

بررسی تأثیر عوامل هندسی بر شدت تصادفات در راه‌های برون‌شهری با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری عمیق

مقاله علمی - پژوهشی

سارا غفاری، دانش آموخته کارشناسی ارشد، گروه مهندسی نقشه برداری، دانشکده مهندسی عمران،

دانشگاه تربیت دبیر شهید رجایی، تهران

فرهاد حسینعلی*، دانشیار، گروه مهندسی نقشه برداری، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجایی، تهران

*پست الکترونیکی نویسنده مسئول: f.hosseinali@sru.ac.ir

دریافت: ۱۴۰۴/۰۴/۱۰ - پذیرش: ۱۴۰۴/۰۸/۰۲

صفحه ۱۴۴-۱۲۳

چکیده

جاده‌ها به عنوان جزئی بسیار مهم و جدانا شدنی از حمل‌ونقل زمینی، با معضلی به نام تصادفات جاده‌ای رو به رو هستند. تصادفات جاده‌ای تأثیرات مالی و جانی گاه جبران‌ناپذیری بر زندگی مردم و جامعه دارند. به همین دلیل اهمیت بررسی ایمنی جاده‌ها و تصادفات مربوط به آن‌ها بدیهی به نظر می‌رسد. در این تحقیق دو محور از نوع هموار با نام‌های اردکان-نائین و نائین-اردکان در استان یزد بر اساس شش پارامتر هندسی و محیطی شامل: قوس افقی، فاصله دید، فاصله از تقاطع، فاصله از پل، شانه راه و کاربری محل مورد بررسی قرار گرفتند. هر دو محور بر اساس این شش پارامتر به صورت جداگانه قطعه‌بندی همگن و بر اساس شدت عوامل هندسی و محیطی حادثه‌خیز طبقه‌بندی شده و به نمایش درآمدند. پس از آن با اضافه کردن نقاط تصادف به هر دو محور، با استفاده از شاخص EPDO شدت تصادفات برای هر قطعه محاسبه و در پنج سطح طبقه‌بندی گردید. سپس با به‌کارگیری سه روش شبکه عصبی مصنوعی عمیق به نام‌های: CNN، RNN و MLFNN شدت تصادفات هر قطعه بر اساس پارامترهای هندسی و محیطی پیش‌بینی شد. دو روش RNN و CNN در بهترین حالت به صحت کلی حدود ۲۰ درصد در هر دو محور دست یافتند درحالی‌که روش MLFNN با صحت کلی حدود ۹۰ درصد در هر دو محور نتایج بسیار بهتری ارائه نمود. سپس امکان پیش‌بینی شدت تصادفات یک محور، در صورت آموزش مدل بر اساس داده‌های محور مشابه دیگر، با به‌کارگیری روش برتر این تحقیق (MLFNN) بررسی شد. شرط مشابه بودن دو محور به معنی شباهت هندسی و حجم تردد روزانه در دو محور مورد مقایسه است. این فرآیند صحت کلی ۸۸ درصد را در حالت آموزش با محور اردکان-نائین و تست محور نائین-اردکان و همچنین صحت کلی ۷۸ درصد را در حالت معکوس به دست آورد که نتایج قابل قبولی می‌باشد. بخش آخر این پژوهش، تحلیل میزان تأثیر بهبود عوامل هندسی و محیطی هر محور بر کاهش شدت تصادفات در قطعات دارای شدت تصادف خیلی بالا است. نتایج این تحلیل نشان داد که در محور اردکان-نائین، عامل وجود شانه راه و در محور نائین-اردکان، کاربری محل بیشترین تأثیر را در کاهش شدت تصادفات خواهند داشت. طبق این نتایج می‌توان اصلاحات لازم را جهت بهبود شرایط این قطعات به منظور کاهش تصادفات در نظر گرفت.

واژه‌های کلیدی: تصادفات جاده‌ای، شبکه عصبی مصنوعی عمیق، قطعه‌بندی، مناطق حادثه‌خیز، عوامل هندسی

۱- مقدمه

ناوگان هوایی، حمل و نقل جاده‌ای ستون فقرات حمل و نقل کشور را تشکیل می‌دهد. صرف‌نظر از مسأله بصره بودن یا نبودن حمل و نقل جاده‌ای، این سیستم با معضلی به نام تصادفات جاده‌ای رو به رو است (Erdogan et al., 2008). تصادفات جاده‌ای همه ساله موجب اتلاف سرمایه، گرفته شدن

سه نوع سیستم حمل و نقل عمده و متعارف در جهان وجود دارد که عبارتند از سیستم‌های حمل و نقل زمینی، هوایی و دریایی. سیستم حمل و نقل زمینی نیز به دو دسته جاده‌ای و ریلی تقسیم می‌شود. در ایران با توجه به گسترش ناکافی خطوط ریلی، نبود مسیرهای آبی و محدودیت‌های فراوان

دیگر با توجه به نبود یا کمبود داده‌های تصادف در بسیاری از جاده‌ها سعی در پاسخ به این سؤال داریم که آیا می‌توان با استفاده از مدلی که روی یک مسیر آموزش داده شده است، شدت تصادفات را در مسیر مشابه دیگری که مشخصات هندسی آن موجود است پیش‌بینی نمود؟ به عبارت دیگر، این فرضیه نوآورانه که امکان پیش‌بینی شدت تصادف در یک مسیر با آموزش مدل در یک مسیر دیگر؛ تا چه حد میسر است مورد آزمون قرار خواهد گرفت. بدین ترتیب بدون در اختیار داشتن داده‌های تصادفات و البته به شرط یافتن یک مسیر مشابه با داده‌های کافی، می‌توان مناطق حادثه‌خیز را تعیین و برای رفع حادثه‌خیزی آن‌ها اقدام نمود. در نهایت از مدل آموزش داده شده استفاده خواهد شد تا پیش‌بینی کند که در صورت اصلاح عوامل هندسی مسبب حادثه، تا چه حد می‌توان انتظار کاهش در شدت تصادفات را داشت. شاخصی که در اینجا به عنوان شدت تصادفات در نظر گرفته می‌شود یک شاخص جهانی است که در ادامه تعریف می‌شود. در واقع کاهش تصادفات یکی از عواملی است که به طریق اولی کاهش شدت را نیز در پی خواهد داشت. از جانب دیگر برای اینکه مناطق مختلف از نظر حادثه‌خیز بودن به خوبی قابل تمایز باشند از قطعه‌بندی مسیر به صورت همگن استفاده می‌شود. از آنجا که هندسه راه یک مفهوم مکانی است و موقعیت مکانی تصادفات در دسترس است، محیط مناسب انجام تحلیل‌ها، سیستم اطلاعات مکانی می‌باشد (Shariff et al., 2018).

سیستم اطلاعات مکانی علاوه بر اینکه به صورت ذاتی امکان نمایش اطلاعات مکانی نظیر هندسه راه و موقعیت تصادفات را فراهم می‌آورد، بستر مناسب و یکتایی برای انجام انواع تحلیل‌های مکانی و مرتبط با مکان است. در ادامه با بررسی گزیده‌ای از پیشینه تحقیق، جهت‌گیری تحقیق به تدریج مشخص‌تر خواهد شد.

عوامل هندسی دخیل در بروز تصادفات نیز متعدد هستند. در مجموع با در نظر گرفتن تحقیقات پیشین می‌توان به عواملی هندسی نظیر قوس افقی، شیب، قوس قائم، فاصله دید، وجود یا عدم وجود شانه خاکی راه، وجود پل و تقاطع، کاربری اطراف راه و شیب جانبی راه اشاره داشت (Cafiso, et al, 2010; Shariff et al, 2018; Sahaf, et al, 2021; Macedo, et al, 2022; Khosravi, et al, 2022).

در این بین برخی از عوامل نقش پررنگ‌تری دارند. از سوی دیگر وجود داده عامل محدودکننده‌ای در استفاده از این عوامل

جان تعداد زیادی از انسان‌ها و معلولیت و زخمی شدن تعداد بسیار بیشتری از آن‌ها در جهان می‌شود. طبق آمار سازمان بهداشت جهانی در سال ۲۰۱۸ میلادی، تلفات تصادفات جاده‌ای تعداد ۱/۳ میلیون نفر بوده است و از علل شایع مرگ‌ومیر در بین افراد ۵ الی ۲۹ سال به شمار می‌رود (WHO, 2018) و این در حالی است که ایران به نسبت جمعیت و تعداد وسائط نقلیه یکی از کشورهای پرحادثه دنیا از نظر تصادفات جاده‌ای به شمار می‌رود. از این رو یافتن راهکارهایی برای کاهش تعداد و شدت تصادفات همیشه ولی با شدت و ضعف، از دغدغه‌های مسئولان حمل و نقل، پلیس راهنمایی‌وراندگی و خودروسازان بوده و هست. به همین دلیل کاهش تمام عوامل تصادفات از جمله عامل راه، و سیله نقلیه و شیوه رانندگی به صورت پیوسته دنبال می‌شود (Effati, 2012). عامل راه یکی از عوامل دخیل در تصادفات است و راه‌های نایمن از مسبب اصلی تصادفات هستند (Mohammed, 2013). نایمن بودن راه‌ها از عوامل مختلفی ناشی می‌شود که یکی از آن‌ها عامل هندسی است (Islam et al., 2021). از عوامل متعددی که مربوط به جاده و محیط اطراف آن هستند و در موضوع ایمنی راه مطرح می‌شوند، می‌توان به عرض راه و عرض شانه، سطح روسازی راه، وضعیت گاردریل، شیب، قوس، فاصله دید، وجود تقاطع‌ها، وجود پل‌ها و فاصله از مراکز جمعیتی و کاربری‌های اطراف جاده اشاره کرد (Effati, 2012; Elvik et al., 2019; Islam et al., 2021; Mohammed, 2013). مؤمن و همکاران در سال ۲۰۲۰ میلادی به بررسی اهمیت هندسه جاده در پیش‌بینی شدت آسیب تصادفات پرداختند. نتایج کار نشان داد که شیب، عرض شانه، قوس افقی، تعداد خطوط، تعداد تقاطع‌ها و ترافیک در بزرگراه، همگی بر تصادفات و فراوانی جراحات تأثیر می‌گذارند (Moomen et al., 2020). به طور کلی می‌توان گفت هندسه راه باید به صورتی باشد که خودروها با سرعت طراحی بتوانند بدون مشکل در آن تردد نمایند، دید کافی راننده در کل مسیر برقرار باشد و عرض مسیر همواره برای مانورهای ضروری پاسخگو باشد.

این تحقیق می‌کوشد رابطه‌ای بین مهمترین عوامل هندسی و تا حدی محیطی دخیل در بروز تصادفات از یک طرف و شدت تصادفات از طرف دیگر برقرار سازد و در این راستا از چند نوع شبکه عصبی عمیق شناخته شده استفاده خواهد شد. از جانب

رابطه عرض شانه و وقوع تصادف به این نتیجه رسیدند که وقوع تصادف با عرض شانه رابطه معکوس دارد. هر چه عرض شانه بیشتر باشد، تعداد تصادفات کاهش می‌یابد (Dinu and Veeraragavan, 2011). گروس و جوانیس نیز تأثیر تغییرات عرض شانه را در ایمنی جاده و کاهش تصادفات مورد مطالعه قرار دادند و در نهایت به این نتیجه رسیدند که افزایش عرض شانه باعث کاهش تعداد تصادفات شده است (Gross and Jovanis, 2007).

تقاطع‌ها بخشی اجتناب‌ناپذیر از شبکه جاده‌ها هستند. علت اصلی تصادفات در تقاطع‌ها همگرایی جریان ترافیک، انحرافات ناگهانی به چپ یا راست و تغییر سرعت در نزدیکی آنهاست (Xu and Zhang, 2024). به همین دلیل آن‌ها را تهدیدی برای ایمنی جاده‌ها می‌دانند. والورده و جوانیس رابطه بین وقوع تصادفات و وجود تقاطع‌های جاده را بررسی کردند و دریافتند که با افزایش تقاطع‌ها در جاده، تعداد تصادفات افزایش می‌یابد به طوری که به ازای هر تقاطع، وقوع تصادف ۸ درصد افزایش را نشان داد (Valverde and Jovanis, 2006). فلاحات نیز در تحقیق خود فاصله ۱۰۰ متری تقاطع‌ها را با حادثه‌خیز شدن آن منطقه مرتبط دانست (Flahaut, 2004).

کاهش عرض مناسب جاده، وجود حفاظ و موانع جانبی و تغییر ناگهانی موقعیت راننده بر روی پل، قدرت مانور ایمن را برای راننده کاهش می‌دهد. هیلتون و میچای در تحقیقات خود به صورت جداگانه رابطه بین وقوع تصادفات و پل را بررسی کردند. آن‌ها در این زمینه به این نتیجه رسیدند که تصادفات روی پل شدیدتر از سایر نقاط جاده است (Hilton, 1973; Michie, 1980).

توانایی راننده در مشاهده روبه‌روی خود و جلوگیری از برخورد ناگهانی وسیله نقلیه با اجسام غیرمنتظره در جاده، تأثیر زیادی بر عملکرد ایمنی جاده می‌گذارد. بنابراین تأمین فاصله دید مناسب و کافی می‌تواند از وقوع تصادفات جلوگیری و باعث افزایش ایمنی راه شود. فواصل دید مختلفی وجود دارد که یکی از آن‌ها فاصله دید توقف نام دارد. فاصله دید توقف مسافتی است که خودرو در حال حرکت با سرعت طرح یا سرعتی نزدیک به آن، پس از مشاهده مانع توسط راننده و عمل ترمز، در مسیر خود طی می‌کند تا قبل از برخورد با مانع متوقف شود (Officials, 2011). فینک و کرامس فاصله دید مناسب در

خواهد بود. این تحقیق بر روی دو محور اردکان-نائین و نائین-اردکان در محدوده استان یزد انجام شده است و با توجه به داده‌های موجود لازم است در ابتدا مهمترین عوامل قابل بررسی در وقوع تصادفات انتخاب شوند.

از بین عوامل مطرح شده، داده‌های لازم برای تعداد خطوط راه، شیب عرضی و عرض شانه خاکی وجود ندارد. مضافاً اینکه در محورهای مورد مطالعه این تحقیق به دلیل هموار بودن، تغییرات شیب عرضی، وجود ندارد یا قابل صرف نظر کرد است. همچنین شیب مسیر یا همان شیب طولی نیز در این محورها ناچیز و تقریباً یکنواخت می‌باشد و پس از آنالیز مشخص شد که می‌توان از آن صرف نظر نمود. عامل عرض شانه راه عاملی است که به دقت مشخص نیست و بر این اساس می‌توان عرض آن را ثابت دانست و فقط وجود یا عدم وجود شانه راه را لحاظ نمود. با این تفاسیر عوامل حادثه‌خیزی که در این تحقیق در نظر گرفته می‌شوند عبارتند از: قوس افقی، تقاطع‌ها، شانه راه، پل، فاصله دید و کاربری محل. بنابراین در ادامه، این عوامل همراه با تحقیقات مرتبط با آنها مختصراً معرفی می‌شوند:

یک قوس افقی دو قسمت مستقیم جاده را با یک قوس به هم متصل می‌کند. پارامتر قوس افقی یکی از عوامل تأثیرگذار بر ایمنی راه است و هر چه شعاع قوس کمتر باشد خطر آن بیشتر می‌شود. طبیعتاً تعداد زیاد عامل، باعث ایجاد مشکل در جاده می‌شود. با توجه به رخداد تعداد قابل توجهی از تصادفات در قوس‌ها نسبت به سایر مکان‌ها، کروپراسرت و همکاران، تصادفات در ناحیه قوس‌ها را پیش‌بینی کردند (Kronprasert et al., 2021) و زگر و همکاران در بررسی رابطه بین میزان تصادفات و قوس‌ها نشان دادند با افزایش تعداد قوس‌ها، تعداد تصادفات نیز افزایش یافت به گونه‌ای که تصادفات در قوس‌ها حدود ۱/۵ تا ۴ برابر بیشتر از جاده‌های مستقیم اتفاق می‌افتاد (Zegeer et al., 1994). نتیجه تحقیقات گلنون نیز افزایش ۲۵ الی ۳۵ درصدی تصادفات در قوس‌ها را نسبت به مسیر مستقیم نشان می‌داد (Glennon, 1987).

شانه راه بخشی از کف جاده است که در کناره‌های جاده قرار گرفته و برای توقف اضطراری خودروها استفاده می‌شود. عرض آن در هنگام سبقت گرفتن و انحراف به چپ و راست در هنگام رانندگی احساس آرامش و آسایش بیشتر و قدرت کنترل بهتر را به راننده می‌دهد. دینو و ویراراگاوآن با بررسی

روش با بالاترین دقت شناسایی می‌شود. روش‌های مختلفی برای شناسایی نقاط حادثه‌خیز و مدیریت ایمنی راه‌ها وجود دارد. تحلیل خوشه‌های تصادفات یکی از روش‌هایی است که برای شناسایی نقاط حادثه‌خیز استفاده می‌شود. برای نمونه خسروی و همکاران در سال ۱۴۰۱ با هدف شناسایی نقاط حادثه‌خیز، علل تصادفات و بهبود وضعیت این نقاط بر روی داده‌های تصادفات محور ده بالا در استان یزد از چند روش مختلف خوشه‌بندی شامل K -means، K -medoids و DBSCAN استفاده کردند و خوشه متراکم را به عنوان خوشه حادثه‌خیز معرفی نمودند. همچنین نقاط حادثه‌خیزی که از روش‌های $Getis-Ord\ Gi^*$ ، تخمین تراکم هسته و موران محلی به دست آمده بود را با هم تلاقی دادند تا نقاط مشترک به عنوان حادثه‌خیزترین نقاط معرفی شوند. در بخش آخر این تحقیق اثر شیب و انحنای قوس بر وقوع تصادفات نشان داده شد (Khosravi et al., 2022). از دیگر رویکردهای حیاتی برای تجزیه و تحلیل بهتر تصادفات و مدیریت ایمنی جاده‌ها، قطعه‌بندی شبکه راه‌ها به بخش‌های کوچکتر است. یکی از روش‌های متداول مورد استفاده برای قطعه‌بندی جاده‌ها بر مبنای یک مقدار ثابت همگن شناخته می‌شود. نیر و بهاواتراتان ترکیبی از پارامترهای هندسی مانند نزدیکی به تقاطع‌ها، شعاع قوس، عوامل محیطی مانند کاربری زمین، و تصاویر سنجنش از دور را برای قطعه‌بندی جاده‌ها به کار گرفتند. آن‌ها از سنجنش از دور و سیستم اطلاعات مکانی برای استحصال و پردازش داده‌ها استفاده و با خوشه‌بندی مکان‌های تصادف، روابط موقعیتی بین آن‌ها را تجزیه و تحلیل کردند (Nair and Bhavathrathan, 2022). در مطالعه دیگری کافیسو و همکاران، تأثیر قطعه‌بندی جاده بر عملکرد ایمنی را مورد بررسی قرار دادند. آن‌ها روش‌های مختلف قطعه‌بندی را بر اساس طول ثابت، پارامترهای قوس جاده، شیب جاده و بخش‌های همگن جاده مقایسه کردند و مشخص نمودند که ایجاد حداقل طول قطعه پیشنهاد شده ۰/۱ مایل (تقریباً ۱۶۰ متر)، برای به دست آوردن نتایج قابل قبول بسیار مهم است (Cafiso et al., 2018). آنان با تکیه بر کار قبلی خود در سال ۲۰۱۰ میلادی مسیری را بر اساس پارامترهای هندسی قطعه‌بندی کردند که منجر به یک روش قطعه‌بندی همگن شد و بخش‌هایی را با خطر بالا که مرتبط با طراحی هندسی بود، شناسایی کردند (Cafiso et al., 2010). دی‌آگوستینو

قوس‌ها را بررسی و بیان کردند که میزان تأثیر منفی فاصله دید کم در قوس‌هایی با شعاع کمتر بیشتر نمایان است (Fink and Krammes, 1995). بربل و همکاران بررسی فاصله دید در طول مسیر را با مقایسه این پارامتر در محیط دوبعدی و سه‌بعدی انجام دادند و بهتر بودن نتایج تشخیصی را منوط به در نظر گرفتن ارتفاع دانستند (Berbel et al., 2017). سهاف و همکاران نیز به اهمیت فاصله دید در تصادفات اشاره کردند و با استفاده از GIS و ابزارهای آن به محاسبه فاصله دید پرداختند (Sahaf et al., 2021).

کاربری محل اطراف جاده عاملی محیطی است که می‌تواند در بروز تصادفات نقش‌آفرین باشد. محدوده‌های اطراف جاده می‌تواند در دسته‌های مختلفی مانند مناطق صنعتی، کشاورزی و مسکونی قرار گیرند. هر کاربری مجاور راه بر اساس میزان درخواست کاربران جاده می‌تواند در رخداد تصادفات حتی به میزان اندک تأثیرگذار باشد. عفتی و همکاران با هدف تحلیل عوامل مکانی مؤثر بر تمرکز تصادفات در تصادفات برون شهری، کاربری مجاور راه را به عنوان یکی از عوامل، مورد بررسی قرار دادند و این عامل را از نوع عوامل گسسته و در چهار دسته مسکونی، کشاورزی، صنعتی و تجاری تقسیم نمودند (Effati et al., 2014). نیر و بهاواتراتان نیز به منظور استخراج اطلاعات مربوط به جاده با استفاده از تصاویر ماهواره‌ای برای قطعه‌بندی مسیر و شناسایی مناطق حادثه‌خیز، کاربری محل را مورد بررسی قرار دادند (Nair and Bhavathrathan, 2022). استینبرگن و همکاران هم به اهمیت این عامل در تمرکز تصادفات اشاره داشته‌اند (Steenberghen et al., 2004).

تحقیقات متعددی در خصوص پارامترهای هندسی تأثیرگذار بر تصادف در سال‌های مختلف انجام شده است. مطالعات ذکر شده برگزیده‌ای از آن‌ها بود که با توجه به شرایط منطقه و مسیر مورد مطالعه انتخاب شده بودند و این عوامل به نوع مسیر و نحوه جمع‌آوری اطلاعات بستگی دارند. در اکثر این مطالعات یک عامل مورد بررسی قرار گرفته شده بود و تعدادی نیز جمعی از موارد را به صورت همزمان بررسی می‌کردند.

پیش‌بینی وقوع و شدت تصادفات و شناسایی و پیش‌بینی مکان‌های حادثه‌خیز با استفاده از روش‌های طبقه‌بندی و شبکه عصبی عمیق، رویکردی رایج در مقالات مختلف پژوهشی است. اغلب چندین روش با هم مقایسه می‌شوند و بهترین

ارتقای ایمنی جاده‌ها، کاهش تعداد و شدت تصادفات را افزایش می‌دهد. در نهایت با در نظر گرفتن رویکرد این تحقیق در استفاده از جدیدترین الگوریتم‌های هوش مصنوعی و با توجه به نتایج به دست آمده از مرور تحقیقات پیشین، سه نوع شبکه عصبی مصنوعی عمیق که عبارتند از MLFNN و CNN و RNN برای پیاده‌سازی و آزمون در این تحقیق در نظر گرفته شدند.

در ادامه این مقاله، ابتدا روش تحقیق و منطقه مورد مطالعه معرفی خواهد شد که در آن در حد گنجایش مقاله، شبکه‌های عصبی مصنوعی مورد استفاده تشریح خواهند شد. پس از آن بخش پیاده‌سازی و متعاقب آن بخش نتایج و بحث قرار دارد و در پایان مقاله نیز بخش نتیجه‌گیری و پیشنهادها جای گرفته است.

۲- مواد و روش

عملیات آماده‌سازی داده‌های این پژوهش در محیط‌های نرم‌افزاری ArcGIS و Google Earth انجام شده است. با استفاده از نقشه‌های موجود، قوس‌های افقی راه مشخص شد. موقعیت پل‌ها و تقاطع‌ها و همچنین وجود شانه خاکی راه و کاربری محل در طول راه بر روی تصاویر ماهواره‌ای موجود در Google Earth تعیین گردید. فاصله دید نیز با استفاده از امکانات نرم‌افزار ArcGIS و توپوگرافی مسیر معین شد.

با توجه به مطالعات پژوهشگران دیگر در حوزه عوامل هندسی مؤثر بر تصادفات جاده‌ای و تحقیقاتی که به شناسایی نقاط حادثه‌خیز پرداخته‌اند و در نهایت تحقیقاتی که پیش‌بینی شدت تصادف را مد نظر داشته‌اند، در این تحقیق برای تحلیل مناطق حادثه‌خیز مسیر از روش قطعه‌بندی راه استفاده شده است. قطعه‌بندی مسیر انواع مختلفی نظیر قطعه‌بندی با طول ثابت و قطعه‌بندی همگن دارد. در قطعه‌بندی همگن از ویژگی‌های مختلف جاده مانند پارامترهای هندسی استفاده می‌شود و اگر این پارامترها در هر قطعه مقدار ثابتی داشته باشند، همگن نامیده می‌شوند. پارامترهای قوس، شیب، شانه راه، فاصله دید، فاصله از تقاطع، فاصله از پل و کاربری محل برای قطعه‌بندی همگن انتخاب شدند ولی به علت تغییرات کم شیب در دو محور هموار اردکان- نائین و نائین- اردکان، این عامل حذف شد و شش پارامتر دیگر برای قطعه‌بندی مسیر مورد بررسی قرار گرفتند. هر کدام از عوامل با توجه به

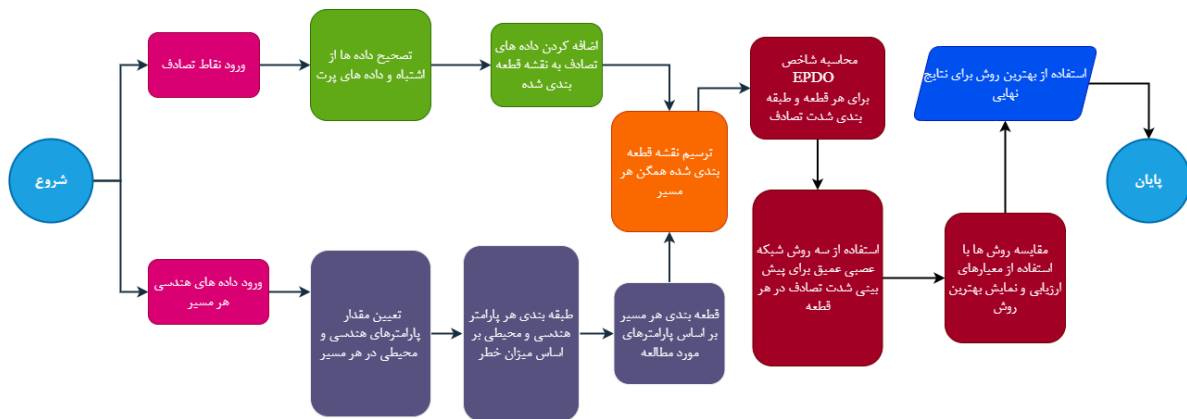
راهنمای ایمنی بزرگراه (HSM) را برای ارزیابی ایمنی چندین بزرگراه در ایتالیا مورد استفاده قرار داد و روش قطعه‌بندی همگن را در آن‌ها اجرا کرد (D'Agostino, 2014). ماسدو و همکاران در سال ۲۰۲۲ میلادی با هدف بهبود پیش‌بینی تصادفات، قطعه‌بندی همگن را به روش فضایی تخمین تراکم هسته (KDE) در بزرگراه‌ها انجام دادند و بر پایه آن به برآورد شدت تصادفات پرداختند. نتایج به دست آمده حاکی از آن است که افزایش شیب و انحنای مسیر، افزایش تصادفات را به همراه دارد (Macedo et al., 2022). در این تحقیق قطعه‌بندی همگن با در نظر گرفتن حداقل طول هر قطعه ۱۶۰ متر مورد استفاده قرار گرفت.

در دیگر رسو، روش‌های متنوعی مورد استفاده برای پیش‌بینی شدت تصادفات قرار گرفته است که روش‌های یادگیری عمیق از جمله موفق‌ترین آن‌ها است. رضاپور و همکاران در سال ۲۰۱۹ میلادی برای بررسی شدت تصادفات موتور سیکلت‌ها از روش‌های مختلف یادگیری عمیق از جمله RNN, DNN, FNN, SLP استفاده کردند. نتایج نشان داد که روش RNN نسبت به مابقی روش‌ها نتایج بهتری داشته است (Rezapour et al., 2019). سامن و همکاران در سال ۲۰۱۷ میلادی با استفاده از ویژگی‌های محیطی و هندسی مسیر با به‌کارگیری روش‌های FNN, RNN, CNN به پیش‌بینی شدت تصادفات پرداختند. ارزیابی‌های آنان نشان داد که هر سه روش، دقتی نزدیک به هم و مناسب دارند (Sameen et al., 2019). آکین و آکا نیز در سال ۲۰۱۰ میلادی از MLFNN به منظور پیش‌بینی تصادفات در تقاطع‌ها استفاده کردند و نتایج قابل قبولی را ارائه دادند (Akin and Akba, 2010). جیما و سیپوس در سال ۲۰۲۲ میلادی تحقیقی با هدف تحلیل تأثیر شکل هندسی جاده بر تصادفات ترافیکی با استفاده از MLFNN انجام دادند و در تقاطع‌ها و قوس‌های افقی رابطه معناداری با حجم تلفات تصادفات یافتند (Jima and Sipos, 2022).

مطالعات ذکر شده تعدادی از تحقیقات متعدد در زمینه تصادفات جاده‌ای است. تحقیقات انجام گرفته از یک سو برتری مطلق هیچ روشی را اثبات نکرده‌اند و از سوی دیگر، عوامل حادثه‌خیز متفاوتی را لحاظ نموده‌اند. از این گذشته، افزایش روزافزون تصادفات، فوتی‌ها، جراحات و خسارات ناشی از آن برای مردم و جامعه، اهمیت ارائه راهکارهایی برای

استفاده از سه روش از روش‌های شبکه عصبی عمیق، یعنی شبکه عصبی پیچشی (CNN)، شبکه عصبی بازگشتی (RNN) و شبکه عصبی چندلایه پیشخور (MLFNN). (Rezapour et al., 2019; Sameen et al., 2019) شدت تصادفات در هر قطعه براساس عوامل هندسی و محیطی پیش‌بینی می‌شود. هدف بعدی، انتخاب بهترین روش پیش‌بینی شدت تصادف با مقایسه صحت و دقت نتایج حاصل از سه روش مذکور است. این کار با استفاده از شاخص‌های آماری معتبر و با در دست داشتن نسبتی از داده‌ها به عنوان داده تست، انجام خواهد شد. با مشخص شدن روش برتر، امکان داشتن آموزش بر اساس یک محور و تست بر روی محور دیگر سنجیده می‌شود. همچنین با به کارگیری همان روش برتر، به نوعی آنالیز حساسیت بر روی قطعاتی با شدت خیلی بالا از هر دو مسیر انجام می‌شود تا مشخص شود با بهبود کدامیک از عوامل ششگانه حادثه ساز، شدت تصادفات، کاهش بیشتری را نشان خواهد داد. شکل (۱) روند اجرای این تحقیق را می‌دهد. در ادامه توضیحاتی درباره منطقه مورد مطالعه، روش مورد استفاده برای محاسبه شدت تصادف یعنی EPDO و مبانی نظری شبکه‌های عصبی مصنوعی مورد استفاده ارائه می‌شود.

ویژگی‌شان بر اساس میزان خطر کم و زیادی که می‌تواند داشته باشند، دسته‌بندی می‌شوند تا عددی را به عنوان کلاس به خود اختصاص دهند. هر محور، بدین شیوه بر اساس هر عامل به صورت جداگانه قطعه‌بندی و سپس شش نقشه قطعه‌بندی حاصل، با یکدیگر تلفیق می‌گردند. این تلفیق بر اساس اشتراک قطعات است، به این صورت که هر قطعه همگن، طولی از مسیر خواهد بود که مقدار آن در هر یک از شش عامل در نظر گرفته شده ثابت باشد. در ادامه کار، شرط حداقل طول ۱۶۰ متر برای هر قطعه به منظور به دست آوردن نتیجه معقول اعمال می‌شود (Cafiso et al., 2018) و بدین ترتیب قطعات بسیار کوتاه حذف می‌گردند تا نقشه قطعه‌بندی نهایی مسیر به دست آید. در مرحله بعد برای نقاط تصادف ضرایب شاخص همسنگ خسارت مالی (EPDO) تعیین شده و شدت تصادفات هر نقطه به مسیر قطعه‌بندی شده منتسب می‌شود (در مورد این شاخص در زیربخش‌های بعدی توضیح داده خواهد شد). مجموع EPDOها در هر قطعه مشخص و سپس مقدار بحرانی در هر مسیر که بر اساس دو برابر میانگین آن در هر مسیر است، محاسبه می‌شود (Khalilzade et al., 2013). با استفاده از مقدار بحرانی EPDO، هر قطعه طبقه‌بندی می‌گردد. این طبقه نشان از مقدار حادثه‌خیز بودن آن قطعه دارد. در مرحله بعد با



شکل ۱. روند اجرای تحقیق

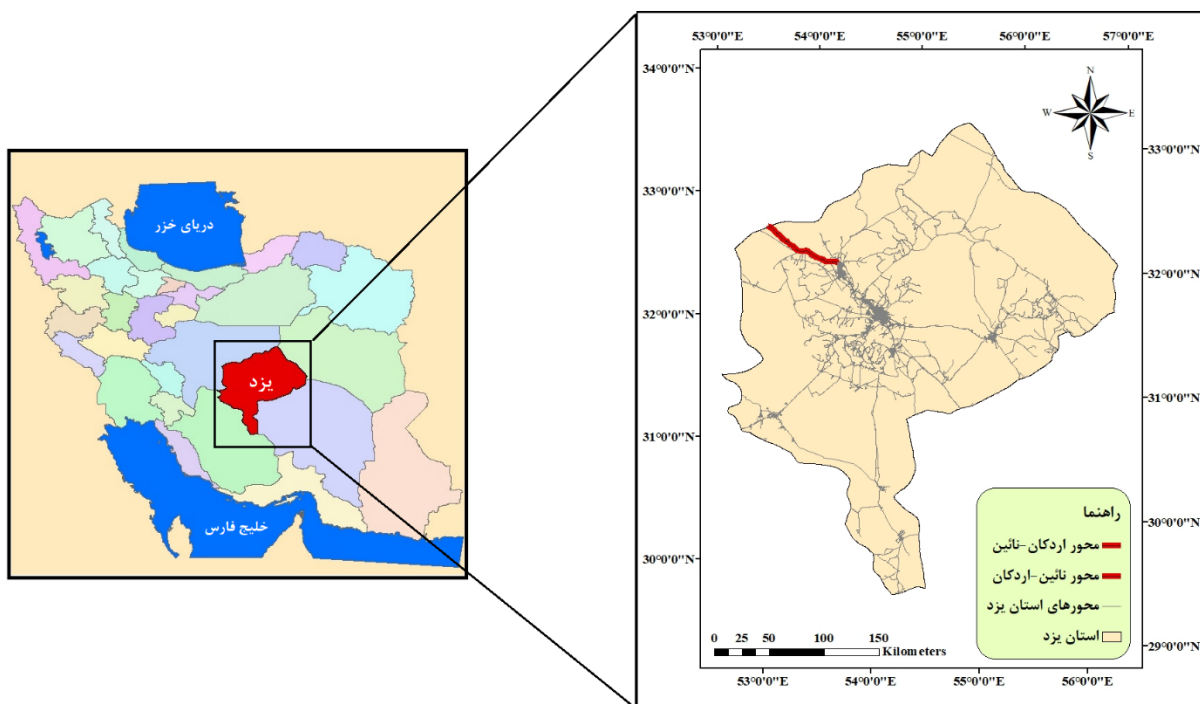
هموار و کویری عبور می‌کنند. حدود ۷۰ کیلومتر از طول هر یک از این دو محور در استان یزد قرار دارد و در این تحقیق بررسی می‌شود. به همین دلیل مبدأ و مقصد این دو محور، شهر

۱-۲- منطقه مورد مطالعه

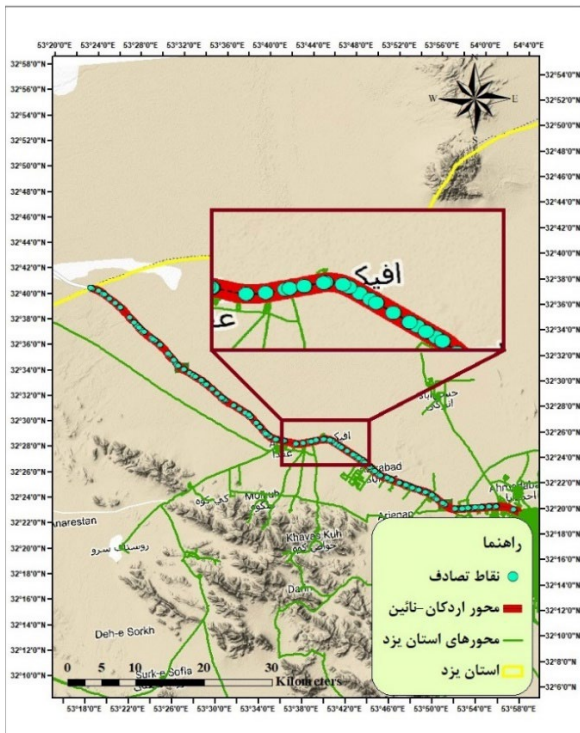
جاده‌های مورد مطالعه در این تحقیق، دو محور در استان یزد به نام‌های اردکان- نائین و نائین- اردکان هستند که از مناطق

تصادف در هر دو محور مربوط به دوره‌ی پنج ساله از ۱۳۹۳ الی ۱۳۹۷ هستند و از سازمان راهداری و حمل و نقل جاده‌ای استان یزد اخذ گردیدند؛ در حالیکه جمع‌آوری این داده‌ها توسط پلیس راهور انجام شده است. این داده‌ها با ابزار تعیین موقعیت ماهواره‌ای توسط مأموران پلیس راه ثبت و ضبط می‌شوند و علاوه بر موقعیت مکانی نقاط تصادف، شامل ویژگی‌های کمی و کیفی مربوط به آن مانند آب‌وهوای لحظه تصادف، اطلاعات راننده، وسیله نقلیه، سطح جاده و دیگر موارد هستند. این داده‌ها به دلیل اخذ از یک منبع معتبر که تنها منبع موجود نیز به شمار می‌رود، قابل اعتماد می‌باشند و صحت کلی آن‌ها با بررسی‌های میدانی مطابقت دارد. شایان ذکر است محور اردکان- نائین شامل ۴۳۱ نقطه و محور نائین- اردکان شامل ۵۲۴ نقطه تصادف می‌شود. شکل (۳) و (۴) توزیع نقاط تصادف را در این دو محور نشان می‌دهد.

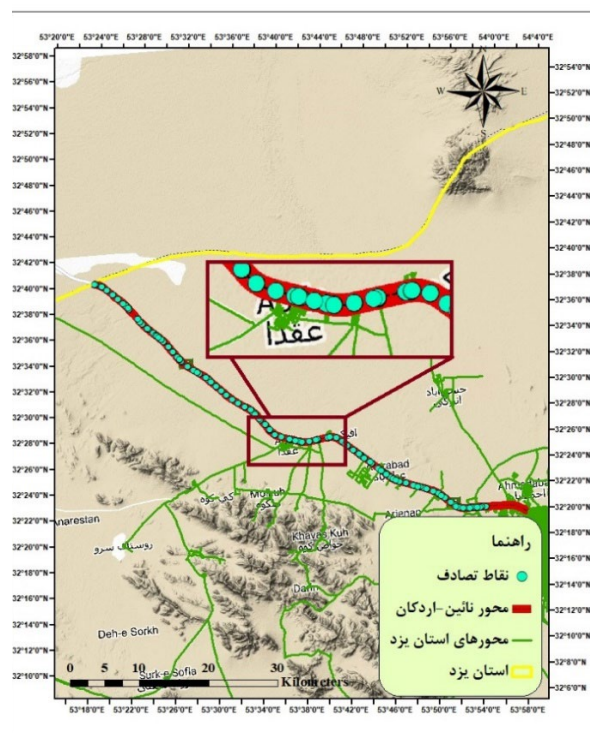
اردکان و مرز استان یزد می‌باشد (به جای شهر نائین در استان اصفهان که در حدود ۳۰ کیلومتر دورتر قرار دارد). دلیل این امر نیز آن است که تنها داده‌های استان یزد در دسترس بوده‌اند. هرچند که الزامی در منتهی شدن مسیر به یک شهر وجود ندارد و این موضوع، خللی در تحقیق ایجاد نمی‌کند. شکل (۲) موقعیت مکانی این دو محور را نشان می‌دهد. مسیر رفت و برگشت این محور، مسیر اصلی ارتباط دهنده پایتخت به شهر یزد می‌باشد و همه‌ساله تصادفات زیادی در آن رخ می‌دهد. به همین دلیل است که این دو مسیر برای مطالعه این تحقیق انتخاب شدند. موقعیت مکانی تصادفات این دو محور به همراه اطلاعات توصیفی آن نظیر تاریخ و زمان وقوع تصادف، علت تصادف و شدت تصادف توسط پلیس راه استان یزد ثبت شده است. این نقاط پس از پیش پردازش‌ها و حذف داده‌های پرت، برای تحلیل در تحقیق مورد استفاده قرار می‌گیرند. نقاط



شکل ۲. موقعیت مکانی دو محور مورد مطالعه



شکل ۴. نمایش نحوه توزیع نقاط تصادف در محور اردکان-نائین



شکل ۳. نمایش نحوه توزیع نقاط تصادف در محور نائین-اردکان

مکان‌ها و یا مقاطعی دیگر از مسیر، آن نقطه را پرتصادف و حادثه‌خیز اعلام می‌کنند. از این مناطق حادثه‌خیز می‌توان در اعتبارسنجی پیش‌بینی شدت تصادفات با استفاده از عوامل مختلفی که بر رخداد تصادفات مؤثر هستند، استفاده کرد. شاخص‌های آماری مختلفی مانند شاخص تعداد تصادف، نرخ تصادف، فراوانی تصادف، چگالی تصادف، امتیاز تصادف وجود دارد. شاخص همسنگ خسارت مالی (EPDO) یکی از این شاخص‌هاست که وجود تعداد تصادف و شدت تصادف را در کنار هم دارد. مرسوم بودن استفاده از این شاخص در سازمان‌های دولتی مانند وزارت راه و ترابری علت دیگر انتخاب آن است (Khalilzade et al., 2013). یکی از روش‌ها برای شناسایی نقاط حادثه‌خیز، بررسی اولویت‌بندی شدت تصادفات است. شاخص همسنگ خسارت مالی (EPDO) به تصادف برحسب شدت آن (منظور فوتی، جرحی و خسارتی بودن) وزن و ضریبی اختصاص می‌دهد تا امتیاز ترکیبی بین فراوانی و شدت حاصل گردد. این مفهوم اولین بار توسط تمبوری و اسمیت با عنوان شاخص ایمنی مطرح شده است و رابطه کلی آن در رابطه (۱) قابل مشاهده است (Tamburri and Smith, 1970).

علاوه بر موقعیت نقاط تصادف و شدت تصادفات هر نقطه، موقعیت و وضعیت عوامل هندسی و محیطی انتخابی در این تحقیق بر روی هر دو محور نیز از جمله داده‌های ورودی به شمار می‌روند. عوامل متعدد محیطی و هندسی در طول مسیر وجود دارد که می‌تواند بر رخداد تصادف مؤثر باشد. عوامل استفاده شده در این تحقیق با توجه به مطالعات پیشین، وجود داده و شرایط منطقه انتخاب شده‌اند که بحث آن در بخش‌های قبلی گذشت و عبارتند از: قوس افقی، شانه راه، فاصله دید، فاصله از تقاطع، فاصله از پل و کاربری محل.

۲-۲- شاخص‌های آماری ارزیابی شدت تصادفات

روش‌های مختلفی برای شناسایی نقاط پرتصادف با استفاده از معیارهای اعتبارسنجی آماری وجود دارد. هر کدام از این روش‌ها تأثیر یک عامل یا عوامل را بررسی می‌کنند. این روش‌ها به بررسی خود تصادف می‌پردازند نه عواملی که بر بروز تصادفات دخالت داشته‌اند. به عبارتی دیگر این معیارها با توجه به فراوانی و شدت تصادفات در هر مکان نسبت به

$$EPDO = \alpha Fat + \beta Inj + \gamma Pdo \quad (۱)$$

ایجاد می‌کند و اگر اطلاعات فقط از طریق لایه های ورودی، پنهان و خروجی به جهت جلو حرکت کند، این شبکه پیشخور نامیده می‌شود؛ زیرا هیچ پیوند بازخوردی وجود ندارد که از طریق آن خروجی مدل به خود بازخورد داده شود (Dong et al., 2018; Rosenblatt, 1958; Yu et al., 2017). در این مطالعه، مدل یک نگاشت غیرخطی بین مقادیر ورودی (پیش‌بینی‌کننده‌های تصادف) و پارامترهای خروجی (شدت تصادف) را نشان می‌دهد. نورون‌ها اتصال سیستماتیک بردارهای وزنی هستند که معمولاً در لایه‌هایی با اتصالات کامل بین لایه‌های متوالی ساختار یافته اند. سیگنال خروجی تابعی از ورودی‌های گره است که توسط یک تابع فعال‌سازی ساده اصلاح می‌شود (Dong et al., 2018). آنچه در شبکه‌های عصبی بیش از همه برای محققان جلب توجه کرده است، امکان یادگیری است. متداول‌ترین الگوریتم یادگیری در شبکه‌های عصبی، روش پس‌انتشار آست که توسط ورپوس در سال ۱۹۷۴ میلادی ایجاد و بعدها توسط روملهارت و پارکر دوباره ارائه شد. این الگوریتم برای کاهش تابع خطا با استفاده از یک رویکرد تکراری طراحی شده که در رابطه (۲) نشان داده شده است (Gardner and Dorling, 1998). که در آن d_j و o_j^m به ترتیب نشان دهنده خروجی و پاسخ جریان گره "j" در لایه خروجی و "L" نشان دهنده تعداد گره‌ها در لایه خروجی است. در این روش، اصلاحاتی در پارامترهای وزن انجام می‌شود و همانطور که در رابطه (۳) نشان داده شده است به مقادیر قبلی اضافه می‌شود.

$$E = \frac{1}{2} \sum_{i=1}^L (d_j - o_j^M)^2 \quad (۲)$$

$$\begin{cases} \Delta w_{i,j} = -\mu \frac{\partial E}{\partial w_{i,j}} \\ \Delta w_{i,j}(t+1) = \Delta w_{i,j} + \alpha \Delta w_{i,j}(t) \end{cases} \quad (۳)$$

که در آن Fat تعداد تصادفات فوتی، Inj تعداد تصادفات جرحی و Pdo تعداد تصادفات خسارتی می‌باشد. ضرایب وزنی α, β, γ که بر اساس تجربه متخصصان و میانگین هزینه تصادفات فوتی و جرحی نسبت به خسارتی است. نظرات مختلفی درباره عدد این ضرایب وجود دارد که بر اساس نظر وزارت راه و ترابری ایران که هم‌اکنون در حال استفاده است، ضریب فوتی ۹، ضریب جرحی ۳ و در نهایت ضریب خسارتی ۱ می‌باشد. همچنین به منظور شناسایی بخش حادثه‌خیز، مقدار بحرانی یعنی دو برابر میانگین شاخص EPDO تمامی بخش‌ها محاسبه می‌شود. هرچه عدد حاصل از این مقدار بحرانی بیشتر باشد، آن بخش از راه از نظر این شاخص حادثه‌خیز خواهد بود (Khalilzade et al., 2013).


۳-۲- شبکه‌های عصبی مصنوعی برای پیش‌بینی شدت تصادفات

در این بخش شبکه‌های عصبی مصنوعی مورد استفاده در این تحقیق به صورت مختصر تشریح می‌گردند.

۳-۲-۱- شبکه عصبی چندلایه پیشخور (MLFNN)

در یادگیری ماشینی، شبکه‌های عصبی خانواده‌ای از مدل‌های یادگیری بیولوژیکی هستند. یک مدل ساده NN یک اتصال متقابل از نورون‌ها یا گره‌ها است که شامل سه لایه به نام لایه‌های ورودی، پنهان و خروجی است. ترکیبی از چندین لایه پنهان با عنوان شبکه عصبی پرسپترون چندلایه (MLP) را

به عامل هموارسازی به دلیل توانایی آن در مراقبت از تغییرات سریع بین وزنه‌ها اشاره دارد (Mia et al., 2015). در شکل (۵) نمونه‌ای از شبکه دارای یک لایه پنهان و چند لایه پنهان قابل مشاهده است.




شکل ۵. ساختار شبکه عصبی ساده و عمیق (Lateef et al., 2019)

عملیات کانولوشن در شبکه‌ها استفاده می‌شود. ReLU خروجی را به صورت عنصری ارائه می‌دهد که مقادیر منفی را در نقشه ویژگی با صفر جایگزین می‌کند و مشکلات دنیای واقعی را با استفاده از غیرخطی بودن آن در شبکه حل می‌شود. علاوه بر این، نمونه برداری فرعی یا پایین نیز به عنوان ادغام مکانی نامیده می‌شود که برای کاهش ابعاد هر نقشه ویژگی مورد استفاده قرار می‌گیرد، اما مهم‌ترین اطلاعات را حفظ می‌کند. پیشینه، میانگین یا مجموع برخی از انواع مختلف ادغام مکانی موجود است. ادغام، حداکثر از بزرگترین عنصر در نقشه ویژگی اصلاح شده در هر محله مکانی تعریف شده استفاده می‌کند. ادغام میانگین همچنین می‌تواند به جای بزرگترین عنصر یا مجموع همه عناصر در آن پنجره در نظر گرفته شود. علاوه بر این، در یک پرسپترون چند لایه سنتی، لایه متصل از یک تابع فعال‌سازی پیشینه هموار در لایه خروجی استفاده می‌کند. خروجی از لایه‌های کانولوشن و ادغام نشان دهنده ویژگی‌های سطح بالای داده‌های ورودی است. دلیل اصلی پیاده سازی لایه کاملاً متصل، قابلیت آن در طبقه بندی ویژگی‌ها در داده‌های ورودی به کلاس‌های مختلف بر اساس مجموعه داده‌های آموزشی است (LeCun et al., 2015).

$W_{i,j}$ پارامتر بین گره i و j را نشان می‌دهد، Δ نرخ یادگیری است که میزان تنظیم را کنترل می‌کند، α یک ضریب حرکت بین ۰ و ۱ است و t تعداد تکرارها را نشان می‌دهد. پارامتر α

۲-۳-۲- شبکه عصبی پیچشی

یکی دیگر از شبکه‌های عصبی مؤثر در حوزه‌های بینایی ماشین، طبقه بندی رایانه و پیش بینی تصادفات، شبکه‌های عصبی کانولوشنال یا پیچشی (CNN) است (Wenqi et al., 2017). اولین CNN توسط یان لی‌چان توسعه داده شد (شکل ۶) که در بسیاری از حوزه‌ها در بینایی کامپیوتر و محیط یادگیری عمیق مشارکت داشته است. این روش به عنوان LeNet نیز شناخته می‌شود و در سال‌های اولیه عمدتاً برای کارهای تشخیص کاراکتر مانند ارقام فشرده، کدها و دست خط استفاده می‌شد. همچنین این شبکه می‌تواند داده‌ها را در قالب آرایه‌های چندگانه (تصاویر رنگی، سیگنال‌ها، توالی‌ها، صدا و ویدیو) بسته به ابعاد عملیات کانولوشن (1D، 2D یا 3D) پردازش کند. به طور معمول، چهار فرآیند در عملیات CNN دخالت دارند: کانولوشن، ادغام یا نمونه برداری فرعی، ReLU غیرخطی و طبقه بندی (لایه کاملاً متصل). این عملیات‌های گفته شده بلوک‌های سازنده CNN را تشکیل می‌دهند. ویژگی‌ها را می‌توان از داده‌های ورودی مانند تصویر و سری‌های زمانی با استفاده از عملیات کانولوشن استخراج کرد. تعاملات فضایی بین داده‌های نمونه، ورودی را از طریق یادگیری زیرمجموعه‌های کوچک داده‌های ورودی حفظ می‌کند. واحد خطی اصلاح شده (ReLU) یک عملیات غیرخطی اضافی است که پس از هر



شکل ۶. نمونه ای از معماری مدل شبکه عصبی پیچشی (Sameen et al., 2019)

۳-۲-۳- شبکه عصبی بازگشتی

(LSTM) را برای حل چنین مشکلاتی پیشنهاد کردند. واحدهای پنهان با بلوک های حافظه در LSTM جایگزین می شوند که حاوی سلول های حافظه متصل به خود و سه واحد ضربی (ورودی، خروجی و دروازه های فراموشی) هستند. این گیت ها عملیات خواندن، نوشتن و تنظیم مجدد را در بلوک حافظه فعال و رفتار بلوک حافظه را کنترل می کنند. شکل (۷) نمودار یک واحد LSTM را نشان می دهد. اگر مجموع ورودی ها در مرحله زمانی t و فعال سازی های مرحله زمانی قبلی آن باشد، بروز رسانی های LSTM برای مرحله زمانی i با ورودی های x_t و h_{t-1} هستند (Donahue et al., 2015):

$$i_t = \sigma(W_{xi} \cdot x_t + W_{hi} \cdot h_{t-1} + W_{ci} \cdot c_{t-1} + b_i) \quad (4)$$


$$f_t = \sigma(W_{xf} \cdot x_t + W_{hf} \cdot h_{t-1} + W_{cf} \cdot c_{t-1} + b_f) \quad (5)$$

$$c_t = i_t \cdot \tanh(W_{xc} \cdot x_t + W_{hc} \cdot h_{t-1} + b_c) + f_t \cdot c_{t-1} \quad (6)$$

$$o_t = \sigma(W_{xo} \cdot x_t + W_{ho} \cdot h_{t-1} + W_{co} \cdot c_t + b_o) \quad (7)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (8)$$

که در آن σ یک غیرخطی از نظر عنصر مانند یک تابع سیگموئید است، W ماتریس وزن، x_t ورودی در مرحله زمانی t ، h_{t-1} بردار حالت پنهان مرحله زمانی قبلی و b_i نشان دهنده بردار بایاس ورودی است.



شکل ۷. ساختار سلول حافظه در LSTM شبکه عصبی بازگشتی (Rezpour et al., 2020)

۲-۴- معیارها و شاخص‌های ارزیابی روش‌های پیش‌بینی

ماتریس ابهام (Confusion Matrix) جدولی است که تعداد پیش‌بینی‌های مثبت واقعی (TP)، مثبت کاذب (FP)، منفی درست (TN) و منفی کاذب (FN) را ارائه می‌دهد (Narkhede, 2018) و این مقادیر به شرح زیر هستند:

- مثبت واقعی (TP): تعداد نمونه‌هایی که به درستی به عنوان مثبت توسط مدل پیش‌بینی شده‌اند.

- مثبت کاذب (FP): تعداد نمونه‌هایی که به اشتباه توسط مدل به عنوان مثبت پیش‌بینی شده‌اند.

- منفی واقعی (TN): تعداد نمونه‌هایی که به درستی توسط مدل منفی پیش‌بینی شده‌اند.

- منفی کاذب (FN): تعداد نمونه‌هایی که به اشتباه توسط مدل منفی پیش‌بینی شده‌اند (Vujović, 2021).

این مقادیر این امکان را می‌دهند تا ارزیابی مدل بر مبنای شناسایی درست یا غلط موارد مثبت و منفی، انجام شود. همچنین این مقادیر برای محاسبه معیارهای مختلف عملکرد مانند صحت کلی، دقت، یادآوری، امتیاز F1 و کاپا استفاده می‌شوند. هر یک از این معیارها بینش‌های متفاوتی را در مورد عملکرد یک مدل پیش‌بینی ارائه می‌دهد (Narkhede, 2018). روابط این پنج معیار در جدول (۱) قابل ملاحظه است. در هر یک از این معیارها هر چه عدد حاصل به عدد یک نزدیک‌تر باشد، روش پیش‌بینی از عملکرد بهتری برخوردار است (Narkhede, 2018; Tharwat, 2020; Vujović, 2021).

جدول ۱. معیارهای ارزیابی برای روش‌های طبقه‌بندی

فرمول‌ها	معیارهای ارزیابی
$(TP + TN) / (TP + TN + FP + FN)$	Accuracy
$TP / (TP + FP)$	Precision
$TP / (TP + FN)$	Recall
$2 \times (Precision \times Recall) / (Precision + Recall)$	F1-Score
$\frac{2 \times (TP \times TN - FN \times FP)}{(TP + FP) \times (FP + TN) + (TP + FN) + (FN + TN)}$	Kappa

۳- پیاده‌سازی

هر کدام از این شش عامل که شامل قوس افقی، شانه راه، فاصله دید، فاصله از تقاطع، فاصله از پل و کاربری محل هستند

با تعیین منطقه مورد مطالعه، موقعیت مکانی شش عامل هندسی و محیطی در نظر گرفته شده بر روی دو مسیر مشخص می‌شود.

در چند دسته طبقه‌بندی می‌شوند. این دسته‌بندی به هر پارامتر با درجه خطر احتمالی یک عدد اختصاص می‌دهد که هر چه عدد اختصاص یافته بیشتر باشد، احتمال حادثه آفرینی بر اساس آن پارامتر بیشتر خواهد بود. اطلاعات مربوط به این نحوه

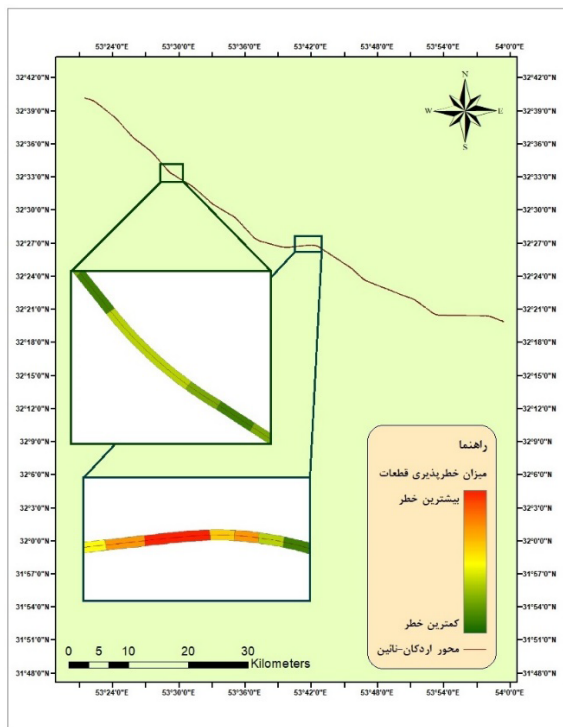
طبقه‌بندی هر پارامتر در جدول (۲) قابل مشاهده است. یادآور می‌شود که عامل شیب به علت تغییرات اندک در این دو محور، از جمع عوامل مؤثر حذف گردید.

جدول ۲. پارامترهای هندسی مورد استفاده در تحقیق

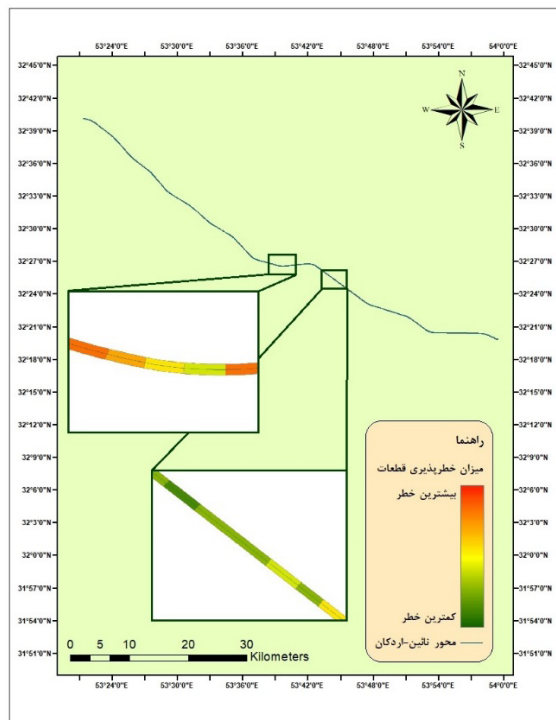
پارامترهای هندسی	جزئیات	طبقه (کلاس) خطر
قوس افقی	مسیر مستقیم	۱
	قوس ملایم	۲
	قوس تیز	۳
فاصله از تقاطع	خارج از محدوده صد متری تقاطع	۱
	در محدوده صد متری یک تقاطع	۲
	در محدوده مشترک صد متری بیش از یک تقاطع	۳
فاصله از پل	خارج از محدوده صد متری پل	۱
	در محدوده صد متری یک پل	۲
	در محدوده مشترک صد متری بیش از یک پل	۳
وجود شانه	شانه دارد	۱
	فاقد شانه	۲
فاصله دید	دید دارد	۱
	فاقد دید	۲
کاربری محل	بایر	۱
	کشاورزی	۲
	صنعتی	۳
	مسکونی	۴

با توجه به طبقه‌بندی هر عامل و موقعیت مکانی آن بر روی دو مسیر، شش نقشه قطعه‌بندی مسیر برای دو محور ایجاد می‌شود و با تلفیق این شش نقشه، نقشه قطعه‌بندی همگن حاصل می‌شود. این نقشه نیازمند ویرایش به علت وجود قطعات بسیار کوچک است که در همین راستا، پیشنهاد حداقل طول ۱۶۰ متر بر روی قطعات ایجاد شده، اعمال می‌گردد. پس از انجام این

فرآیند، تعداد ۲۳۹ قطعه در محور اردکان- نائین و تعداد ۲۴۷ قطعه در محور نائین- اردکان ایجاد شد که در شکل‌های (۸) و (۹) نمایش داده شده‌اند. در این دو شکل هرچقدر رنگ قطعات بیشتر متمایل به رنگ سرخ باشد، احتمال حادثه‌خیزی آن‌ها بر اساس عوامل هندسی و محیطی بیشتر است.



شکل ۹. نقشه قطعه بندی محور اردکان-نائین



شکل ۸. نقشه قطعه بندی محور نائین-اردکان

قرار می‌گیرند. این مقادیر به قطعات مربوط به خود الحاق می‌گردند. نحوه طبقه‌بندی EPDOهای هر قطعه از دو مسیر مورد مطالعه در جدول (۳) نشان داده شده است. گفتنی است که آماده‌سازی داده‌ها و نمایش نقشه‌ها در کنار اندازه‌گیری عوامل هندسی نظیر شعاع قوس و فاصله دید در نرم‌افزارهای AutoCAD 2020 و ArcGIS 10.5 انجام شده و پیاده‌سازی مدل‌های شبکه عصبی مصنوعی با استفاده از زبان برنامه‌نویسی Python به انجام رسیده است.

پس از ایجاد نقشه قطعه‌بندی نهایی بر اساس عوامل هندسی و محیطی، نقاط تصادف هر مسیر به نقشه قطعه‌بندی شده وارد می‌شوند. توزیع این نقاط در شکل‌های (۳) و (۴) قابل ملاحظه هستند. ضرایب شاخص EPDO برای همه نقاط مشخص و مجموع این ضرایب در هر قطعه از مسیر محاسبه می‌شود. سپس مقدار بحرانی که دو برابر میانگین این شاخص در هر محور است، تعیین می‌شود و با توجه به این مقدار، تمامی EPDOهای مربوط به هر قطعه از دو مسیر در یکی از پنج حالت تصادف ندارد، خفیف، متوسط، شدید و خیلی شدید

جدول ۳. طبقه بندی شدت تصادفات بر اساس EPDO

نام مسیر	مقدار بحرانی	شدت	طبقه بندی بر اساس شدت تصادف
اردکان-نائین	۱۱/۸	EPDO=۰	بدون تصادف
		$۰ < EPDO \leq ۵/۹$	کم
		$۵/۹ < EPDO \leq ۱۱/۸$	متوسط
		$۱۱/۸ < EPDO < ۲۳/۶$	شدید
		$EPDO \geq ۲۳/۶$	خیلی شدید
نائین-اردکان	۱۵/۴	EPDO=۰	بدون تصادف
		$۰ < EPDO \leq ۷/۷$	کم
		$۷/۷ < EPDO \leq ۱۵/۴$	متوسط
		$۱۵/۴ < EPDO < ۳۰/۸$	شدید
		$EPDO \geq ۳۰/۸$	خیلی شدید

۴- نتایج و بحث

نقش پررنگی در تمایز حادثه‌خیز بودن نقاط مختلف راه دارند. در واقع عوامل انسانی، جوی و وسایل نقلیه، نقش ثابتی در بروز حادثه دارند ولی بروز این عوامل خود در مناطق حادثه‌خیز نمود می‌یابد. اما برخی از عوامل متغیر دیگر نظیر نوع روسازی، خط‌کشی و علائم راهنمایی و رانندگی، روشنایی مسیر و نظایر آن هم هستند که در طول مسیر متغیر می‌باشند و با دانستن آنها می‌توان برآوردهای حوادث را بهبود بخشید.

پس از مشاهده برتری مدل MLFNN به بررسی فرضیه امکان آموزش این شبکه بر اساس یک محور و پیش‌بینی شدت تصادف در محور دیگر پرداخته شد. مزیت این کار آن خواهد بود که در محورهایی که داده‌های تصادف موجود نیست می‌توان با بهره‌گیری از داده‌های تصادف محورهای مشابه آن به پیش‌بینی تصادفات آن محور پرداخت و در نتیجه با یافتن مناطق مستعد حادثه، جهت رفع یا کاهش عوامل هندسی حادثه‌خیز اقدام نمود. برای بررسی این فرضیه، دو محور مورد بررسی از نظر ویژگی‌ها و شرایط هندسی باید به هم شبیه باشند. در اینجا هر دو محور در محیطی با شرایط مشابه هموار و بیابانی قرار دارند و ویژگی‌های هندسی تقریباً یکسانی دارند. شرط بعدی که انتظار می‌رود بر نتایج حاصل از این فرضیه تأثیر بگذارد، شباهت کاربری اصلی آن دو جاده است که برای بررسی شباهت این موضوع نیز دو مورد مد نظر است؛ اول اینکه هر دو مسیر از نظر نوع بزرگراه دو خطه هستند و دوم شباهت حجم تردد است که با استفاده از شاخص AADT (میانگین سالانه حجم تردد روزانه) مشخص می‌شود. این شاخص در محور اردکان - نائین حدود ۹۰۰۰ و در محور نائین - اردکان حدود ۹۵۰۰ می‌باشد که نشان از شباهت آن دو دارد. نتایج بررسی این فرضیه در جدول (۵) نشان داده شده است.

پس از ایجاد نقشه قطعه‌بندی بر اساس عوامل هندسی و محاسبه شاخص EPDO و طبقه مربوط به آن برای هر قطعه، مرحله بعدی، پیش‌بینی شدت تصادف یا پنج دسته شاخص EPDO در هر قطعه بر اساس مقادیر عوامل هندسی و همچنین طول هر قطعه به عنوان ورودی دیگر است. شیوه کار به این صورت است که عوامل هندسی-محیطی مربوط به هر قطعه به شبکه عصبی وارد می‌شود و شبکه عصبی باید کلاس EPDO را در آن قطعه پیش‌بینی نماید. داده‌های تصادفات هر محور برای ورود به سه شبکه RNN، CNN و MLFNN به ۷۰ درصد داده آموزش و ۳۰ درصد داده تست تقسیم می‌شوند. هر کدام از این شبکه‌های عصبی پارامترهای مؤثری دارند که با مشخص شدن بهترین مقدار آن‌ها انتظار می‌رود نتایج مورد قبول و معقول‌تری حاصل گردد. در مدل RNN یک لایه LSTM و در مدل CNN کانولوشن یک بعدی برای داده‌های جدولی این تحقیق که زمانمند و تصویری نبودند، بهترین نتایج را داشتند اما این نکته در نتایج روش MLFNN مؤثر نبود. نتایج و پارامترهای مؤثر دیگر در هر سه روش در جدول (۴) نشان داده شده‌اند. نتایج موجود در این جدول نشان می‌دهد که روش شبکه عصبی پیش‌خور چندلایه (MLFNN) بهترین عملکرد را نسبت به دو روش دیگر در هر دو محور دارد. شایان ذکر است که در این جدول، منظور از Epoch تعداد تکرار شبکه برای همگرا شدن و توقف فرآیند آموزش است. همچنین باید در اینجا به این نکته توجه نمود که مدل پیش‌بینی کننده نه تعداد تصادف و نه شدت تصادف، بلکه کلاس شدت متوسط تصادف در هر قطعه را پیش‌بینی می‌کند. نتایج مناسب مدل MLFNN نشان می‌دهد که عوامل هندسی

جدول ۲. نتایج ارزیابی دقت مدل‌های شبکه عصبی عمیق در مورد داده‌های تست برای هر دو محور

معیارهای ارزیابی					پارامترهای مؤثر			
Kappa	F1-Score	Recall	Precision	Accuracy	Epochs	تعداد واحدهای پنهان		RNN
۰/۰۱۷	۰/۰۸۷	۰/۲۰۹	۰/۰۶۱	۰/۱۶	۲۰۰	۱۲۸		اردکان-نائین
۰	۰/۰۲	۰/۲	۰/۰۱۱	۰/۱۰۶	۱۵۰	۳۲		نائین-اردکان
Kappa	F1-Score	Recall	Precision	Accuracy	Epochs	تعداد فیلترها		CNN
۰/۰۱۹	۰/۱۱۱	۰/۲۱۳	۰/۴۶۸	۰/۱۸	۱۵۰	۴۸		اردکان-نائین
۰/۰۱۵	۰/۰۷۲	۰/۲۰۸	۰/۶۱۱	۰/۱۳۳	۲۰۰	۴۸		نائین-اردکان
Kappa	F1-Score	Recall	Precision	Accuracy	Epochs	تعداد لایه‌های پنهان	تعداد نرون‌های هر لایه پنهان	MLFNN
۰/۹۳۷	۰/۹۴۹	۰/۹۳۴	۰/۹۶	۰/۹۵۵	۲۰۰	۳	۱۰	اردکان-نائین
۰/۹۷	۰/۹۵۹	۰/۹۷۵	۰/۹۷۷	۰/۹۸۵	۱۰۰	۲	۵	نائین-اردکان

جدول ۳. نتایج روش MLFNN در آموزش بر اساس یک مسیر و تست بر اساس مسیر دیگر

Kappa	F1-Score	Recall	Precision	Accuracy	داده تست	داده آموزش
۰/۸۱۶	۰/۷۸۸	۰/۸۱۱	۰/۸۰۷	۰/۸۸۶	نائین-اردکان	اردکان-نائین
۰/۶۲۴	۰/۵۷۹	۰/۵۷	۰/۶۴۵	۰/۷۸۲	اردکان-نائین	نائین-اردکان

تغییرات نسبت به وضع موجود محاسبه می‌گردد. این کار در ۱۹ قطعه گزینش شده در محور اردکان-نائین و ۱۸ قطعه یافته شده در محور نائین-اردکان که بیشترین شدت تصادفات را داشتند انجام شد. جدول (۶) نشان‌دهنده درصدهای بهبود حادثه‌خیزی در دو محور است. این عمل به نوعی آنالیز حساسیت عوامل تأثیرگذار بر شدت تصادفات نیز به شمار می‌رود. نتایج حاکی از آن است که در محور اردکان-نائین با بهبود عامل شانه راه (۷۷/۲٪) و در محور نائین-اردکان با ترمیم عامل کاربری (۷۶/۶۷٪) بیشترین تغییرات مثبت از نظر حادثه‌خیزی مسیر حاصل می‌شود. در تفسیر نتایج می‌توان گفت که در محورهای یاد شده، نظر به ناهموری‌های کم، قوس‌های افقی شدت زیادی ندارند و به همین دلیل، ترمیم آن‌ها تأثیر زیادی در کاهش شدت تصادفات نخواهد داشت. از سوی دیگر مهم بودن عامل کاربری محل بدان معنی است که در قطعاتی از مسیر، عبور مسیر از کاربری‌های حادثه‌خیز یعنی مسکونی و صنعتی سبب حادثه‌خیزی آن‌ها شده است. بدیهی است که تغییر این کاربری‌ها یا میسر نیست و یا اینکه هزینه بسیار بالایی دارد که شاید به نسبت ایمن‌سازی ناشی از تغییر آن، ارزش کافی نداشته باشد و لذا به هیچ وجه منطقی نیست. در چنین مواردی، ایجاد دیوار حائل میان راه و کاربری اطراف می‌تواند یک عامل راهگشا در کاهش تصادفات باشد. شیوه به کار گرفته شده در اینجا، هم امکانپذیر بودن کاهش حادثه‌خیزی مسیر در صورت اصلاح عوامل هندسی-محیطی را نشان می‌دهد و هم به صورت خیلی عمومی، عامل اصلی حادثه‌خیزی را در هر محور مشخص می‌سازد. اما برای رفع یا بهبود حادثه‌خیزی هر قطعه، لازم است آن قطعه به صورت جداگانه بررسی و عامل یا عوامل اصلی حادثه‌خیزی آن شناسایی و در جهت بهبود آن اقدام شود.

کلاس هر یک از عوامل هندسی-محیطی مربوط به هر قطعه و شدت تصادفات متناسب به آن، شاخص‌های راهنما در این اقدام خواهند بود.

نگاهی به نتایج به دست آمده در جدول ۵ نشان از موفقیت شبکه عصبی در پیش‌بینی مورد نظر دارد. در واقع این فرضیه که با استفاده از داده‌های یک محور می‌توان شدت تصادفات در قطعات محور مشابه را با داشتن هندسه آن، به خوبی پیش‌بینی کرد، تأیید می‌شود. البته نوسان در دو حالت پیش‌بینی نشان می‌دهد که در این مورد باید هنوز کمی محتاط بود ولی به هر حال، در حالت نبود یا کمبود داده تصادف، می‌توان پیش‌بینی‌های ارزشمندی را در اختیار داشت. ناگفته نماند که میزان دقت پیش‌بینی به میزان شباهت دو مسیر بستگی دارد و در این شباهت غیر از عوامل هندسی و محیطی، سایر عوامل دخیل در حوادث مانند عوامل جوی، وسایل نقلیه، ترافیک، روسازی راه و غیره نیز ایفای نقش می‌کنند. بنابراین برای بهره‌گیری از این روش باید شباهت دو مسیر را از کلیه جنبه‌ها مورد بررسی قرار داد. در این تحقیق از آنجا که دو محور مورد مطالعه، در واقع مسیرهای رفت و برگشت یک محور مواصلاتی هستند و به موازات یکدیگر کشیده شده‌اند، شرایط بسیار مشابهی دارند و از این رو گزینه‌های مناسبی برای تست فرضیه مطرح شده به شمار می‌روند. مورد آخر تحلیل‌ها، بررسی میزان تأثیر بهبود عوامل هندسی و محیطی حادثه‌ساز هر مسیر در کاهش شدت تصادفات است. در اینجا با توجه به تعداد زیاد قطعات مسیر، تنها قطعاتی که شدت تصادفات در آن‌ها بسیار زیاد بود در نظر گرفته شدند و این یک گزینش منطقی است؛ چراکه اصولاً قطعاتی که شدت تصادف بالایی ندارند نیاز به اصلاح هندسی هم نخواهند داشت. به این منظور با تغییر کلاس عوامل هندسی و محیطی قطعات گزینش شده به ایمن‌ترین حالت و ورود مقادیر به شبکه MLFNN آموزش دیده، شبکه به پیش‌بینی شدت تصادفات در قطعات مزبور به فرض انجام تغییرات و در شرایط جدید پرداخت. گفتنی است که در این آزمون، هر بار یک از عوامل هندسی بهبود می‌یابد و سایر عوامل ثابت می‌مانند و با این کار، شبکه آموزش دیده، مقدار جدید شدت تصادف را در قطعه حساب می‌کند و سپس درصد

جدول ۴. تأثیر بهبود عوامل حادثه‌خیز در کاهش شدت تصادفات در قطعات دارای شدت تصادف بالا

نام مسیر	قوس افقی (%)	فاصله دید (%)	تقاطع (%)	پل (%)	کاربری محل (%)	وجود شانه راه (%)
اردکان-نائین	۲۱/۰۶	۶۳/۱۶	۳۳/۳۴	۴۶/۷۹	۲۷/۲	۷۷/۲
نائین-اردکان	۵۶/۶۷	۷۴/۰۸	۵۰	۵۱/۹۷	۷۶/۶۷	۳۹/۶۳

۵- نتیجه‌گیری

۸۸ درصد را در آموزش با محور اردکان-نائین و تست با محور نائین-اردکان و صحت کلی ۷۸ درصد را در آموزش بر اساس محور نائین-اردکان و تست بر اساس اردکان-نائین نشان داد که در هر دو حالت نتایج مناسبی بود. تحلیل دیگر این تحقیق، بررسی میزان تأثیر بهبود عوامل هندسی و محیطی هر مسیر در کاهش شدت تصادفات در قطعاتی با EPDO بسیار شدید بود. این تحلیل نشان داد که به صورت کلی در محور اردکان-نائین، اصلاح عامل شانه راه و در محور نائین-اردکان، اصلاح کاربری محل بیشترین تأثیر را در کاهش شدت تصادفات خواهند داشت. البته اصلاح کاربری می‌تواند به صورت فیزیکی با ایجاد حائل بین راه و مناطق مسکونی و صنعتی اطراف آن حاصل گردد. بررسی و اصلاح عوامل حادثه‌خیز اصلی در قطعات شناسایی شده با شدت تصادف بسیار بالا می‌تواند به شکل قابل توجهی از حادثه‌خیزی این قطعات بکاهد. شبکه‌های یادگیری عمیق به کار رفته در این تحقیق این قابلیت را دارند که علاوه بر پارامترهای هندسی و محیطی استفاده شده، از پارامترهای دیگری نظیر وضعیت ایمنی جاده‌ها و علائم آن‌ها، وضعیت روسازی جاده‌ها در صورت وجود داده‌های آن استفاده نمایند و در این صورت نتایج بهتری حاصل خواهد شد. استفاده از برخی دیگر از مدل‌های شبکه عصبی عمیق و الگوریتم‌های یادگیری ماشین و مقایسه نتایج آن‌ها می‌تواند پیشنهاد دیگری برای ادامه کار در این زمینه باشد. در این تحقیق تأثیر بهبود پارامترها در کاهش شدت تصادفات در قطعات با شدت خیلی بالا بررسی شد. بررسی قطعات با سطوح شدت کمتر تصادف نیز ممکن است در درجات بعدی اهمیت، ارزش صرف وقت را داشته باشد. این تحقیق با استفاده از داده‌های تصادفات پنج ساله در دو محور مورد مطالعه انجام پذیرفت. افزایش دوره زمانی داده‌های مطالعاتی می‌تواند نتایج جامع‌تری را ارائه نماید.

تصادفات جاده‌ای یکی از مهم‌ترین مشکلات و معضلات هر کشوری است که اغلب تأثیرات جبران‌ناپذیری بر جامعه و مردم دارد. به دلیل اهمیت این موضوع مدت‌هاست از سوی محققان مطالعات بسیاری برای بررسی آن و ارائه پیشنهادهایی به جهت بهبود این اوضاع صورت گرفته ولی همچنان این مشکل وجود دارد و تلاش‌ها، تحلیل‌ها و ایده‌پردازی‌ها برای کاهش تصادفات جاده‌ای بیش از گذشته در اولویت دستگاه‌های اجرایی هر کشور قرار گرفته است. شناسایی نقاط و مناطق حادثه‌خیز، بررسی عوامل مختلف انسانی، محیطی، هندسی و عملکرد و سایل نقلیه تأثیرگذار بر تصادف و پیش‌بینی شدت تصادف، فصل مشترک بسیاری از تحقیقات در این حوزه هستند. در این تحقیق دو محور اردکان-نائین و نائین-اردکان واقع در مناطق هموار استان یزد، با استفاده از شش عامل هندسی و محیطی قوس افقی، فاصله دید، فاصله از تقاطع، فاصله از پل، شانه راه و کاربری محل قطعه‌بندی شدند. نقشه همگن دو محور از ادغام شش نقشه قطعه‌بندی شده مربوط به عوامل هندسی و محیطی ایجاد گردید و با الحاق نقاط تصادف هر مسیر، شدت تصادفات در هر قطعه بر اساس شاخص EPDO محاسبه و در پنج حالت مختلف دسته‌بندی شد. سپس با استفاده از سه مدل شبکه عصبی عمیق RNN, CNN و MLFNN شدت تصادفات هر قطعه با به کارگیری کلاس هر عامل هندسی و محیطی مربوط به آن پیش‌بینی شد. در نتیجه مدل‌های CNN و RNN در بهترین حالت با صحت کلی حدود ۲۰ درصد شدت تصادفات را در دو محور پیش‌بینی کردند در حالیکه مدل MLFNN با صحت کلی بالای ۹۰ درصد نتایج بسیار بهتری را در پیش‌بینی شدت تصادفات هر دو مسیر ارائه داد. در مرحله بعد با به کارگیری مدل MLFNN، امکان پیش‌بینی شدت تصادفات یک محور بر اساس آموزش‌های حاصل از یک محور مشابه دیگر بررسی شد. نتایج به دست آمده، صحت کلی

- 1 Multi-Layer Feed-Forward Neural Network
2. Multi-Layer Perceptron
3. Back Propagation
4. Rectified Linear Unit
5. Long Short-Term Memory
6. Forget Gates
7. Accuracy
8. Precision
9. Recall
10. F1-Score
11. Kappa

- Dinu, R. R., & Veeraragavan, A. (2011). Random parameter models for accident prediction on two-lane undivided highways in India. *Journal of Safety Research*, 42(1), 39-42.
- Donahue, J., Anne Hendricks, L., Guadarrama, S., Rohrbach, M., Venugopalan, S., Saenko, K., & Darrell, T. (2015). Long-term recurrent convolutional networks for visual recognition and description. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2625-2634.
- Dong, C., Shao, C., Li, J., & Xiong, Z. (2018). An improved deep learning model for traffic crash prediction. *Journal of Advanced Transportation*, 2018(1), 3869106.
- Effati, M., Rajabi, M. A., Samadzadegan, F., & Blais, J. R. (2012). Developing a novel method for road hazardous segment identification based on fuzzy reasoning and GIS. *Journal of Transportation Technologies*, 2(01), 32-40.
- Effati, M., Rajabi, M. A., Hakimpour, F., & Shabani, S. (2014). Analysis of Spatial Factors Contributing on Concentration of Highway Corridors Crashes Using GIS and Data Mining. *Journal of Geomatics Science and Technology*, 4(2), 87-102 (in Persian).
- Elvik, R., Sagberg, F., & Langeland, P. A. (2019). An analysis of factors influencing accidents on road bridges in Norway. *Accident Analysis & Prevention*, 129, 1-6.
- Aguero-Valverde, J., & Jovanis, P. P. (2006). Spatial analysis of fatal and injury crashes in Pennsylvania. *Accident Analysis & Prevention*, 38(3), 618-625.
- Akin, D., & Akba, B. (2010). A neural network (NN) model to predict intersection crashes based upon driver, vehicle and roadway surface characteristics. *Sci. Res. Essays*, 5(19), 2837-2847.
- Cafiso, S., Di Graziano, A., Di Silvestro, G., La Cava, G., & Persaud, B. (2010). Development of comprehensive accident models for two-lane rural highways using exposure, geometry, consistency and context variables. *Accident Analysis & Prevention*, 42(4), 1072-1079.
- Cafiso, S., D'Agostino, C., & Persaud, B. (2018). Investigating the influence of segmentation in estimating safety performance functions for roadway sections. *Journal of Traffic and Transportation Engineering (English Edition)*, 5(2), 129-136.
- D'agostino, C. (2014). Investigating transferability and goodness of fit of two different approaches of segmentation and model form for estimating safety performance of Motorways. *Procedia Engineering*, 84, 613-623.
- de Santos-Berbel, C., Essa, M., Sayed, T., & Castro, M. (2017). Reliability-Based Analysis of Sight Distance Modelling for Traffic Safety. *Journal of Advanced Transportation*, 2017(1), 5612849.

Journal of Applied Research Bureau Traffic Police 9: 27-54.

-Khosravi, Y., Hosseinali, F., & Adresi, M. (2022). Assessing Road Accidents in Spatial Context via Statistical and Nonstatistical Approaches to Detect Road Accident Hotspot Using GIS. *Geodetski vestnik*, 66(3), 412-431.

-Kronprasert, N., Boontan, K., & Kanha, P. (2021). Crash prediction models for horizontal curve segments on two-lane rural roads in Thailand. *Sustainability*, 13(16), 9011.

-Lateef, A. A. A., Al-Janabi, S., & Al-Khateeb, B. (2019). Survey on intrusion detection systems based on deep learning. *Periodicals of Engineering and Natural Sciences*, 7(3), 1074-1095.

-LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.

-Macedo, M. R., Maia, M. L., Rabbani, E. R. K., Neto, O. C. L., & Andrade, M. (2022). Traffic accident prediction model for rural highways in Pernambuco. *Case Studies on Transport Policy*, 10(1), 278-286.

-Mia, M. M. A., Biswas, S. K., Urmi, M. C., & Siddique, A. (2015). An algorithm for training multilayer perceptron (MLP) for Image reconstruction using neural network without overfitting. *International Journal of Scientific & Technology Research*, 4(02), 271-275.

-Michie, J. D. (1980). Strategy for selection of bridges for safety improvement. *Transportation Research Record*, 757, 17-22.

-Mohammed, H. (2013). The influence of road geometric design elements on highway safety. *International Journal of Civil Engineering and Technology*, 4(4), 146-162.

-Moomen, M., Rezapour, M., Raja, M. N., & Ksaibati, K. (2020). Predicting injury severity and crash frequency: Insights into the impacts of geometric variables on downgrade crashes in Wyoming. *Journal of Traffic and Transportation Engineering (English Edition)*, 7(3), 375-383.

-Nair, S. R., & Bhavathrathan, B. K. (2022). Hybrid segmentation approach to identify crash

-Erdogan, S., Yilmaz, I., Baybura, T., & Gullu, M. (2008). Geographical information systems aided traffic accident analysis system case study: city of Afyonkarahisar. *Accident Analysis & Prevention*, 40(1), 174-181.

-Fink, K. L., & Krammes, R. A. (1995). Tangent length and sight distance effects on accident rates at horizontal curves on rural two-lane highways. *Transportation Research Record*, 1500, 162-168.

-Flahaut, B. (2004). Impact of infrastructure and local environment on road unsafety: Logistic modeling with spatial autocorrelation. *Accident Analysis & Prevention*, 36(6), 1055-1066.

-Gardner, M. W., & Dorling, S. R. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric Environment*, 32(14-15), 2627-2636.

-Glennon, J. C. (1987). Effect of alignment on highway safety. *State of the Art Report*, 6, 48-63.

-Gross, F., & Jovanis, P. P. (2007). Estimation of safety effectiveness of changes in shoulder width with case control and cohort methods. *Transportation Research Record*, 2019(1), 237-245.

-Hilton, M. H. (1973). Some case studies of highway bridges involved in accidents. *Highway Research Record*, 432, 41-51.

-Islam, M. R., Jenny, I. J., Nayon, M., Islam, M. R., Amiruzzaman, M., & Abdullah-Al-Wadud, M. (2021, August). Clustering algorithms to analyze the road traffic crashes. In *2021 International Conference on Science & Contemporary Technologies (ICSCCT)* (pp. 1-6). IEEE.

-Jima, D., & Sipos, T. (2022). The impact of road geometric formation on traffic crash and its severity level. *Sustainability*, 14(14), 8475.

-Khalilzadeh, M., Zoghi, H., & Kazemi, A. (2013). The Study of the Identification and Prioritization Methods of the Black Spots Correction (Full-text in Persian). *RAHVAR*

- Tamburri, T. N., & Smith, R. N. (1970). The safety index: A method of evaluating and rating safety benefits. *Highway Research Record*, (332).
- Tharwat, A. (2021). Classification assessment methods. *Applied computing and informatics*, 17(1), 168-192.
- Vujović, Ž. (2021). Classification model evaluation metrics. *International Journal of Advanced Computer Science and Applications*, 12(6), 599-606.
- Wenqi, L., Dongyu, L., & Menghua, Y. (2017, September). A model of traffic accident prediction based on convolutional neural network. In *2017 2nd IEEE international conference on intelligent transportation engineering (ICITE)*, IEEE. 198-202.
- WHO (2018). World health statistics 2018: monitoring health for the SDGs, sustainable development goals: *World Health Organization*.
- Xu, M., & Zhang, J. (2024). MGL2Rank: Learning to rank the importance of nodes in road networks based on multi-graph fusion. *Information Sciences*, 667, 120472.
- Yu, S., Wu, Y., Li, W., Song, Z., & Zeng, W. (2017). A model for fine-grained vehicle classification based on deep learning. *Neurocomputing*, 257, 97-103.
- Zegeer, C. V., Stewart, R., Council, F., & Neuman, T. R. (1994). Accident relationships of roadway width on low-volume roads. *Transportation Research Record*, 160-161.
- susceptible locations in large road networks. *Safety Science*, 145, 105515.
- Narkhede, S. (2018). Understanding confusion matrix. *Towards Data Science*, 180(1), 1-12.
- Transportation Officials. (2011). *A Policy on Geometric Design of Highways and Streets*, 2011. AASHTO.
- Rezapour, M., Nazneen, S., & Ksaibati, K. (2020). Application of deep learning techniques in predicting motorcycle crash severity. *Engineering Reports*, 2(7), e12175.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Sahaf, A., Mohammadi, M., & Abdoli, A. (2021). 3D Sight Distance Calculation and Estimation of its Effect on Road Accidents in GIS Environment. *Shock and Vibration*, 2021(1), 5298309.
- Sameen, M. I., Pradhan, B., Shafri, H. Z. M., & Hamid, H. B. (2019). Applications of deep learning in severity prediction of traffic accidents. In *GCEC 2017: Proceedings of the 1st Global Civil Engineering Conference 1*, Springer Singapore, 793-808.
- Schmidhuber, J., & Hochreiter, S. (1997). Long short-term memory. *Neural Comput*, 9(8), 1735-1780.
- Shariff, S. R., Maad, H. A., Halim, N. N. A., & Derasit, Z. (2018). Determining hotspots of road accidents using spatial analysis. *Indones. J. Electr. Eng. Comput. Sci*, 9(1), 146-151.
- Steenberghen, T., Dufays, T., Thomas, I., & Flahaut, B. (2004). Intra-urban location and clustering of road accidents using GIS: a Belgian example. *International Journal of Geographical Information Science*, 18(2), 169-181.

Investigating the Effect of Geometrical Factors on the Severity of Car Crashes on Suburban Roads Utilizing Artificial Intelligence and Deep Learning Algorithms

*Sara Ghafari, M.Sc., Grad., Department of Surveying Engineering,
Faculty of Civil Engineering, Shahid Rajaei Teacher Training University, Tehran, Iran.
Farhad Hosseinali, Associate Professor, Department of Surveying Engineering,
Faculty of Civil Engineering, Shahid Rajaei Teacher Training University, Tehran, Iran.*

E-mail: f.hosseinali@sru.ac.ir

Received: April 2025- Accepted: November 2025

ABSTRACT

As an essential part of terrestrial transportation, roads face the pressing challenge of accidents. These accidents can have devastating financial and human impacts on individuals and society as a whole. Consequently, the importance of examining road safety and the factors contributing to accidents is evident. This research examines two smooth road segments, Ardakan-Naeen and Naeen-Ardakan, located in Yazd province, based on six geometric and environmental parameters: horizontal curvature, sight distance, distance from intersections, distance from bridges, shoulder width, and land use. Each road was separately categorized into homogeneous segments based on these six parameters and classified according to the severity of the geometric and environmental factors associated with accidents. After incorporating accident data into both roads, the severity of accidents for each segment was assessed using the EPDO index and was classified into five distinct levels. Subsequently, the severity of accidents for each road was predicted using three Deep Artificial Neural Network models: RNN, CNN, and MLFNN, based on the geometric and environmental parameters. The RNN and CNN models achieved an overall accuracy of approximately 20% on both roads, while the MLFNN model demonstrated significantly better performance, with an overall accuracy of around 90%. The next phase involved assessing the ability to predict accident severity on a particular route by training a model with data from comparable routes, employing the advanced method established in this study (MLFNN). The requirement for the similarity of two routes is based on their geometric characteristics and the daily traffic volume on both routes being analyzed. This process achieved an overall accuracy of 88% when trained on the Ardakan-Naeen route and tested on the Naeen-Ardakan route, as well as an overall accuracy of 78% in the reverse scenario, which are considered acceptable results. The concluding part of this research focused on evaluating how improvements in geometric and environmental factors on each route could reduce the severity of accidents in segments with extremely high accident rates. The findings indicated that on the Ardakan-Naeen route, the presence of a shoulder significantly influences the reduction of accident severity, while on the Naeen-Ardakan route, land use has the most substantial effect. Based on these results, necessary modifications can be proposed to enhance the conditions of these segments to mitigate accidents.

Keywords: Road Accidents, Deep Artificial Neural Network, Segmentation, Accident-Prone Areas, Geometrics Parameters