

کاربرد معماری نوین مدل آموزش عمیق ترکیبی CNN-LSTM در پیش‌بینی تعداد تخلفات سرعت غیرمجاز با داده‌های ترافیکی ساعتی

مقاله علمی-پژوهشی

*علی اکبر کرماند (نویسنده مسئول)، دانش آموخته دکتری، گروه مهندسی عمران، دانشکده فنی مهندسی،

دانشگاه آزاد اسلامی واحد علوم تحقیقات، تهران، ایران

*پست الکترونیکی نویسنده مسئول: Ali.karamvand@gmail.com

دریافت: ۱۴۰۴/۰۹/۲۰ - پذیرش: ۱۴۰۵/۰۳/۰۹

صفحه ۴۸۰-۴۶۵

چکیده

تخلف سرعت یکی از عوامل اصلی حوادث در آزادراه‌ها می‌باشد و آسیب‌های جانی، اقتصادی و اجتماعی متعددی در پی دارد. تاکنون در مطالعات متفاوتی پژوهشگران به پیش‌بینی تخلفات و حوادث پرداخته‌اند، اما مطالعه تعداد تخلفات با تفکیک زمانی ساعتی و معماری ترکیبی از مدل‌های آموزش عمیق کمتر دیده می‌شود. روش: مطالعه حاضر با ارائه معماری ترکیبی نوینی از روش‌های آموزش عمیق به پیش‌بینی تعداد تخلفات سرعت در ساعت میپردازد. مدل پیشنهادی مبتنی بر روش شبکه‌های کانولوشنی و روش حافظه طولانی مدت کوتاه مدت است که جهت پیش‌بینی تعداد تخلفات سرعت غیرمجاز با داده‌های ترافیکی ساعتی توسعه داده شده است. داده‌ها شامل متغیرهایی مانند تعداد وسایل نقلیه، سرعت، تخلفات فاصله و زمان وقوع تخلف بودند. داده‌ها پس از پیش‌پردازش به سه بخش آموزش ۷۰٪، اعتبارسنجی ۱۵٪، و آزمون ۱۵٪ تقسیم شدند و از اعتبارسنجی متقاطع در مدل استفاده شده است. نتایج حاصل از اعتبارسنجی متقاطع ۵ تایی نشان‌دهنده عملکرد قابل‌قبول مدل در پیش‌بینی تعداد تخلفات سرعت غیرمجاز است. در آموزش، مقادیر $RMSE$ در محدوده ۰/۶۹ تا ۲۰/۱۵ متغیر بود که به جز فولد اول، سایر فولدها عملکرد بهتری با R^2 بین ۰/۶۸ تا ۰/۸۵ و KGE بین ۰/۶۷ تا ۰/۸۳ نشان دادند. در فاز آزمون، میانگین $RMSE$ و KGE به ترتیب ۰/۷۷، ۰/۷۸ و ۰/۷۸ به طور قابل‌توجهی نزدیک به میانگین مقادیر فاز آموزش بود، که حاکی از عملکرد مورد تایید مدل است. در اعتبارسنجی مدل عملکرد $RMSE$ و KGE به ترتیب ۰/۷۶، ۰/۷۹ و ۰/۷۶ از خود نشان داد. استفاده از مدل‌های ترکیبی از آموزش عمیق مانند آنچه در این مطالعه مطرح شد، می‌تواند در تشخیص نقاط حادثه خیز با دقت و سرعت بهتر کمک کنند. بهینه‌سازی نظارت، تخصیص منابع، و افزایش ایمنی جاده‌ای به تبع این اقدام می‌تواند اتفاق بیافتد. پیشنهاد می‌شود به‌عنوان ورودی مدل در مطالعات آتی داده‌های شرایط جوی برای بهبود دقت نهایی ادغام شوند.

واژه‌های کلیدی: آموزش عمیق، پیش‌بینی، تخلفات سرعت، شبکه عصبی کانولوشنی، تخلفات ترافیکی

۱- مقدمه

ضرورت مداخلات فوری برای کاهش تصادفات را نشان می‌دهد. پیش‌بینی مبتنی بر داده‌های آماری موقعیت‌های پرخطر تخلفات رانندگی و نقاط بحرانی ترافیکی، امکان طراحی مداخلات هدفمند و زمانبندی شده برای کاهش ریسک‌های ایمنی را فراهم می‌سازد. این رویکرد پیش‌گیرانه مبتنی بر تحلیل الگوهای رفتاری رانندگان و عوامل تاثیرگذار محیطی، بهینه‌سازی تخصیص منابع نظارتی را ممکن می‌کند. (Hemanth Kumar et al., 2025). همچنین پیش‌بینی در مقیاس‌های

موضوع تخلفات سرعت و سبقت غیرمجاز همواره یکی از چالش‌های مدیریت ترافیک و ایمنی بوده است که دارای ارتباط مستقیمی با مسئله برنامه ریزی ایمنی راه و شناسایی نقاط پرخطر است. اهمیت تعداد تخلفات، حوادث و ایمنی زمانی بهتر مشخص می‌شود که توجه شود در سال‌های گذشته در کشور نرخ‌های حدود ۷ الی ۱۰ نفر مرگ‌ومیر در هر ۱۰۰۰۰ وسیله نقلیه نیز وجود داشته است که تقریباً دو برابر شرایط جهانی می‌باشد (Hemanth Kumar et al., 2025). این آمار

تا ویژگیهای مرتبط با برخورد را بهتر یاد بگیرد و از سوگیری به سمت رده اکثریت جلوگیری کند. پس از این پیش‌پردازش‌ها داده‌های اصلاح شده به عنوان ورودی به مدل CNN وارد می‌شوند. نتایج آزمایشها نشان می‌دهد مدل پیشنهادی ایشان با این راهبرد پیش‌پردازش، عملکرد پیش‌بینی بهتری را در مقایسه با روش‌های سنتی تر هوندا و برکلی و همچنین مدل پایه شبکه عصبی پرسپترون چندلایه^۲ MLP ارائه می‌دهد که عمدتاً ناشی از توانایی CNN در استخراج ویژگیهای پیچیده از داده‌های بهینه و حل موثر مشکل ناپایداری مدل است.

همچنین (Karamvand et al., 2024) در مطالعه دیگری چند روش مختلف پیش‌پردازش را در ورود به مدل‌های آموزش عمیق LSTM و GRU در پیش‌بینی استفاده کرده و سپس مدل‌های خود را بر اساس نمره مکتسبه از جمع آماره‌های خطا امتیازبندی نموده است. مطالعات ایشان نشان داد که حتی داده‌های با نوسان و تغییرات بالا در صورت استفاده از روش پیش‌پردازش صحیح قابلیت ارتقاء جهت استفاده در مدل‌های تخمینگر آموزش عمیق را خواهند داشت. پس از موضوع پیش‌پردازش در علم پیش‌بینی داده‌ها، نوع مدل و محاسبات تشخیص الگو اهمیت ویژه‌ای دارند که در ادامه به برخی از انواع مرتبط با تحقیق حاضر می‌پردازیم. امروزه پدیده‌های دارای الگوی پیچیده و داده‌های با عدم قطعیت‌های متفاوت در پی پیشرفت‌های علم کامپیوتر و سخت‌افزارهای پردازشی، بیشتر در معرض پیش‌بینی صحیح هستند و امکان استفاده از روش‌های محاسباتی پیچیده‌تر جهت دستیابی به پیش‌بینی دقیق‌تر و سریع‌تر فراهم شده است. در مطالعه حاضر، از دو الگوریتم قدرتمند هوش مصنوعی در زیرشاخه یادگیری عمیق استفاده خواهد شد تا ترکیبی برای پیش‌بینی تعداد تصادفات در مقیاس ساعتی ایجاد شود. بخشی از گستره وسیع علم هوش مصنوعی شامل الگوریتم‌هایی است که با یادگیری از داده‌های گذشته، الگوها را شناسایی کرده و پیش‌بینی انجام می‌دهند (Deng, 2018). پیش از این مطالعات گسترده‌ای در خصوص استفاده از روش‌های آموزش ماشین در پیش‌بینی‌های مرتبط با علم حمل و نقل انجام شده است. برای مثال می‌توان اشاره کرد که (Dai et al., 2020) در مطالعه خود تلاش می‌کند تا چهار مدل آموزش عمیق را بررسی کرده و سپس یک چارچوب یادگیری عمیق فضایی‌زمانی برای پیش‌بینی سرعت ترافیک معرفی می‌کند. در این مطالعه از ترکیب دو مدل ConvLSTM و GCN

کوچک‌زمانی، مکانی و یا پیش‌بینی از تعداد تخلفاتی که به وقوع می‌پیوندد، می‌تواند هزینه‌ها را کاهش داده و جان انسان‌ها را نجات دهد (Rasa-Ezadi et al., 2022). تحلیل داده‌های گذشته و پیش‌بینی آینده، شناسایی نقاط حادثه‌خیز و اجرای اقدامات کاهش ریسک را تسهیل می‌کنند. جهت دستیابی به تخمین صحیح از تعداد حوادث، بهره‌مندی از داده‌های میدانی جمع‌آوری شده از گذشته مسیر ضروری بوده و روش‌های علمی دقیق پیش‌بینی داده، نتایج مدل‌ها را بهبود می‌بخشد. در ایران، یکی از روش‌های مؤثر برای گردآوری اطلاعات تردد و تخلفات ترافیکی، استفاده از داده‌های استخراج شده از دوربین‌های ترددشمار و کنترل سرعت است. این داده‌ها که در حجم گسترده تولید و ذخیره می‌شوند، پس از فرآیند پیش‌پردازش و پاکسازی، برای کاربرد در پژوهش‌های علمی قابل استفاده خواهند بود. دسترسی به برخی داده‌های مذکور از سازمان راهداری و حمل نقل جاده‌ای و راهنمایی و رانندگی با مقیاس زمانی یک ساعته فراهم می‌باشد، با این حال، کیفیت و جامعیت این داده‌ها برای پیش‌بینی دقیق نیاز به بهبود دارد. در ادامه به برخی از این مطالعات در خصوص انجام پیش‌بینی‌های حوادث و تخلفات ترافیکی پرداخته خواهد شد. (Wang et al., 2020) در مطالعه‌ای به بررسی تکنیک‌های پیش‌پردازش داده‌ها برای بهبود پیش‌بینی تخلفات ترافیکی پرداخته‌اند. ایشان در اصل یک چارچوب یادگیری عمیق مبتنی بر شبکه عصبی کانولوشنال^۱ CNN را برای پیش‌بینی دقیق‌تر تصادفاتی که در آن برخورد از پشت صورت می‌گیرند معرفی کرده‌اند. هسته اصلی نوآوری این پژوهش در روش‌های پیش‌پردازش داده است که دو چالش عمده را هدف قرار می‌دهد. ابتدا با پاکسازی داده‌های خام، تغییرات شدید و نوسانات غیر مرتبط را شناسایی و کاهش می‌دهد تا الگوهای اساسی حرکت خودروها آشکارتر شوند. سپس به‌طور ویژه به مشکل عدم تعادل شدید رده‌ها می‌پردازد؛ جایی که نمونه‌های واقعی برخورد (رده اقلیت) به مراتب کمتر از نمونه‌های عدم برخورد (رده اکثریت) هستند. این پژوهش با صاف‌سازی داده‌ها تغییرات شدید داده را کاهش داده و با استفاده از الگوریتم ژنتیک، عدم تعادل رده‌ها را برطرف می‌کند. این روش با الهام از فرآیندهای تکاملی مانند ترکیب و جهش، نمونه‌های جدید و متنوعی از وضعیت‌های منجر به برخورد خلفی تولید می‌کند، بدون آنکه صرفاً به تکرار داده‌های موجود پردازد. این رویکرد، پایگاه داده را متعادلتر ساخته و مدل را قادر می‌سازد

می‌کند که در آن LSTM برای ضبط وابستگی‌های بلندمدت در داده‌های سری زمانی مانند جریان ترافیک و CNN برای استخراج ویژگی‌های ثابت زمانی به کار گرفته شده است. ایشان از منابع داده‌ای متنوعی شامل داده‌های بلوتوث، حسگرهای ترافیکی و شرایط جوی برای یک دوره یک‌ساله بهره برده و تکنیک‌های مختلف آماده‌سازی داده را به کار گرفته است. برای رفع مشکل عدم تعادل داده‌های تصادف، از تکنیک نمونه‌برداری بیش از حد اقلیت مصنوعی استفاده شده که به بهبود شناسایی موارد نادر تصادف کمک کرده است. مدل پیشنهادی ایشان با پنج مدل متداول دیگر مانند XGBoost، رگرسیون لجستیک بیزی و LSTM پایه مقایسه شده و عملکرد آن با معیارهایی نظیر مساحت زیر منحنی AUC، حساسیت و نرخ هشدار کاذب ارزیابی شده است. نتایج نشان می‌دهد که مدل LSTM-CNN در پیش‌بینی ریسک تصادف در معابر شهری نسبت به سایر مدل‌ها عملکرد بهتری داشته و پتانسیل بالایی برای کاربرد در پیشگیری از تصادفات و بهبود ایمنی معابر شهری دارد. این مطالعه با ترکیب معماری نوین، استفاده از داده‌های متنوع و مقایسه جامع، گامی مؤثر در توسعه ابزارهای پیش‌بینی ریسک تصادف برداشته و می‌تواند به عنوان پایه‌ای برای تحقیقات آتی در این حوزه مورد استفاده قرار گیرد. (Cypto et al., 2022)

در مطالعه خود پیرامون آموزش عمق داده‌ها در بخش حمل و نقل بیان می‌کنند که سرعت غیرمجاز تأثیر قابل توجهی بر حمل و نقل داشته، اما شناسایی و جریمه متخلفان زمان‌بر است و بدنبال نیاز کاهش زمان یک روش جدید تشخیص خودکار تخلف سرعت در ترافیک مبتنی بر یادگیری عمیق پیشنهاد می‌دهد. این روش شامل دو بخش تشخیص اشیا و شناسایی پلاک خودرو بوده است. کد مربوط به بخش تشخیص اشیا از شبکه عصبی PP YOLO استفاده می‌کند و برای شناسایی پلاک خودروهایی که با سرعت غیرمجاز حرکت می‌کنند، از سیستم Open ALPR بهره می‌برد. نتایج شبیه‌سازی ایشان نشان داده که این سیستم با دقت ۹۸/۸٪ برای تشخیص تخلف سرعت و ۹۹/۳٪ برای شناسایی پلاک، عملکرد بالایی دارد و در مقایسه با روش‌های موجود، دقت بهتری ارائه می‌دهد. (Alomari et al., 2023)

درخت تصمیم‌گیری و رگرسیون، جنگل تصادفی و شبکه عصبی چندلایه با بهره‌گیری از حدود پنجاه هزار داده مربوط به چهار سال در حد فاصله بین سالهای ۲۰۱۵ تا ۲۰۱۹، تلاش کرده است

استفاده می‌کند و مدل جدیدی ارائه می‌دهد. مدل ConvLSTM ویژگی‌های زمانی داده‌های ترافیکی را استخراج می‌کند، درحالی‌که مدل GCN ویژگی‌های فضایی شبکه ترافیک را تحلیل می‌کند. نتایج آزمایش‌ها نشان می‌دهد که این چارچوب در مقایسه با سه روش یادگیری عمیق دیگر، با یادگیری بهتر دینامیک‌های زمانی و پیچیدگی‌های فضایی داده‌های ترافیکی، بهترین عملکرد را در پیش‌بینی سرعت ترافیک در بازه‌های زمانی مختلف ارائه می‌دهد.

در پژوهشی (Cai et al., 2020)، از شبکه مولد تخصصی کانولوشنی عمیق DCGAN به‌عنوان رویکردی پیشرفته در یادگیری عمیق برای پیش‌بینی تصادفات جاده‌ای استفاده کرده‌اند. این مدل با تحلیل دقیق داده‌های تصادفات و ارائه آن‌ها به صورت ماتریس‌های دو بعدی، الگوهای پیچیده منجر به تصادف را شناسایی و داده‌های مصنوعی با ویژگی‌های مشابه داده‌های واقعی تولید می‌کند. این فرآیند به بهبود تعادل آماری مجموعه داده کمک کرده و دقت تحلیل را افزایش می‌دهد. عملکرد DCGAN با داده‌های واقعی بزرگراه‌ها سنجیده و با روش‌های متداول مانند نمونه‌برداری اقلیت SMOTE و نمونه‌برداری تصادفی کمتر مقایسه شد. نتایج نشان داد که DCGAN داده‌های مصنوعی یکنواخت‌تری تولید می‌کند و درک عمیق‌تری از ویژگی‌های داده‌های تصادفی ارائه می‌دهد. در این مطالعه، چهار الگوریتم پیش‌بینی شامل رگرسیون لجستیک، ماشین بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی کانولوشنی آزمایش شدند. مدل شبکه عصبی کانولوشنی مبتنی بر داده‌های DCGAN به شکل محسوس در پیش‌بینی تصادفات عملکرد بهتری داشت. یکی از یافته‌های برجسته، توانایی DCGAN در تشخیص اثر اختلاف سرعت بین نواحی بالادست و پایین‌دست بود که می‌تواند به طراحی سیاست‌های مدیریت ترافیک مؤثر منجر شود. استفاده از داده‌های متعادل‌شده توسط DCGAN در مدل‌های پیش‌بینی، امکان اجرای راهکارهای پیشگیرانه مانند حدود سرعت متغیر VSL و تابلوهای پیام پویا DMS^۳ را فراهم می‌کند و نه تنها دقت پیش‌بینی را بهبود می‌بخشد، بلکه ایمنی در شبکه‌های جاده‌ای را نیز تقویت می‌کند. (Li et al., 2020)

یک مدل پیش‌بینی ریسک تصادف در لحظه، برای معابر شهری پیشنهاد کرده که در مقایسه با مطالعات پیشین و با تمرکز بر آزادراه‌ها نوآورانه محسوب می‌شود. این پژوهش از یک شبکه عصبی ترکیبی LSTM-CNN استفاده

عملکرد نشان داده اند. به نظر می‌رسد فقدان روش‌های پیش‌بینی پیشرفته با دقت بالا در مقیاس‌های زمانی کوتاه‌مدت، همچنان یک شکاف پژوهشی است.

پژوهش حاضر با هدف توسعه یک مدل هیبریدی معماری جدید مبتنی بر شبکه‌های کانولوشنی CNN و LSTM برای پیش‌بینی ساعتی تخلفات سرعت غیرمجاز در آزادراه زنجان-قزوین (محدوده صائین قلعه - خرم‌دره) انجام شده است. با این تفاوت که در تحقیق حاضر تغییراتی در معماری شبکه پیشنهادی داده خواهد شد و با استفاده از داده‌های ساعتی شامل تعداد وسایل نقلیه، سرعت متوسط، و تخلفات فاصله غیرمجاز، این مدل الگوهای محلی و وابستگی‌های زمانی تخلفات را شناسایی و مطالعه خواهد کرد. نتایج این پژوهش می‌تواند به اداره راه‌داری و حمل‌ونقل جاده‌ای و پلیس راهور در بهینه‌سازی منابع نظارتی، افزایش ایمنی جاده‌ای، و کاهش حوادث کمک کند.

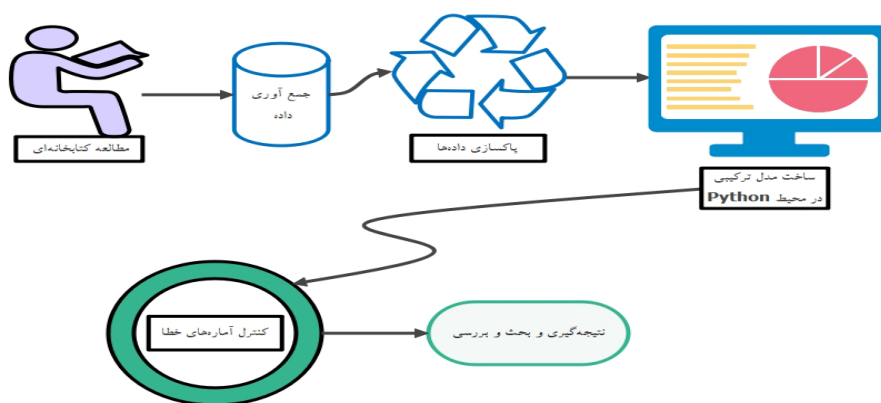
۲- مواد و روش

۲-۱- مراحل تحقیق

در تحقیق حاضر پس از انجام مطالعه کتابخانه‌ای و بررسی مدل‌های مشابه دو روش از زیرمجموعه مدل‌های آموزش عمیق انتخاب و به صورت ترکیبی مدل جدید را ایجاد کرده اند و سپس نتایج مدل در مراحل مختلف آموزش و آزمایش و اعتبار سنجی توسط آماره‌های خطا کنترل شده است. می‌توان گفت مراحل تحقیق مطابق فلوجارت تصویر ۱ انجام شده است. از ادبیات تحقیق در تدوین مبانی نظری مدل‌های ترکیبی، شناسایی روش‌های پیش‌پردازش داده‌ها، و مقایسه عملکرد مدل‌های پیش‌بینی تخلفات ترافیکی استفاده شده است. مطالعات پیشین مانند (Wang et al., 2020) برای بهینه‌سازی داده‌ها، (Cai et al., 2020) برای کاربرد DCGAN، و (Li et al., 2020) برای ترکیب CNN-LSTM، چارچوب نظری و روش‌شناختی تحقیق حاضر را شکل داده‌اند و به طراحی مدل هیبریدی و انتخاب معیارهای ارزیابی (RMSE, R2, KGE) کمک کرده‌اند.

تا پیش‌بینی تعداد تصادفات را انجام دهد. این مطالعه که از داده‌های ده ایالت اول از نظر نرخ تصادف در امریکا استفاده کرده است نشان داد مدل جنگل تصادفی، می‌تواند به‌طور مؤثری تخلفات سرعتی در جاده‌ها را تحلیل و پیش‌بینی کنند. همچنین بیان میکنند که عوامل اصلی تأثیرگذار بر تخلفات سرعت شامل سن راننده (به‌ویژه گروه‌های سنی زیر ۳۵ سال)، تراز جاده (بیشتر در پیچ‌ها)، محدودیت سرعت، شرایط آب‌وهوایی بد و زمان تصادف بودند.

(Hemanth Kumar et al., 2025) نیز از مدل‌سازی گرافی یادگیری ماشین و تحلیل داده‌های بلادرنگ استفاده کرده و به پیش‌بینی تخلفات رانندگان می‌پردازند. این سیستم با تحلیل رفتار راننده، شرایط جاده، سوابق تخلفات و الگوهای ترافیکی، یک شبکه سلسله‌مراتبی می‌سازد. از تکنیک‌های یادگیری ماشین مانند شبکه‌های عصبی گرافی GNN، جنگل تصادفی و مدل آموزش عمیق LSTM برای استخراج ویژگی‌های مکانی-زمانی و پیش‌بینی احتمال تخلفات استفاده کرده است. نتایج آزمایش‌ها ایشان روی داده‌های واقعی ترافیک، دقت بالاتر این مدل آموزش عمیق در شناسایی رانندگان پرخطر نسبت به روش‌های سنتی را نشان می‌دهد. (Gutierrez-Osorio et al., 2020) بر روش‌های یادگیری ماشین برای تحلیل و پیش‌بینی تصادفات جاده‌ای ارائه می‌دهد. با بررسی جامع روش‌های نوین مانند شبکه‌های عصبی کانولوشنی CNN و شبکه‌های LSTM در معماری‌های یادگیری عمیق، منابع داده متداول (داده‌های باز، فناوری‌های اندازه‌گیری، تجهیزات خودرویی و شبکه‌های اجتماعی) را بر اساس خاستگاه و ویژگی‌هایشان طبقه‌بندی می‌کند. پژوهشگران الگوریتم‌های پیش‌بینی را بر اساس نوع داده، دقت و تفسیرپذیری مقایسه کرده و نشان داده‌اند که مدل‌های ترکیبی دقت بالاتری دارند. چالش آینده، ادغام داده‌های ناهمگون مانند داده‌های مکانی، ترافیک، ویدئو، صوت، متن و تحلیل احساسات شبکه‌های اجتماعی است که دقت پیش‌بینی‌ها را بهبود می‌بخشد. همانطور که دیده شد در سال‌های اخیر تمرکز بسیاری از مطالعات بر مدل‌های ترکیبی بوده و تحقیقات نشان داد که این مدل‌ها با هدف کشف الگوهای اولیه توسط یک مدل و سپس آموزش مدل پیش‌بینی کننده توسط مدل دوم در اکثر موارد بهبود

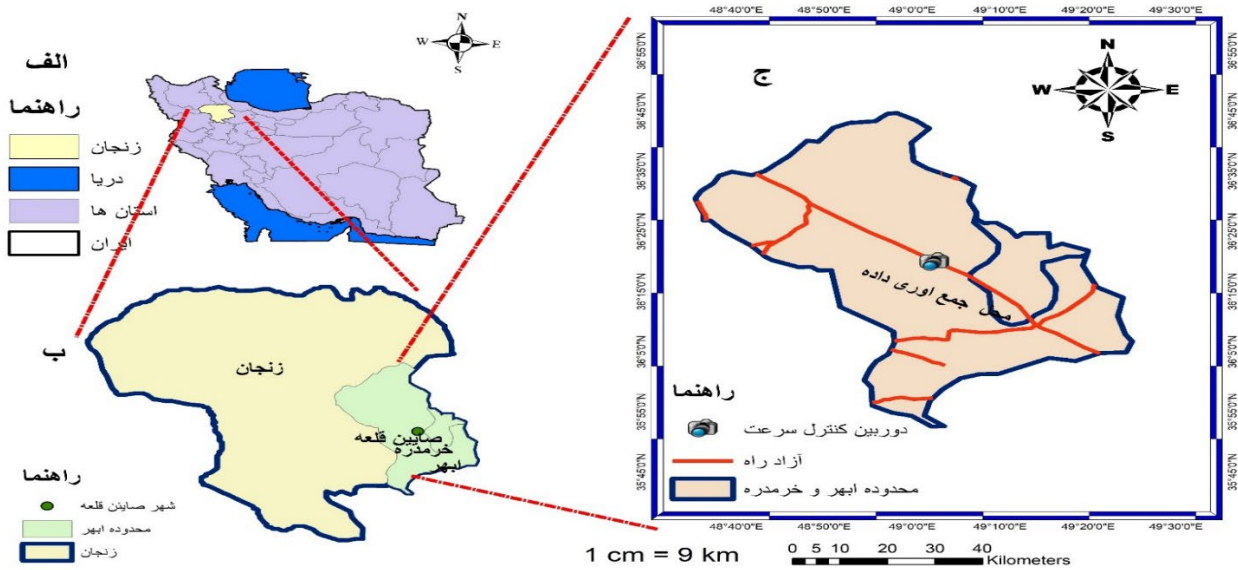


تصویر ۱. فلوچارت مراحل تحقیق

۲-۲- منطقه مورد مطالعه

آزادراه زنجان-قزوین، به‌عنوان یکی از گذرگاه‌های مهم ایران، نقش راهبردی و اقتصادی برجسته‌ای در اتصال شمال غرب به مرکز کشور داشته و مسیر انتقال کالا و مسافر غرب به شرق می‌باشد. این محور با تردد بالا و اهمیت سیاسی، اقتصادی، امنیتی و فرهنگی، شریان حیاتی حمل‌ونقل ایران است و از شهرهایی مانند خرم‌دره و صائین‌قلعه عبور می‌کند. این آزادراه به جاده بین‌المللی تهران-بازرگان متصل است و با وجود ایستگاه راه‌آهن خرم‌دره، دسترسی به شبکه ریلی را نیز تقویت می‌کند، که تجارت، گردشگری و انتقال کالا و مسافر منطقه‌ای را بهبود می‌بخشد. خواب‌آلودگی رانندگان، به‌ویژه در خودروهای سنگین، و تجاوز از سرعت مجاز از عوامل اصلی تصادفات

هستند، که با استرس و مشکلات اقتصادی رانندگان تشدید می‌شود. وضعیت نامناسب آسفالت، کمبود روشنایی، و محدودیت‌های مالی، چالش‌هایی برای رسیدن به استانداردهای مطلوب ایجاد کرده است. این آزادراه با تقویت زیرساخت‌های حمل‌ونقل، پتانسیل بالایی برای توسعه اقتصادی منطقه دارد، اما نیاز به سرمایه‌گذاری مداوم در ایمن‌سازی و نگهداری دارد تا خسارات جانی و مالی کاهش یابد و نقش راهبردی آن حفظ شود. در مطالعه حاضر مدل تخمینگر تعداد تصادفات با استفاده از داده‌های برداشت شده از دوربین مشخص شده بر روی تصویر ۲ اجرا شده است. در این تصویر منطقه مورد مطالعه نمایش داده شده است.




تصویر ۲. منطقه مورد مطالعه الف) محدوده قرارگیری استان زنجان در کشور ب) منطقه مورد مطالعه در استان زنجان ج) محل جمع‌آوری داده در آزاد راه زنجان- قزوین

۳-۲- داده‌های ورودی مدل

مجاز، تعداد تخلف سبقت غیر مجاز) بودند، تعدادی با استدلال حذف شدند و با استفاده از داده‌های زمانی سه ستون داده ورودی به شرح ساعت از شبانه روز، روز در هفته، روز در ماه اضافه شدند. همچنین با توجه به رابطه مستقیم بین تعداد کل وسایل نقلیه و تعداد هر رده وسیله نقلیه پس از انجام تحلیل فاکتور تورم واریانس برای داده‌های ترافیکی مشخص شد به علت وجود پدیده هم‌خطی بین متغیرهای مستقل رده وزنی وسیله‌های نقلیه حذف و فقط تعداد کل تردد نگه داشته خواهد شد. ستون‌های نهایی داده شامل (زمان سه ستون، تعداد کل وسیله نقلیه، سرعت متوسط، تعداد تخلف سرعت غیرمجاز و تعداد تخلف فاصله غیرمجاز خواهند بود) جدول ۱ یک تحلیل آماری اولیه از شرایط و پراکندگی داده‌های ترافیکی نمایش می‌دهد. بعلاوه از آنجا که داده هدف جهت پیش‌بینی تعداد تخلف خواهد بود میانگین تعداد تخلف در ساعت در تصویر ۳ نمایش داده شده است.

در تحقیق حاضر داده‌های ورودی دریافتی شامل اطلاعات ساعتی مربوط به تردد و تخلفات ترافیکی در آزادراه زنجان-قزوین (محدوده صائین قلعه - خرم‌دره) از تاریخ ۱۴۰۳/۰۳/۰۱ معادل ۲۰۲۴/۰۵/۲۱ تا ۱۴۰۴/۰۳/۰۱ (معادل ۲۰۲۵/۰۵/۲۱) خواهد بود. داده‌ها شامل ۷۴۹۱ ردیف (مشاهده) و ۱۶ ستون خام هستند که هر ردیف نشان‌دهنده یک بازه زمانی ساعتی یا کمتر (در برخی موارد به دلیل قطع ثبت داده، بازه‌ها کوتاه‌تر هستند) و ستون‌ها ویژگی‌های مختلف ترافیکی را توصیف می‌کنند. این داده‌ها از درگاه اداره کل راهداری و حمل و نقل جاده‌ای معروف به سامانه ۱۴۱ جمع‌آوری شده‌اند. از میان ستون داده‌ها که به شرح (زمان شروع، زمان پایان، مدت زمان کارکرد دوربین بر حسب دقیقه، تعداد کل وسیله نقلیه، تعداد وسیله نقلیه رده ۱، تعداد وسیله نقلیه رده ۲، تعداد وسیله نقلیه رده ۳، تعداد وسیله نقلیه رده ۴، تعداد وسیله نقلیه رده ۵، سرعت متوسط، تعداد تخلف سرعت غیر مجاز، تعداد تخلف فاصله غیر



شکل ۳. میانگین تخلف در ساعت در حد فاصله خرداد ۱۴۰۳ تا خرداد ۱۴۰۴، از محل دوربین آزادراه زنجان-قزوین در موقعیت جغرافیایی محدوده شهر صائین قلعه

جدول ۱. خلاصه آماری شاخص‌های ترافیک و تخلفات

نام ردیف	کل وسایل نقلیه عبوری	تعداد تخلف سرعت غیرمجاز	میانگین سرعت	تعداد تخلف فاصله غیرمجاز
تعداد مشاهدات	۷۴۹۱	۷۴۹۱	۷۴۹۱	۷۴۹۱
میانگین	۷۹۹/۱	۲۰۲/۹	۸۸,۴۸	۱۷۷/۹۷
انحراف معیار	۵۲۷/۰۶	۲۱۰	۱۱,۷۱	۲۵۸/۹۴
حداقل	۰	۰	۰	۰
چارک اول (۲۵٪)	۴۴۸	۱۵	۸۲	۴۵
میانه (۵۰٪)	۷۳۴	۱۶۴	۸۹	۱۱۹
چارک سوم (۷۵٪)	۱,۰۶۶/۵	۳۰۹	۹۶	۲۲۴
حداکثر	۵,۳۸۸	۱۵۰۴	۱۱۲	۴۰۲۸

در ادامه روش‌های اصلی استفاده شده در ساختار مدل ترکیبی توضیح داده شده‌اند.

۲-۴- روش CNN

شبکه‌های کانولوشنی یکی از انواع شبکه عصبی یادگیری عمیق هستند که به‌ویژه برای پردازش داده‌های ساختاریافته مانند تصاویر و سری‌های زمانی طراحی شده‌اند (Bhattacharya et al., 2023). با پیشرفت سخت‌افزارها، دسترسی به داده‌های بزرگ و بهبود الگوریتم‌های بهینه‌سازی در دهه ۲۰۱۰ این روش که در گذشته به علت حجم بالای محاسبات کنار گذاشته شده بود احیا شد. نقطه عطف کلیدی در سال ۲۰۱۲ با معرفی شبکه‌الکس توسط الکس کریژفسکی و همکارانش به وقوع

پیوست (Aloysius et al., 2017). شبکه‌الکس در مسابقه ایمنجت با اختلاف زیاد برنده شد و نشان داد که CNN می‌تواند در تشخیص تصویر عملکردی فوق‌العاده‌ای داشته باشند. این مدل از لایه‌های عمیق‌تر، فعال‌سازی ReLU و Dropout برای جلوگیری از بیش‌برازش استفاده کرد. در حال حاضر شبکه‌های کانولوشنی به دلیل دو ویژگی اصلی خود، یعنی عملیات کانولوشنی و لایه‌های تجمیع، به ابزاری قدرتمند برای پردازش داده تبدیل شده‌اند. عملیات کانولوشنی با استفاده از فیلترهای کوچک که روی داده‌های ورودی حرکت می‌کنند، الگوهای محلی را شناسایی کرده و با اشتراک‌گذاری وزنی، تعداد عوامل تاثیرگذار را کاهش می‌دهد و یادگیری ویژگی‌های سلسله‌مراتبی را ممکن می‌سازد. از سوی دیگر، لایه‌های تجمیع

حمل و نقل و پیش‌بینی‌های هیدرولوژیکی مانند مدل‌سازی جریان رودخانه‌ها، دقت و تعمیم‌پذیری را افزایش می‌دهد. در مطالعه حاضر مدل ترکیبی ارائه شده از نوع یادگیری عمیق بوده و برای پیش‌بینی تعداد تخلیفات سرعت غیرمجاز در داده‌های ترافیکی به شکل سری زمانی طراحی شده است. این مدل از ترکیب شبکه‌های کانولوشنی و LSTM استفاده می‌کند که با استفاده از دو کتابخانه کراس و تنسورفلو در پایتون پیاده‌سازی شده و با پردازنده T4 شرکت گوگل به صورت ابری و در بستر بر خط وبسایت گوگل کولب پردازش شده است. مراحل اصلی پیش‌پردازش داده، تقسیم بندی داده‌ها آموزش ۷۰٪ داده‌ها با اعتبارسنجی متقاطع کیفولد جهت جلوگیری از بیش‌برازش و ارزیابی روی مجموعه داده‌های مرحله آزمایش (۱۵٪ داده‌ها) است و نهایت اعتبارسنجی با الباقی داده‌ها (۱۵٪ داده‌ها) می‌باشد در کلیه مراحل آماره‌های خطا کنترل شده اند. معماری مدل به‌گونه‌ای طراحی شده که الگوهای محلی و وابستگی‌های زمانی را به‌طور مؤثر استخراج کند. پیش‌پردازش و آماده‌سازی داده در مرحله پیش‌پردازش، داده‌ها با تبدیل ستون زمان شروع به فرمت تاریخ-زمان و تبدیل ستون‌های عددی به نوع عددی مناسب آماده می‌شوند. ویژگی‌های جدیدی مانند نرخ تخلیفات سرعت در ساعت نرخ وسایل نقلیه در ساعت برای نرمال‌سازی داده‌ها ایجاد می‌شوند. این ویژگی‌ها به مدل کمک می‌کنند تا به‌جای مقادیر خام، روی نرخ‌های استاندارد تمرکز کند. داده‌ها با حذف مقادیر گمشده پاک‌سازی شده و ورودی‌ها و هدف (تخلیفات سرعت غیرمجاز) تعریف می‌شوند. برای سری‌های زمانی، داده‌ها به توالی‌هایی با طول مشخص (پیش‌فرض ۱۲) تبدیل می‌شوند تا برای ورودی مدل آماده شوند. از دیدگاه معماری مدل میتوان گفت در این مطالعه، مدل پیشنهادی از یک معماری ترتیبی استفاده می‌کند که با تلفیق لایه‌های CNN و LSTM طراحی شده است. ساختار اصلی با دو لایه Conv1D آغاز می‌شود که به ترتیب دارای ۳۲ و ۱۶ فیلتر با اندازه هسته ۳ هستند و با فعال‌سازی ReLU و تنظیم‌کننده L2 برای پیشگیری از بیش‌برازش به کار گرفته می‌شوند. این لایه‌ها با دو لایه MaxPooling1D دنبال می‌شوند که ابعاد را کاهش داده و ویژگی‌های مهم را استخراج می‌کنند، به‌طوری‌که نیمی از ابعاد قبلی حفظ شده و خروجی‌هایی با شکل 6, 32, None و 16, 3, None تولید می‌کنند. سپس، ویژگی‌ها به دو لایه LSTM منتقل می‌شوند که به ترتیب با ۳۲ و ۱۶ واحد حافظه و فعال‌سازی Tanh عمل می‌کنند؛ لایه اول خروجی‌های متوالی تولید می‌کند تا داده‌ها برای لایه دوم آماده شوند و لایه دوم خروجی نهایی را به شکل 16, None تبدیل می‌کند. این فرآیند

(مانند Max Pooling) با کاهش ابعاد داده‌ها، ضمن حفظ ویژگی‌های کلیدی، پیچیدگی محاسباتی را کم کرده و مقاومت مدل را در برابر تغییرات کوچک مانند جابجایی یا چرخش افزایش می‌دهند، که این امر به بهبود تعمیم‌دهی و کارایی مدل کمک می‌کند.

۲-۵-روش LSTM

LSTM ها نوعی از شبکه‌های عصبی بازگشتی یا RNN محسوب می‌شوند که در تحقیقات (Hochreiter et al., 1997) معماری این شبکه را با گیت‌های فراموشی، ورودی و خروجی معرفی شد. این ساختار امکان حفظ و مدیریت اطلاعات بلندمدت را فراهم کرد. در کل این مدل به پردازش به خاطر سپردن به جهت استفاده در آینده معروف می‌باشند، به جاماندن اثرات آموزش و یا بخاطر سپردن، جزئی از مرحله آموزش آنها محسوب نمی‌شود و در رفتار پیش فرض آنها موجود است. یعنی به جای بخش‌های تکرار شونده با قابلیت به خاطر سپردن بخشی از اطلاعات دارای نوعی دیگر از بخش‌های خاص می‌باشند که توانایی کپی کردن اطلاعات مؤثر را دارند. پس از انجام یک پیش‌بینی اولیه در سطح هر نرون با استفاده از تابعی بهینه ساز به نام ADAM بهینه‌ترین ضرایب انتخاب شده و مراحل آموزش ادامه می‌یابد. انتخاب یک الگوریتم بهینه ساز مؤثر در آموزش عمیق می‌تواند موجب کمتر شدن زمان حل و بهبود نتایج گردد. این روش بهینه سازی یک روش آماری جهت بهینه سازی بوده که توسط شده است.

۲-۶-مدل ترکیبی

مبانی نظری این تحقیق بر پایه اصول یادگیری عمیق استوار است، جایی که شبکه‌های کانولوشنی بر اساس عملیات فیلترگذاری و استخراج ویژگی‌های محلی از داده‌های ساختاریافته مانند سری‌های زمانی ترافیکی عمل می‌کنند، همان‌طور که در مدل‌های اولیه مانند الکسنت در سال ۲۰۱۲ معرفی شد و برای پردازش الگوهای پیچیده مناسب است؛ در عین حال، شبکه‌های حافظه طولانی مدت کوتاه مدت به عنوان نوعی از شبکه‌های عصبی بازگشتی، با استفاده از درگاه‌های ورودی، خروجی و فراموشی، وابستگی‌های بلندمدت زمانی را مدیریت می‌کنند تا مشکلات محو شدن گرادیان در داده‌های ترتیبی را حل کنند، که این ترکیب هیبریدی در مطالعات

داده‌های ترافیکی ساعتی و بکارگیری روش کیفولد برای اعتبارسنجی، نوآوری را در کاربرد عملی آن برای پیش‌بینی تخلفات سرعت غیرمجاز در آزادراه‌ها افزایش داده و رویکردی جامع‌تر نسبت به مدل‌های سنتی ارائه می‌دهد.

۷-۲- کنترل مدل

روش اعتبارسنجی متقاطع کیفولد یک روش ارزیابی مدل‌های پیش‌بینی است. در این روش، داده‌ها به چند بخش تقسیم می‌شوند و مدل در چند مرحله آموزش می‌بیند. هر بار یکی از بخش‌ها برای آزمون و بقیه برای آموزش استفاده می‌شوند. این کار کمک میکند تا مدل روی تمام داده‌ها ارزیابی شود و از بیش‌برازش جلوگیری می‌کند. در مدل‌های سری‌زمانی که داده‌ها به ترتیب زمان مرتب هستند، نمی‌توان از تقسیم تصادفی استفاده کرد. به‌جای آن از روش‌های اصلاح‌شده مانند پنجره متحرک یا پیش‌روی گام‌به‌گام استفاده می‌شود تا اطلاعات آینده در پیش‌بینی گذشته تأثیر نگذارند. کیفولد در پیش‌بینی سری‌زمانی باعث می‌شود مدل پایدارتر شود و از تمام داده‌ها بهینه استفاده شود. همچنین با میانگین‌گیری از نتایج چندین اجرا، خطای پیش‌بینی کاهش می‌یابد. از جمله چالش‌های این روش در داده‌های زیاد سنگین شدن محاسبات می‌باشد. محاسبه آماره خطا در نهایت بین متغیرهای پیش‌بینی شده و مقادیر واقعی انجام خواهد شد. از این بین ضریب تعیین از رابطه زیر محاسبه می‌گردد.

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (1)$$

RMSE نشان دهنده آماره جذر میانگین مربعات خطا بوده و n تعداد کل داده‌های جامعه آماری می‌باشد و Y_i یک داده در سری زمانی و \hat{Y}_i مقدار داده پیش‌بینی در هر مرحله می‌باشد.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{1}{n} (Y_i - \hat{Y}_i)^2} \quad (2)$$

مدل‌های پیش‌بینی استفاده کرد. این شاخص از ترکیب دقت، قابلیت اطمینان و تغییرپذیری در پیش‌بینی یک سری زمانی یا

با یک لایه Dense با ۳۲ نورون و فعال‌سازی ReLU ادامه می‌یابد که ویژگی‌ها را برای پیش‌بینی نهایی پردازش می‌کند، و یک لایه Dropout با نرخ ۰٫۴ برای کاهش بیش‌برازش و یک لایه Dense با خروجی 1, None برای پیش‌بینی تعداد تخلفات سرعت به کار می‌رود. داده‌ها ابتدا از طریق لایه‌های Conv1D و MaxPooling1D پردازش می‌شوند تا ویژگی‌های محلی و زمانی از داده‌های سری‌زمانی ترافیکی استخراج گردند؛ این فرآیند با کاهش ابعاد و حفظ اطلاعات کلیدی، داده‌ها را برای تحلیل الگوهای پیچیده آماده می‌کند. سپس، لایه‌های LSTM با بهره‌گیری از حافظه داخلی خود الگوهای زمانی بلندمدت را مدل‌سازی کرده و خروجی‌ها به لایه‌های Dense منتقل می‌شوند تا پیش‌بینی نهایی شکل گیرد. جریان داده‌ها به‌گونه‌ای است که از استخراج ویژگی‌های فضایی توسط CNN به مدل‌سازی سری‌زمانی با LSTM و در نهایت به طبقه‌بندی یا رگرسیون با Dense می‌رسد، که این ترتیب برای داده‌های ترافیکی ساعتی با ویژگی‌های فضایی و زمانی، مناسب و مؤثر است. این معماری به دلیل تلفیق نوآورانه CNN و LSTM همراه با تنظیم‌کننده L2 و لایه Dropout که به‌طور همزمان از بیش‌برازش جلوگیری کرده و دقت مدل را حفظ می‌کند، جدید و متمایز تلقی می‌شود. استفاده از دو لایه Conv1D با کاهش تدریجی فیلترها از ۳۲ به ۱۶ و دو لایه LSTM با واحدهای متفاوت ۳۲ و ۱۶، امکان استخراج ویژگی‌های چندمرحله‌ای را فراهم می‌کند که در مطالعات پیشین کمتر مورد توجه قرار گرفته است. همچنین، ادغام این ساختار با

معیار ضریب تعیین معیاری که با R^2 نمایش داده شده، جهت تعیین دقت داده‌های پیش‌بینی استفاده می‌شود. خروجی رابطه مربوط به این معیار همواره یک عدد بین ۰ تا ۱ را نمایش می‌دهد و که هر چه به عدد ۱ نزدیکتر باشد نشان‌دهنده دقت بالاتر در پیش‌بینی است. مجذور میانگین مربعات خطا از رابطه ۲ محاسبه می‌شود.

برای کنترل عملکرد مدل‌های آموزش ماشین شاخص وجود دارد که می‌توان از آن به عنوان یک معیار برای ارزیابی دقت

به شرح رابطه ۳ است. با استفاده از عدد بدست آمده مدل را به چندین دسته می‌توان تقسیم‌بندی کرد که در اکثر مطالعات مدل‌ها را به: عالی مقدار KGE بیشتر از (۰/۸) و خوب بین (۰/۶) الی (۰/۸) و متوسط مقدار بین (۰/۴) تا (۰/۶) و عملکرد ضعیف کمتر از (۰/۴) تقسیم بندی می‌کنند. در صورتیکه r نماینده و نشانگر قابلیت اعتماد به داده‌ها (همبستگی پیرسون خطی بین مشاهدات و شبیه‌سازی‌ها) باشد و بتا ضریب بایاس رابطه و گاما عدد حاصل از تقسیم میانگین داده‌های شبیه‌سازی بر داده‌های واقعی) رابطه به شکل زیر تعریف می‌گردد.

$$KGE = 1 - \sqrt{(1 - \beta)^2 + (1 - r)^2 + (1 - \gamma)^2}$$

مکانی استفاده می‌کند. قابلیت اطمینان که بیانگر میزان توانایی مدل در باز تولید مقادیر واقعی داده‌ها است، دقت که نشان‌دهنده توانایی مدل در پیش‌بینی تغییرات داده‌ها است و در نهایت تغییرپذیری دارد که توانایی مدل در باز تولید تغییرات مقیاس داده‌ها می‌باشد. با ترکیب این سه مؤلفه، شاخص KGE به عنوان یک معیار جامع برای ارزیابی دقت مدل استفاده می‌شود و می‌تواند به عنوان یک ابزار مفید برای انتخاب و ارزیابی مدل‌های پیش‌بینی مورد استفاده قرار گیرد (Wegayehu et al., 2022). رابطه اصلی این شاخص

(۳)

۳- نتایج

دوربین موردنظر در آزادراه زنجان-قزوین، که داده‌های این مدل از آن جمع‌آوری شده‌اند، در یکی از نقاط پرتردد یا پرخطر این محور نصب شده است، با توجه به میانگین بالای تخلفات این آزادراه به‌عنوان یکی از مسیرهای اصلی ارتباطی بین تهران و شمال‌غرب ایران، حجم ترافیک بالایی دارد، به‌ویژه در ساعات بعدازظهر (۱۴:۰۰-۱۸:۰۰) که آمار بیشترین تخلفات را شناسایی کرده است. تحلیل داده‌ها نشان می‌دهد که متغیرهایی مانند تعداد کل وسایل نقلیه و تخلفات فاصله غیرمجاز تأثیر زیادی بر تخلفات سرعت دارند، که ممکن است به دلیل تراکم ترافیک یا رفتارهای رانندگی پرخطر در این نقطه باشد. برای بهبود ایمنی، پیشنهاد می‌شود که اداره راهداری و پلیس راهور در این نقطه دوربین‌های اضافی یا تابلوهای هشداردهنده نصب کنند و گشت‌های نظارتی را در ساعات پرخطر افزایش دهند. همچنین، افزودن داده‌های محیطی مانند شرایط جوی یا وضعیت جاده می‌تواند دقت پیش‌بینی‌ها را در این مکان خاص افزایش دهد. در این مطالعه، یک مدل ترکیبی مبتنی بر شبکه‌های کانولوشنی و حافظه بلندمدت کوتاه‌مدت برای پیش‌بینی تخلفات سرعت در داده‌های ترافیکی سری زمانی توسعه داده شد. این مدل با هدف استخراج الگوهای محلی و وابستگی‌های زمانی طراحی شده و از تکنیک‌های اعتبارسنجی متقاطع سری زمانی، منظم‌سازی L_2 ، و معیار کارایی کلینگ-گوپتا بهره می‌برد. در بخش نتایج، عملکرد مدل از طریق آماره‌های خطا در مراحل حل ارزیابی شده و نمودارهای بصری برای مقایسه مقادیر واقعی و پیش‌بینی شده

در ادامه ارائه می‌شوند. نتایج نشان‌دهنده توانایی مدل در پیش‌بینی دقیق تخلفات سرعت و کارایی آن در محیط‌های ترافیکی پیچیده است. نتایج اعتبارسنجی متقاطع مدل به شرح جدول ۲ می‌باشد، از آنجا که اعتبارسنجی متقاطع پنج-تایی انجام شده است، داده‌ها به پنج زیرمجموعه (فولد) تقسیم شده‌اند و در هر مرحله $K-1$ فولد برای آموزش استفاده می‌شوند. یک فولد برای آزمون استفاده می‌شود. این فرآیند K بار تکرار می‌شود، به‌طوری‌که هر فولد دقیقاً یکبار به‌عنوان مجموعه آزمون و $K-1$ بار به‌عنوان بخشی از مجموعه آموزش استفاده می‌شود. این روش تضمین می‌کند که مدل روی داده‌های متنوعی ارزیابی شود و از وابستگی بیش‌ازحد به یک زیرمجموعه خاص از داده‌ها جلوگیری می‌کند. در جدول فوق معیارهای ارزیابی شامل ریشه میانگین مربعات خطا، ضریب تعیین و شاخص کلینگ-گوپتا بودند. نتایج به‌دست‌آمده نشان‌دهنده عملکرد کلی پایدار مدل در فازهای آموزش و آزمون است، به‌جز در فولد اول که ناهنجاری‌هایی مشاهده شد. این تحلیل با تمرکز بر تعمیم‌پذیری و قابلیت اعتماد مدل انجام شده است. اعتبارسنجی نتایج تحقیق با استفاده از روش اعتبارسنجی متقاطع پنج‌تایی (K -Fold) انجام شد که داده‌ها را به پنج زیرمجموعه تقسیم کرده و در هر مرحله، یک زیرمجموعه (فولد) به‌عنوان داده آزمون و چهار زیرمجموعه دیگر برای آموزش مدل استفاده شدند. این فرآیند پنج بار تکرار شد تا هر زیرمجموعه یک‌بار به‌عنوان داده آزمون ارزیابی شود، که این روش با حفظ ترتیب زمانی داده‌های سری زمانی ترافیکی،

افراطی نیاز به تحلیل بیشتر دارد. این روش اعتبارسنجی، مشابه تکنیک‌های مورد استفاده در مدل‌سازی هیدرولوژیکی، با ارائه ارزیابی چندجانبه، از بیش‌برازش جلوگیری کرده و قابلیت اعتماد مدل را برای کاربرد عملی در پیش‌بینی تخلفات سرعت تضمین می‌کند. در فاز آموزش، مقادیر RMSE در فولدهای مختلف بین ۶۶/۰۵ تا ۲۰۱/۵۲ متغیر بود. فولد اول با RMSE بالا عملکرد ضعیفی نشان داد، در حالیکه سایر فولدها مقادیر کمتری (بین ۶۶/۰۵ و ۹۵/۰۲) داشتند. مقادیر ضریب تعیین در فاز آموزش (به‌جز فولد اول با ۰/۱۲) بین ۰/۶۷۸ و ۰/۸۴۶ قرار داشتند، که نشان‌دهنده توانایی خوب مدل در توضیح واریانس داده‌هاست. همچنین، مقادیر KGE در فاز آموزش (به‌جز فولد اول با ۰/۱۴) بین ۰/۶۷ و ۰/۸۳ بودند، که نشان‌دهنده تطابق مناسب مدل با داده‌های آموزشی است. این نتایج بیانگر پایداری مدل در اکثر زیرمجموعه‌های آموزشی است.

از نشت اطلاعات آینده به گذشته جلوگیری کرد. برای ارزیابی عملکرد مدل، سه معیار اصلی به کار رفت: (۱) ریشه میانگین مربعات خطا برای سنجش میزان انحراف پیش‌بینی‌ها از مقادیر واقعی، (۲) ضریب تعیین برای ارزیابی توانایی مدل در توضیح واریانس داده‌ها، و (۳) شاخص کلینگ-گوپتا برای بررسی جامع همبستگی، بایاس و تغییرپذیری پیش‌بینی‌ها. در فاز آموزش، RMSE بین ۶۹،۰۵ تا ۲۰۱،۵۲، R^2 بین ۰،۱۲- (فولد اول) به دلیل ناهنجاری داده) تا ۰،۸۵، و KGE بین ۰،۱۴ تا ۰،۸۳ متغیر بود. در فاز آزمون، میانگین RMSE برابر ۸۹،۴۶، R^2 برابر ۰،۷۷ و KGE برابر ۰،۷۸ بود، که نزدیکی این مقادیر به فاز آموزش، نشان‌دهنده تعمیم‌پذیری بالای مدل است. در فاز اعتبارسنجی، مقادیر $RMSE=88.4$ ، $R^2=0.76$ و $KGE=0.79$ تأییدکننده پایداری مدل بودند. برای اطمینان از استحکام نتایج، داده‌های پرت در فولد اول بررسی شدند و نمودارهای پراکنندگی مقادیر واقعی در برابر پیش‌بینی‌شده، تمرکز نقاط حول خط رگرسیون را نشان دادند که دقت مدل را در محدوده‌های میانی داده‌ها تأیید کرد، اگرچه پراکنندگی در مقادیر

جدول ۲. مقادیر آماره‌های خطا در روند آموزش و تست داده‌ها

شماره فولد	RMSE	R^2	KGE	فاز
1	201.5221	-0.12793	0.146186	آموزش
2	79.5149	0.755452	0.821208	آموزش
3	69.05539	0.678339	0.673445	آموزش
4	81.0246	0.781767	0.824663	آموزش
5	95.02714	0.846256	0.834104	آموزش
	89.46823	0.777325	0.781628	آزمون


۴- بحث

در فولد اول ($RMSE: 201/52$ ، $R^2: -0/12$ ، $KGE: 0/14$) ممکن است به دلیل وجود داده‌های غیرعادی یا نویز در این زیرمجموعه باشد. این ناهنجاری می‌تواند ناشی از توزیع متفاوت داده‌ها یا عدم توانایی مدل در یادگیری الگوهای خاص این فولد باشد. با این حال، پایداری معیارها در سایر فولدها و فاز آزمون نشان می‌دهد که این مشکل احتمالاً به داده‌های خاص فولد اول محدود است و تأثیر کلی بر اعتبار مدل ندارد. برای تأیید این فرضیه، بررسی دقیق‌تر داده‌های فولد اول توصیه می‌شود. در مجموع، نتایج اعتبارسنجی متقاطع K-تایی نشان‌دهنده قابلیت اعتماد و تعمیم‌پذیری بالای مدل پیشنهادی است. نزدیکی

در فاز آزمون، میانگین RMSE برابر با ۸۹/۴۶ بود که در محدوده مقادیر خوب فولدهای آموزشی قرار دارد. مقدار R^2 در فاز آزمون ۰/۷۷ و KGE برابر ۰/۷۸ نیز بسیار نزدیک به میانگین مقادیر فولدهای آموزشی بودند. این نزدیکی بین معیارهای فاز آزمون و آموزش نشان‌دهنده تعمیم‌پذیری بالای مدل و عدم بیش‌برازش است، زیرا مدل توانسته است عملکرد مشابهی را روی داده‌های دیده‌نشده ارائه دهد. استفاده از معیارهای چندگانه کنترل آماره‌های خطا ارزیابی جامعی از توانایی مدل در پیش‌بینی، توضیح واریانس و حفظ تعادل بین همبستگی، واریانس و بایاس فراهم کرده است. عملکرد ضعیف

نیاز به بررسی بیشتر دارد، اما پایداری مدل در سایر فولدها و فاز آزمون، همراه با استفاده از روش استاندارد کیفی، اعتبار نتایج را تأیید می‌کند.

معیارهای فاز آزمون به میانگین معیارهای فاز آموزش، همراه با مقادیر بالای R^2 و KGE، نشان‌دهنده عملکرد قوی مدل در پیش‌بینی داده‌های جدید است. اگرچه ناهنجاری در فولد اول



شکل ۴. مقایسه مقادیر واقعی و پیش‌بینی شده در مرحله تست مدل


(رنگ‌های سبز و آبی) این موضوع را تأیید می‌کند. با این حال، در نواحی انتهایی گراف، به‌ویژه در مقادیر بالای محور افقی (نزدیک به ۱۰۰۰ تا ۱۵۰۰) و مقادیر بالای محور عمودی (نزدیک به ۷۵۰ تا ۱۰۰۰)، پراکندگی بیشتری مشاهده می‌شود که با رنگ‌های زرد و بنفش نشان داده شده است. این پراکندگی می‌تواند ناشی از وجود داده‌های پرت یا محدودیت مدل در تعمیم‌پذیری به مقادیر افراطی باشد، که نیاز به بررسی بیشتر در مطالعات آتی دارد اما در کل مقادیر خطا با عنایت به بررسی آماره‌های خطا مورد تأیید می‌باشد. نزدیکی نسبی نقاط به خط رگرسیون در محدوده میانی نشان‌دهنده دقت بالای مدل در پیش‌بینی مقادیر متداول است.

از منظر آماری، انحرافات مشاهده شده در گوشه‌های گراف (مانند نقاطی که در محور Y به ۷۵۰ می‌رسند اما در محور X

شکل ۴ یا نمودار پراکندگی ارائه شده نتایج روی هم گذاری در مرحله تست مدل آموزش عمیق را با مقایسه مقادیر پیش‌بینی شده توسط مدل (محور عمودی، در بازه ۰ تا ۱۰۰۰ واحد) و مقادیر واقعی (محور افقی، در بازه ۰ تا ۱۵۰۰ واحد) به نمایش می‌گذارد. خط رگرسیون سیاه‌رنگ که از مبدأ شروع شده و با زاویه‌ای نزدیک به ۴۵ درجه امتداد دارد، نمایانگر یک رابطه خطی مثبت بین این دو متغیر است. تراکم داده‌ها با یک گرادینان رنگی از بنفش تیره تا زرد نشان داده شده است، که تمرکز اصلی داده‌ها را در محدوده میانی مقادیر (بین ۲۵۰ تا ۷۵۰ در هر دو محور) برجسته می‌کند. این الگو نشان‌دهنده عملکرد کلی مناسب مدل در پیش‌بینی مقادیر در این محدوده است. این تصویر نشان می‌دهد که نقاط داده به‌طور قابل‌توجهی حول خط رگرسیون متمرکز هستند، به‌ویژه در محدوده میانی، که تراکم بالای نقاط

در محدوده میانی، که تراکم بالای نقاط (رنگ‌های سبز و آبی) این موضوع را تأیید می‌کند. با این حال، در گوشه‌های گراف، به‌ویژه در مقادیر پایین نزدیک به ۰ و مقادیر بالا نزدیک به ۶۰۰ در محور Y و ۹۰۰ در محور X ، پراکندگی بیشتری مشاهده می‌شود که با رنگ‌های بنفش و زرد نشان داده شده است. این پراکندگی می‌تواند ناشی از محدودیت‌های مدل در پیش‌بینی مقادیر افراطی باشد. خط رگرسیون، که به‌عنوان مرجع عملکرد عمل می‌کند، نشان می‌دهد که مدل به‌طور کلی توانسته رابطه‌ای مثبت و معنادار بین مقادیر واقعی و پیش‌بینی شده برقرار کند. نمی‌برد و تعمیم‌پذیری قابل قبولی دارد. تراکم بالای داده‌ها در محدوده میانی همچنین نشان می‌دهد که مدل احتمالاً روی داده‌های آموزشی با توزیع مشابه بهینه‌سازی شده است، که عملکرد آن را در این ناحیه تقویت کرده است. در مجموع، نتایج مرحله تست این مدل آموزش عمیق نشان‌دهنده توانایی قابل توجه آن در پیش‌بینی مقادیر واقعی است، به‌ویژه در محدوده‌های میانی داده‌ها.

کمتر از ۷۵۰ هستند) پیشنهاد می‌دهد که مدل ممکن است در برخی موارد مقادیر واقعی را بیش‌ازحد یا کمتر‌ازحد پیش‌بینی کند. با این حال، توزیع یکنواخت نقاط حول خط رگرسیون و عدم وجود الگوی آشکار از پراکندگی بیش‌ازحد، حاکی از آن است که مدل در مرحله تست به‌طور کلی از بیش‌برازش رنج تصویر ۵ یا نمودار پراکندگی فوق رابطه بین دو متغیر مقدار واقعی در مرحله اعتبارسنجی محور افقی که در بازه ۰ تا ۹۰۰ واحد و مقدار پیش‌بینی شده محور عمودی که در بازه ۰ تا ۶۰۰ واحد متغیر است. این نمودار شامل یک خط رگرسیون سیاه‌رنگ است که از مبدأ شروع شده و با زاویه‌ای ۴۵ درجه امتداد دارد، نمایانگر یک رابطه خطی مثبت بین این دو متغیر می‌باشد. تراکم داده‌ها با یک گردایان رنگی از بنفش تیره (نمایش‌دهنده تراکم کم) تا زرد (نمایش‌دهنده تراکم بالا) نشان داده شده است، که تمرکز اصلی داده‌ها را در محدوده میانی مقادیر بین ۱۰۰ تا ۴۰۰ در هر دو محور آشکار می‌کند. بررسی دقیق‌تر نشان می‌دهد که نقاط داده حول خط رگرسیون به‌خوبی متمرکز هستند، به‌ویژه



شکل ۱. مقایسه مقادیر واقعی و پیش‌بینی شده در مرحله اعتبارسنجی مدل

کند. تراکم بالای داده‌ها در محدوده میانی پیشنهاد می‌کند که مدل احتمالاً روی داده‌های آموزشی با توزیع متمرکز در این محدوده بهینه‌سازی شده است. این الگو می‌تواند نشان‌دهنده موفقیت مدل در پیش‌بینی مقادیر متوسط و چالش آن در مدیریت مقادیر خارج از محدوده نرمال باشد. همچنین به نظر نمی‌رسد دچار

از نظر آماری، نزدیکی نسبی نقاط به خط رگرسیون حاکی از دقت قابل قبول مدل است، اما انحرافات در گوشه‌های گراف (مانند نقاطی که در محور Y به ۶۰۰ می‌رسند اما در محور X کمتر از ۶۰۰ هستند) نشان‌دهنده این است که مدل ممکن است در برخی موارد مقادیر واقعی را بیش‌ازحد یا کم‌تر از حد پیش‌بینی

با تکنیک‌هایی مانند وزن‌دهی متفاوت مدیریت کرد و اثرات آنرا بر مدل نهایی مطالعه کرد. در مرحله اعتبارسنجی مدل عملکرد R^2 ، RMSE و KGE به ترتیب ۰/۸۸، ۰/۷۶ و ۰/۷۹ از خود نشان داد که تایید کننده عملکرد مدل می‌باشد.

بیش‌برازش شده باشد، زیرا پراکندگی نقاط به‌طور یکنواخت حول خط رگرسیون توزیع شده است. با این حال، برای بهبود دقت، پیشنهاد می‌شود داده‌های پرت در گوشه‌های گراف شناسایی و تحلیل شوند؛ در صورت نیاز، می‌توان آن‌ها را در مطالعات آتی بار روشهای حذف نویز حذف کرد یا

۵- نتیجه گیری

وسایل نقلیه، سرعت متوسط و تخلفات فاصله غیرمجاز، الگوهای محلی و وابستگی‌های زمانی را با دقت بالا شناسایی می‌کند. برخلاف مطالعات پیشین که عمدتاً بر پیش‌بینی تصادفات یا تخلفات در مقیاس‌های زمانی بزرگ‌تر تمرکز داشتند، این پژوهش با بهره‌گیری از تنظیم‌کننده L2، لایه Dropout و اعتبارسنجی متقاطع پنج‌بخشی (K-Fold) در داده‌های سری زمانی، بیش‌برازش را به حداقل رسانده و تعمیم‌پذیری مدل را تقویت کرده است. این معماری با کاهش تدریجی فیلترها در لایه‌های CNN (از ۳۲ به ۱۶) و استفاده از دو لایه LSTM با واحدهای متفاوت (۳۲ و ۱۶)، امکان استخراج ویژگی‌های چندمرحله‌ای را فراهم می‌کند که در مقایسه با مدل‌های سنتی مانند MLP یا روش‌های تک‌لایه‌ای، دقت و پایداری بیشتری ارائه می‌دهد. همچنین، کاربرد این مدل در بستر پردازش ابری گوگل کولب با پردازنده T4، امکان پردازش سریع و مقیاس‌پذیر داده‌های ترافیکی را فراهم کرده و قابلیت استفاده عملی آن را برای مدیریت ایمنی جاده‌ای در آزادراه‌های پرتردد ارتقا داده است. در نهایت، این پژوهش با ارائه یک معماری ترکیبی نوآورانه و کاربردی، گامی مهم در جهت کاهش حوادث جاده‌ای و بهبود ایمنی آزادراه‌ها برداشته است. پیشنهاد می‌شود در تحقیقات آتی، ادغام داده‌های محیطی مانند شرایط جوی و وضعیت جاده به‌عنوان متغیرهای ورودی، همراه با بهینه‌سازی‌های بیشتر در معماری مدل، دقت پیش‌بینی را افزایش دهد. نتایج این مطالعه می‌تواند به‌عنوان مبنایی برای توسعه سیستم‌های هوشمند نظارت ترافیکی و تخصیص بهینه منابع توسط اداره راه‌داری و پلیس راهور مورد استفاده قرار گیرد، که در نهایت به کاهش خسارات جانی و اقتصادی در آزادراه‌های پرتردد منجر خواهد شد.

نتایج این مطالعه نشان داد که معماری نوین ترکیبی مبتنی بر CNN و LSTM می‌تواند به‌طور مؤثری تعداد تخلفات سرعت غیرمجاز را در داده‌های ترافیکی ساعتی آزادراه زنجان-قزوین پیش‌بینی کند. با استفاده از روش‌های پیشرفته پیش‌پردازش و اعتبارسنجی متقاطع K-Fold، مدل پیشنهادی توانست تعمیم‌پذیری قابل‌قبولی را در فازهای آموزش، آزمون و اعتبارسنجی به نمایش بگذارد، که با مقادیر معیارهای خطا مانند RMSE با میانگین ۰/۸۹/۴ در آزمون، R^2 با میانگین ۰/۷۷ در آزمون و KGE با میانگین ۰/۷۸ در آزمون تأیید شد. تمرکز مدل بر الگوهای محلی و وابستگی‌های زمانی، همراه با کاهش بیش‌برازش از طریق تنظیم‌کننده L2 و لایه Dropout، این معماری را به ابزاری قدرتمند برای بهینه‌سازی نظارت و افزایش ایمنی جاده‌ای تبدیل کرده است، که پتانسیل بالایی برای کاربرد عملی در مدیریت ترافیک دارد. پراکندگی بیشتری مواجهه است که ممکن است به دلیل وجود داده‌های پرت یا محدودیت‌های مدل در تعمیم‌پذیری به مقادیر افراطی باشد. این یافته‌ها با نتایج مطالعات پیشین مانند (Li et al., 2020) و یا (Karamvand et al., 2024) هم‌راستا است که بر اهمیت ترکیب ویژگی‌های فضایی و زمانی در مدل‌های پیش‌بینی تأکید دارند. با این حال، ناهنجاری مشاهده‌شده در فولد اول آموزش نشان‌دهنده نیاز به بررسی دقیق‌تر داده‌های ورودی و احتمالاً اعمال تکنیک‌های حذف نویز یا وزن‌دهی در مطالعات آینده است تا دقت مدل در پیش‌بینی مقادیر خارج از محدوده نرمال بهبود یابد. نوآوری تحقیق حاضر در توسعه یک معماری هیبریدی نوین مبتنی بر ترکیب شبکه‌های کانولوشنی و حافظه طولانی‌مدت کوتاه‌مدت است که به‌طور خاص برای پیش‌بینی ساعتی تخلفات سرعت غیرمجاز در آزادراه زنجان-قزوین طراحی شده و با استفاده از داده‌های ترافیکی ساعتی شامل تعداد

۶- مراجع

- Transportation Engineering (English Edition)*, 7(4), 432–446. doi: 10.1016/j.jtte.2020.05.002
- Hemanth Kumar, C., & SMT.A.Kalpana. (2025). The Hierarchical Network-Based Method for Predicting Driver Traffic Violations. *Journal of Engineering Sciences*, 16(04), 170–173.
doi: 10.36893/jes.2025.v16i04.028
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
doi: 10.1162/neco.1997.9.8.1735
- Karamvand, A., Hosseini, S. A., & Aziz, S. A. (2024). Enhancing Streamflow Simulations with Gated Recurrent Units Deep Learning Models in the Flood Prone Region with Low-Convergence Streamflow -Data. *Physics and Chemistry of the Earth, Parts A/B/C*, 103737.
doi: 10.1016/j.pce.2024.103737
- Li, P., Abdel-Aty, M., & Yuan, J. (2020). Real-time crash risk prediction on arterials based on LSTM-CNN. *Accident Analysis and Prevention*, 135, 105371.
doi: 10.1016/j.aap.2019.105371
- Rasa-Ezadi, A., & Seyed-Abreshami, S. E. (2022). Traffic state prediction with machine learning algorithms for short-term and mid-term prediction time horizons. *Amirkabir Journal of Civil Engineering*, 54(4), 1503–1520.
doi: 10.22060/ceej.2021.19650.7219
- Wang, X., Liu, J., Qiu, T., Mu, C., Chen, C., & Zhou, P. (2020). A Real-Time Collision Prediction Mechanism With Deep Learning for Intelligent Transportation System. *IEEE Transactions on Vehicular Technology*, 69(9), 9497–9508.
doi: 10.1109/TVT.2020.3003933
- Wegayehu, E. B., & Muluneh, F. B. (2022). Short-Term Daily Univariate Streamflow Forecasting Using Deep Learning Models. *Advances in Meteorology*, 2022.
doi: 10.1155/2022/1860460
- Alomari, A. H., Al-Mistarehi, B. W., Alnaasan, T. K., & Obeidat, M. S. (2023). Utilizing Different Machine Learning Techniques to Examine Speeding Violations. *Applied Sciences*, 13(8), 5113.
doi: 10.3390/app13085113
- Aloysius, N., & Geetha, M. (2017). A review on deep convolutional neural networks. *2017 International Conference on Communication and Signal Processing (ICCSP)*, 0588–0592.
doi: 10.1109/ICCSP.2017.8286426
- Bhattacharya, S., & Raman, R. (2023). Speed Violation Detection and Enforcement with CNN and IoT Integration. *2023 3rd International Conference on Smart Generation Computing, Communication and Networking, SMART GENCON 2023*, 1–5.
doi:10.1109/SMARTGENCON60755.2023.10441950
- Cai, Q., Abdel-Aty, M., Yuan, J., Lee, J., & Wu, Y. (2020). Real-time crash prediction on expressways using deep generative models. *Transportation Research Part C: Emerging Technologies*, 117, 102697.
doi: 10.1016/j.trc.2020.102697
- Cypto, J., & Karthikeyan, P. (2022). Automatic detection system of speed violations in a traffic based on deep learning technique. *Journal of Intelligent & Fuzzy Systems*, 43(5), 6591–6606.
doi: 10.3233/JIFS-220577
- Dai, F., Huang, P., Xu, X., Qi, L., & Khosravi, M. R. (2020). Spatio-temporal deep learning framework for traffic speed forecasting in IoT. *IEEE Internet of Things Magazine*, 3(4), 66–69.
doi: 10.1109/IOTM.0001.2000031
- Deng, L. (2018). Artificial Intelligence in the Rising Wave of Deep Learning: The Historical Path and Future Outlook [Perspectives]. *IEEE Signal Processing Magazine*, 35(1), 180–177.
doi: 10.1109/MSP.2017.2762725
- Gutierrez-Osorio, C., & Pedraza, C. (2020). Modern data sources and techniques for analysis and forecast of road accidents: A review. *Journal of Traffic and*

Application of a Novel Hybrid Deep Learning CNN-LSTM Model for Predicting the Number of Speeding Violations Using Hourly Traffic Data

Aliakbar Karamvand, Ph.D., Grad., Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.

E-mail: Ali.karamvand@gmail.com

Received: February 2026- Accepted: May 2026

ABSTRACT

Background: Speeding violations are a primary cause of accidents on highways, leading to significant human, economic, and social consequences. While numerous studies have explored the prediction of traffic violations and accidents, few have focused on hourly violation counts using hybrid deep learning architectures. **Methods:** This study introduces a novel hybrid deep learning model combining Convolutional Neural Networks (CNN) and Long Short-Term Memory (LSTM) networks to predict the hourly number of speeding violations. The model was developed using hourly traffic data, including variables such as vehicle count, average speed, distance violations, and violation occurrence times. Following preprocessing, the dataset was divided into 70% training, 15% validation, and 15% testing sets. A 5-fold cross-validation approach was employed to assess model performance. **Results:** The cross-validation results demonstrated satisfactory performance in predicting speeding violations. During training, RMSE values ranged from 69.05 to 201.5, with the first fold showing anomalous performance; the remaining folds exhibited better results, with R^2 values between 0.68 and 0.85 and KGE values between 0.67 and 0.83. In the testing phase, average RMSE, R^2 , and KGE were 89.4, 0.77, and 0.78, respectively, closely aligning with training phase averages, indicating robust model performance. In the validation phase, the model achieved an RMSE of 88.4, R^2 of 0.76, and KGE of 0.79. **Conclusion:** The proposed hybrid deep learning model effectively identifies high-risk locations for speeding violations with improved accuracy and speed, facilitating optimized resource allocation and enhanced road safety. Future studies are recommended to integrate weather condition data to further improve prediction accuracy.

Keywords: Deep Learning, Prediction, Speeding Violations, Convolutional Neural Network, Traffic Violations