

مدل پیش‌بینی کوتاه‌مدت سرعت متوسط غیرمجاز با رویکرد یادگیری ماشین

رضا محمدحسینی (مسئول مکاتبات)، استادیار، دانشکده مهندسی راه‌آهن، دانشگاه علم و صنعت، تهران، ایران

آرش رساءیزدی، دکتری برنامه‌ریزی و مهندسی حمل‌ونقل، دانشکده مهندسی عمران و محیط‌زیست، دانشگاه تربیت مدرس، تهران، ایران

E-mail: rmhasany@iust.ac.ir

پذیرش: ۱۴۰۰/۰۶/۳۰

دریافت: ۱۳۹۹/۰۸/۰۲

چکیده

سرعت غیرمجاز یکی از عوامل اصلی وقوع تصادفات رانندگی است. در اثر سرعت غیرمجاز در راه‌های برون‌شهری نه تنها احتمال وقوع تصادف افزایش پیدا می‌کند بلکه بر شدت تصادفات نیز افزوده می‌شود، لذا کنترل سرعت امری واجب به نظر می‌رسد. نکته حائز اهمیت دیگر تلاش برای جلوگیری از وقوع تخلف سرعت غیرمجاز است. در این پژوهش سرعت متوسط ترافیک برای محور خرم‌آباد به اراک برای آینده نزدیک پیش‌بینی می‌شود. چنانچه سرعت متوسط پیش‌بینی شده به سرعت مجاز نزدیک یا از آن بیشتر شود، می‌توان قبل از وقوع حادثه تمهیدات لازم به‌منظور کاهش سرعت متوسط ترافیک به وسیله استفاده‌کنندگان از راه یا گردانندگان سیستم‌اندیشیده شود. به‌منظور پیش‌بینی سرعت متوسط ترافیک، داده ترافیکی محور یاد شده توسط دستگاه‌های سرعت‌سنج در سال‌های اخیر ثبت شده است. استخراج ویژگی‌های مؤثر بر سرعت ترافیک نیز سبب تکمیل شدن مجموعه داده شده می‌شود تا بتوان از این ویژگی‌ها برای پیش‌بینی سرعت متوسط استفاده کرد. سه مدل ماشین بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی مصنوعی بازگشتی به‌عنوان سه روش مبتنی بر یادگیری ماشین مورد استفاده قرار گرفته‌اند. هر سه روش قابلیت تحلیل داده‌های حجیم ترافیکی را داشته و در ضمن روش شبکه عصبی مصنوعی بازگشتی به‌عنوان یک روش مبتنی بر یادگیری عمیق تطابق بیشتری با ماهیت سری زمانی داده دارد. نتایج نشان می‌دهد برای هر دو جهت رفت و برگشت این محور، زمانی که تنها از ویژگی‌های تقویمی و آب‌وهوا استفاده شود میانگین درصد خطای مطلق مدل‌ها بین ۲/۸ تا ۵/۱ درصد است و درصد پیش‌بینی صحیح سرعت‌های بالای ۸۵ کیلومتر بر ساعت بالای ۸۰ درصد است. همچنین با افزودن مقادیر مشاهده شده سرعت در بازه زمانی ۳ تا ۸ ساعت گذشته به‌عنوان متغیر پیش‌بینی‌کننده، میانگین درصد خطای مطلق مدل‌ها به ۲/۵ تا ۴/۶ درصد تقلیل پیدا می‌کند.

واژه‌های کلیدی: تشخیص تخلف سرعت، شبکه عصبی بازگشتی، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، یادگیری ماشین

۱. مقدمه

مجاز راه نزدیک یا از آن عبور کند، آن مقطع از مسیر به عنوان یک نقطه پر تخلف شناسایی می شود. بدیهی است که هر مقطع از راه-های برون شهری ممکن است در چند ساعت در طول سال به عنوان نقطه پر تخلف شناسایی شود و نقاط پر تخلف در طول زمان ثابت نخواهند بود. با در اختیار داشتن پیش بینی های دقیق می توان قبل از وقوع حالات بحرانی در وضعیت ایمنی راه ها، تدابیر لازم اندیشیده شود و فرصت کافی جهت برنامه ریزی و استفاده بهینه از منابع انسانی و تجهیزات پلیس راهور فراهم آید.

از آنجا که داده های ترافیکی راه های برون شهری از نوع کلان داده به شمار می آیند و تحلیل این داده ها با روش های سنتی دقت قابل توجهی را نتیجه نمی دهد، رویکردهای مبتنی بر یادگیری ماشین می تواند بسیار راهگشا باشد. نوآوری این پژوهش استفاده از الگوریتم های یادگیری ماشین متنوع به منظور تحلیل کلان داده ترافیکی راه های برون شهری و پیش بینی سرعت متوسط به عنوان شاخصی از ایمنی راه است. دلیل استفاده از الگوریتم های یادگیری ماشین متنوع، وجود نقاط ضعف و قوت متفاوت برای هر الگوریتم است. این پژوهش سعی دارد نبود روش یکتایی که بیشترین دقت پیش بینی را به همراه داشته باشد را با به کارگیری الگوریتم های متفاوت پوشش دهد. در ادامه، ادبیات پیشین مرور می شود و پس از آن داده مورد استفاده معرفی و تحلیل می شود.

۲. ادبیات پیشین

به طور کلی روش های پیش بینی کوتاه مدت به سه دسته نایب، پارامتری و غیر پارامتری تقسیم می شوند. هر کدام از این دسته بندی ها شامل روش های متنوعی می شود. روش های نایب بدون فرض هیچ گونه مدلی تفسیر می شوند. این روش های محاسبات کم و تفسیر آسانی دارند در مقابل دقت روش ها بسیار پایین است. در مقایسه با سایر روش های پیش بینی این روش ساده ترین و

یکی از مباحث مهم در حوزه حمل و نقل مبحث ایمنی راه ها است. آمار تصادفات در کشور ایران نگران کننده است و در بازه زمانی مارس ۲۰۱۵ تا فوریه ۲۰۱۶، در اثرات تصادفات رانندگی ۵۰۷۵۵ نفر فوت کرده یا جراحت دیده اند [Shahbazi et al. 2019]. علاوه بر تلفات جانی، وقوع معلولیت ها و خسارات مالی بخش دیگری از هزینه های سنگین ناشی از پایین بودن سطح ایمنی جاده ها است. یکی از مهم ترین عوامل در وقوع تصادفات جاده ای سرعت غیرمجاز است. سرعت زیاد می تواند باعث وقوع تصادفات و همچنین باعث افزایش شدت تصادفات شود. لذا ارائه راهکارهایی به منظور کاهش سرعت رانندگان متخلف اثر چشمگیری بر افزایش ایمنی راه ها دارد. یکی از راهکارهای موجود، به کارگیری نیروهای پلیس راهور در راه های برون شهری است تا با ثبت سرعت لحظه ای وسایل نقلیه و برخورد با رانندگان متخلف از بروز سوانح ناگوار جلوگیری شود؛ اما تجهیزات و نیروهای انسانی پلیس راهور با محدودیت هایی روبرو است و اساساً کنترل سرعت در تمام راه های برون شهری امکان پذیر به نظر نمی رسد.

این پژوهش در پی پاسخ دادن به این سؤال است که در چه ساعتی در طول سال احتمال وقوع تخلف سرعت بیشتر است؟ پس از تشخیص نقاط پر تخلف، کنترل سرعت به وسیله پلیس راهور با برنامه ریزی مناسب تری انجام می شود. نکته حائز اهمیت این است که نقاط پر تخلف در طول یک سال ثابت نیستند. در این پژوهش به منظور تشخیص نقاط پر تخلف، با بهره گیری از داده های ترافیکی راه های برون شهری که توسط سازمان راهداری و حمل و نقل جاده ای ثبت و در اختیار عموم قرار گرفته است، مدل پیش بینی کننده سرعت پرداخت می شود. با استفاده از این مدل سرعت متوسط ترافیک راه های برون شهری برای یک ساعت تا چند ماه آینده پیش بینی می شود. زمانی که سرعت متوسط پیش بینی شده به سرعت

مدل پیش‌بینی کوتاه‌مدت سرعت متوسط غیرمجاز با رویکرد یادگیری ماشین

که انعطاف‌پذیری بیشتری دارند. علاوه بر این برای هر بازه زمانی (مثلاً ۱۵ دقیقه) قابلیت تعیین نقاط بیشینه یا کمینه آن پارامتر نیز وجود دارد. در این مقاله با استفاده از اطلاعات ترافیکی شهر دویلین در جمهوری ایرلند مدل SARIMA از روش‌های کلاسیک و روش بیزین تخمین زده شده و نتایج با هم مقایسه می‌شود.

در مطالعه‌ای توسط ژیاو و همکاران [Xiaoyu, Yisheng, and Siyu 2013] فرآیند پیش‌بینی سرعت جریان ترافیک با استفاده از الگوریتم K -نزدیک‌ترین همسایه دولایه انجام شده است. داده‌های این مطالعه مربوط به شهر پکن است که در بازه‌های زمانی ۵ دقیقه‌ای جمع‌آوری شده‌اند. به‌منظور یافتن پارامتر K (تعداد همسایه) مدل‌هایی با k متفاوت پرداخته و بر اساس معیار خطا با هم مقایسه شده‌اند. در این مطالعه مقدار $K=11$ به دلیل داشتن کمترین مقدار خطای پیش‌بینی برای مدل نهایی انتخاب شده است.

لی و [lee 2009] با استفاده از منطق فازی نوع دوم به پیش‌بینی کوتاه‌مدت پارامترهای ترافیکی پرداخته است. در این مطالعه روش منطق فازی نوع دوم توانسته است برای پیش‌بینی جریان ترافیکی از ۹۵ درصد دقت و برای پیش‌بینی چگالی از ۸۸ درصد دقت برخوردار باشد. یکی دیگر از نتایج قابل توجه این مطالعه اثر استفاده از هر دو منبع اطلاعاتی تاریخی و بهنگام در بهبود دقت پیش‌بینی در مقایسه با اطلاعات تاریخی به‌صورت منفرد است.

ژانگ و همکاران [Zhang, Sun, and Yu 2004] در مطالعه‌ای برای پیش‌بینی کوتاه‌مدت پارامترهای ترافیکی از رویکرد شبکه بیزین استفاده کرده‌اند. عموماً برای پیش‌بینی کوتاه‌مدت پارامترهای ترافیکی یک کمان از اطلاعات پیشین مربوط به همان کمان استفاده می‌شود، در این مقاله با استفاده از رویکرد شبکه بیزین، برای پیش‌بینی از اطلاعات پیشین همان کمان و اطلاعات حال و پیشین کمان-های مجاور استفاده شده است.

کم‌دقت‌ترین روش است. از جمله مدل‌های نایبو می‌توان به مدل-های آنی، میانگین تاریخی و خوشه‌بندی اشاره کرد [Westeyn et al. 2009].

روش‌های پارامتری عموماً با عنوان روش‌های تحلیل سری زمانی شناخته می‌شوند. در مدل‌های سری زمانی، یک متغیر تابعی از مقادیر گذشته آن متغیر، سایر عوامل اثرگذار و بخش خطا است. این مدل‌ها به فرآیند ساکن کردن داده نیاز دارد، در صورتی که داده ساکن نباشد معمولاً از مدل‌های فصلی استفاده می‌شود [Dengen 2016]. منظور از داده ساکن این است که مقادیر میانگین و واریانس متغیر مدنظر به زمان وابسته نباشند.

در روش‌های غیر پارامتری، غیر پارامتری بودن بر نبود هیچ پارامتری دلالت ندارد بلکه این مدل‌ها نیز دارای پارامتر هستند با این تفاوت که پارامترها منعطف و متغیر هستند. ساختار و پارامترهای این مدل‌ها با توجه به داده مشخص می‌شود، به همین دلیل به داده‌های بیشتری برای پرداخت مدل نیاز هست [Rasaizadi, Ardestani, Seyedabrishami 2020]. مزیت دیگر این مدل‌ها توانایی به تصویر کشیدن روابط غیرخطی و پویا است و فرضیات کمتری بر نوع روابط حاکم است [Garg et al. 2015].

در مطالعه‌ای قوش و همکاران [Ghosh, Basu, and Mahony 2007] برای پیش‌بینی پارامترهای ترافیکی از مدل میانگین متحرک خود همبسته یکپارچه فصلی^۲ (SARIMA) و برای تخمین پارامترهای آن از تخمین‌گر بیزین استفاده کرده‌اند. تخمین‌گرهای کلاسیک بیشتر به دنبال استنباط‌های آماری هستند، اما تخمین‌گر بیزین بیشتر به دنبال استنباط‌های احتمالاتی است. در واقع به‌جای تخمین یک پارامتر ثابت برای مدل SARIAM، یک توزیع احتمال شرطی برای هر پارامتر و برای هر نقطه تخمین می‌زند. نهایتاً این روش بازه‌های متغیر پیش‌بینی‌ای را تخمین می‌زند.

دقیق و درعین حال با پیچیدگی کمتر می‌دانند. عیب روش‌های ARIMA تأخیر زیاد در محاسبات، زمانی که نوسانات سریع وجود دارد، شمرده می‌شود. بر اساس گزارش این مطالعه حدود ۴۰۰ حسگر ترافیکی در بزرگراه شهری در پکن نصب شده و حجم ترافیکی در بازه‌های ۵ دقیقه‌ای برای یک شبانه‌روز جمع‌آوری شده است. از مجموع ۲۸۳ مجموعه مشاهده (هر مشاهده حجم ترافیکی ۵ دقیقه‌ای است) ۲۰۰ مجموعه مشاهده برای آموزش و ۸۳ مشاهده برای آزمون مورد استفاده قرار گرفته است. نتایج نشان می‌دهد، حجم ترافیکی پیش‌بینی شده و مشاهده شده از تطابق خوبی برخوردار هستند. همچنین بیشینه خطای نسبی ۰/۴۵ درصد است و به طور متوسط از بازه‌ی شماره ۸۰ تا ۲۷۰ (ساعات ۷ تا ۲۲)، حدود ۰/۰۰۱ درصد خطا وجود دارد. یکی از نتایج مهم این مطالعه دقت بالای نتایج برای این بازه است. قبل و بعد از این بازه به دلیل این که حجم ترافیکی بسیار کم است، دقت کمی پایین می‌آید، اما باین حال همچنان درصد خطای نسبی ناچیز است و پیش‌بینی حجم ترافیکی از دقت بالایی برخوردار است. مطالعات پیشین تنها محدود به همین مدل‌ها نمی‌شود و مدل‌های متنوعی به منظور پیش‌بینی سرعت ترافیکی قابل استفاده هستند. ماجی و همکاران [Maji et al 2018] سرعت عملکردی بزرگراهی در برون‌شهری پیش‌بینی کرده‌اند. یانگ و همکاران [Yang et al. 2020] با استفاده از دو رویکرد متفاوت، یادگیری ماشین و آماری سرعت ترافیکی را پیش‌بینی و مقایسه کرده‌اند. چن و همکاران [Chen, Chen, and Yu 2020] با مدل‌های یادگیری عمیق سرعت وسایل نقلیه حمل‌ونقل بار را پیش‌بینی کرده‌اند. ژو و همکاران [Zhu et al 2019] با استفاده از مدل احتمالاتی شرطی سرعت ترافیکی را پیش‌بینی کرده‌اند.

۳. روش‌شناسی

دونگ و همکاران [Dong et al. 2009] از مدل‌های میانگین متحرک خود همبسته یکپارچه^۳ (ARIMA) برای پیش‌بینی سرعت، جریان و چگالی ترافیک بر اساس اطلاعات ترافیک شهر پکن استفاده کرده‌اند. در این مطالعه نتایج بر اساس مقدار خطای پیش‌بینی برحسب بازه زمانی ۵ دقیقه یا ۱۰ دقیقه و برای ساعات اوج صبح، ساعات غیر اوج و ساعات اوج شب با یکدیگر مقایسه شده است.

کومار و همکاران [Kumar, Parida, and Katiya 2014] در مطالعه خود از مدل شبکه عصبی مصنوعی^۴ برای پیش‌بینی پارامتر ترافیکی حجم ترافیک در بزرگراهی برون‌شهری برای کشور هند استفاده کرده‌اند. در این مطالعه به دلیل تفاوت متغیرها برحسب نوع وسیله نقلیه، متغیرهای ورودی و خروجی برحسب نوع وسیله نقلیه تفکیک شده‌اند. وسایل نقلیه شامل، سواری، موتورسیکلت، مینی-بوس، اتوبوس، کامیون، سه‌چرخه، تریلی و کالسکه می‌شود. متغیرهای ورودی نیز شامل روز هفته، زمان روز، حجم و سرعت میانگین وسایل نقلیه به تفکیک نوع وسیله و چگالی ترافیک است. هدف این مطالعه پیش‌بینی پارامتر حجم ترافیک برای ۵ و ۱۵ دقیقه آینده است. به منظور رسیدن به بهترین عملکرد شبکه عصبی از رویکرد سعی و خطا استفاده شده است. بدین منظور ۱۰ مدل با تعداد نرون‌های مخفی متفاوت ساخته شده است و با یک داده یکسان آموزش انجام شده است. ارزیابی عملکرد مدل‌ها از طریق استفاده از داده‌های اعتبارسنجی عرضی و آزمون انجام می‌شود. نتایج نشان می‌دهد، شبکه عصبی با ۶ نرون مخفی پیش‌بینی‌های بهتری را به همراه دارد.

رونگ و چون [Rong and Chun 2010] در مطالعه‌ای از روش ماشین بردار پشتیبان^۵ (SVM) برای پیش‌بینی کوتاه‌مدت جریان ترافیک استفاده کرده‌اند. نویسندگان این مقاله با بحث مختصر پیرامون انواع روش‌ها، روش رگرسیون بردار پشتیبانی را روش

مدل پیش‌بینی کوتاه‌مدت سرعت متوسط غیرمجاز با رویکرد یادگیری ماشین

بین داده‌هاست به گونه‌ای که بیشترین فاصله ممکن را از تمام دسته-ها (بردارهای پشتیبان آن‌ها) داشته باشد [Tang et al. 2019]. چهار ویژگی زیر از جمله دلایل اصلی انتخاب این مدل در این پژوهش به حساب می‌آیند:

- استفاده از رویکرد طبقه‌بندی به‌عنوان یک رویکرد متفاوت در مدل‌سازی
- دقت قابل قبول مدل بر اساس مطالعات پیشین
- سرعت اجرای قابل قبول مدل
- مدل‌سازی ساده با توجه به عدم تعریف معناداری

مدل SVM برای طبقه‌بندی داده‌هایی که به صورت غیرخطی توزیع شده باشند با استفاده از توابع کرنل^۷ داده را به دستگاه مختصات جدیدی با ویژگی خطی بودن طبقه‌بندی انتقال می‌دهد. در این مطالعه از تابع مبنای شعاعی^۸ (رابطه ۱) استفاده شده است.

$$K(X_i, X) = \exp\left(-\frac{\|X_i - X\|^2}{2\sigma^2}\right) \quad (1)$$

در رابطه ۱، σ پارامتر آزاد مدل است که باید تخمین زده شود و $\|X_i - X_j\|^2$ فاصله اقلیدسی میان بردار متغیرهای دو مشاهده i و j است.

مدل‌های شبکه عصبی مصنوعی روش دیگری برای پیش‌بینی سری‌های زمانی است که در سال‌های اخیر شهرت زیادی به دست آورده است. هدف اساسی این مدل‌ها، ساخت یک مدل بر مبنای به‌کارگیری از هوش مغز بشر در ماشین است. مشابه کار مغز انسان، شبکه عصبی مصنوعی سعی می‌کند که نظم و الگوی اطلاعات ورودی را تشخیص داده، از تجربه‌ها یاد گرفته و نتایج جدید را بر اساس دانش گذشته تهیه نماید.

یکی از ساده‌ترین و پرکاربردترین شبکه عصبی مصنوعی در پیش‌بینی مسائل، پرسپترون چندلایه^۹ است که از یک لایه پنهان برای پیش بردن شبکه استفاده می‌کند. این مدل با یک شبکه سه

روش‌های پیش‌بینی کوتاه‌مدت حمل و نقل از تنوع زیادی برخوردار هستند. در بخش قبل به برخی از این روش‌ها اشاره شد و ادبیات پیشین آن‌ها مورد بررسی قرار گرفت. تنوع روش‌ها از دو جنبه قابل تأمل است. جنبه‌ی مثبت آن عدم محدودیت در انتخاب روش و انعطاف‌پذیری انتخاب روش بر اساس نیاز مسئله و ویژگی‌های داده است. از طرف دیگر و به‌عنوان جنبه‌ی منفی، روش یکتایی وجود ندارد که به‌عنوان روش برتر مورد تأیید پژوهش‌گران قرار بگیرد. وجود مزایا و معایب به‌طور هم‌زمان برای هر روش به نسبت سایر روش‌ها کار اتخاذ روش مناسب را سخت‌تر می‌کند. همین موضوع سبب بررسی هم‌زمان چندین روش مختلف و مقایسه نتایج در مطالعات پیشین شده است. در این پژوهش به‌منظور دستیابی به پیش‌بینی دقیق‌تر سه روش با مبنای متفاوت مورد بررسی قرار گرفته است. این روش‌ها شامل روش‌های زیر می‌شود:

- ماشین بردار پشتیبان
- شبکه عصبی مصنوعی
- شبکه عصبی بازگشتی^۶

یکی از الگوریتم‌ها و روش‌های بسیار رایج در حوزه دسته‌بندی داده‌ها، الگوریتم SVM یا ماشین بردار پشتیبان است. بردارهای پشتیبان به زبان ساده، مجموعه‌ای از نقاط در فضای n بعدی داده‌ها هستند که مرز دسته‌ها را مشخص می‌کنند و مرزبندی و دسته‌بندی داده‌ها بر اساس آن‌ها انجام می‌شود و با جابجایی یکی از آن‌ها، خروجی دسته‌بندی ممکن است تغییر کند. در واقع SVM یا ماشین بردار پشتیبان، یک دسته‌بند یا مرزی است که با معیار قرار دادن بردارهای پشتیبان، بهترین دسته‌بندی و تفکیک بین داده‌ها را برای ما مشخص می‌کند.

در SVM فقط داده‌های قرار گرفته در بردارهای پشتیبان مبنای یادگیری ماشین و ساخت مدل قرار می‌گیرند و این الگوریتم به سایر نقاط داده حساس نیست و هدف آن‌هم یافتن بهترین مرز در

شبکه عصبی مورد استفاده در مورد مطالعه شامل یک لایه ورودی، یک لایه خروجی و ده لایه نهان است.

شبکه‌های عصبی بازگشتی در سال ۱۹۸۰ ایجاد شدند اما تنها در چند سال اخیر بوده است که این گونه از شبکه‌ها به‌طور گسترده مورد استفاده قرار گرفته‌اند. از دلایل عمده وقوع چنین رخدادی می‌توان به پیشرفت‌های صورت گرفته در طراحی شبکه‌های عصبی به‌طور عام و بهبود چشمگیر قدرت محاسباتی و به‌طور ویژه بهره‌وری از قدرت واحدهای پردازش موازی کارت‌های گرافیک اشاره نمود. این گونه از شبکه‌های عصبی به‌طور خاص برای پردازش داده‌های سری یا دنباله‌دار مفید هستند و در آن‌ها هر نورون یا واحد پردازشی قادر به حفظ حالت داخلی یا همان حافظه به‌منظور حفظ اطلاعات مرتبط با ورودی قبلی است. این ویژگی به‌طور ویژه در کاربردهای مختلف مرتبط با داده‌های سری زمانی اهمیت اساسی پیدا می‌کند. این ویژگی حفظ حالت درونی یا همان قابلیت حافظه به شبکه کمک می‌کند تا قادر به فهم و کشف ارتباط بین مشاهدات متوالی مختلف در دنباله‌های طولانی‌تر باشد.

ایده اصلی پشت این نوع از معماری، بهره‌برداری از این ساختار سری داده است. نام این شبکه عصبی از این واقعیت به دست می‌آید که این نوع از شبکه‌ها به‌صورت بازگشتی عمل می‌کنند؛ یعنی یک عملیات برای تک‌تک المان‌های یک دنباله انجام می‌گیرید و خروجی آن وابسته به ورودی فعلی و عملیات قبلی است. این مهم از طریق تکرار یک خروجی از شبکه در زمان با ورودی شبکه در زمان انجام می‌شود (خروجی از مرحله قبل با ورودی تازه در مرحله جدید ترکیب می‌شوند). این چرخه‌ها اجازه وجود اطلاعات از یک گام زمانی به گام زمانی بعدی را موجب می‌شوند. به عبارت بهتر این نوع شبکه‌ها دارای حلقه‌ای در درون خود هستند که به‌وسیله آن می‌توانند اطلاعات را در حین خواندن ورودی از نورون‌ها عبور دهند [Zhou, Qu, and Yu 2017].

لایه‌ای شامل لایه ورودی، پنهان و خروجی مشخص می‌شود. گره‌ها در لایه‌های مختلف به‌عنوان المان‌های پردازشی شناخته می‌شوند. فرض می‌شود داده‌های پیش‌بینی سرعت ترافیک محورهای برون-شهری به‌صورت سری زمانی در دست است. شبکه عصبی به‌گونه‌ای طراحی می‌شود که قادر است پیش‌بینی وضعیت ترافیک محورها را از ابتدای شروع دوره در دسترس تا زمان t دریافت کند و سپس با استفاده از این داده‌ها آموزش دیده و قادر است سرعت ترافیک محورها را در بازه زمانی t تا پایان دوره‌ای مورد نظر را پیش‌بینی کند. این پیش‌بینی به‌عنوان آزمونی برای عملکرد مدل طراحی شده است. الگوریتم مورد استفاده برای آموزش شبکه الگوریتم آموزش لونیگ - مارکوت^{۱۰} است که انتخاب این الگوریتم به دلیل نرخ همگرایی بهتر و سریع‌تر بودن این الگوریتم در مسائل تقریب زدن توابع است [Do et al 2019].

مزایای اصلی این روش شامل موارد زیر است:

- استفاده از مدلی با رویکرد غیر پارامتری بر پایه‌ی یادگیری ماشین
 - دقت قابل قبول مدل بر اساس مطالعات پیشین
 - مدل‌سازی ساده با توجه به عدم تعریف معناداری
- در مدل شبکه عصبی مورد استفاده ورودی هر نرون، به‌عنوان یک واحد پردازشی، با استفاده از رابطه ۲ تعیین می‌شود.

$$u_j = \sum_{i=1}^n w_{ij} x_i + \theta_i \quad (2)$$

که در آن بردار وزن خروجی نرون قبلی (i) به نرون فعلی (j) است. w_{ij} بردار متغیرهای مورد استفاده و θ_i آستانه مدل است. همچنین با استفاده از تابع سیگنویید^{۱۱} (رابطه ۳) خروجی نرون‌ها محاسبه می‌شود.

$$h_j = \frac{1}{1 + \exp(-u_j)} \quad (3)$$

مدل پیش‌بینی کوتاه‌مدت سرعت متوسط غیرمجاز با رویکرد یادگیری ماشین

اطلاعات سرعت هر محور به‌صورت روزانه و ساعتی بر روی وب-سایت سازمان راهداری و حمل‌ونقل جاده‌ای قرار گرفته است.^{۱۲} نکته حائز اهمیت داده‌های دریافتی از سایت، خام بودن این داده و امکان تولید متغیرهای مستقل بیشتر با پیش‌پردازش اولیه این داده‌ها است. بدین ترتیب، با استفاده از اطلاعات مربوط به تاریخ و زمان می‌توان اطلاعات زیادی از داده موجود استخراج نمود. متغیرهای کلی اولیه و استخراج شده از بانک اطلاعاتی در جدول ۱ **Error!** **Reference source not found.** نشان داده شده است.


جدول ۱. تعریف کلی متغیرهای موجود در بانک اطلاعاتی

ردیف	اطلاعات	توضیحات
۱	حجم ترافیک ساعتی	کل حجم هر ایستگاه در بازه زمانی یک ساعت
۲	سرعت متوسط ساعتی	متوسط سرعت هر ایستگاه در بازه زمانی یک ساعت
۳	فصل	شامل بهار، تابستان، پاییز و زمستان
۴	ماه شمسی	شامل ۱۲ ماه یک سال شمسی
۵	ماه قمری	شامل ۱۲ ماه یک سال قمری
۶	ساعت	شامل ۲۴ ساعت یک روز
۷	تعطیلی	بیانگر تعطیلی رسمی در کشور
۸	نوع تعطیلی	بیانگر نوع تعطیلی رسمی در کشور
۹	روزهای بعد از تعطیلی	بیانگر وجود تعطیلی ۱، ۲ و ۳ روز بعد از روز مذکور
۱۰	نوع تعطیلی روزهای بعد	بیانگر نوع تعطیلی ۱، ۲ و ۳ روز بعد از روز مذکور
۱۱	تعطیلی روزهای قبل از	بیانگر وجود تعطیلی ۱، ۲ و ۳ روز قبل از روز مذکور
۱۲	نوع تعطیلی روزهای قبل	بیانگر نوع تعطیلی ۱، ۲ و ۳ روز قبل از روز مذکور
۱۳	وضعیت آب‌وهوا	شامل آفتابی، بارانی و برفی

از جمله مزایای این روش می‌توان به موارد زیر اشاره کرد:

- استفاده از مدلی با رویکرد غیر پارامتری بر پایه یادگیری ماشین عمیق
- دقت قابل قبول مدل بر اساس مطالعات پیشین
- مدل‌سازی ساده با توجه به عدم تعریف معناداری
- امکان در نظرگیری ارتباط مشاهدات متوالی و سازگاری بیشتر با ماهیت داده سری زمانی

شبکه عصبی بازگشتی مورد استفاده در مورد مطالعه شامل یک لایه ورودی، یک لایه خروجی و ده لایه نهان است.

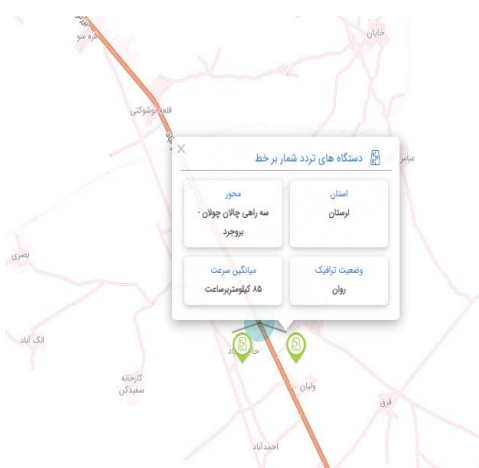


شکل ۱. Error! No text of specified style in document.

فلوچارت روش تحقیق

۴. داده

هدف این پژوهش پیش‌بینی سرعت متوسط راه‌های برون‌شهری برای بازه ساعتی مختلف آینده بوده و تشخیص نقاط پر تخلف است و بدین منظور از داده‌های ثبت شده توسط ایستگاه‌های برداشت اطلاعات تعبیه شده در جاده‌های کشور استفاده شده است. پارامتر سرعت در این ایستگاه‌ها توسط دستگاه‌های سرعت‌سنج (ایستگاه‌های ترددشماری هم نامیده می‌شود) برداشت می‌شوند.



شکل ۲. موقعیت مقطعی که در آن اطلاعات برداشت شده است
جدول ۲. اطلاعات آماری متغیرهای ترافیکی به تفکیک داده آموزش و آزمون

متغیر	داده	تعداد مشاهدات	میانگین		انحراف معیار
			(کیلومتر بر ساعت)	(کیلومتر بر ساعت)	
سرعت آموزش	۳۰۹۶۹	۸۵/۳	۸/۹	۲۷	۱۴۴
متوسط آزمون	۷۷۴۲	۸۷/۷	۹/۲	۲۴	۱۴۶
حجم آموزش	۳۰۹۶۹	۳۹۶/۸	۲۳۹	۶	۳۴۴۶
ترافیک آزمون	۷۷۴۲	۴۱۲/۴	۲۵۶/۲	۵	۳۷۸۹

۵. نتایج

پس از به‌کارگیری سه مدل شبکه عصبی مصنوعی و بازگشتی و ماشین بردار پشتیبان به‌منظور پیش‌بینی سرعت متوسط ترافیک، ساعاتی از روز که وضعیت ایمنی ترافیک با توجه به سرعت ترافیک رو به حالت نایمن می‌رود مشخص می‌شود. سه مدل نامبرده برای هر دو جهت رفت و برگشت محور بروجرد-سه راه چالان چولان به کارگرفته شده است و با استفاده از مدل آموزش دیده، برای داده‌ی آزمون که در فرآیند آموزش وارد نشده مقادیر سرعت پیش-بینی شده و با مقادیر واقعی مقایسه شده است.

فصلنامه مهندسی حمل و نقل / سال سیزدهم / شماره دوم (۵۱) / زمستان ۱۴۰۰

یکی از مراحل مهم قبل از فرآیند مدل‌سازی، بررسی داده‌های مورد استفاده برای ساخت مدل و اصلاح داده‌های نامعتبر است. بدین منظور داده‌های سرعت ثبت شده برای تردد شمارهای مد نظر بررسی و به دلیل مشاهده برخی خطاها، فیلترهایی برای این داده‌ها در نظر گرفته شده و داده‌های نامعتبر اصلاح می‌گردد. داده‌های نامعتبر شامل داده‌هایی می‌شود که شامل مقادیر غیرمنطقی و غیرواقعی باشند. منظور از داده‌های غیرمنطقی و غیرواقعی داده‌هایی است که به لحاظ امکان‌پذیری غیرممکن باشند، نظیر سرعت و حجم منفی یا دارای مقادیر دور افتاده باشند. به‌عنوان مثال سرعتی که دو برابر سرعت آزاد محور باشد. این مشاهدات شناسایی و حذف شده‌اند.

اطلاعات ترافیکی استفاده شده در این پژوهش محور اراک-خرم آباد بزرگراه خلیج فارس مقطع سه‌راهی چالان چولان-بروجرد، در دو مسیر رفت و برگشت است. شکل ۲ موقعیت مقطعی که در آن اطلاعات برداشت شده است را نشان می‌دهد. به‌منظور مدل‌سازی و پیش‌بینی سرعت ترافیک از کلان داده ترافیکی که در بازه زمانی ۱ مهر ۱۳۹۲ تا ۲۱ مهر ۱۳۹۷ ثبت شده و مجموعاً شامل ۳۸۷۱۱ مشاهده ساعتی می‌شود، استفاده شده است. این کلان داده برای هر دو مسیر رفت و برگشت بزرگراه خلیج فارس به کار گرفته شده است. ۸۰ درصد ابتدایی داده‌ها به‌منظور آموزش مدل‌ها و ۲۰ درصد باقیمانده به‌منظور آزمون نتایج پیش‌بینی تخصیص یافته است. همچنین جدول ۲ اطلاعات آماری سرعت متوسط و حجم ترافیک را به تفکیک داده آموزش و آزمون را نشان می‌دهد. مطابق با این جدول مقادیر میانگین و انحراف معیار سرعت متوسط و حجم ترافیک در داده آزمون بیشتر از داده آموزش است. شکل ۲ نیز فراوانی حالت‌های گوناگون مشاهده شده متغیرهای پیش‌بینی کننده را نشان می‌دهد.

مدل پیش‌بینی کوتاه‌مدت سرعت متوسط غیرمجاز با رویکرد یادگیری ماشین

اطلاع‌رسانی شرایط ترافیک استفاده می‌شود که نیاز به افق بلندمدت ندارند. در مقابل مدل‌های بلندمدت با توجه به افق زمانی بلندتر فرصت تصمیم‌گیری بیشتری برای مواجهه با شرایط ترافیکی بحرانی را به همراه دارد. در آخر توجه به این نکته ضرورت دارد که این دو مدل به صورت مکمل یکدیگر عمل می‌کنند و وجود هر دو نوع مدل ضروری است. در ادامه نتایج به دست آمده مدل‌های کوتاه‌مدت و بلندمدت به تفکیک ارائه شده است. در بخش پیوست مقادیر مشاهده شده و پیش‌بینی شده به تفکیک مدل‌ها برای بازه زمانی مشخصی ارائه شده است.

۵-۱ پیش‌بینی سرعت با مدل‌های بلندمدت

همان‌طور که بیان شد در مدل‌های بلندمدت تنها متغیرهای تقویمی و آب‌وهوا استفاده شده است. پیش‌بینی با این مدل‌ها می‌تواند برای یک ساعت آینده تا یک سال آینده قابل اعتماد باشد. برای ارزیابی نتایج پیش‌بینی‌ها از شاخص‌های میانگین درصد خطای مطلق^{۱۳} (قاسم‌پور و بهزادی، ۱۳۹۹)، درصد دقت پیش‌بینی سرعت بالای ۹۰ کیلومتر بر ساعت و درصد دقت پیش‌بینی سرعت بالای ۸۵ کیلومتر بر ساعت استفاده شده است. سرعت ۹۰ کیلومتر بر ساعت سرعت مجاز راه و سرعت ۸۵ کیلومتر بر ساعت سرعت راه است. نتایج به دست آمده پس از استفاده از مدل‌های ماشین بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی بازگشتی به صورت کوتاه‌مدت به شرح جدول ۳ است:

یکی از نکات بسیار مهم استفاده از متغیرهای ترافیکی متنوع به عنوان متغیر مستقل مدل پیش‌بینی کننده سرعت ترافیک است. در این پژوهش دو دسته مدل پیش‌بینی کننده آموزش داده شده‌اند. دسته اول مدل‌هایی هستند که از متغیرهای تقویمی و آب‌وهوا به عنوان متغیرهای پیش‌بینی کننده استفاده می‌کنند. با توجه به این متغیرها برای آینده مشخص یا قابل پیش‌بینی هستند، می‌توان پیش‌بینی سرعت را برای بازه زمانی نسبتاً طولانی انجام داد. در این پژوهش به این مدل‌ها اصطلاحاً مدل‌های بلندمدت اطلاق می‌شود. در طبقه دوم مدل‌ها، علاوه بر متغیرهای تقویمی و آب‌وهوا، از مقادیر سرعت مشاهده شده در ساعات گذشته برای پیش‌بینی سرعت در آینده نیز استفاده شده است. بدین صورت ارتباط میان مشاهدات متوالی به صورت مشخص تری دیده می‌شود. چنانچه در ساعات قبل سرعت ترافیک کم باشد، این احتمال وجود دارد که این روند در ساعات بعد هم ادامه داشته باشد؛ اما چالش اصلی این است که مقادیر سرعت در ساعات قبل باید مشاهده شود و این مقادیر برای آینده بلندمدت مجهول هستند. در این مدل‌ها که مدل‌های کوتاه‌مدت نام‌گذاری شده‌اند، از سرعت مشاهده شده ۳ ساعت پیش تا ۸ ساعت پیش نیز به عنوان متغیر پیش‌بینی کننده استفاده شده است؛ بنابراین این مدل‌ها تنها می‌توانند سرعت ترافیک را برای یک تا سه ساعت آینده پیش‌بینی کنند. اگرچه که بازه‌ی پیش‌بینی این مدل‌ها محدودتر است اما انتظار می‌رود دقت بیشتری را به همراه داشته باشند. پیش‌بینی‌های این مدل‌ها معمولاً برای تابلوهای

جدول ۳. نتایج پیش‌بینی سرعت با مدل‌های بلندمدت

شاخص	مدل شبکه عصبی مصنوعی		مدل ماشین بردار پشتیبان		شبکه عصبی بازگشتی	
	بروجرد به سهراه	سهراه چالان	بروجرد به سهراه	سهراه چالان	بروجرد به سهراه	سهراه چالان
	چالان چولان	چولان به بروجرد	چالان چولان	چولان به بروجرد	چولان به بروجرد	چولان به بروجرد
میانگین درصد خطای مطلق (درصد)	۲/۸	۴/۴	۳/۲	۴/۸	۴	۵/۱

درصد دقت پیش‌بینی	۶۳/۶	۷۰/۴	۷۲/۶	۷۹/۷	۶۵/۸	۷۶/۲
سرعت بالای ۹۰ کیلومتر بر ساعت						
درصد دقت پیش‌بینی	۹۰/۹	۸۱/۸	۹۳/۵	۸۷/۹	۸۳	۸۹/۱
سرعت بالای ۸۵ کیلومتر بر ساعت						

۲-۵ پیش‌بینی سرعت با مدل‌های کوتاه‌مدت

است. پیش‌بینی با این مدل‌ها می‌تواند برای یک ساعت آینده تا یک سال آینده قابل‌اعتماد باشد. نتایج به دست آمده پس از استفاده از مدل‌های ماشین بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی بازگشتی به صورت کوتاه‌مدت به شرح جدول ۴ است.

در مدل‌های کوتاه‌مدت علاوه بر متغیرهای تقویمی و آب‌وهوا از سرعت ترافیک در بازه زمانی ۳ تا ۸ ساعت گذشته نیز استفاده شده

جدول ۴. نتایج پیش‌بینی سرعت با مدل‌های کوتاه‌مدت

شاخص	مدل شبکه عصبی مصنوعی		مدل ماشین بردار پشتیبان		شبکه عصبی بازگشتی	
	بروجرد به سهره	سهره چالان	بروجرد به سهره	سهره چالان	بروجرد به سهره	سهره چالان
میانگین درصد خطای مطلق (درصد)	۲/۵	۴/۱	۳/۱	۴/۶	۳/۳	۴/۶
درصد دقت پیش‌بینی	۷۹/۲	۶۸/۳	۸۲/۱	۷۵/۵	۷۴	۶۷/۳
سرعت بالای ۹۰ کیلومتر بر ساعت						
درصد دقت پیش‌بینی	۹۱/۵	۸۶/۶	۹۰/۱	۹۵	۸۶/۸	۹۲/۱
سرعت بالای ۸۵ کیلومتر بر ساعت						

۳-۵ تحلیل حساسیت مدل‌ها

در هر دو گروه مدل‌های کوتاه‌مدت و بلندمدت حذف و دقت مدل‌ها بدون آن متغیر محاسبه شده است. به عبارت دیگر متغیری که با حذف آن خطای پیش‌بینی سرعت افزایش یابد متغیر مؤثرتری در پیش‌بینی سرعت ترافیک است و می‌توان این‌گونه استنباط کرد که تغییرات سرعت ترافیک ارتباط معناداری با تغییرات آن متغیر دارد. جداول ۵ و ۶ به ترتیب اثر حذف متغیرهای مورد استفاده بر میانگین فصلنامه مهندسی حمل‌ونقل / سال سیزدهم / شماره دوم (۵۱) / زمستان ۱۴۰۰

یکی از معایب اصلی مدل‌های مبتنی بر یادگیری ماشین عدم ارائه اهمیت متغیرها و روابط میان متغیرهای مستقل و وابسته است (شکیبا و همکاران، ۱۳۸۸). در این پژوهش به منظور مشخص نقش متغیرهای پیش‌بینی‌کننده در دقت پیش‌بینی سرعت، تک‌تک متغیرها

مدل پیش‌بینی کوتاه‌مدت سرعت متوسط غیرمجاز با رویکرد یادگیری ماشین

درصد خطای مطلق مدل‌های بلندمدت و کوتاه‌مدت را نشان

می‌دهد.

جدول ۵. اثر حذف متغیرهای پیش‌بینی کننده بر میانگین درصد خطای مطلق مدل‌های بلندمدت

متغیر حذف شده	مدل شبکه عصبی مصنوعی		مدل ماشین بردار پشتیبان		شبکه عصبی بازگشتی	
	سرهراه چالان	بروجرد به سرهراه چالان	سرهراه چالان	بروجرد به سرهراه چالان	سرهراه چالان	بروجرد به سرهراه چالان
دقت پایه	۲/۸	۴/۴	۳/۲	۴/۸	۴	۵/۱
فصل	۳/۲	۴/۹	۴	۵/۲	۴/۶	۵/۵
ماه شمسی	۳/۳	۵/۲	۳/۹	۵/۱	۴/۸	۵/۸
ماه قمری	۳	۴/۷	۳/۷	۴/۹	۴/۳	۵/۳
ساعت	۷/۵	۸/۸	۸/۲	۹/۴	۱۰/۱	۱۱
تعطیلی	۶/۱	۷/۴	۷/۷	۸/۶	۹/۲	۹/۹
نوع تعطیلی	۵/۹	۷/۱	۷/۴	۸/۲	۹	۹/۳
روزهای بعد از تعطیلی	۳/۳	۵/۱	۳/۸	۵/۲	۴/۹	۵/۸
نوع تعطیلی روزهای بعد	۳/۲	۵/۴	۴	۵/۳	۴/۸	۵/۸
روزهای قبل از تعطیلی	۳/۶	۵/۵	۴/۱	۵/۵	۵	۵/۹
نوع تعطیلی روزهای قبل	۳/۸	۵/۱	۳/۹	۵/۶	۴/۴	۶/۱
وضعیت آب‌وهوا	۴/۴	۵/۵	۴/۶	۵/۹	۵/۱	۷
انسداد	۳/۱	۴/۶	۳/۵	۵/۱	۴/۸	۶/۹

جدول ۶. اثر حذف متغیرهای پیش‌بینی کننده بر میانگین درصد خطای مطلق مدل‌های کوتاه‌مدت

متغیر حذف شده	مدل شبکه عصبی مصنوعی		مدل ماشین بردار پشتیبان		شبکه عصبی بازگشتی	
	سرهراه چالان	بروجرد به سرهراه چالان	سرهراه چالان	بروجرد به سرهراه چالان	سرهراه چالان	بروجرد به سرهراه چالان
دقت پایه	۲/۵	۴/۱	۳/۱	۴/۶	۳/۳	۴/۶

شبکه عصبی بازگشتی		مدل ماشین بردار پشتیبان		مدل شبکه عصبی مصنوعی		متغیر حذف شده
سرهراه چالان چولان به بروجرد	بروجرد به سرهراه چالان چولان	سرهراه چالان چولان به بروجرد	بروجرد به سرهراه چالان چولان	سرهراه چالان چولان به بروجرد	بروجرد به سرهراه چالان چولان	
۵/۱	۴	۴/۸	۳/۲	۴/۴	۲/۸	سرعت ساعات قبل
۵/۲	۴/۹	۵/۱	۳/۸	۴/۵	۳/۱	فصل
۵/۷	۴/۷	۵/۳	۳/۸	۵/۵	۳/۲	ماه شمسی
۵/۳	۴/۲	۵	۳/۴	۴/۴	۲/۹	ماه قمری
۹/۷	۸/۵	۸/۸	۷/۷	۸/۷	۶/۹	ساعت
۹	۸/۶	۷/۷	۷/۱	۷/۱	۵/۸	تعطیلی
۸/۳	۷/۹	۸	۷/۲	۶/۹	۵/۸	نوع تعطیلی
۵/۶	۴/۷	۵/۱	۳/۹	۵/۱	۳/۲	روزهای بعد از تعطیلی
۵/۹	۴/۷	۵/۴	۴/۱	۵/۳	۳/۱	نوع تعطیلی روزهای بعد
۵/۷	۵/۱	۵/۱	۴/۲	۵/۴	۳/۶	روزهای قبل از تعطیلی
۶	۴/۷	۵/۵	۳/۸	۵	۳/۹	نوع تعطیلی روزهای قبل
۶/۶	۵/۴	۶	۴/۷	۵/۳	۴/۳	وضعیت آب و هوا
۷/۱	۵	۵/۳	۳/۸	۴/۷	۳/۲	انسداد

۶. جمع بندی و نتیجه گیری

در این پژوهش به منظور تشخیص نقاط پر تخلف در طول زمان، از روش پیش‌بینی سرعت و اقدام پیش از وقوع بروز تخلف سرعت استفاده شده است. بدین منظور داده‌های ترافیکی محور اراک-خرم-آباد، مقطع سرهراه چالان چولان به خرم‌آباد، بزرگراه خلیج فارس مورد بررسی قرار گرفت. به منظور رسیدن به بالاترین دقت ممکن سه روش متفاوت در کنار یکدیگر مورد استفاده قرار گرفت. دو روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان به‌عنوان دو

همان‌گونه که نتایج جداول ۵ و ۶ نشان می‌دهد در هر دو گروه مدل‌های بلندمدت و کوتاه‌مدت، متغیرهای ساعت، تعطیلی، نوع تعطیلی و آب‌وهوا متغیرهای مؤثرتری هستند و با حذف آن‌ها میانگین درصد خطای مطلق مدل‌ها افزایش چشم‌گیری می‌یابد. لذا می‌توان چنین برداشت کرد که تغییرات سرعت ترافیک به تغییرات این متغیرها وابستگی بیشتری دارد. نکته حائز اهمیت دیگر افزایش میانگین خطای مطلق مدل‌ها با حذف هر متغیر است. به عبارت دیگر تمام متغیرهای مورد استفاده مؤثر بوده و دقت پیش‌بینی را افزایش می‌دهند.

مدل پیش‌بینی کوتاه‌مدت سرعت متوسط غیرمجاز با رویکرد یادگیری ماشین

خروجی این پیش‌بینی‌ها به استفاده‌کنندگان از راه و گرداندگان سیستم حمل‌ونقل امکان مقابله با شرایط ترافیکی ناایمن را پیش از وقوع حادثه فراهم می‌سازد و می‌توان انتظار بروز کمتر تصادفات ناشی از سرعت غیرمجاز بود. در ادامه استراتژی‌های قابل استفاده برای تحقق این امر مورد بررسی قرار می‌گیرد.

۶-۱ کاربرد خروجی پیش‌بینی‌ها

با افزایش ایمنی این مسیر علاوه بر جلوگیری از تلفات ناشی از تصادفات، می‌توان سطح عملکردی این بزرگراه را افزایش داده و آورده مالی و اعتباری به همراه داشت. در ادامه استراتژی‌هایی که بعد از مشخص شدن سرعت ترافیک در آینده می‌توان به کار گرفت، بررسی شده است.

استراتژی ۱: استفاده از تابلوهای هوشمند اعلام وضعیت ایمنی جاده

استراتژی ۲: آرام‌سازی موقت ترافیک

استراتژی ۳: اعلام وضعیت ایمنی جاده از طریق وب‌سایت یا اپلیکیشن تلفن همراه

استراتژی ۴: ثبت تخلف توسط پلیس یا دوربین کنترل سرعت به‌عنوان پیشنهاد برای ادامه این پژوهش می‌توان از سایر روش‌های مبتنی بر یادگیری ماشین نظیر روش K-نزدیک‌ترین همسایه، درخت تصادفی و درخت تصمیم استفاده کرد. همچنین از آنجا که مدل‌های یادگیری ماشین قابلیت کشف روابط علت و معلولی را ندارند، پیشنهاد می‌شود مدل‌های مبتنی بر آمار و احتمالات بدین منظور مورد استفاده قرار گیرند.

۷. پی‌نوشت‌ها

- 1- Naïve
- 2- Seasonal autoregressive integrated moving average model
- 3- Autoregressive integrated moving average Model

روش با کارایی مناسب در پیش‌بینی سرعت ترافیک به همراه روش شبکه عصبی بازگشتی به‌عنوان یک روش مبتنی بر اساس یادگیری ماشین عمیق می‌تواند انتخاب‌های مناسبی محسوب شوند. پس از پیش‌پردازش داده سه مدل یادگیری ماشین در محیط کد نویسی R آموزش داده شده و از مدل‌های آموزش داده شده به‌منظور پیش‌بینی استفاده شده است. از آنجا که داده‌های ترافیکی به‌عنوان داده سری زمانی تابعی از زمان بوده و مشاهدات متوالی از یکدیگر مستقل نیستند، مدل‌سازی در دو گروه بلندمدت و کوتاه‌مدت انجام شده است. در گروه بلندمدت ویژگی‌های تقویمی و آب‌وهوا مورد استفاده قرار گرفته است. اگرچه که در این مدل‌ها ارتباط مشاهدات متوالی نادیده گرفته شده است، اما می‌توانند افق زمانی بلندتری را به‌منظور پیش‌بینی سرعت به همراه داشته باشند. در مقابل مدل پیش‌بینی کوتاه‌مدت علاوه بر ویژگی‌های تقویم و آب‌وهوا، مشاهدات سه تا پنج ساعت قبل را به‌عنوان متغیر پیش‌بینی کننده در نظر گرفته و دقت پیش‌بینی به شکل چشمگیری افزایش یافته است. طبیعتاً استفاده از چنین متغیرهای منجر به کوتاه‌تر شدن افق زمانی پیش‌بینی‌ها شده است.

نتایج نشان می‌دهد بر اساس شاخص میانگین درصد خطای مطلق مدل ماشین بردار پشتیبان کمترین خطای پیش‌بینی را برای هر دو مدل کوتاه‌مدت و بلندمدت نتیجه می‌دهد. در مدل‌های کوتاه‌مدت، این مدل سرعت متوسط مسیر بروجرد به چالان چولان را با $2/5$ درصد خطا و برای جهت مقابل آن با $4/1$ درصد خطا پیش‌بینی می‌کند. همچنین در مدل‌های بلندمدت، مدل ماشین بردار پشتیبان سرعت متوسط مسیر بروجرد به چالان چولان را با $2/8$ درصد خطا و برای جهت مقابل آن با $4/4$ درصد خطا پیش‌بینی می‌کند.

در پایان می‌توان از نتایج مدل کوتاه‌مدت برای پیش‌بینی دقیق‌تر سرعت در یک تا سه ساعت آینده استفاده کرد و نتایج مدل بلندمدت برای سه ساعت تا یک سال آینده مورد استفاده قرار بگیرد.

prediction". Transportation research part C: emerging technologies, Vol. 108, pp. 12-28.

- Dong, H., Jia, L., Sun, X., Li, C., & Qin, Y. (2009) "Road traffic flow prediction with a time-oriented ARIMA model". In 2009 Fifth International Joint Conference on INC, IMS and IDC, pp. 1649-1652.

- Garg, N., Mangal, S. K., Saini, P. K., Dhiman, P., & Maji, S. (2015) "Comparison of ANN and analytical models in traffic noise modeling and predictions". Acoustics Australia, Vol. 43, No. 2, pp. 179-189.

- Ghosh, B., Basu, B., O'Mahony, M., (2007) "Bayesian time-series model for short-term traffic flow forecasting". Journal of Transportation Engineering, Vol. 133, No. 3, pp. 180-189.

- Kumar, K., Parida, M., Katiya, V.K., (2014) "Short Term Traffic Flow Prediction for a Non-Urban Highway Using Artificial Neural Network". International Journal of Environmental Science and Technology, Vol. 11, No. 3, pp. 719-730.

- Lee, Y. (2009) "Freeway travel time forecast using artificial neural networks with cluster method" In Information Fusion, 12th International Conference on IEEE.

- Maji, A., Singh, D., Agrawal, N., & Zaman, M. (2018). "Operating speed prediction models for tangent sections of two-lane rural highways in Oklahoma State". Transportation Letters, Vol. 12, No. 2, pp. 130-137.

- Rasaizadi, A., A. Ardestani, and S.E. Seyedabrishami, (2020) Traffic management via traffic parameters prediction by using machine

4- Artificial neural network

5- Support vector machine

6- Recurrent neural network

7- Kernel functions

8- Radial basis function

9- Multi-layer perceptrons

10- Levenberg-Marquardt

11- Sigmoid function

12- 141.ir

13- Mean absolute percentage error

۸ منابع

- قاسم پور، بهزادی، سعید. (۱۳۹۹). مدلسازی و پیش بینی ترافیک با استفاده از شبکه ی عصبی پایه و شبکه ی عصبی موجک و به کارگیری سه الگوریتم فراابتکاری ژنتیک، ازدحام ذرات و رقابت استعماری جهت بهینه سازی. نشریه علمی علوم و فنون نقشه برداری، ۱۰(۳)، ۱۴۷-۱۶۳.

- شکیباء، م.، و تشنه لب، م.، و زکایی، س. (۱۳۸۸). پیش بینی نرخ ترافیک ورودی به مسیر یاب با استفاده از شبکه عصبی با قابلیت وزن های دینامیک دار. مهندسی برق مجلسی، ۳(۲)، ۹-۵.

- Chen, Y., Chen, Y., & Yu, B. (2020) "Speed distribution prediction of freight vehicles on mountainous freeway using deep learning methods". Journal of Advanced Transportation, Vol. 2020.

- Dengen, N. (2016) "Comparison of SARIMA, NARX and BPNN models in forecasting time series data of network traffic". In Science in Information Technology (ICSITech), 2nd International Conference on IEEE.

- Do, L. N., Vu, H. L., Vo, B. Q., Liu, Z., & Phung, D. (2019) "An effective spatial-temporal attention based neural network for traffic flow

- Yang, X., Zou, Y., Tang, J., Liang, J., & Ijaz, M. (2020) "Evaluation of Short-Term Freeway Speed Prediction Based on Periodic Analysis Using Statistical Models and Machine Learning Models". *Journal of Advanced Transportation*.
- Zhang, C., Sun, S., Yu, G., (2004) "A Bayesian Network Approach to Time Series Forecasting of Short-Term Traffic Flows". In *Intelligent Transportation Systems, Proceedings. The 7th International IEEE Conference*.
- Zhou, M., Qu, X., & Li, X. (2017) "A recurrent neural network based microscopic car following model to predict traffic oscillation". *Transportation research part C: emerging technologies*, Vol. 84, pp. 245-264.
- Zhu, Z., Tang, L., Xiong, C., Chen, X., & Zhang, L. (2019) "The conditional probability of travel speed and its application to short-term prediction". *Transportmetrica B: Transport Dynamics*, Vol. 7, No. 1, pp. 684-706.
- learning algorithms. *International Journal of Human Capital in Urban Management*.
- Rong, C. L., Chun, W. Q., (2010) "Prediction model for urban expressway short-term traffic flow based on the support vector regression". In *tenth International conference of Chinese Transportation Professionals (ICCTP)*.
- Tang, J., Chen, X., Hu, Z., Zong, F., Han, C., & Li, L. (2019) "Traffic flow prediction based on combination of support vector machine and data denoising schemes". *Physica A: Statistical Mechanics and its Applications*, pp. 120642.
- Westeyn, T., Presti, P., Johnson, J., & Starner, T. (2009) "A naive technique correcting time-series data for recognition applications". In *2009 International Symposium on Wearable Computers*, pp. 159-160.
- Xiaoyu, H., Yisheng, W., Siyu, H., (2013) "Short-Term traffic flow forecasting based on two-tier K-nearest neighbor algorithm". *Procedia - Social and Behavioral Sciences*, Vol. 96, No. 6, pp. 2529-2536.

رضا محمدحسینی، آرش رساءایزدی

رضا محمدحسینی، درجه دکتری تخصصی مهندسی عمران، گرایش برنامه‌ریزی حمل‌ونقل را از دانشگاه صنعتی شریف دریافت نموده است. زمینه‌های پژوهشی مورد علاقه ایشان برنامه‌ریزی حمل‌ونقل ریلی است. ایشان در حال حاضر عضو هیات علمی دانشکده راه‌آهن دانشگاه علم و صنعت با مرتبه استادیاری است.



آرش رساءایزدی، درجه کارشناسی مهندسی عمران را در سال ۱۳۹۲ از دانشگاه شهید باهنر کرمان، درجه کارشناسی ارشد را در سال ۱۳۹۴ از دانشگاه صنعتی شریف و درجه دکتری تخصصی خود را در سال ۱۴۰۰ از دانشگاه تربیت مدرس دریافت نموده است. زمینه‌های پژوهشی مورد علاقه ایشان داده‌کاوی، تحلیل کلان داده-های ترافیکی و یادگیری ماشین است.

