

ارائه مدل‌های هوشمند طبقه بندی داده‌های تصادفات ترافیکی بر مبنای شبکه بیزین، درخت تصمیم و شبکه عصبی مصنوعی

مقاله علمی - پژوهشی

علی نادران، استادیار، دانشکده مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

محمدرضا احدی، دانشیار، مرکز تحقیقات راه، مسکن و شهرسازی، تهران، ایران

رسول ذبیحیان*، دانشجوی دکتری، گروه مهندسی عمران، واحد بین‌المللی کیش، دانشگاه آزاد اسلامی، جزیره کیش، ایران

*پست الکترونیکی نویسنده مسئول: r.zabihian@iau.ir

دریافت: ۱۴۰۴/۰۱/۲۷ - پذیرش: ۱۴۰۴/۰۵/۰۱

صفحه ۱۷۴-۱۶۳

چکیده

هرسال تعداد زیادی از کاربران جاده در نتیجه تصادفات ترافیکی جان خود را از دست می‌دهند یا مجروح می‌شوند. تحلیل نقاط حادثه‌خیز برای و رانندگی، سازمان حمل‌ونقل و ترافیک شهرداری‌ها و سازمان‌های امرتبط با ایمنی‌اترافیک بسیار با اهمیت می‌باشد. برای شناسایی نقاط پرخطر تصادف از روش‌هایی مانند نزدیک‌ترین همسایگی و برازش استفاده می‌شود، اما این روش‌ها پیش‌بینی ناکافی و درصد برآورد نادرستی دارند. هدف این تحقیق، طبقه بندی داده‌های تصادفات و ارائه یک روش بهتر برای شناسایی نقاط پرخطر از نظر تصادف است. برای این منظور، عملکرد درخت‌های تصمیم، مدل بیزین، و شبکه عصبی با استفاده از روش‌های متداول مانند نزدیک‌ترین همسایگی و برازش مقایسه شدند. با استفاده از ابزار GIS و روش‌های مبتنی بر تراکم همانند تابع چگالی کرنل، نقاط پرخطر تصادفات به صورت نقشه‌های کاربردی شناسایی شدند. نتایج نشان داد که روش درخت تصمیم، شبکه بیزین و شبکه عصبی به ترتیب با ۸۳٪ و ۷۸٪ درصد برآورد صحیح، نسبت به روش‌های سنتی عملکرد بهتری دارند. همچنین، نتایج نشان داد که تعداد تصادفات در دوره‌های اوج ترافیک، به عنوان مثال صبح و عصر، نسبت به دوره‌های غیر اوج بیشتر است. با بررسی نقاط حادثه‌خیز پس از شناسایی به این نتیجه دست می‌توان یافت که نقاط حادثه‌خیز درون شهری بیشتر در نزدیکی تقاطعات بوده و اغلب در شرایط جوی مناسب و در روشنایی کافی روز اتفاق می‌افتند.

واژه‌های کلیدی: تصادفات داخل شهری، طبقه‌بندی، GIS، شبکه بیزین، درخت تصمیم و شبکه عصبی مصنوعی

۱- مقدمه

مکان‌های پرخطر تصادف را تشخیص داد. سیستم اطلاعات مکانی GIS ابزار مناسبی برای شناسایی و تحلیل نقاط پرخطر تصادفات می‌باشد که در چند دهه‌ی اخیر بسیار مورد استفاده قرار گرفته است. تصادفات جاده‌ای یکی از چالش‌های عمده جوامع مدرن است که سالانه هزینه‌های انسانی، اقتصادی و اجتماعی قابل توجهی به همراه دارد. با افزایش روزافزون تعداد وسایل نقلیه و پیچیدگی‌های روزافزون ترافیک، نیاز به روش‌های مؤثر و کارآمد برای تحلیل و پیش‌بینی تصادفات بیش از پیش احساس می‌شود.

ایمنی، یک پارامتر بسیار مهم در کیفیت زندگی ادر بسیاری از کشورهای پیشرفته از دیدگاه مردم و مجامع مهم بین‌المللی است. تصادفات ترافیکی سالانه منجر به فوت، معلولیت دائمی و جراحت افراد زیادی از کاربران راه‌ها مخصوصاً در کشورهای درحال توسعه می‌شود (لینهو لی و همکارانش، ۲۰۰۷). تعریف و توصیف عوامل مؤثر در تصادفات اقدامی عملی برای کاهش و به حداقل رساندن عوامل ایجاد تصادف است که باعث بهبود ایمنی سیستم حمل و نقل می‌شود. برای این منظور، ضرورت دارد

در این راستا، استفاده از مدل‌های هوشمند و روش‌های پیشرفته می‌تواند به بهبود تصمیم‌گیری در زمینه مدیریت ترافیک و ارتقای ایمنی جاده‌ها کمک کند. هدف از این مطالعه، ارائه مدل‌های هوشمند برای طبقه‌بندی داده‌های تصادفات است که به‌ویژه بر مبنای سه رویکرد متفاوت یعنی شبکه بیزین، درخت تصمیم و شبکه عصبی مصنوعی بنا نهاده شده‌اند. این مدل‌ها به دلیل قابلیت‌های متفاوت خود در تحلیل داده‌های پیچیده و غیرخطی، می‌توانند به شناسایی الگوهای پنهان در داده‌های تصادفات کمک کرده و نتیجه‌گیری‌های دقیق‌تری ارائه دهند.

ضرورت این مطالعه نه تنها در ایجاد بینش‌های جدید در زمینه علل و عوامل مؤثر بر تصادفات جاده‌ای، بلکه در بهینه‌سازی استراتژی‌های پیشگیرانه و کاهش آمار تصادفات محسوس است. با توسعه و به‌کارگیری مدل‌های هوشمند، می‌توان به شناسایی نقاط خطرناک، ارزیابی تأثیر متغیرهای مختلف بر تصادفات و از همه مهمتر، ارائه راهکارهای پیوسته و مبتنی بر داده‌های واقعی برای بهبود ایمنی جاده‌ها و کاهش تلفات و خسارات ناشی از تصادفات پرداخت. به‌کارگیری این سه مدل مختلف باعث می‌شود که مقایسه‌ای جامع میان کارایی و دقت هر یک از آنها صورت گیرد و در نهایت، بهترین رویکرد برای تحلیل داده‌های تصادفات شناسایی شود. این مطالعه می‌تواند نه تنها به جامعه علمی کمک کند، بلکه به‌عنوان یک منبع علمی و عملی در دسترس سازمان‌های دولتی و خصوصی، پژوهشگران و متخصصان این حوزه قرار گیرد. لذا، این تحقیق دارای ارزش بالایی در ارتقای امنیت ترافیکی و کاهش تصادفات خواهد بود. با مطالعه تصادفات می‌توان عوامل مؤثر در رخداد تصادفات ترافیکی را شناسایی کرد. از این رو تحلیل نقاط حادثه‌خیز برای راهنمایی و رانندگی، سازمان حمل‌ونقل و ترافیک شهرداری‌ها و سازمان‌های مرتبط با ایمنی ترافیک بسیار با اهمیت می‌باشد. هدف از این تحقیق شناسایی پارامترهای تأثیرگذار و محاسبه میزان اهمیت و تأثیرگذاری هر یک از عوامل مؤثر در تصادفات می‌باشد. با تشخیص این نقاط می‌توان در جلوگیری از این عوامل پیش‌قدم شد تا به میزان مطلوبی از ایمنی در راه‌ها برسیم.

لینهو لی و همکارانش (۲۰۰۷) از رویکرد Bayesian برای تحلیل مکانی و زمانی تصادفات درون‌شهری و محاسبه‌ی ریسک تصادفات استفاده کردند و سپس با استفاده از نرم‌افزار (GIS Arc scene) به‌صورت سه‌بعدی تراکم تصادفات را در نقشه‌هایی سه‌بعدی به تصویر کشیدند. پلات و دوردوران از ترکیه در سال ۲۰۱۰ روش‌های انتخاب مشخصه مبتنی بر همبستگی و ماشین بردار و شبکه عصبی را ترکیب کرده و برای پیش‌بینی تصادفات به‌کاربرده و عوامل جوی، رطوبت هوا و زمان رخداد تصادف را به‌عنوان داده‌های مطالعه‌ی خود قرار داده است. (Kemal Polat, ۲۰۱۱)

مصطفی جعفری و همکاران تعیین نقاط حادثه‌خیز تصادفات موتورسیکلت با استفاده از سیستم اطلاعات جغرافیایی در شهرستان‌های گناباد و بجستان پارساناکومار (۲۰۱۱) در هندوستان از توابع تعریف‌شده در نرم‌افزار GIS که در بحث محاسبه نقاط حادثه‌خیز استفاده کرده و سه روش شاخص همبستگی مکانی موران، گتیس-اورد جی آی استار و توابع چگالی نقطه‌ای کرنل را به کار برده است که جزو مرسوم‌ترین روش‌ها در بحث تحلیل‌های مکانی هستند. (Parsana Kumar ۲۰۱۱) در جدول ۱ به کارهای گذشتگان می‌پردازیم. (Romi ۲۰۱۶) (Satria)

جعفری، تبریزی، اسماعیل زاده و زمانی به تعیین نقاط حادثه‌خیز تصادفات موتورسیکلت با استفاده از سیستم اطلاعات جغرافیایی در شهرستان‌های گناباد و بجستان پرداخته‌اند. (۲۰۱۱) (Jafari et al)

در این راستا، استفاده از مدل‌های هوشمند و روش‌های پیشرفته می‌تواند به بهبود تصمیم‌گیری در زمینه مدیریت ترافیک و ارتقای ایمنی جاده‌ها کمک کند. هدف از این مطالعه، ارائه مدل‌های هوشمند برای طبقه‌بندی داده‌های تصادفات است که به‌ویژه بر مبنای سه رویکرد متفاوت یعنی شبکه بیزین، درخت تصمیم و شبکه عصبی مصنوعی بنا نهاده شده‌اند. این مدل‌ها به دلیل قابلیت‌های متفاوت خود در تحلیل داده‌های پیچیده و غیرخطی، می‌توانند به شناسایی الگوهای پنهان در داده‌های تصادفات کمک کرده و نتیجه‌گیری‌های دقیق‌تری ارائه دهند.

ضرورت این مطالعه نه تنها در ایجاد بینش‌های جدید در زمینه علل و عوامل مؤثر بر تصادفات جاده‌ای، بلکه در بهینه‌سازی استراتژی‌های پیشگیرانه و کاهش آمار تصادفات محسوس است. با توسعه و به‌کارگیری مدل‌های هوشمند، می‌توان به شناسایی نقاط خطرناک، ارزیابی تأثیر متغیرهای مختلف بر تصادفات و از همه مهمتر، ارائه راهکارهای پیوسته و مبتنی بر داده‌های واقعی برای بهبود ایمنی جاده‌ها و کاهش تلفات و خسارات ناشی از تصادفات پرداخت. به‌کارگیری این سه مدل مختلف باعث می‌شود که مقایسه‌ای جامع میان کارایی و دقت هر یک از آنها صورت گیرد و در نهایت، بهترین رویکرد برای تحلیل داده‌های تصادفات شناسایی شود. این مطالعه می‌تواند نه تنها به جامعه علمی کمک کند، بلکه به‌عنوان یک منبع علمی و عملی در دسترس سازمان‌های دولتی و خصوصی، پژوهشگران و متخصصان این حوزه قرار گیرد. لذا، این تحقیق دارای ارزش بالایی در ارتقای امنیت ترافیکی و کاهش تصادفات خواهد بود. با مطالعه تصادفات می‌توان عوامل مؤثر در رخداد تصادفات ترافیکی را شناسایی کرد. از این رو تحلیل نقاط حادثه‌خیز برای راهنمایی و رانندگی، سازمان حمل‌ونقل و ترافیک شهرداری‌ها و سازمان‌های مرتبط با ایمنی ترافیک بسیار با اهمیت می‌باشد. هدف از این تحقیق شناسایی پارامترهای تأثیرگذار و محاسبه میزان اهمیت و تأثیرگذاری هر یک از عوامل مؤثر در تصادفات می‌باشد. با تشخیص این نقاط می‌توان در جلوگیری از این عوامل پیش‌قدم شد تا به میزان مطلوبی از ایمنی در راه‌ها برسیم.

۲- پیشینه تحقیق

در کشورهای مختلف، تعاریف متعددی برای نقاط حادثه‌خیز بر اساس شاخص‌هایی نظیر شدت تصادف (فوتی، جرحی، خسارتی)، بازه زمانی (یک‌ساله، سه‌ساله، پنج‌ساله) و واحد تصادف (قطعه‌راه، نقطه تصادف، مساحت و شعاع اثر) ارائه می‌شود. در ادامه شاخص‌های حادثه‌خیزی برخی کشورهای منتخب، ارائه می‌شود. در آلمان، این کشور برای مطالعه‌ی نقاط

جدول ۱. مروری بر روش‌های تحلیل تصادفات

روش مورد استفاده	منطقه مورد مطالعه	نویسندگان
ابزارهای مکانی که درجه تمرکز مکانی را مشخص می‌کنند و الگوهای مکانی تصادفات مختلف را تحلیل می‌کنند	شهری و برون‌شهری	کیم و نیتز (۱۹۹۵)
موقعیت تصادف، خوشه‌بندی مکانی توسط تحلیل چگالی کرنل	شهری	استینبرگن و همکاران (۲۰۰۴)
مدل بیزین کامل سلسله مراتبی با اثرات زمانی و مکانی در مقایسه با روش دوجمله‌ای منفی برای تخمین فراوانی تصادف سالانه	شهری و برون‌شهری	آگرو-والورده و ژوانیس (۲۰۰۶)
شناسایی لکه‌های داغ با تحلیل‌های آماری (تحلیل چگالی کرنل و پواسون)	شهری و برون‌شهری	اردوغان و همکاران (۲۰۰۸)
آماره موران و گنیس-اورد (۵)	شهری	اردوغان (۲۰۰۹)
روش قطعات داغ برای تعیین امتداد بحرانی از تصادفات جاده‌ای و نقاط احتمالی برای پیش‌بینی نقاط بحرانی	شهری	گوندو و غندو (۲۰۱۱)
شاخص شدت، الگوهای فضایی اطلاعات تصادفات عابران پیاده و نقشه‌های نقاط داغ نقاط عابر پیاده با خودرو.	شهری و برون‌شهری	ترونک و سومنهالی (۲۰۱۱)
لکه‌های سیاه تصادف: سه روش (تخمین چگالی کرنل، تحلیل خوشه و ناخوشه)	شهری	بودیپهارتو و ساییدو (۲۰۱۲)
الگوهای مکانی تصادف با استفاده از شبکه K -function و برآورد تراکم کرنل شبکه‌ای (KDE) برای یافتن خوشه‌ها و شناسایی مکان‌های خوشه واقعی.	شهری	چلا و همکاران (۲۰۱۳)
تحقیق در مورد پتانسیل استفاده از سیستم اطلاعات جغرافیایی در شناسایی موقعیت‌های ناشی از تصادفات عابر پیاده.	شهری و برون‌شهری	رانکاوات و تیواری (۲۰۱۳)
رویکرد فازی فضایی جغرافیایی برای شناسایی مناطق خطرناک	شهری	عفتی و همکاران (۲۰۱۴)
مدل پواسون-کوآسی	شهری	ما و همکاران (۲۰۱۴)
آماره موران و گنیس-اورد	شهری و برون‌شهری	تورتوم و آتالای (۲۰۱۵)
سه روش تحلیل الگوی مکانی در شبکه: چگالی کرنل، نزدیک‌ترین فاصله همسایگی، تابع K	شهری	یالچین و دوزگون (۲۰۱۵)

۳- روش تحقیق

راهنمایی و رانندگی، و پایگاه‌های داده عمومی جمع‌آوری شود. مهم است که داده‌ها به‌طور کامل و دقیق باشند تا نتایج تحلیل‌ها معتبر و قابل اعتماد باشند. داده‌های جمع‌آوری شده ممکن بود شامل نواقص، داده‌های گمشده، و ناهماهنگی‌ها باشند. بنابراین، در این مرحله، از تکنیک‌های پیش‌پردازش مانند پاک‌سازی، نرمال‌سازی و تبدیل داده‌ها به فرمت مناسب استفاده می‌شود. همچنین، این مرحله شامل شناسایی و حذف نویزها و داده‌های غیرمعتبر نیز می‌باشد.

در این مرحله، از سه الگوریتم یادگیری ماشین شامل شبکه بیزین، درخت تصمیم و شبکه عصبی مصنوعی برای مدل‌سازی داده‌ها استفاده می‌شود.

- **شبکه بیزین:** این الگوریتم بر مبنای نظریه احتمال پایه‌گذاری شده و به‌خوبی برای شرایط عدم قطعیت مناسب است. در این تحقیق، شبکه بیزین برای شناسایی ارتباطات میان

فرآیند انجام تحقیق بدین صورت است که ابتدا باید داده‌های دریافت شده از ترکیه را برای انجام مدل‌سازی‌های لازم پاک‌سازی نموده و با تحلیل‌های آماری داده‌های مهم را از میان داده‌ها را انتخاب کنیم. روش شناسی این پژوهش به بررسی و پیاده‌سازی الگوریتم‌های یادگیری ماشین برای تحلیل داده‌های تصادفات جاده‌ای متمرکز است. استفاده از تکنیک‌های پیشرفته یادگیری ماشین به‌ویژه در مطالعات تحلیلی مانند این تحقیق، گام مهمی در جهت بهبود دقت و قابلیت پیش‌بینی در شناسایی و طبقه‌بندی الگوهای تصادف است. در این بخش، به تشریح مراحل اصلی روش شناسی این پژوهش پرداخته خواهد شد.

در گام نخست، جمع‌آوری داده‌های مربوط به تصادفات جاده‌ای شامل انواع تصادفات، زمان وقوع، مکان، شرایط جوی، نوع وسایل نقلیه و عوامل انسانی صورت می‌گیرد. این داده‌ها ممکن است از منابع مختلفی مانند سامانه‌های مدیریت ترافیک، پلیس

مدل‌ها استفاده خواهد شد. معیارهای ارزیابی شامل دقت، صحت، یادآوری، و F1-Score خواهد بود تا به مقایسه عملکرد مدل‌ها کمک کند.

در این مرحله، نتایج حاصل از مدل‌های مختلف مورد بررسی و تحلیل قرار می‌گیرد. نقاط قوت و ضعف هر یک از مدل‌ها به‌طور دقیق مورد ارزیابی قرار می‌گیرد تا مشخص شود کدام مدل قادر به شناسایی دقیق‌تر الگوهای تصادف است. همچنین، این مرحله شامل بررسی تأثیر ویژگی‌های مختلف بر وقوع تصادفات خواهد بود. از آنجا که این مطالعه به بررسی عملکرد سه رویکرد مختلف می‌پردازد، نتایج به‌دست‌آمده می‌تواند مبنایی برای تحقیقات آینده و توسعه مدل‌های پیشرفته‌تر باشد.

در جداول ۲ و ۳ به ترتیب آمار توصیفی داده‌های اسمی و عددی آمده است که پس از پاک‌سازی داده‌های خام می‌باشند. سپس مدل‌های مختلف را که در مراحل انجام تحقیق در شکل ۱ آمده بر داده‌ها اعمال می‌کنیم.

متغیرهای مختلف تصادف، و به‌خصوص شناسایی عوامل مؤثر بر وقوع تصادفات مورد استفاده قرار می‌گیرد.

- **درخت تصمیم:** این الگوریتم برای مدل‌سازی تصمیمات و گزینه‌های مختلف استفاده می‌شود. با ساختن درخت‌هایی که میزان احتمال وقوع تصادفات را با توجه به ویژگی‌ها و پارامترهای مختلف نشان می‌دهند، می‌توان به تحلیل عمیق‌تری از عوامل مؤثر بر این پدیده دست یافت.

- **شبکه عصبی مصنوعی:** این مدل به‌ویژه در شناسایی الگوهای غیرخطی و پیچیده مؤثر است. با استفاده از این تکنیک، می‌توان به شبیه‌سازی و پیش‌بینی الگوهای پیچیده تصادفات بر اساس داده‌های ورودی مختلف پرداخته و دقت پیش‌بینی‌ها را افزایش داد. مدل‌های ایجادشده بایستی با استفاده از مجموعه‌ای از داده‌های آموزشی آموزش داده شوند. برای این منظور، داده‌ها به دو بخش آموزش و تست تقسیم‌بندی می‌شوند. پس از آموزش مدل‌ها، از داده‌های تست برای ارزیابی دقت و کارایی هر یک از

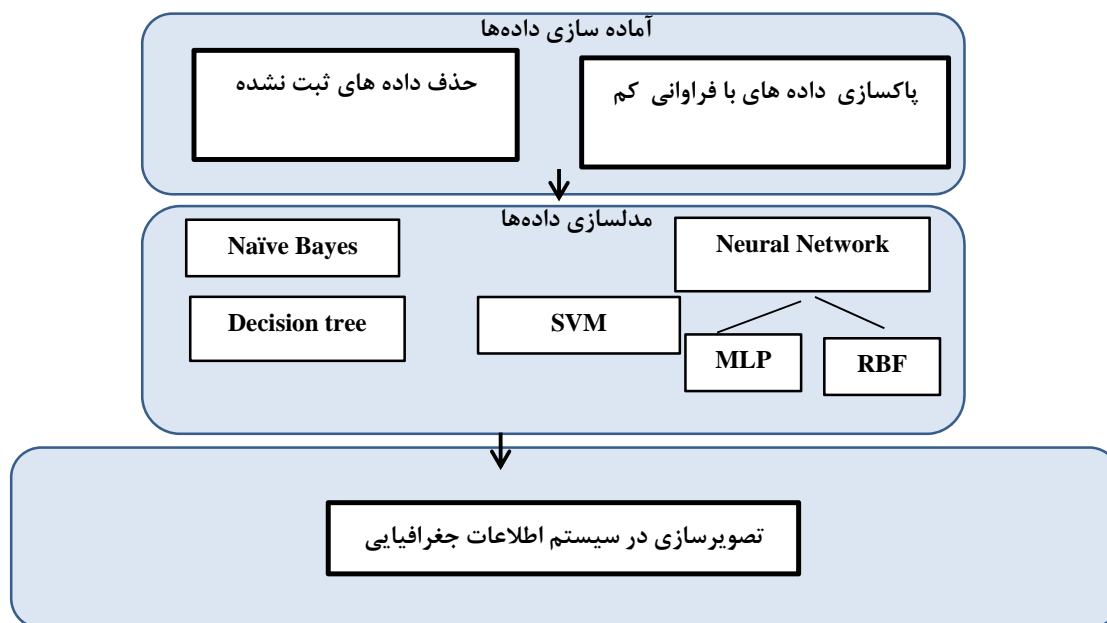
جدول ۲. فراوانی داده‌ها اسمی

متغیر	زیرشاخه	فراوانی نسبی (مطلق)	متغیر	زیرشاخه	فراوانی نسبی (مطلق)
نوع راه	جداشده	۴۸/۴ (۱۳۲۳)	روز و شب	روز	۵۶/۸ (۱۵۵۲)
	یک‌طرفه	۸/۸ (۲۴۰)		شب	۴۳/۲ (۱۱۸۲)
طبقه راه	دوطرفه جدا نشده	۴۲/۸ (۱۱۷۱)	آب‌وهوا	هوای صاف	۸۴/۴ (۲۳۰۸)
	بزرگراه	۲۴/۱ (۶۵۹)		بارانی/ برفی	۱۵/۶ (۴۲۶)
وجود گارد ریل	خیابان	۷۵/۹ (۲۰۷۵)	وضعیت سطح جاده	خشک	۷۹/۲ (۲۱۶۴)
	خیبر	۷۸/۶ (۲۱۵۰)		خیس	۲۰/۸ (۵۷۰)
وجود شانه مسیر	بله	۲۱/۴ (۵۸۴)	هندسه افقی مسیر	قوس	۱۳/۶ (۳۷۲)
	خیر	۷۸/۱ (۲۱۳۶)	مسیر مستقیم	۸۶/۴ (۲۳۶۲)	
وجود خط‌کشی	بله	۲۱/۹ (۵۹۸)	هندسه قائم مسیر	شیب‌دار	۲۷/۹ (۷۶۳)
	خیر	۳۲/۴ (۸۸۵)		شیب صفر	۷۲/۱ (۱۹۷۱)
علائم راهنمایی رانندگی	بله	۶۷/۷ (۱۸۴۹)	روشنایی مسیر	خیر	۳۱ (۸۴۷)
	خیر	۵۵/۳ (۱۵۱۳)		بله	۶۹ (۱۸۸۷)
علائم چراغ‌دار	بله	۴۴/۷ (۱۲۲۱)	نوع تصادف	تصادف از روبرو	۱۰/۷ (۲۹۳)
	خیر	۸۸/۸ (۲۴۲۸)		برخورد با شیء ثابت	۱۳/۹ (۳۷۹)
بله	۱۱/۲ (۳۰۶)	برخورد از عقب		۱۵/۱ (۴۱۲)	
تقاطع	چهارراه	۲۲/۴ (۶۶۱)	تعداد خودرو	برخورد زاویه‌ای	۴۶/۶ (۱۲۷۳)
	دور از تقاطع	۴۵/۹ (۱۲۵۵)		واژگونی	۷/۶ (۲۰۹)
	میدان	۴/۸ (۱۳۲)		خروج از جاده	۶/۱ (۱۶۸)
	سه‌راهی T شکل	۲۰/۲ (۵۵۳)		چند خودرویی	۷۶/۵ (۲۰۹۱)
	سه‌راهی Y شکل	۴/۹ (۱۳۳)	تک خودرویی	۲۳/۵ (۶۴۳)	
	میان راه	۴/۶ (۱۲۶)			

متغیر	زیرشاخه	فراوانی نسبی (مطلق)	متغیر	زیرشاخه	فراوانی نسبی (مطلق)
محل تصادف	روی مسیر	۸۲/۳ (۲۲۵۱)			
	در شانه راه	۲/۲ (۵۹)			
	در کناره راه	۶/۷ (۱۸۴)			
	در پیاده‌رو	۴/۲ (۱۱۴)			

جدول ۳. آمار توصیفی داده‌های عددی

آمار توصیفی	تعداد خودروها	تعداد مجروحین	محدوده سرعت (کیلومتر بر ساعت)
کمینه	۱	۱	۲۰
بیشینه	۷	۲۳	۱۱۰
مد	۲	۱	۵۰
میانه	۱/۹۰۱	۱/۷۸	۴۹/۸۳
انحراف معیار	۰/۶۵۹	۱/۴۷۷	۱۶/۴۲۵




شکل ۱. مراحل انجام تحقیق

از نوعی از قانون هرس بعدی استفاده می‌کند. همچنین قادر است صفات گسسته، صفات فاقد مقدار و داده‌های نویزی را استفاده کند. این الگوریتم بهترین صفت را با استفاده از معیار بی‌نظمی انتخاب می‌کند و به دلیل استفاده از عامل Gain Ratio قادر به به‌کارگیری صفات با مقادیر بسیار زیاد می‌باشد. حتی اگر هیچ خطایی در داده‌های آموزشی وجود

الگوریتم یادگیری درخت تصمیم پایه بیشتر الگوریتم‌های که برای درختان تصمیم یادگیری توسعه یافته‌اند از یک الگوریتم پایه مشتق شده‌اند که یک جستجوی حریصانه‌ی بالا به پایین را در فضای درختان تصمیم ممکن، بکار می‌گیرد. این روش توسط الگوریتم ID3 و نسخه‌ی کامل‌تر آن C4.5 نشان داده می‌شود. الگوریتم C4.5 نسل بعدی الگوریتم ID3 است و

الگوریتم دسته‌بندی دو صفحه، در مرز دو کلاس داده‌ها قرار گرفته می‌شود و مسئله یافتن مرز حداکثری بین این دو صفحه و در نتیجه بین دودسته داده‌ها می‌باشد. به این صورت که دو صفحه آنقدر از هم دور شوند که به داده‌ها برخورد نکنند. همان‌طور که در شکل ۳ نشان داده شده است، هدف یافتن دو صفحه‌ای است که بیشترین فاصله را دارد و در نتیجه صفحه بین این دو صفحه بهترین جداکننده خواهند بود. (SavaşDurduran ۲۰۱۰)



شکل ۳. صفحات ماشین بردار پشتیبان


۴- یافته‌ها

با اعمال مدل‌های مختلف بر داده‌ها مشاهده می‌شود که داده‌های برداشت شده با دقت خوبی طبقه‌بندی می‌شوند؛ که در شکل ۴ مشاهده می‌شود که مدل‌های درخت تصمیم (C4.5) و ماشین بردارها (SVM) با درصد صحت زیادی داده‌ها را طبقه‌بندی می‌کنند.

نداشته باشد هرس انجام می‌شود که باعث می‌شود درخت عام‌تر شده و کمتر به مجموعه‌ی آموزشی وابسته شود (Kemal Polat ۲۰۱۱)

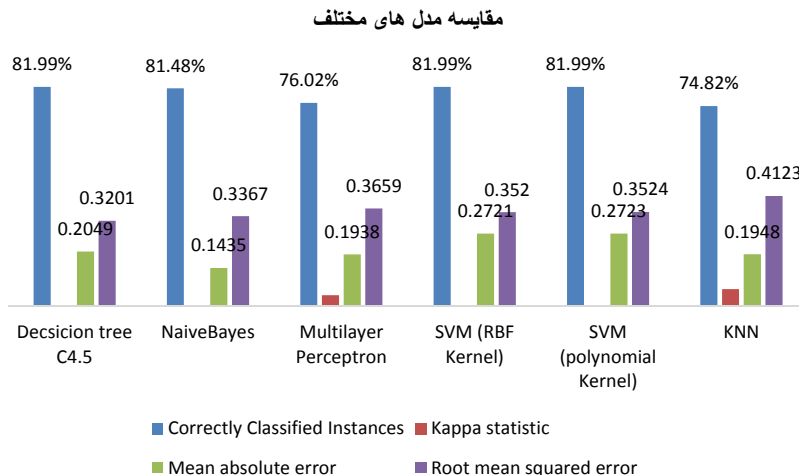
الگوریتم MLP شبکه‌های عصبی چندلایه پرسپترون شبکه‌های چندلایه‌ی پیش‌خور یکی از مهم‌ترین ساختارهای شبکه‌های عصبی مصنوعی می‌باشد. به‌طور معمول این شبکه‌ها شامل مجموعه‌ای از واحدهای حسی (نورون‌های پایه) می‌باشند و یک لایه‌ی خروجی ۵، یک یا چند لایه‌ی پنهان ۴ که تشکیل دهنده‌ی لایه‌ی ورودی می‌باشند. ۶ سیگنال ورودی در خلال شبکه و در مسیری روبه‌جلو به‌صورت لایه به لایه منتشر می‌شود. این نوع شبکه معمولاً با عنوان پرسپترون چندلایه (MLP) نامیده می‌شود.

الگوریتم RBF شبکه‌های با تابع مدار شعاعی به‌طور گسترده‌ای برای تخمین غیر پارامتریک توابع چندبعدی از طریق مجموعه‌ای محدود از اطلاعات آموزشی به کار می‌رود. شبکه‌های عصبی شعاعی به‌واسطه آموزش سریع و فراگیر، بسیار جالب و مفید هستند و مورد توجه خاصی قرار گرفته‌اند. معماری اصلی RBF متشکل از یک شبکه سه لایه مانند شکل ۲ می‌باشد.




شکل ۲. ساختار سه لایه‌ای RBF

الگوریتم‌های ماشین‌های بردار پشتیبان عموماً برای مسائلی که در آن‌ها دو دسته وجود دارد، استفاده می‌شوند، اما روش‌های متفاوتی برای ترکیب چند SVM و ایجاد یک الگوریتم دسته‌بندی چند کلاس پیشنهاد شده است. در این



شکل ۴. نتایج مدل سازی

شکل ۵ توزیع زمانی تصادفات مربوط به دو سال ۲۰۱۳ و ۲۰۱۴ در این استان نشان می دهد در ساعات اوج ترافیک تعداد مجروحین بسیار بیشتر می باشد که باید برای حل مشکلات ترافیکی باید اهمیت بیشتری به بررسی مشکلات ترافیکی در این ساعات پرداخت. (József Benedek ۲۰۱۶, Al-Ghamdi ۲۰۰۳)



شکل ۵. توزیع زمانی تصادفات

در فضای توزیع شده باشند ظاهراً نباید بین آن ها ارتباطی وجود داشته باشد. آخرین ابزاری که در زمینه تحلیل الگوهای پراکنش و توزیع عوارض و پدیده ها در فضا و مکان توضیح داده می شود تحلیل خودهمبستگی فضایی که آماره موران (Moran's I) نیز معروف است، می باشد. آمار فضایی خود همبستگی فضایی یکی از کاربردی ترین و مهم ترین ابزارهای تحلیلی برای تحقیق در مورد داده های فضایی از این تحلیل نه تنها به خودی خود

سپس این داده ها را در نرم افزار GIS وارد کرده و می توانیم نقاط حادثه خیز را در مشاهده کنیم. برای اینکه بتوانیم داده ها را از دیدگاه مکانی مورد بررسی قرار دهیم ابتدا باید چند پارامتر را مورد بررسی قرار دهیم که در قسمت زیر به آن می پردازیم. خودهمبستگی قوی زمانی رخ می دهد که مقادیر یک متغیر که از نظر جغرافیایی به هم نزدیک هستند باهم مرتبط باشند. اگر عوارض و مقادیر متغیرهای مربوط به آن ها به صورت تصادفی

پراکنش عوارض و مقادیر خصایص آن‌ها مورد تحلیل قرار می‌گرفتند. این تحلیل الگوی توزیع عوارض در فضا را با ملاحظه هم‌زمان موقعیت مکانی و خصیصه مورد ارزیابی قرار می‌دهد. نتایج حاصل از این تحلیل نشان می‌دهد که عوارض به‌صورت تصادفی پراکنده و یا خوشه‌ای در فضا توزیع شده‌اند. این ابزار در حقیقت آماره و یا شاخص موران را محاسبه می‌کنند و با استفاده از امتیاز استاندارد Z و Pvalue ارزیابی معنادار بودن شاخص محاسبه‌شده می‌پردازد. شاخص موران برای خودهمبستگی فضایی به‌صورت زیر محاسبه می‌شود.

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n \omega_{ij} z_i z_j}{S_0 \sum_{i=1}^n z_i^2}$$

تعداد کل عوارض جغرافیایی موجود در لایه مورد استفاده بوده و جمع کل وزن‌های فضایی می‌باشد.

$$S_0 = \sum_{i=1}^n \sum_{j=1}^n \omega_{ij}$$

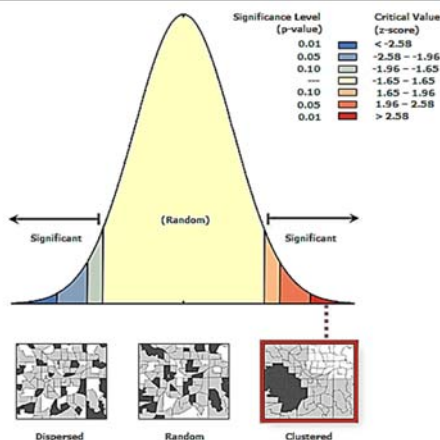
اطلاعات مفیدی در مورد ارتباط درونی عوارض به دست می‌دهد و نتایج آن برای بسیاری از تحلیل‌های پیچیده‌تر آماری نیز مورد استفاده قرار می‌گیرند. ابزار تحلیل خودهمبستگی فضایی موران به بررسی خود همبستگی فضایی بر اساس مکان دو مقدار خصیصه مورد نظر عوارض جغرافیایی می‌پردازد. فرض کنید تعدادی عوارض جغرافیایی با خصیصه مشخصی را در دست داریم، این ابزار نشان می‌دهد که الگوی پراکنش این عوارض با در نظر گرفتن مقدار خصیصه مورد مطالعه از الگوی خوشه‌ای و یا پراکنده برخوردار است. در ابزارهای قبلی فقط الگوی

(۱)

در اینجا z_i تفاضل بین مقدار خصیصه عارضه i با میانگین آن $(x_i - \bar{x})$ می‌باشد. وزن فضایی بین عارضه i و j می‌باشد. n

(۲)

Moran's Index:	0.067422	
z-score:	2.904074	■
p-value:	0.003683	




شکل ۶. الگوی خوشه‌ای

۵- نتیجه گیری

بسیار کوچک و مقدار Z محاسبه شده (قدر مطلق آن) بسیار بزرگ باشد (خارج از محدوده اطمینان قرار گیرد) آنگاه می توان فرضیه صفر را رد کرد. اگر مقدار شاخص موران بزرگ تر از صفر باشد داده ها نوعی خوشه بندی فضایی را نشان می دهند. اگر مقدار شاخص کمتر از صفر باشد عوارض مورد مطالعه دارای الگوی پراکنده می باشند. تصویرسازی نقاط حادثه خیز با استفاده از تابع چگالی کرنل انجام می شود (شکل ۷). با وزن دهی نقاط بر اساس تراکم نقطه ای هر تصادف و ارزش دهی نقاط بر اساس تعداد مجروحین نقاط حادثه خیز به صورت گرافیکی قابل مشاهده هستند (Seiji Hashimoto et al ۲۰۱۶)

تحلیل خودهمبستگی فضایی به صورت گرافیکی و عددی ارائه می دهد. خروجی گرافیکی نشان می دهد که آیا داده ها پراکنده و یا خوشه بندی شده هستند به طور کلی اگر مقدار شاخص موران نزدیک به عدد مثبت یک باشد داده ها دارای خودهمبستگی فضایی و دارای الگوی خوشه ای بوده و اگر مقدار شاخص موران نزدیک به عدد منفی باشد آنگاه داده ها از هم گسسته و پراکنده می باشند. البته این مقدار از نظر معناداری آماری سنجیده می شود؛ (شکل شماره ۶) که در اینجا با توجه به عدد $0,067$ داده ها دارای خودهمبستگی فضایی می باشند و قابلیت خوشه بندی را دارند. (۱۰). در مورد این ابزار فرضیه صفر آن است که "هیچ خوشه بندی فضای بین مقادیر خصیصه ی مرتبط با عوارض جغرافیایی مورد نظر وجود ندارد". حال زمانی که مقدار P value



شکل ۷. نقاط حادثه خیز با استفاده از روش مبتنی بر تراکم کرنل

است. همچنین تحلیل های آماری آنها از داده های تصادفات تصدیق می کند که رانندگان در شرایط مطلوب، با احتیاط کمتری رانندگی می کنند. خاص، مقاله ای از راوی و همکاران (۲۰۱۸) نشان می دهد که انسان ها به دلیل درک نادرست شرایط و یا کاهش حواس جمع در زمان های خاص، اغلب منجر به تصادفات می شوند. این موضوع در نتایج شما نیز منعکس شده است و نشان دهنده این است که باید به آموزش و آگاهی رانندگان توجه بیشتری شود. استفاده از تحلیل های مکانی-زمانی و تکنیک های داده کاوی در این تحقیق، به عنوان یک رویکرد نوین در شناسایی و تحلیل نقاط حادثه خیز برجسته بوده است. این روش ها می توانند در شناسایی الگوهای تصادفی کمک زیادی کنند. پژوهش های متعددی برخی از این تکنیک ها را تأیید کرده اند، از جمله مطالعه ای که توسط دورمان (۲۰۱۰) انجام شده و به استفاده از تکنیک های یادگیری ماشین برای پیش بینی و شناسایی نقاط خطرناک می پردازد. نتایج به دست آمده از این

در این تحقیق ما با استفاده از تحلیل های مکانی-زمانی و داده کاوی تصادفات درون شهری استان کوچیلی ترکیه را مورد بررسی قرار دادیم و با الگوریتم های مختلفی با دقت بالایی این نقاط را مدل کردیم. روش های داده کاوی نقش مهمی در تحلیل تصادفات دارند. با بررسی نقاط حادثه خیز پس از شناسایی به این نتیجه دست می توان یافت که نقاط حادثه خیز درون شهری بیشتر در نزدیکی تقاطعات بوده و اغلب در شرایط جوی مناسب و در روشنایی کافی روز اتفاق می افتند چرا که رانندگان در شرایط ایده آل با احتیاط کمتری رانندگی می کنند. این نشان می دهد که عامل انسانی تأثیر بیشتری در وقوع تصادفات دارد. این تحقیق مشخص کرده است که تصادفات بیشتر در شرایط جوی نامناسب و در روزهای با نور کافی رخ می دهد. این یافته نیز همخوانی خوبی با نتایج دیگر پژوهش ها دارد. به عنوان مثال، مطالعه ای که توسط سلطانی (۲۰۱۷) انجام شد، بیان می کند که شرایط جوی نامساعد به طور مستقیم با افزایش تصادفات مرتبط

انسانی و شرایط محیطی تمرکز بیشتری داشته باشند و از روش‌های نوین تحلیل داده بهره‌برداری کنند تا بتوانند به بهبود ایمنی جاده‌ها و کاهش تعداد تصادفات کمک کنند.

تحقیق و تحلیل‌ها، نشان می‌دهد که حوادث جاده‌ای تحت تأثیر عوامل مختلفی هستند که باید به آنها توجه ویژه‌ای کرد. در نهایت، پیشنهاد می‌شود که پژوهش‌های آینده بر روی عوامل

۶-مراجع

- Saffet Erdogan, I.Y. (2008). Tamer Baybura, Mevlut Gullu, eographical information systems aided traffic accident analysis system case study: city of Afyonkarahisar. *Accident Analysis & Prevention*, 40(1),174-181.
- SavaşDurduran, S. A (2010). decision making system to automatic recognize of traffic accidents on the basis of a GIS platform. *Expert Systems with Applications*, 37(12). 7729-7736.
- Al-Ghamdi, A.S. (2003). Analysis of traffic accidents at urban intersections in Riyadh. 717-724.
- József Benedek, S.M.C. (2016). Titus Cristian Man, Hotspots and social background of urban traffic crashes: A case study in Cluj-Napoca (Romania). *Accident Analysis & Prevention*, 87. 117-126.
- Ali Soltani, S.A. (2017). Exploring Spatial Autocorrelation of Traffic Crashes based on Severity, in Injury. 637-647.
- Seiji Hashimoto, S. RyokoSaeki, YasuhiroMimura, RyosukeAndo, ShutaroNanba, (2016). Development and application of traffic accident density estimation models using kernel density estimation. *Journal of Traffic and Transportation Engineering*, 3(3). 262-270.
- Elvik, R., (2008). A survey of operational definitions of hazardous road locations in some European countries. *Accident Analysis & Prevention*, 40(6).1830-1835.
- Kemal Polat, S.S.D. Subtractive clustering attribute weighting (SCAW) to discriminate the traffic accidents on Konya-Afyonkarahisar highway in Turkey with the help of GIS: A case study. *Advances in Engineering Software*, 2011. 42(7). 491-500.
- V.Prasannakumar, H.V. R.Charutha, N.Geetha, (2011). Spatio-Temporal Clustering of Road Accidents: GIS Based Analysis and Assessment. *Procedia - Social and Behavioral Sciences*, 21, 317-325.
- Jafari M, Tabrizi A, Esmaeilzadeh MH, Zamani A. (2022). Determining of Accidental Points of Motorcycle Accidents Using Geographic Information System (GIS) in Gonabad and Bajestan Counties, North-East Iran. *Irtiqa Imini Pishgiri Masdumiyat*. 10(3), 262-268.
- Romi Satria, M.C. (2016). GIS Tools for Analyzing Accidents and Road Design. A Review. *Transportation Research Procedia*, 18. 242-247.

Providing Intelligent Models for Traffic Accident Data Classification based on Bayesian Network, Decision Tree and Artificial Neural Network

*Ali Naderan, Assistant Professor, Department of Civil Engineering, SR.C.,
Islamic Azad University, Tehran, Iran.*

*Mohammad Reza Ahadi, Associate Professor, Transportation Research Institute,
Road, Housing and Urban Development Research Center.*

*Rasoul Zabihian, Ph.D., Candidate, Department of Civil Engineering, Kish International
Branch, Islamic Azad University, Kish Island, Iran.*

E-mail: r.zabihian@iau.ir

Received: May 2025- Accepted: August 2025

ABSTRACT

Every year, a large number of road users die or are injured as a result of traffic accidents. Analyzing accident-prone points for driving, transportation and traffic organizations, municipalities and organizations related to traffic safety is very important. In order to identify high-risk points of accidents, methods such as nearest neighbor are used, but these methods have insufficient prediction and incorrect estimation percentage. The purpose of this research is to classify accident data and provide a better method for identifying high-risk points in terms of accidents. For this purpose, the performance of decision trees, Bayesian model, and neural network were compared using common methods such as nearest neighbor and fitting. Using GIS tools and density-based methods such as kernel density function, high-risk points of accidents were identified in the form of functional maps. The results showed that decision tree method, Bayesian network and neural network have better performance than traditional methods with 83%, 83% and 78% percentage of correct estimation, respectively. Also, the results showed that the number of accidents in peak traffic periods, for example by examining the accident-prone points after identification, it can be concluded that the inner-city accident-prone points are mostly near intersections and often occur in suitable weather conditions and in sufficient daylight.

Keyword: Urban Accidents, Classification, GIS, Bayesian Network, Decision Tree and Artificial Neural Network