RNN با مقدار ۰,۹۰ کمترین عملکرد را در میان مدل‌ها دارد، هرچند همچنان عملکردی بالاتر از حد تصادفی ارائه می‌دهد. در مجموع، این نتایج نشان می‌دهد که استفاده از روش‌های بهینه‌سازی فراپارامتر، به‌ویژه الگوریتم AOA، نقش مهمی در افزایش توان تفکیک مدل داشته و مدل LSTM+AOA به‌عنوان برترین مدل از

نظر معیار AUC-ROC قابل‌انتخاب است.

۵-۶- تحلیل Log Loss

معیار Log Loss یکی از شاخص‌های کلیدی برای ارزیابی عملکرد مدل‌های طبقه‌بندی است که میزان ناهماهنگی بین پیش‌بینی‌های احتمالی مدل و مقادیر واقعی را اندازه‌گیری می‌کند. مقادیر کمتر Log Loss نشان‌دهنده دقت بالاتر مدل در برآورد احتمالات و خطای کمتر در پیش‌بینی کلاس‌های صحیح است.

جدول ۸: مقایسه عملکرد مدل پیشنهادی و مدل‌های پایه بر اساس معیار *LogLoss*

مدل	Log Loss
LSTM+AOA	۰,۲۹
GA+LSTM	۰,۳۲
LSTM	۰,۵۰
RNN	۰,۶۰

بر اساس جدول ۸، مدل LSTM+AOA با مقدار Log Loss برابر ۰,۲۹ کمترین خطا را در میان مدل‌های مورد بررسی داشته و بهترین عملکرد را ارائه می‌دهد. این نتیجه نشان‌دهنده توان بالای این مدل در پیش‌بینی دقیق احتمالات کلاس‌ها و کالیبراسیون مناسب خروجی‌ها است. پس از آن، مدل GA+LSTM با مقدار Log Loss برابر ۰,۳۲ عملکرد مناسبی از خود نشان داده است که بیانگر تأثیر مثبت استفاده از الگوریتم ژنتیک در کاهش خطای پیش‌بینی احتمالات نسبت به مدل LSTM پایه می‌باشد. مدل LSTMبا مقدار Log Loss برابر ۰,۵۰ عملکرد متوسطی دارد و نسبت به دو مدل بهینه‌سازی‌شده (LSTM+AOA) و (GA+LSTM) خطای بیشتری در پیش‌بینی احتمالات نشان می‌دهد. در نهایت، مدل RNN با مقدار Log Loss برابر ۰,۶۰ ضعیف‌ترین عملکرد را در میان مدل‌ها دارد که حاکی از ناهماهنگی بیشتر بین پیش‌بینی‌های احتمالی و برچسب‌های واقعی است. در مجموع، نتایج جدول ۸ نشان می‌دهد که به‌کارگیری روش‌های بهینه‌سازی فراپارامتر، به‌ویژه الگوریتم AOA، نقش مؤثری در کاهش Log Loss و بهبود دقت پیش‌بینی احتمالی داشته و مدل LSTM+AOAبه‌عنوان برترین مدل از نظر این معیار قابل‌انتخاب است.

۶- نتیجه‌گیری

در این پژوهش، عملکرد یک مدل LSTMبهینه‌سازی‌شده با استفاده از الگوریتم بهینه‌سازی ریاضی (AOA) برای پیش‌بینی شدت تصادفات در محیط‌های مبتنی بر شبکه‌های خودرویی VANET مورد بررسی قرار گرفت. به‌منظور ارزیابی دقیق اثربخشی روش پیشنهادی، عملکرد این مدل با مدل‌های پایه LSTM و RNN و همچنین روش بهینه‌سازی‌شده GA+LSTM مقایسه شد. این مقایسه بر اساس مجموعه‌ای جامع از معیارهای ارزیابی شامل Accuracy، Precision، Recall، F1-Score، AUC-ROC، RMSE و Log Loss و تحت شرایط آموزشی یکسان، شامل تقسیم داده مشابه و تعداد epoch ثابت، انجام گرفت تا منصفانه بودن ارزیابی‌ها تضمین شود.

نتایج تجربی نشان داد که مدل LSTM+AOA در اغلب معیارهای ارزیابی عملکرد برتری نسبت به مدل‌های مقایسه‌ای ارائه می‌دهد. این مدل با دستیابی به مقادیر بالاتر در معیارهایی نظیر Precision، Recall، F1-Score و AUC-ROC و همچنین کاهش مقادیر خطا، توانایی بالای خود را در استخراج الگوهای پیچیده داده‌ها و تعمیم آن‌ها به داده‌های جدید نشان داد. اگرچه اختلافی محدود میان عملکرد آموزش و اعتبارسنجی مشاهده شد، تحلیل نتایج حاکی از آن است که این اختلاف بیانگر بیش برازش خفیف اما کنترل‌شده بوده و شدت آن در مقایسه با مدل‌های پایه کمتر است.

در مقابل، مدل LSTM پایه علی‌رغم دستیابی به عملکرد مناسب در داده‌های آموزشی، نشانه‌های آشکارتری از بیش برازش را نشان داد؛ به‌گونه‌ای که اختلاف محسوسی میان معیارهای آموزش و اعتبارسنجی، به‌ویژه در مقادیر RMSE وLoss، مشاهده شد. مدل RNN نیز با ثبت مقادیر پایین‌تر در اغلب معیارهای ارزیابی و نوسانات بیشتر در داده‌های اعتبارسنجی، ضعیف‌ترین عملکرد را در میان مدل‌های بررسی‌شده ارائه داد. همچنین، مقایسه نتایج مدل GA+LSTM با روش پیشنهادی نشان داد که اگرچه استفاده از الگوریتم‌های فراابتکاری می‌تواند به بهبود عملکرد LSTM منجر شود، اما الگوریتم AOA در تنظیم مؤثرتر ابرپارامترها و دستیابی به تعادل مناسب‌تر میان دقت و قابلیت تعمیم، عملکرد بهتری نسبت به GA از خود نشان می‌دهد.

در مجموع، یافته‌های این پژوهش نشان می‌دهد که به‌کارگیری الگوریتم بهینه‌سازی AOA به‌عنوان یک رویکرد کارآمد برای تنظیم ابرپارامترهای مدل LSTM، می‌تواند نقش مؤثری در کاهش شدت بیش برازش، افزایش پایداری مدل و بهبود قابلیت تعمیم در مسئله پیش‌بینی شدت تصادف ایفا کند. بااین‌حال، نتایج بیانگر آن است که حذف کامل بیش برازش نیازمند به‌کارگیری راهکارهای تکمیلی است.

ازاین‌رو، پیشنهاد می‌شود در پژوهش‌های آینده، روش‌هایی نظیر منظم‌سازی قوی‌تر، توقف زودهنگام(Early Stopping) ، کاهش ظرفیت مدل و استفاده از داده‌های آموزشی گسترده‌تر یا ویژگی‌های

مکانی - زمانی مورد بررسی قرار گیرد تا دقت و کارایی مدل در کاربردهای واقعی بیش‌ازپیش ارتقا یابد.

مراجع

[1]. N. Bohra et al., “Intelligence-Based Strategies with Vehicle-to-Everything Network: A Review,” Future Internet, vol. 17, no. 2, 2025. https://doi.org/10.3390/fi17020079

[2]. P. Sicard et al., “Trends in Urban Air Pollution over the Last Two Decades: A Global Perspective,” Science of the Total Environment, vol. 858, Art. no. 160064, 2023. https://doi.org/10.1016/j.scitotenv.2022.160064

[3]. K. N. Qureshi and A. H. Abdullah, “A Survey on Intelligent Transportation Systems,” Middle-East Journal of Scientific Research, vol. 15, no. 5, pp. 629–642, 2013.doi:10.5829/idosi.mejsr.2013.15.5.11215

[4]. J. A. Guerrero-Ibáñez, C. Flores-Cortés, and S. Zeadally, “Vehicular Ad-hoc Networks (VANETs): Architecture, Protocols and Applications,” in Next-Generation Wireless Technologies: 4G and Beyond. London, U.K.: Springer, 2013, pp. 49–70.

[5]. I. T. Abdel-Halim and H. M. A. Fahmy, “Prediction-based Protocols for Vehicular Ad Hoc Networks: Survey and Taxonomy,” *Computer Networks*, vol. 130, pp. 34–50, 2018.https://doi.org/10.1016/j.comnet.2017.10.009

[6]. A. Mahmoud and A. Mohammed, “A Survey on Deep Learning for Time-series Forecasting,” in Machine Learning and Big Data Analytics Paradigms: Analysis, Applications and Challenges, 2021, pp. 365–392. https://doi.org/10.1007/978-3-030-59338-4_19

[7]. X. Ma et al., “Learning Traffic as Images: A Deep Convolutional Neural Network for Large-scale Transportation Network Speed Prediction,” Sensors, vol. 17, no. 4, Art. no. 818, 2017.https://doi.org/10.3390/s17040818

[8]. S. Hochreiter and J. Schmidhuber, “Long Short-term Memory,” Neural Computation, vol. 9, no. 8, pp. 1735–1780, 1997. https://doi.org/10.1007/978-3-642-24797-2_4

[9]. J. Bergstra and Y. Bengio, “Random Search for Hyper-parameter Optimization,” Journal of Machine Learning Research, vol. 13, no. 1, pp. 281–305, 2012.

[10]. K. G. Dhal et al., “A Comprehensive Survey on Arithmetic Optimization Algorithm,” Archives of Computational Methods in Engineering, vol. 30, no. 5, pp. 3379–3404, 2023.https://doi.org/10.1007/s11831-023-09902-3

[11]. X.-S. Yang, “Nature-inspired Optimization Algorithms: Challenges and Open Problems,” Journal of Computational Science, vol. 46, Art. no. 101104, 2020.https://doi.org/10.1016/j.jocs.2020.101104

[12]. S. S. Sepasgozar and S. Pierre, “Network Traffic Prediction Model Considering Road Traffic Parameters Using Artificial Intelligence Methods in VANET,” IEEE Access, vol. 10, pp. 8227–8242, 2022.

[13]. Great Britain Department for Transport. Road Safety Data (STATS19). 2023. Available from:www.data.gov.uk/dataset/road-safety-data.

[14]. L. Abualigah et al., “The Arithmetic Optimization Algorithm,” Computer Methods in Applied Mechanics and Engineering, vol. 376, Art. no. 113609, 2021. https://doi.org/10.1016/j.cma.2020.113609

[15]. Y.-J. Zhang et al., “AOAAO: The hybrid algorithm of arithmetic optimization algorithm with aquila optimizer,” IEEE Access, vol. 10, pp. 10907–10933, 2022. https://doi.org/10.1109/ACCESS.2022.3144431

[16]. M. Abualigah, “Recent Advances in Metaheuristic Algorithms: Theory and Applications,” Artificial Intelligence Review, vol. 55, no. 7, pp. 5445–5506, 2022.https://doi.org/10.1007/978-3-030-72284-5_18

[17]. M. Q. Ibrahim et al., “Optimizing convolutional neural networks: A comprehensive review of hyperparameter tuning through metaheuristic algorithms,” Archives of Computational Methods in Engineering, vol. 32, no. 8, pp. 5123–5160, 2025.https://doi.org/10.1007/s11831-025-10292-x

[18]. G. E. P. Box et al., Time Series Analysis: Forecasting and Control. Hoboken, NJ, USA: John Wiley & Sons, 2015.https://doi.org/10.2307/3008255

[19]. V. N. Katambire et al., “Forecasting the Traffic Flow by Using ARIMA and LSTM Models: Case of Muhima Junction,” Forecasting, vol. 5, no. 4, pp. 616–628, 2023.https://doi.org/10.3390/forecast5040034

[20]. J. Smith and T. Brown, “Leveraging STATS19 for Traffic Accident Prediction: A Case Study,” Transportation Research Procedia, vol. 78, pp. 123–130, 2024.

[21]. S. Khatri et al., “Machine Learning Models and Techniques for VANET Based Traffic Management: Implementation Issues and Challenges,” Peer-to-Peer Networking and Applications, vol. 14, pp. 1778–1805, 2021.https://doi.org/10.1007/s12083-020-00993-4

[22]. J. L. Elman, “Finding Structure in Time,” Cognitive Science, vol. 14, no. 2, pp. 179–211, 1990. https://doi.org/10.1207/s15516709cog1402_1

[23]. J. Kim et al., “A Comprehensive Survey of Deep Learning for Time Series Forecasting: Architectural Diversity and Open Challenges,” Artificial Intelligence Review, vol. 58, no. 7, pp. 1–95, 2025.https://doi.org/10.1007/s10462-025-11223-9

[24]. A. Belhadi et al., “A Recurrent Neural Network for Urban Long-term Traffic Flow Forecasting,” Applied Intelligence, vol. 50, pp. 3252–3265, 2020.https://doi.org/10.1007/s10489-020-01716-1

[25]. J. Zhang et al., “Improved Genetic Algorithm Optimized LSTM Model and Its Application in Short-term Traffic Flow Prediction,” PeerJ Computer Science, vol. 8, Art. no. e1048, 2022. https://doi.org/10.7717/peerj-cs.1048

[26]. E. Fu et al., “Temporal Self-Attention-Based Conv-LSTM Network for Multivariate Time Series Prediction,” Neurocomputing, vol. 501, pp. 162–173, 2022.https://doi.org/10.1016/j.neucom.2022.06.014

[27]. E. H. Alkhammash, “An Optimized Gradient Boosting Model by Genetic Algorithm for Forecasting Crude Oil Production,” Energies, vol. 15, no. 17, Art. no. 6416, 2022.https://doi.org/10.3390/en15176416

[28]. Y. Li et al., “EA-LSTM: Evolutionary Attention-Based LSTM for Time Series Prediction,” Knowledge-Based Systems, vol. 181, Art. no. 104785, 2019.https://doi.org/10.1016/j.knosys.2019.05.028

[29]. S. Atef, S. Zahran, and A. Karam, “Bayesian Hyperparameter Optimization of GRU and LSTM Models for Short-Term Traffic Flow Prediction: A Case Study of Globe Roundabout in Saudi Arabia,” Applied System Innovation, vol. 9, no. 3, Art. no. 57, 2026.https://doi.org/10.3390/asi9030057

[30]. K. K. Chandriah and R. V. Naraganahalli, “RNN/LSTM with Modified Adam Optimizer in Deep Learning Approach for Automobile Spare Parts Demand Forecasting,” Multimedia Tools and Applications, vol. 80, no. 17, pp. 26145–26159, 2021.https://doi.org/10.1007/s11042-021-10913-0

[31]. M. Zahid et al., “Short Term Traffic State Prediction via Hyperparameter Optimization Based Classifiers,” Sensors, vol. 20, no. 3, Art. no. 685, 2020.https://doi.org/10.3390/s20030685

[32]. M. Aliyari et al., “Ant Colony Optimization of Hyper-Parameters in Multi-Head Attention Layer for Time Series Forecasting,” Applied Soft Computing, Art. no. 113562, 2025.https://doi.org/10.1016/j.asoc.2025.113562

[33]. A. R. Abdellah and A. Koucheryavy, “VANET Traffic Prediction Using LSTM with Deep Neural Network Learning,” in International Conference on Next Generation Wired/Wireless Networking. Cham, Switzerland: Springer, 2020. https://doi.org/10.1007/978-3-030-65726-0_25

[34]. C. Pan et al., “Vehicle Trajectory Prediction Based on Spatial-Temporal Graph Transformer Networks with LSTM,” Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, Art. no. 09544070251398023, 2025.https://doi.org/10.1177/09544070251398023

پاورقی

[1] Intelligent Transportation System (ITS)
[2] Vehicular ad-hoc Network (VANET)
[3] Long-Short Term Memory (LSTM)
[4] Arithmetic Optimization Algorithm (AOA)
[5] Receiver Operating Characteristic – Area Under the Curve (ROC-AUC)
[6] Root Mean Squared Error(RMSE)
[7] Genetic Algorithm (GA)
[8] Particle Swarm Optimization (PSO)
[9] Mean Absolute Error (MAE)
[10] Auto Regressive Integrated Moving Average (ARIMA)
[11] Support Vector Machine (SVM)

[12] Recurrent Neural Network (RNN)
[13] Dropout
[14] Seasonal Global Trend
[15] Exploration
[16] Exploitation