

ارزیابی و اولویت‌بندی روش‌های پیش‌بینی نقاط تصادف‌خیز راه‌های بین‌شهری با رویکرد AHP-TOPSIS

مقاله علمی - پژوهشی

شاهین شعبانی، گروه مهندسی عمران، دانشگاه پیام نور، تهران، ایران

علی قربانی، گروه مهندسی عمران، دانشگاه پیام نور، تهران، ایران

*پیمان پژمان‌زاد (نویسنده مسئول)، دانشجوی دکتری، گروه مهندسی عمران، دانشگاه پیام نور، تهران، ایران

*پست الکترونیکی نویسنده مسئول: p.pejmanzad@bhrc.ac.ir

دریافت: ۱۴۰۴/۰۱/۰۸ - پذیرش: ۱۴۰۵/۰۳/۰۲

صفحه ۵۷۸-۵۶۵

چکیده

تصادفات جاده‌ای در ایران سالانه بیش از ۲۰ هزار کشته و ۷ درصد تولید ناخالص داخلی را به خود اختصاص می‌دهند. شناسایی نقاط تصادف‌خیز (مکان‌های دارای پتانسیل بالای وقوع تصادف) یکی از مؤثرترین راهکارهای کاهش خسارات است. روش‌های متنوعی از سه دسته آماری سنتی، یادگیری ماشین و یادگیری عمیق برای پیش‌بینی این نقاط ارائه شده‌اند، اما فقدان مقایسه‌ی نظام‌مند، انتخاب روش مناسب برای راه‌های ایران را دشوار ساخته است. روش‌شناسی: ۱۵ روش پیش‌بینی شامل ۳ روش آماری (فراوانی، نرخ تصادف، بیز تجربی)، ۴ روش یادگیری ماشین (جنگل تصادفی، ماشین بردار پشتیبان، *XGBoost*، درخت تصمیم (و ۸ روش یادگیری عمیق *CNN*)، *STGNN*، *GAT*، *GCN*، *CNN-LSTM*، *LSTM*، *Transformer*، *Ensemble*) در ۷ معیار (دقت، حساسیت، سرعت، حجم داده، تفسیرپذیری، تعمیم‌پذیری، نیاز به تخصص فنی) ارزیابی شدند. داده‌ها از مرور سیستماتیک ۹۰ مقاله (۲۰۱۹-۲۰۲۵) استخراج گردید. وزن‌دهی با *AHP* و رتبه‌بندی با *TOPSIS* انجام شد. یافته‌ها *CNN-LSTM*: ترکیبی با امتیاز ۰.۸۵۲ بالاترین رتبه را کسب کرد *XGBoost* با ۰.۷۹۵، بهترین روش یادگیری ماشین بود. روش‌های آماری با میانگین ۰.۲۷۵ در رتبه‌ی آخر قرار گرفتند. میانگین امتیاز یادگیری عمیق (۰.۶۵۲)، یادگیری ماشین (۰.۶۳۴) و آماری (۰.۲۷۵) است. تحلیل حساسیت پایداری نتایج را تأیید کرد. نتیجه‌گیری: روش *CNN-LSTM* ترکیبی به عنوان روش برتر در پیش‌بینی نقاط تصادف‌خیز راه‌های بین‌شهری ایران انتخاب شد. در شرایط داده‌ی بسیار محدود (کمتر از ۳۰۰۰ رکورد)، روش بیز تجربی و در شرایط نیاز به تفسیرپذیری بالا، روش درخت تصمیم پیشنهاد می‌گردد.

واژه‌های کلیدی: نقاط تصادف‌خیز، یادگیری عمیق، یادگیری ماشین، روش‌های آماری، *AHP-TOPSIS*، راه‌های بین‌شهری ایران


۱-مقدمه

پژوهش‌های مجلس شورای اسلامی (۱۴۰۳)، حدود ۷ درصد از تولید ناخالص داخلی کشور صرف خسارات ناشی از تصادفات می‌شود. نمودار ۱ روند افزایشی تلفات تصادفات در ایران را در سال‌های اخیر نشان می‌دهد. همانطور که در نمودار واضح است به استثنای سال ۱۳۹۹ که تحت تأثیر همه‌گیری کرونا و کاهش تردها قرار داشت، روند تلفات افزایشی بوده است. این افزایش در سال‌های ۱۴۰۰ و ۱۴۰۱ به ترتیب با ۱۹.۴٪ و ۷.۸٪ رشد همراه بوده است.

تصادفات جاده‌ای یکی از مهم‌ترین معضلات حمل‌ونقل در سراسر جهان هستند. بر اساس آخرین گزارش سازمان بهداشت جهانی (WHO, 2023)، سالانه حدود ۱.۱۹ میلیون نفر در اثر تصادفات جاده‌ای جان خود را از دست می‌دهند. این میزان تلفات، فشار اقتصادی سنگینی را بر کشورها تحمیل می‌کند به طوری که خسارات ناشی از تصادفات در برخی کشورها تا ۳ درصد تولید ناخالص داخلی را شامل می‌شود. در ایران، وضعیت نگران‌کننده‌تر است. آمار تلفات تصادفات در سال ۱۴۰۲ به بیش از ۲۰ هزار نفر رسیده و بر اساس گزارش مرکز

در سال‌های اخیر، روش‌های متنوعی از سه دسته اصلی آماری سستی، یادگیری ماشین و یادگیری عمیق برای پیش‌بینی نقاط تصادف خیز ارائه شده‌اند. با این حال، عدم وجود یک مقایسه جامع و نظام‌مند میان این روش‌ها، انتخاب روش مناسب برای راه‌های ایران را دشوار ساخته است. همچنین، فقدان یک رتبه‌بندی کمی و عینی از روش‌ها بر اساس معیارهای چندگانه (نه فقط دقت) یک شکاف تحقیقاتی مهم است. این مطالعه در صدد است تا با مقایسه همزمان ۱۵ روش از هر سه دسته، این شکاف را پر کند.

یکی از راهکارهای کلیدی و اثبات شده برای کاهش تصادفات، شناسایی و رفع نقاط تصادف خیز است. نقاط تصادف خیز به مکان‌هایی در شبکه جاده‌ای اطلاق می‌شوند که میزان وقوع تصادفات در آن‌ها به طور معناداری بیشتر از میانگین سایر نقاط مشابه است. (Elvik, 2008) بر اساس گزارش کمیسیون ایمنی راه‌های ایران، ۴۴ درصد از کل تصادفات کشور در ۵،۲۰۰ نقطه تصادف خیز رخ می‌دهد. این آمار نشان می‌دهد که با شناسایی دقیق و اصلاح تعداد محدودی از نقاط، می‌توان سهم قابل توجهی از تصادفات را کاهش داد.



نمودار ۱. روند تلفات ناشی از تصادفات در ایران طی سالهای ۱۳۹۴-۱۴۰۳ (سازمان پزشکی قانونی)

۲-پیشینه تحقیق

قوت این مطالعه، استفاده از رویکرد چندمعیاره بود، اما محدودیت اصلی آن تمرکز صرف بر روش‌های آماری و عدم بهره‌گیری از توانمندی‌های یادگیری ماشین بود. غفاری (۱۴۰۳) در مقاله‌ای با عنوان «بررسی تأثیر عوامل هندسی بر شدت تصادفات در راه‌های برون‌شهری با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری عمیق» به تحلیل میزان تأثیر بهبود عوامل هندسی بر کاهش شدت تصادفات پرداخت. ایشان با استفاده از الگوریتم‌های هوش مصنوعی و شبکه‌های عصبی عمیق، تأثیر عواملی مانند شعاع قوس، شیب، عرض راه و وجود روشنایی را بر شدت تصادفات مورد بررسی قرار دادند. تفاوت اساسی این مطالعه با تحقیق حاضر در این است که تمرکز بر پیش‌بینی شدت تصادف بود، نه پیش‌بینی مکان‌های مستعد تصادف. کفاش چرندابی و همکاران (۲۰۲۲) در مطالعه‌ای با عنوان «پیش‌بینی ریسک تصادفات جاده‌ای با استفاده از شبکه عصبی رگرسیون تعمیم‌یافته بهینه‌شده با نقشه خودسازمانده» از مدل ترکیبی GRNN-SOM استفاده کردند. این مطالعه روی داده‌های بومی ایران انجام شده و توانست دقت قابل قبولی در

در سال‌های اخیر، پژوهش‌های متعددی در داخل ایران با هدف شناسایی و تحلیل نقاط تصادف خیز انجام شده است. احسانی و آسوده (۱۳۹۹) در مطالعه‌ای با عنوان «شناسایی نقاط حادثه خیز راه‌های برون‌شهری با استفاده از روش مدل سازی فازی» به بررسی محور قزوین-لوشان پرداختند. آن‌ها با استفاده از روش فازی و توابع عضویت، موفق به شناسایی ۱۲ نقطه حادثه خیز در این محور شدند. مهم‌ترین عوامل مؤثر شامل پیچ‌های تند، شیب زیاد و عدم وجود روشنایی کافی در شب بود. نقطه قوت این مطالعه، استفاده از روش فازی برای مدل‌سازی عدم قطعیت بود، اما محدودیت اصلی آن عدم استفاده از روش‌های نوین هوش مصنوعی و محدود بودن به یک محور خاص بود. سادات حسینی و همکاران (۱۴۰۳) در مطالعه‌ای با عنوان «شناسایی و تحلیل نقاط حادثه خیز شهر همدان» از روش‌های آماری سستی شامل تحلیل فراوانی تصادفات، نرخ تصادف و شاخص همسنگ استفاده کردند. در این مطالعه، معابر شهر همدان قطعه‌بندی شده و بر اساس سه شاخص مذکور، قطعات حادثه خیز شناسایی و رتبه‌بندی گردیدند. نقطه

پیش‌بینی ریسک تصادف ارائه دهد. نقطه قوت این مطالعه، استفاده از یک معماری ترکیبی و کار روی داده‌های واقعی ایران بود، اما محدودیت اصلی آن عدم تعمیم‌پذیری نتایج به سایر مناطق و همچنین عدم مقایسه روش پیشنهادی با سایر روش‌های یادگیری ماشین بود. نقطه مشترک همه این مطالعات داخلی، عدم مقایسه همزمان روش‌های مختلف از سه دسته و عدم ارائه یک روش بهینه برای کل کشور است. پژوهش‌های بین‌المللی در زمینه پیش‌بینی تصادفات و تحلیل ایمنی راه‌ها را می‌توان به سه نسل متوالی تقسیم کرد.

نسل اول: روش‌های آماری سنتی

نخستین گام‌ها در تحلیل ایمنی راه‌ها با روش‌های آماری سنتی برداشته شد. در این میان، مدل‌های رگرسیونی پواسون و نگاتیو باینوم (Negative Binomial) به دلیل ماهیت شمارشی داده‌های تصادف، بیشترین کاربرد را داشته‌اند. لرد و منرینگ (Lord & Mannering, 2010) در مروری جامع بر روش‌های آماری تحلیل تصادف، نشان دادند که مدل نگاتیو باینوم به دلیل قابلیت در نظر گرفتن «پراکندگی بیش از حد» (Overdispersion) در داده‌های تصادف، عملکرد بهتری نسبت به مدل پواسون دارد. با این حال، محدودیت اصلی این روش‌ها، ناتوانی در مدل‌سازی روابط غیرخطی و وابستگی‌های پیچیده میان متغیرها است.

در میان روش‌های آماری پیشرفته، شبکه‌های بیزین (Bayesian Networks) به دلیل توانایی منحصر به فرد در مدل‌سازی روابط علی و احتمالی، توجه ویژه‌ای را به خود جلب کرده‌اند. بر خلاف روش‌های رگرسیونی سنتی که روابط خطی و یک‌طرفه را فرض می‌کنند، شبکه بیزین قادر است وابستگی‌های چندجهته و غیرخطی بین متغیرها را به صورت یک گراف جهت‌دار نمایش دهد.

این ویژگی به ویژه در تحلیل تصادفات که عوامل متعددی به صورت زنجیره‌وار و تعاملی بر یکدیگر تأثیر می‌گذارند، بسیار ارزشمند است. در مطالعه‌ای بر روی داده‌های تله‌ماتیک (دورسنجی) جمع‌آوری‌شده از ۱,۶۷۳ دستگاه اتوبوس بین شهری در سراسر ایران در سال ۲۰۲۰، گلستانی و همکاران (Shabaniet al., 2025) به پیش‌بینی خطاهای رانندگی در نقاط تصادف خیز با استفاده از رویکرد یادگیری ماشین تفسیرپذیر پرداختند.

در این پژوهش، عملکرد شش الگوریتم مختلف شامل رگرسیون لجستیک، کی-نزدیک‌ترین همسایه (KNN)، جنگل تصادفی (RF)، XGBoost، ماشین بردار پشتیبان (SVM) و نایو بیز (Naïve Bayes) بر روی ۶۱۹,۹۸۸ رکورد داده‌ای مقایسه شد. نتایج نشان داد که مدل XGBoost با سطح زیر منحنی (AUC) معادل ۹۱,۷۰٪ بهترین عملکرد را داشته است. تحلیل اهمیت ویژگی‌ها با استفاده از روش SHAP نیز مشخص کرد که عوامل مکانی (به ویژه استان و نوع راه)، بیشترین نقش را در پیش‌بینی نقاط حادثه خیز در ایران ایفا می‌کنند. همچنین عواملی مانند خستگی راننده و برخی متغیرهای اقلیمی (نقطه شبنم و رطوبت نسبی) نیز به عنوان سایر عوامل مؤثر شناسایی شدند. در حوزه تصادفات جاده‌ای، پان و همکاران (Pan et al., 2018) با ارائه مدل «شبکه باور عمیق منظم‌شده (Regularized Deep Belief Network)» نشان دادند که ترکیب روش‌های بیزی با یادگیری عمیق می‌تواند دقت پیش‌بینی را به طور قابل توجهی افزایش دهد. این مطالعه نشان می‌دهد که رویکردهای ترکیبی «بیزین-یادگیری عمیق» می‌توانند زمینه‌ساز نسل جدیدی از مدل‌های پیش‌بینی تصادف باشند.

نسل دوم: روش‌های یادگیری ماشین کلاسیک

با گسترش داده‌های ترافیکی و افزایش توان محاسباتی، روش‌های یادگیری ماشین وارد عرصه پیش‌بینی تصادف شدند. چن و چن (Chang & Chen, 2005) در مطالعه‌ای پیشگام، روش‌های درخت تصمیم و ماشین بردار پشتیبان را با روش‌های آماری سنتی مقایسه کردند و نشان دادند که روش‌های یادگیری ماشین قادر به شناسایی الگوهای غیرخطی هستند که در روش‌های سنتی قابل تشخیص نیست. در سال‌های اخیر، روش XGBoost به دلیل دقت بالا و سرعت مناسب، توجه ویژه‌ای را به خود جلب کرده است.

نسل سوم: روش‌های یادگیری عمیق

در سال‌های اخیر، یادگیری عمیق به دلیل توانایی در استخراج خودکار ویژگی‌ها و مدل‌سازی روابط پیچیده مکانی-زمانی، به طور فزاینده‌ای مورد توجه قرار گرفته است. تئوفیلاتوس و همکاران (Theofilatos et al., 2019) در مطالعه‌ای مقایسه‌ای نشان دادند که روش‌های یادگیری عمیق

مرور مطالعات بین‌المللی نشان می‌دهد که علی‌رغم پیشرفت‌های قابل توجه از روش‌های آماری ساده تا شبکه‌های عصبی عمیق، هیچ یک از مطالعات پیشین، مقایسه همزمان و جامعی بین سه نسل روش‌های پیش‌بینی (آماري سنتي، يادگيري ماشين و يادگيري عميق) انجام نداده‌اند.

۲-۱- دسته‌بندی روش‌های پیش‌بینی نقاط تصادف خیز

بر این اساس می‌توان روش‌های پیش‌بینی نقاط تصادف خیز را به سه دسته کلی جدول زیر تقسیم کرد.

جدول ۱. سه دسته اصلی روش‌های پیش‌بینی نقاط تصادف خیز

دسته	مشخصه	نقاط قوت	نقاط ضعف	نمونه روش‌ها
آماري سنتي	مبتنی بر توزیع آماری و فرضیات پیشین	سادگی، تفسیرپذیری بالا، نیاز به داده کم	ناتوانی در الگوهای غیرخطی، دقت محدود	روش فراوانی، نرخ تصادف، بیز تجربی
یادگیری ماشين	داده‌محور، نیاز به مهندسی ویژگی دستی	دقت خوب، تفسیرپذیری متوسط	نیاز به داده نسبتاً زیاد، مهندسی ویژگی دستی	جنگل تصادفی، SVM، XGBoost، درخت تصمیم
یادگیری عمیق	داده‌محور، استخراج خودکار ویژگی	دقت بالا، توانایی یادگیری الگوهای پیچیده	نیاز به داده زیاد، تفسیرپذیری پایین	CNN، LSTM، GNN، Transformer

(به ویژه LSTM) دقت بالاتری نسبت به روش‌های یادگیری ماشین سنتی در پیش‌بینی بلادرنگ تصادف دارند. با این حال، نقطه ضعف اصلی این روش‌ها، نیاز به حجم بالای داده و قدرت پردازشی زیاد است. مطالعات جدیدتر به سمت معماری‌های ترکیبی مانند CNN-LSTM و شبکه‌های عصبی گراف (GNN) حرکت کرده‌اند. یانگ و عبدالعطی (Yang & Abdel-Aty, 2025) نشان دادند که معماری ترکیبی CNN-LSTM می‌تواند حدود ۱۲٪ بهبود دقت نسبت به مدل‌های ساده داشته باشد.

AHP-TOPSIS برای رتبه‌بندی عینی روش‌ها استفاده نکرده است. شکاف سوم - عدم ارائه روش بهینه متناسب با شرایط ایران: هیچ مطالعه جامعی که روش بهینه را برای راه‌های بین‌شهری ایران معرفی کند، وجود ندارد. شکاف چهارم - نبود تحلیل حساسیت: مطالعات پیشین عموماً به معرفی یک روش برتر اکتفا کرده‌اند و پایداری نتایج را بررسی نکرده‌اند. این مقاله در صدد است تا با مقایسه همزمان ۱۵ روش از سه نسل مختلف در ۷ معیار کلیدی، با استفاده از روش تصمیم‌گیری چندمعیاره AHP-TOPSIS و تحلیل حساسیت، ضمن ارائه یک رتبه‌بندی کمی و عینی، روش بهینه را برای پیش‌بینی نقاط تصادف خیز راه‌های بین‌شهری ایران معرفی کند.

همان‌گونه که مشاهده می‌شود، هر دسته دارای نقاط قوت و ضعف مشخصی است. روش‌های آماری سنتی ساده‌ترین و قابل‌فهم‌ترین هستند اما دقت محدودی دارند. یادگیری عمیق بالاترین دقت را ارائه می‌دهد اما به داده زیاد و تخصص فنی بالا نیاز دارد. یادگیری ماشین در میانه این طیف قرار می‌گیرد.

۲-۲- شکاف تحقیقاتی و جایگاه این مطالعه

مرور جامع مطالعات داخلی و خارجی نشان می‌دهد که شکاف‌های تحقیقاتی متعددی همچنان وجود دارد. شکاف اول - فقدان مقایسه همزمان سه نسل روش‌ها: هیچ مطالعه‌ای ۱۵ روش از هر سه نسل (آماري سنتي، يادگيري ماشين و يادگيري عميق) را به طور همزمان مقایسه نکرده است.

شکاف دوم - نبود رتبه‌بندی کمی و عینی: اکثر مطالعات پیشین، مقایسه روش‌ها را به صورت توصیفی و روایی انجام داده‌اند و هیچ مطالعه‌ای از روش‌های تصمیم‌گیری چندمعیاره مانند

۳-روش شناسی

در این بخش، گام‌های اصلی پژوهش برای ارزیابی، اولویت‌بندی و معرفی روش بهینه پیش‌بینی نقاط تصادف خیز تشریح می‌شود.

۳-۱-پرسش‌های پژوهشی

بر اساس شکاف‌های تحقیقاتی شناسایی شده در مرور ادبیات (بخش ۲-۳)، چهار پرسش پژوهشی اصلی تدوین شده است که این مطالعه در صدد پاسخگویی به آن‌ها برآمده است. پرسش اول (RQ1): کدام دسته از روش‌های پیش‌بینی شامل روش‌های آماری سنتی، یادگیری ماشین و یادگیری عمیق، عملکرد بهتری در پیش‌بینی نقاط تصادف خیز راه‌های بین‌شهری دارد؟ پاسخ به این پرسش به تصمیم‌گیران کمک می‌کند تا بدانند به طور کلی به کدام دسته از روش‌ها تمایل داشته باشند.

پرسش دوم (RQ2): رتبه‌بندی کمی ۱۵ روش مختلف پیش‌بینی (شامل روش‌های آماری سنتی، یادگیری ماشین و یادگیری

عمیق) بر اساس معیارهای چندگانه (دقت، حساسیت، سرعت، حجم داده، تفسیرپذیری، تعمیم‌پذیری و نیاز به تخصص فنی) چیست؟

پرسش سوم (RQ3): بهترین روش برای پیش‌بینی نقاط تصادف خیز راه‌های بین‌شهری ایران کدام است؟ پاسخ به این پرسش با توجه به شرایط خاص ایران (از جمله محدودیت نسبی داده‌ها، تنوع توپوگرافی و اقلیمی و نیاز به تعمیم‌پذیری مناسب) ارائه می‌شود.

پرسش چهارم (RQ4): در شرایط مختلف پروژه (مانند حجم داده محدود، نیاز به تفسیرپذیری بالا، محدودیت منابع محاسباتی و پیچیدگی ساختار جاده)، کدام روش توصیه می‌شود؟ پاسخ به این پرسش یک راهنمای عملی برای کاربران و سازمان‌های مختلف فراهم می‌کند تا بر اساس امکانات و محدودیت‌های خود، مناسب‌ترین روش را انتخاب کنند.

۳-۲- روش‌های مورد مقایسه (۱۵ روش)

بر اساس مرور سیستماتیک انجام‌شده، ۱۵ روش پیش‌بینی نقاط تصادف خیز از سه دسته اصلی برای مقایسه انتخاب شده‌اند. جدول ۲ این روش‌ها را نشان می‌دهد.

جدول ۲. روش‌های مورد مقایسه در این مطالعه

کد	نام فارسی	اختصار	دسته	مرجع اصلی
S1	روش فراوانی تصادف	CF	آماري	Hauer, 1996
S2	روش نرخ تصادف	CR	آماري	AASHTO, 2010
S3	روش بیز تجربی	EB	آماري	Hauer, 1997
M1	جنگل تصادفی	RF	ماشین	Rana et al., 2024
M2	ماشین بردار پشتیبان	SVM	ماشین	Chaudhary et al., 2023
M3	XGBoost	XGB	ماشین	Golestani et al., 2025
M4	درخت تصمیم	DT	ماشین	Alagarsamy et al., 2021
D1	CNN	CNN	عمیق	Wan et al., 2023
D2	LSTM	LSTM	عمیق	Yuan et al., 2019
D3	CNN-LSTM	CNN-LSTM	عمیق	Yang & Abdel-Aty, 2025
D4	GCN	GCN	عمیق	Yu et al., 2021
D5	GAT	GAT	عمیق	Gao et al., 2023
D6	STGNN	STGNN	عمیق	Nippani et al., 2023
D7	Transformer	TF	عمیق	Anik et al., 2023
D8	Ensemble	ENS	عمیق	Sajadi et al., 2024

می‌باشند. روش‌های یادگیری ماشین (M1-M4) داده‌محور هستند و نیاز به مهندسی دستی ویژگی‌ها دارند. روش‌های

در این جدول روش‌های آماری سنتی (S1-S3) ساده‌ترین روش‌ها هستند که مبتنی بر شمارش تصادفات و فرمول‌های ساده

یادگیری عمیق (D1-D8) پیشرفته‌ترین روش‌ها هستند که قادر به استخراج خودکار ویژگی‌ها و مدل‌سازی الگوهای پیچیده می‌باشند.

۳-۳- معیارهای ارزیابی (۷ معیار)

برای مقایسه عادلانه و جامع روش‌ها، ۷ معیار کلیدی تعریف شده است. جدول ۳ این معیارها را نشان می‌دهد. معیارهایی مانند دقت، حساسیت و... تا نیازهای فنی و تخصصی.

جدول ۳. معیارهای ارزیابی روش‌های پیش‌بینی

کد	نام معیار	واحد	جهت بهینه	روش اندازه‌گیری
C1	دقت (F1-Score)	۱-۰	بیشتر ↑	میانگین F1-Score در مقالات
C2	حساسیت (AUC)	۱-۰	بیشتر ↑	میانگین AUC در مقالات
C3	سرعت آموزش	ساعت (نسبی)	کمتر ↓	زمان با سخت‌افزار یکسان
C4	حجم داده مورد نیاز	تعداد رکورد	کمتر ↓	حداقل داده برای $F1 > 0.7$
C5	تفسیرپذیری	مقیاس ۱-۵	بیشتر ↑	امتیازدهی توسط ۳ کارشناس
C6	تعمیم‌پذیری	مقیاس ۱-۵	بیشتر ↑	امتیازدهی توسط ۳ کارشناس
C7	نیاز به تخصص فنی	مقیاس ۱-۵	کمتر ↓	امتیازدهی توسط ۳ کارشناس

معیارهای C1 و C2 معیارهای اصلی عملکرد مدل هستند F1-Score. برای داده‌های نامتوازن مناسب‌تر از Accuracy است. AUC قدرت تفکیک مدل را نشان می‌دهد. معیارهای C5، C6 و C7 سه کارشناس با حداقل ۱۰ سال سابقه در ایمنی راه‌های ایران، هر روش را در مقیاس لیکرت ۱-۵ بر اساس تعاریف عملیاتی جدول ۳ امتیاز دادند. ضریب توافق بین‌ارزیابان (ICC) برابر ۰٫۸۵ محاسبه شد.

خلاصه داده‌های استخراج شده از مرور سیستماتیک: از مرور سیستماتیک ۹۰ مقاله، مقادیر میانگین هر روش در هر معیار استخراج شد. روش CNN-LSTM (D3) بالاترین دقت (F1=0.82) و AUC (0.89) را داشت. روش XGBoost (M3) با F1=0.85 و AUC=0.88 عملکرد بسیار خوبی نشان داد. روش‌های آماری سنتی (S1-S3) دقت پایینی (F1=0.45-0.55) داشتند. از نظر سرعت، روش فراوانی (S1) با ۰٫۱ ساعت سریع‌ترین و روش Transformer (D7) با ۸ ساعت کندترین بود. از نظر تفسیرپذیری، روش فراوانی با امتیاز ۴٫۵ از ۵ بهترین و روش Transformer با ۱٫۵ از ۵ ضعیف‌ترین بود.

۳-۵- رتبه‌بندی با روش TOPSIS

پس از تعیین وزن معیارها، از روش TOPSIS برای رتبه‌بندی نهایی ۱۵ روش استفاده شد. در این روش، فاصله هر روش از راه‌حل ایده‌آل مثبت (بهترین حالت ممکن) و راه‌حل ایده‌آل منفی (بدترین حالت ممکن) محاسبه شده و امتیاز نزدیکی نسبی (C_i) برای هر روش تعیین می‌گردد. نتایج در بخش یافته‌ها ارائه شده است.

۳-۶- تحلیل حساسیت

برای بررسی پایداری نتایج، تحلیل حساسیت در دو حالت انجام شد: (۱) تغییر وزن معیار اصلی (F1-Score) از ۰٫۲۰ تا ۰٫۵۰ و (۲) تغییر یک‌باره وزن هر معیار به میزان ۲۰٪ افزایش و کاهش. نتایج در بخش یافته‌ها ارائه شده است.

۳-۴- وزن‌دهی با روش AHP

برای تعیین وزن هر معیار، از روش تحلیل سلسله‌مراتبی (AHP) استفاده شد. سه کارشناس اهمیت نسبی هر جفت از

۴- یافته‌ها

در این بخش، نتایج حاصل از اجرای روش‌های AHP و TOPSIS برای رتبه‌بندی ۱۵ روش پیش‌بینی نقاط تصادف خیز ارائه می‌شود.

۴-۱- رتبه‌بندی نهایی ۱۵ روش

جدول ۴ رتبه‌بندی نهایی ۱۵ روش را بر اساس امتیاز TOPSIS نشان می‌دهد. روش CNN-LSTM ترکیبی

(D3) با امتیاز TOPSIS ۰,۸۵۲ بالاترین رتبه را کسب کرده است. این روش کمترین فاصله از ایده‌آل مثبت ($S^+=0.042$) و بیشترین فاصله از ایده‌آل منفی ($S^-=0.241$) را دارد که نشان می‌دهد به بهترین حالت ممکن بسیار نزدیک و از بدترین حالت ممکن بسیار دور است. روش XGBoost (M3) با امتیاز ۰,۷۹۵ در رتبه دوم قرار گرفته است که نشان می‌دهد یک روش یادگیری ماشین می‌تواند با روش‌های پیشرفته یادگیری عمیق رقابت کند. روش‌های آماری سنتی (S1) تا (S3) با امتیازهای ۰,۲۶۸ تا ۰,۳۶۵ در رتبه‌های آخر قرار دارند که فاصله معناداری با روش‌های داده‌محور دارند. لازم به ذکر است که امتیاز TOPSIS حاصل تلفیق ۷ معیار با وزن‌های AHP است و با F1-Score تفاوت دارد.

جدول ۴. رتبه‌بندی نهایی روش‌های پیش‌بینی نقاط تصادف خیز

رتبه	کد	روش	دسته	امتیاز TOPSIS	S^+	S^-
۱	D3	CNN-LSTM	یادگیری عمیق	۰,۸۵۲	۰,۰۴۲	۰,۲۴۱
۲	M3	XGBoost	یادگیری ماشین	۰,۷۹۵	۰,۰۵۸	۰,۲۲۵
۳	D6	STGNN	یادگیری عمیق	۰,۷۹۱	۰,۰۶۱	۰,۲۳۲
۴	D5	GAT	یادگیری عمیق	۰,۷۲۳	۰,۰۷۲	۰,۱۸۸
۵	D8	Ensemble	یادگیری عمیق	۰,۷۱۰	۰,۰۶۰	۰,۱۴۷
۶	M1	RF	یادگیری ماشین	۰,۶۹۲	۰,۰۸۲	۰,۱۸۶
۷	D4	GCN	یادگیری عمیق	۰,۶۵۸	۰,۰۸۵	۰,۱۶۲
۸	D7	Transformer	یادگیری عمیق	۰,۵۶۰	۰,۱۰۲	۰,۱۳۰
۹	D1	CNN	یادگیری عمیق	۰,۵۴۳	۰,۱۰۵	۰,۱۲۵
۱۰	D2	LSTM	یادگیری عمیق	۰,۴۹۱	۰,۱۱۲	۰,۱۰۸
۱۱	M2	SVM	یادگیری ماشین	۰,۴۶۴	۰,۱۱۸	۰,۱۰۲
۱۲	M4	DT	یادگیری ماشین	۰,۴۵۷	۰,۱۲۵	۰,۱۰۵
۱۳	S3	بیز تجربی	آماري	۰,۳۶۵	۰,۱۴۸	۰,۰۸۵
۱۴	S2	نرخ تصادف	آماري	۰,۳۲۵	۰,۱۶۲	۰,۰۷۸
۱۵	S1	فراوانی	آماري	۰,۲۶۸	۰,۱۷۸	۰,۰۶۵

۴-۲- مقایسه عملکرد دسته‌های روش‌ها

بررسی میانگین امتیاز TOPSIS هر دسته نشان می‌دهد که دسته یادگیری عمیق با میانگین ۰,۶۵۲ بالاترین رتبه را دارد. دسته یادگیری ماشین با میانگین ۰,۶۰۲ در رتبه دوم قرار دارد و اختلاف کمی با یادگیری عمیق دارد. دسته آماری سنتی با میانگین ۰,۳۱۹ به طور معناداری (حدود ۵۰٪) از دو دسته دیگر پایین‌تر است. انحراف معیار بالای یادگیری ماشین (۰,۱۵۶) نشان می‌دهد که عملکرد روش‌های این دسته بسیار متفاوت است

(از XGBoost خوب با ۰,۷۹۵ تا درخت تصمیم ضعیف با ۰,۴۵۷).

۴-۳- تحلیل حساسیت

نتایج تحلیل حساسیت نشان می‌دهد که با افزایش وزن معیار F1-Score از ۰,۲۰ به ۰,۵۰، امتیاز روش CNN-LSTM از ۰,۷۸۵ به ۰,۸۹۸ افزایش می‌یابد. این روش

تمایز اصلی این مطالعه، مقایسه همزمان ۱۵ روش از هر سه نسل و ارائه یک رتبه‌بندی کمی و عینی است.

تفسیر شکاف عملکرد بین روش‌های داده‌محور و آماری
فاصله معنادار ۵۰ درصدی میانگین امتیاز TOPSIS روش‌های داده‌محور (۰,۶۲۷) نسبت به روش‌های آماری سنتی (۰,۳۱۹) نشان می‌دهد که الگوهای حاکم بر وقوع تصادفات در راه‌های بین‌شهری ذاتاً غیرخطی، وابسته به زمان و مکان، و دارای تعاملات پیچیده میان متغیرها هستند. روش‌های آماری سنتی با فرض استقلال مشاهدات و روابط خطی، قادر به کشف این الگوها نیستند. این یافته تأیید می‌کند که حرکت از نسل روش‌های آماری به سمت روش‌های داده‌محور در حوزه ایمنی راه، یک ضرورت است، نه یک انتخاب.

چرا XGBoost از برخی روش‌های عمیق بهتر عمل کرد؟

رتبه دوم XGBoost (امتیاز ۰,۷۹۵) در حالی که از نظر دقت خام ($F1=0.85$) حتی از CNN-LSTM بهتر است، نشان می‌دهد که مزیت روش‌های یادگیری عمیق لزوماً در دقت خالص نیست، بلکه در تعمیم‌پذیری ($C6$) و توانایی در داده‌های با ابعاد بالا است. XGBoost با وجود دقت بالا، در تعمیم‌پذیری امتیاز ۳,۰ (از ۵) را کسب کرد در حالی که CNN-LSTM امتیاز ۳,۵ را دارد. بنابراین، برای راه‌های با تنوع اقلیمی و توپوگرافی بالا (مانند ایران)، روشی با تعمیم‌پذیری بهتر اولویت دارد.

راهنمای انتخاب روش بر اساس شرایط پروژه
اگرچه CNN-LSTM به عنوان بهترین روش کلی معرفی شد، اما بسته به شرایط خاص هر پروژه، روش‌های دیگری نیز می‌توانند مناسب باشند. جدول ۵ راهنمای عملی برای انتخاب روش مناسب ارائه می‌دهد.

در ۷ از ۸ سناریو (۸۷,۵٪) در رتبه اول باقی می‌ماند. تنها در وزن بسیار پایین ($F1=0.20$)، روش STGNN به رتبه اول می‌رسد. بررسی تغییر یک‌باره وزن هر معیار (۲۰٪ افزایش و کاهش) نیز نشان داد که CNN-LSTM در تمامی سناریوها رتبه اول خود را حفظ می‌کند. این نتایج نشان‌دهنده پایداری بالای انتخاب CNN-LSTM به عنوان روش بهینه است.

بحث و تفسیر نتایج

چرا CNN-LSTM به عنوان روش بهینه انتخاب شد؟
دلایل برتری روش CNN-LSTM را می‌توان در چند عامل جستجو کرد. نخست، این روش بالاترین دقت ($F1=0.82$) و $AUC (0.89)$ را در میان تمام روش‌ها دارد. این برتری به دلیل توانایی همزمان CNN در استخراج ویژگی‌های مکانی و LSTM در یادگیری وابستگی‌های زمانی است. دوم، از نظر حجم داده مورد نیاز، CNN-LSTM با نیاز به ۸,۰۰۰ رکورد در وضعیت متوسط قرار دارد؛ نه به اندازه روش‌های آماری نیاز به داده کمی دارد و نه به اندازه STGNN نیاز به داده زیادی دارد. این ویژگی برای راه‌های ایران که با محدودیت داده مواجه هستند، حائز اهمیت است. سوم، تعمیم‌پذیری این روش در سطح خوب (۳,۵ از ۵) ارزیابی شده است. به عبارت دیگر، CNN-LSTM بهترین تعادل را بین دقت بالا و سایر معیارهای عملی ایجاد کرده است.

مقایسه با مطالعات پیشین یافته‌های این مطالعه با اکثر مطالعات پیشین همخوانی دارد. مطالعه یانگ و عبدالعاطی (Yang & Abdel-Aty, 2025) که معماری ensemble LSTM را پیشنهاد کرده، با یافته‌های این مطالعه-CNN LSTM به عنوان بهترین روش (همخوانی کامل دارد. مطالعه گلستانی و همکاران (Golestani et al., 2025) که روی داده‌های ایران با XGBoost به $AUC 91.7\%$ دست یافت، با رتبه دوم XGBoost در این مطالعه همخوانی دارد. نقطه

جدول ۵. راهنمای انتخاب روش پیش‌بینی بر اساس شرایط پروژه

شرایط پروژه	روش پیشنهادی	دسته	امتیاز	دلیل
دقت اولویت اول + داده کافی (+۸,۰۰۰)	CNN-LSTM	عمیق	۰,۸۵۲	بالاترین دقت و AUC
دقت بالا + محدودیت منابع	XGBoost	ماشین	۰,۷۹۵	دقت خوب با زمان کمتر
داده بسیار محدود (-۳,۰۰۰)	بیز تجربی	آماري	۰,۳۶۵	نیاز به داده کم
ساختار گراف جاده پیچیده	STGNN/GAT	عمیق	۰,۷۲۳/۰,۷۹۱	تعمیم‌پذیری بالا
تفسیرپذیری حیاتی است	DT/بیز تجربی	ML/آماري	۰,۴۵۷/۰,۳۶۵	قابل فهم برای مدیران
نیاز به مدل سریع و سبک	نرخ تصادف	آماري	۰,۳۲۵	بسیار سریع (۰,۲ ساعت)

۵- نتیجه گیری

این مطالعه با هدف ارزیابی، اولویت بندی و معرفی روش بهینه برای پیش بینی نقاط تصادف خیز راه های بین شهری ایران انجام شد. مهم ترین یافته ها به شرح زیر است:

-نخست، روش CNN-LSTM ترکیبی با امتیاز TOPSIS ۰,۸۵۲ به عنوان بهترین روش معرفی شد. این روش بالاترین دقت ($F1=0.82$) و ($AUC (0.89)$) را داشته و از تعادل مناسبی بین دقت بالا و سایر معیارهای عملی برخوردار است.

-دوم، روش XGBoost با امتیاز ۰,۷۹۵ در رتبه دوم قرار گرفت و نشان داد که یک روش یادگیری ماشین می تواند با روش های پیشرفته یادگیری عمیق رقابت کند.

-سوم، از نظر عملکرد دسته ها، یادگیری عمیق (میانگین ۰,۶۵۲) و یادگیری ماشین (میانگین ۰,۶۰۲) عملکرد مشابه و بالایی دارند، در حالی که روش های آماری سنتی (میانگین ۰,۳۱۹) به طور معناداری ضعیف تر هستند.

-چهارم، تحلیل حساسیت نشان داد که CNN-LSTM در ۸۷,۵٪ سناریوهای تغییر وزن معیارها در رتبه اول باقی می ماند که نشان دهنده پایداری بالای نتایج است.

در این بخش، بر اساس یافته های ارائه شده در بخش های ۴ و ۵ و نتایج حاصل از اجرای روش های AHP و TOPSIS (بخش های ۳-۳ و ۴-۳)، به چهار پرسش پژوهشی مطرح شده در بخش ۳-۱ پاسخ داده می شود.

در ادامه به پاسخ به پرسش های مطرح شده می پردازیم. اول (RQ1): کدام دسته از روش های پیش بینی (آماری سنتی، یادگیری ماشین یا یادگیری عمیق) عملکرد بهتری در پیش بینی نقاط تصادف خیز دارد؟

همان گونه که در بخش ۴-۲ (مقایسه عملکرد دسته های روش ها) تشریح شد، با محاسبه میانگین امتیاز TOPSIS روش های هر دسته، مشخص گردید که دسته یادگیری عمیق با میانگین امتیاز ۰,۶۵۲ و دسته یادگیری ماشین با میانگین امتیاز ۰,۶۰۲ عملکرد مشابه و بالایی دارند. در مقابل، دسته آماری سنتی با میانگین امتیاز ۰,۳۱۹ به طور معناداری (حدود ۵۰ درصد) از دو دسته دیگر پایین تر است. همچنین، انحراف معیار بالای یادگیری ماشین (۰,۱۵۶) نشان می دهد که عملکرد روش های این دسته بسیار متفاوت است) از XGBoost با امتیاز ۰,۷۹۵ تا درخت تصمیم با امتیاز ۰,۴۵۷، در حالی که انحراف معیار پایین

روش های آماری (۰,۴۹) نشان می دهد هر سه روش این دسته عملکرد مشابه و ضعیفی دارند. بنابراین، نتیجه گرفته می شود که برای پیش بینی نقاط تصادف خیز، روش های داده محور (یادگیری عمیق و یادگیری ماشین) به طور قابل توجهی بر روش های آماری سنتی برتری دارند.

پاسخ به پرسش دوم (RQ2): رتبه بندی کمی ۱۵ روش مختلف پیش بینی بر اساس معیارهای چندگانه چیست؟

در بخش ۴-۱ (رتبه بندی نهایی ۱۵ روش) و بر اساس نتایج حاصل از اجرای روش TOPSIS (بخش ۳-۴)، امتیاز نزدیکی نسبی (C_i) برای هر یک از ۱۵ روش محاسبه شد. بر این اساس، روش CNN-LSTM ترکیبی (D3) با امتیاز ۰,۸۵۲ بالاترین رتبه را کسب کرد. این روش کمترین فاصله از ایده آل مثبت ($S^+=0.042$) و بیشترین فاصله از ایده آل منفی ($S^-=0.241$) را دارد که نشان می دهد به بهترین حالت ممکن بسیار نزدیک و از بدترین حالت ممکن بسیار دور است. روش XGBoost (M3) با امتیاز ۰,۷۹۵ در رتبه دوم قرار گرفت که نشان می دهد یک روش یادگیری ماشین می تواند با روش های پیشرفته یادگیری عمیق رقابت کند. روش STGNN (D6) با امتیاز ۰,۷۹۱ در رتبه سوم و روش GAT (D5) با امتیاز ۰,۷۲۳ در رتبه چهارم قرار گرفتند. در انتهای جدول، روش های آماری سنتی با امتیازهای ۰,۲۶۸ تا ۰,۳۶۵ در رتبه های آخر قرار دارند که فاصله معناداری با روش های داده محور دارد. جزئیات کامل رتبه بندی در جدول ۴ ارائه شده است.

پاسخ به پرسش سوم (RQ3): بهترین روش برای پیش بینی نقاط تصادف خیز راه های بین شهری ایران کدام است؟

بر اساس رتبه بندی انجام شده در پاسخ به پرسش دوم و با توجه به شرایط خاص راه های بین شهری ایران (از جمله محدودیت نسبی داده های تصادف در مقایسه با کشورهای پیشرفته، تنوع توپوگرافی و اقلیمی، و نیاز به روشی با تعمیم پذیری مناسب)، روش CNN-LSTM ترکیبی (D3) به عنوان روش بهینه معرفی می شود.

این روش نه تنها بالاترین امتیاز TOPSIS (۰,۸۵۲) را کسب کرده است، بلکه از نظر حجم داده مورد نیاز (۸,۰۰۰ رکورد) در وضعیت متوسط قرار دارد و تعمیم پذیری آن در سطح خوب

(۳,۵ از ۵) ارزیابی شده است (جدول‌های ۲ و ۳). همچنین، تحلیل حساسیت انجام شده در بخش ۴-۳ نشان داد که این روش در ۸۷,۵ درصد سناریوهای تغییر وزن معیارها، رتبه اول خود را حفظ می‌کند که نشان‌دهنده پایداری بالای انتخاب آن است. بنابراین، برای پیاده‌سازی در راه‌های بین‌شهری ایران در شرایطی که داده کافی (بیشتر از ۸,۰۰۰ رکورد) و دسترسی به متخصص داده وجود دارد، این روش توصیه می‌شود.

پاسخ به پرسش چهارم (RQ4): در شرایط مختلف (حجم داده محدود، نیاز به تفسیرپذیری، محدودیت منابع محاسباتی) کدام روش توصیه می‌شود؟

بر اساس تحلیل نقاط قوت و ضعف روش‌ها در بخش ۵ و راهنمای ارائه شده در جدول ۵، پاسخ به این پرسش به صورت سناریویی به شرح زیر است. در شرایط داده بسیار محدود (کمتر از ۳,۰۰۰ رکورد) که روش CNN-LSTM دچار بیش‌برازش می‌شود، روش بیز تجربی (EB) با امتیاز ۰,۳۶۵ با وجود امتیاز پایین، بهترین گزینه عملی است زیرا نیاز به داده کمی دارد. (۳,۰۰۰ رکورد) و تفسیرپذیری بالایی (۳,۵ از ۵) نیز دارد. در شرایطی که تفسیرپذیری برای تصمیم‌گیران (مانند مدیران سازمان راهداری) حیاتی است، روش بیز تجربی (EB) یا درخت تصمیم (DT) با امتیاز ۰,۴۵۷ توصیه می‌شوند، زیرا نتایج آن‌ها به راحتی قابل فهم و توضیح است. در شرایط محدودیت منابع محاسباتی و نبود متخصص داده، روش XGBoost (M3) با امتیاز ۰,۷۹۵ گزینه مناسبی است، زیرا با دقت بسیار خوب ($F1=0.85$) و سرعت آموزش مناسب (۱ ساعت)، به منابع کمتری نسبت به CNN-LSTM نیاز دارد. در شرایطی که ساختار گراف جاده بسیار پیچیده است (مانند جاده‌های کوهستانی با پیچ‌های متعدد و تقاطع‌های زیاد) و داده کافی (بیشتر از ۱۵,۰۰۰ رکورد) در دسترس است، روش‌های STGNN (امتیاز ۰,۷۹۱) یا GAT (امتیاز ۰,۷۲۳) به دلیل تعمیم‌پذیری بالا (۴,۰ از ۵ برای STGNN) توصیه می‌شوند. در نهایت، در شرایط نیاز به مدل سریع و سبک برای سیستم‌های بلادرنگ، روش نرخ تصادف (CR) با امتیاز ۰,۳۲۵ علیرغم دقت پایین، به دلیل سرعت بسیار بالا (۰,۲ ساعت) و نیاز به داده کم، می‌تواند به عنوان یک راهکار موقت مورد استفاده قرار گیرد.

توصیه‌های عملی برای کاربران ایرانی

برای سازمان‌هایی با داده محدود (کمتر از ۳,۰۰۰ رکورد)، روش بیز تجربی توصیه می‌شود. برای سازمان‌هایی با داده کافی (بیشتر از ۸,۰۰۰ رکورد) و دسترسی به متخصص، CNN-LSTM توصیه می‌شود. برای سازمان‌هایی با محدودیت منابع، XGBoost گزینه مناسبی است. برای سازمان‌هایی که نیاز به توجیه هزینه‌ها برای مدیران دارند، روش بیز تجربی یا درخت تصمیم توصیه می‌شود.

محدودیت‌های مطالعه

این مطالعه با محدودیت‌هایی مواجه بوده است: تعداد محدود مقالات برای روش‌های جدید (Transformer)، (GAN)، ناهمگونی داده‌ها در مقالات مختلف، کیفی بودن برخی معیارها، عدم دسترسی به متن کامل حدود ۵٪ مقالات، و تمرکز بر مقالات انگلیسی و فارسی.

پیشنهادهای پژوهش‌های آتی

در اولویت اول، پیاده‌سازی و ارزیابی CNN-LSTM بر روی داده‌های واقعی راه‌های ایران توصیه می‌شود. همچنین ایجاد یک دیتاست استاندارد مرجع برای راه‌های ایران پیشنهاد می‌گردد. در اولویت دوم، بررسی معماری‌های جدید (Transformer)، (GAN) با داده‌های ایران و توسعه معیارهای کمی برای تفسیرپذیری پیشنهاد می‌شود.

جمع‌بندی نهایی

این مطالعه نشان داد که روش CNN-LSTM ترکیبی به عنوان روش برتر برای پیش‌بینی نقاط تصادف خیز راه‌های بین‌شهری ایران شناخته می‌شود. با این حال، انتخاب روش نهایی باید بر اساس شرایط خاص هر پروژه انجام شود. امید است نتایج این مطالعه بتواند به عنوان یک راهنمای عملی برای پژوهشگران، مهندسان و مدیران حوزه ایمنی راه‌های ایران مورد استفاده قرار گیرد.

۶-مراجع

- Golestani, N., Moosavi, S. M. H., & Shabani, S. (2025). Bus telematics data analysis for crash risk prediction on Iranian intercity roads. *PLoS ONE*, 20(4), e0312345.
- Hauer, E. (1996). Identification of sites with promise. *Transportation Research Record*, 1542, 54-60.
- Hauer, E. (1997). Observational before-after studies in road safety. *Pergamon*.
- Hwang, C. L., & Yoon, K. (1981). Multiple attribute decision making. *Springer*.
- Kaffash Charandabi, N., Gholami, A., & Abdollahzadeh Bina, A. (2022). Road accident risk prediction using generalized regression neural network optimized with self-organizing map. *Neural Computing and Applications*, 34(11), 8511-8524.
- Lipton, Z. C. (2018). The mythos of model interpretability. *Queue*, 16(3), 31-57.
- Lord, D., & Mannering, F. (2010). The statistical analysis of crash-frequency data. *Transportation Research Part A*, 44(5), 291-305.
- Nippani, A., et al. (2023). Graph neural networks for road safety modeling. *arXiv:2311.00164*.
- Pan, Y., et al. (2018). Regularized deep belief network for traffic accident prediction. *IEEE Transactions on Intelligent Transportation Systems*, 19(12), 3890-3900.
- Rana, P., et al. (2024). Machine learning approach to enhance highway railroad grade crossing safety. *Transportation Research Record*, 2678(3), 245-260.
- Saaty, T. L. (1980). The analytic hierarchy process. *McGraw-Hill*.
- Sajadi, P., et al. (2024). Accident impact prediction based on deep convolutional and recurrent neural network. *arXiv:2411.07537*.
- Shabani, S., et al. (2019). A risk based model for the switch derailment using Bayesian network. *Proceedings of the 4th International Conference on Railway Technology*.
- احسانی، سید مجید و آسوده، راضیه (۱۳۹۹). شناسایی نقاط حادثه خیز راه‌های برون شهری با استفاده از روش مدل‌سازی فازی. *مجله راهور*، ۴(۲)، ۱۰۳-۱۰۳.
- سادات حسینی، سید محمد؛ سلیمی کوچی، محمدباقر؛ جوزی دستچره، امیر و بیرانوند، محسن (۱۴۰۳). شناسایی و تحلیل نقاط حادثه خیز شهر همدان. *مجله راهور*، ۸(۱)، ۱۳۱-۱۵۲.
- غفاری، سارا و حسینعلی، فرهاد (۱۴۰۳). بررسی تأثیر عوامل هندسی بر شدت تصادفات در راه‌های برون‌شهری با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری عمیق. *پژوهشنامه حمل و نقل*، ۲۱(۳)، ۴۵-۶۸.
- مرکز پژوهش‌های مجلس شورای اسلامی (۱۴۰۳). بسته سیاستی کاهش تصادفات رانندگی در سال ۱۴۰۳. تهران.
- سازمان پزشکی قانونی کشور (۱۴۰۲). گزارش آمار تلفات حوادث رانندگی کشور. تهران.
- AASHTO. (2010). Highway safety manual. AASHTO.
- Alagarsamy, S., et al. (2021). Prediction of road accidents using machine learning technique. *IJARST*, 6(1), 45-52.
- Anik, B. M. T. H., et al. (2023). inTformer: A time-embedded attention-based transformer for crash likelihood prediction. *arXiv:2307.03854*.
- Bradley, A. P. (1997). The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7), 1145-1159.
- Chang, L. Y., & Chen, W. C. (2005). Data mining of tree-based models to analyze freeway accident frequency. *Journal of Safety Research*, 36(4), 365-375.
- Chaudhary, M., et al. (2023). Risk maps and intervention strategies in road traffic accidents using GIS. *Transport Safety Review*, 52, 21-38.
- Elvik, R. (2008). A survey of operational definitions of hazardous road locations. *Accident Analysis & Prevention*, 40(6), 1830-1835.
- Gao, Y., et al. (2023). STZITDGNN: Spatiotemporal zero-inflated Tweedie distribution graph neural network. *Transportation Research Part C*, 148, 104002.

- Wan, R., et al. (2023). Traffic accident hotspot prediction using temporal convolutional networks. *In ACM SIGSPATIAL 2023*.
- Yang, S., & Abdel-Aty, M. (2025). Real-time crash prediction with limited connected vehicle data using ensemble LSTM-CNN. *Transportation Research Part C*, 162, 104112.
- Yu, L., et al. (2021). Deep spatiotemporal graph convolutional network for traffic accident prediction. *Neurocomputing*, 423, 135-147.
- Yuan, J., et al. (2019). Real-time crash risk prediction using LSTM recurrent neural network. *Transportation Research Record*, 2673(4), 314-326.
- Shabani, S., et al. (2021). Developing a model for the risk of the rail vehicles collision using Bayesian network. *Journal of Transportation Safety*, 43(2), 145-162.
- Singh, G., et al. (2020). Deep neural network-based predictive modeling of road accidents. *Procedia Computer Science*, 167, 1672-1681.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437.
- Theofilatos, A., et al. (2019). Comparing machine learning and deep learning methods for real-time crash prediction. *Accident Analysis & Prevention*, 132, 105278.

Evaluation and Prioritization of Crash Hotspot Prediction Methods for Interurban Roads using an AHP-TOPSIS Approach

Shahin Shabani, Department of Civil Engineering, Payame Noor University (PNU), Tehran, Iran.

Ali Ghorbani, Department of Civil Engineering, Payame Noor University (PNU), Tehran, Iran.

Peyman Pejmanzad, Ph.D., Student, Department of Civil Engineering, Payame Noor University (PNU), Tehran, Iran.

E-mail: p.pejmanzad@bhrc.ac.ir

Received: February 2026- Accepted: May 2026

ABSTRACT

Road accidents in Iran cause over 20,000 deaths annually and account for approximately 7% of GDP. Identifying crash hotspots is one of the most effective strategies to reduce these losses. Various methods from three categories—traditional statistical, machine learning, and deep learning—have been proposed for hotspot prediction. However, the lack of a systematic comparison makes it difficult to select the appropriate method for Iranian roads. Fifteen prediction methods, including 3 statistical (Crash Frequency, Crash Rate, Empirical Bayes), 4 machine learning (Random Forest, SVM, XGBoost, Decision Tree), and 8 deep learning (CNN, LSTM, CNN-LSTM, GCN, GAT, STGNN, Transformer, Ensemble), were evaluated across 7 criteria (accuracy, sensitivity, speed, data volume, interpretability, generalizability, technical expertise). Data were extracted from a systematic review of 90 articles (2019–2025). AHP was used for weighting and TOPSIS for ranking. The hybrid CNN-LSTM achieved the highest rank with a TOPSIS score of 0.852. XGBoost was the best machine learning method with 0.795. Statistical methods ranked last with a mean score of 0.275. The mean score for deep learning (0.652) was higher than machine learning (0.634) and statistical methods (0.275). Sensitivity analysis confirmed the stability of the results. The hybrid CNN-LSTM method was selected as the top-ranked method for predicting crash hotspots on Iranian interurban roads. In very limited data conditions (fewer than 3,000 records), Empirical Bayes is recommended, and in situations requiring high interpretability, Decision Tree is proposed.

Keywords: Crash Hotspots, Deep Learning, Machine Learning, Statistical Methods, AHP-TOPSIS