پیش‌بینی حجم تردد در ایام تعطیل با استفاده از مدل شبکه عصبی مصنوعی (نمونه موردی: راه‌های برون‌شهری ایران)

مقاله علمی – پژوهشی

سینا صاحبی*، استادیار، گروه مهندسی حمل‌ونقل، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران
مانا مس‌کار، دانشجوی دکتری، دانشکده مهندسی صنایع، دانشگاه صنعتی شریف، تهران، ایران
محمد بافنده، دانشجوی کارشناسی ارشد، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران
*پست الکترونیکی نویسنده مسئول: s_sahebi@sbu.ac.ir

دریافت: ۱٤۰۳/۰٤/۰۱– پذیرش: ۱٤۰۳/۱۱/۰۱
صفحه ۲۳٤-۲۱۹

چکیده

حجم ترافیک از جمله مهم‌ترین پارامترهای ترافیکی است که در بسیاری از تحلیل‌های حمل‌ونقلی از جمله طراحی، برنامه‌ریزی، سیاست‌گذاری و نیز توسعه مدل‌های مختلف مورداستفاده قرار می‌گیرد. در ایام تعطیل، با اوج‌گرفتن سفرهای برون‌شهری، الگوی حجم ترافیک در شبکه راه‌های برون‌شهری کشور دچار تغییرات قابل‌توجهی می‌شود. در ایران، تعطیلات با تطابق مناسبت‌های قمری و شمسی الگوهای متفاوتی به خود می‌گیرند و با چینش‌های مختلف روزهای تعطیل، حجم تردد در راه‌های برون‌شهری کشور تغییر محسوسی می‌یابد. هدف از این مطالعه، بررسی الگوی تغییرات حجم تردد در ایام تعطیل و نیز ارائه مدلی برای پیش‌بینی حجم تردد در تعطیلات است. بدین منظور، مدل شبکه عصبی مصنوعی جهت پیش‌بینی حجم تردد در جاده‌های برون‌شهری استان‌های کشور توسعه داده شد که نسبت به تعطیلات حساس است. مقیاس زمانی مدل‌ها، روزانه است و به تفکیک استان‌های کشور ساخته شده‌اند. میانگین درصد خطای مطلق به‌عنوان شاخص ارزیابی مدل‌ها مورداستفاده قرار گرفت. متوسط این شاخص برای تمام مدل‌ها ۹/۲۸ درصد و به‌عنوان نمونه برای استان مازندران، ۸/۸۹ درصد بود. نتایج این پژوهش به سیاست‌گذاران کمک می‌کند تا در شرایط مختلف ایام سال، حجم تردد در محورهای مواصلاتی کشور را در سطح استان-روز پیش‌بینی کرده و از قبل تدابیر لازم را برای مواجه شدن با تراکم‌های ترافیکی در ایام خاص و تعطیلات اتخاذ نمایند. همچنین می‌توان با به‌کارگیری مدل توسعه داده شده، تأثیر سناریوهای مختلف تعطیلات را بر حجم تردد محورهای کشور بررسی نمود.

واژه‌های کلیدی: پیش‌بینی حجم تردد، تعطیلات، شبکه عصبی مصنوعی

۱-مقدمه

سوانح رانندگی در جهان تهدیدی جدی برای منابع انسانی تلقی می‌شوند. مرگ‌ومیر ناشی از تلفات رانندگی هشتمین علت فوت در جهان است و ۲/۵ درصد از علت فوت را شامل می‌شود. مطابق آمار سازمان بهداشت جهانی در سال ۲۰۱٦، بیش از ۱۷ هزار ایرانی در حوادث رانندگی جان خود را ازدست‌داده‌اند (WHO, 2018). متوسط سن جان‌باختگان در سوانح رانندگی در ایران حدود ۲۵ سال است درحالی‌که متوسط سن جان‌باختگان بیماری‌های قلبی به‌عنوان نخستین علت مرگ در ایران بیش از ۵۰ سال است. تصادفات در مقایسه با سایر علل فوت قشر جوان‌تری از جامعه را در معرض مرگ قرار می‌دهند و به همین دلیل ازدیاد متوفیات ناشی از تصادفات رانندگی، ضرر بزرگی به منابع انسانی جامعه وارد می‌دارد. متوفیات حوادث جاده‌ای به‌صورت یکنواخت در معابر شهری و راه‌های بین‌شهری توزیع نشده‌اند. مقایسه آمار تلفات ناشی از

تصادفات درون‌شهری و برون‌شهری ایران نشان می‌دهد حدود ۷۰ درصد کل تلفات ناشی از تصادفات ترافیکی، مربوط به تصادفات برون‌شهری است که این امر نشان‌دهنده اهمیت توجه ویژه به ایمنی ترافیک راه‌های برون‌شهری است. تلفات ناشی از تصادفات مهم‌ترین معضل در راه‌های برون‌شهری تلقی می‌شود که در ارتباط تنگاتنگ با شمار تردد و افزایش تقاضای سفر در راه‌های برون‌شهری است. هرچند معضلات حمل‌ونقلی در درون و برون شهر، هر دو با افزایش تقاضای سفر تشدید می‌شوند، اما ماهیت تقاضای سفر و عوامل مؤثر بر آن‌ها در راه‌های درون‌شهری و برون‌شهری متفاوت است. افزایش تقاضای سفر در راه‌های درون‌شهری عمدتاً ناشی از تقاضای سفرهای کاری یا اجباری است. به همین دلیل در مطالعات برنامه‌ریزی حمل‌ونقل شهری آنچه عمدتاً مورد مطالعه، پرسشگری و تحلیل قرار می‌گیرد، سفرهای کاری افراد است. اما در خصوص سفرهای برون‌شهری سفرهای کاری نقش پررنگی ایفا نمی‌کنند و تقاضای سفرهای برون‌شهری عموماً ماهیتی تفریحی دارد و به همین دلیل در ارتباط مستقیم با شمار ایام تعطیل است. هدف از این مطالعه، بررسی الگوی تغییرات حجم تردد در ایام تعطیل و نیز ارائه مدلی برای پیش‌بینی حجم تردد در تعطیلات است. بدین منظور، مدل شبکه عصبی مصنوعی[1] توسعه داده شد که نسبت به تعطیلات حساس است. مقیاس زمانی مدل‌ها روزانه است و به تفکیک استان‌های کشور ساخته شده‌اند. از خروجی این مدل‌ها (که همان حجم تردد پیش‌بینی شده است) می‌توان در مدل‌های شمار و شدت تصادفات استفاده کرد. بدین ترتیب می‌توان اثر تعطیلات را بر تعداد تصادفات و تلفات جاده‌ای بررسی نمود. به طور مشخص پژوهش حاضر به این سؤال پاسخ می‌دهد که «باتوجه‌به شرایط آب‌وهوایی مختلف و چینش‌های خاص تعطیلات در ایام سال در هر روز در هر استان از کشور چه میزان حجم تردد وسایل نقلیه پیش‌بینی می‌شود؟» پاسخ به این سؤال به پلیس راهور فراجا کمک می‌کند تا در شرایط مختلف ایام سال حجم تردد در محورهای مواصلاتی کشور را در سطح استان-روز پیش‌بینی نماید و از قبل تدابیر لازم برای مواجه‌شدن با تراکم‌های ترافیکی در ایام خاص و تعطیلات در کشور را اتخاذ نماید.

۲-پیشینه تحقیق

در بخش مرور ادبیات مقاله حاضر به بررسی پیشینه مطالعات در حوزه ارتباط حجم تردد و سوانح جاده‌ای، تجربیات جهانی مدیریت جریان و ایمنی ترافیک در ایام تعطیل و مرور ادبیات فنی پرداخته می‌شود. در بخش تجربیات جهانی مدیریت جریان و ایمنی ترافیک در ایام تعطیل، مطالعات و راهکارهایی که در کشورهای پیشرو در جهان به تصمیم‌گیران و گردانندگان حمل‌ونقل در جهت کاهش معضلات ناشی از تراکم ترافیکی در ایام تعطیل کمک می‌نماید مورد بررسی قرار گرفته است. در انتهای این بخش، ادبیات فنی مورداستفاده در این پژوهش مورد بررسی و مرور قرار گرفته است. در گذشته مطالعات بسیاری به بررسی رابطه حجم تردد و شمار تصادفات پرداختند که این امر مقدمات انجام یک تحلیل متا را در این زمینه برای محققان فراهم نمود. تحلیل متا فرایند کمی‌سازی نتایج چندین مطالعه است که هر یک اثرات متغیر خاصی را بر شمار تصادفات بررسی کرده‌اند و نتایج را به‌صورت تخمینی از میانگین وزنی اثر بیان کرده‌اند (Hauer, 1997). مطالعه متا بر روی ۲۸ مطالعه انجام شده در خصوص مبانی تئوری تأثیر حجم تردد بر شمار تصادفات، نشان می‌دهد که با فرض کنترل متغیرهای اثرگذار بر تصادفات، بین حجم ترافیک و شمار تصادفات رابطه غیرخطی مقعر صعودی وجود دارد (Elvik et al., 2009). دلیل تقعر را می‌توان عواملی نظیر افزایش استاندارد راه یا توجه بیشتر رانندگان در جاده‌های شلوغ دانست. در خصوص مدیریت جریان و ایمنی ترافیک در ایام تعطیل، رویکردهای متعددی در کشورهای مختلف اتخاذ شده است. یکی از این رویکردها شناسایی الگوهای حجم تردد در ایام تعطیل است. حجم ترافیک وابسته به تغییرات تقاضای سفر است و با تغییرات زمان و مکان، حجم ترافیک تغییرات قابل‌توجهی دارد. شناسایی این تغییرات به طور چشمگیری می‌تواند در تنظیم برنامه‌های کنترل ترافیک، زمان‌بندی علائم، برنامه‌های ایمنی، نظارت و پیش‌بینی حجم ترافیک کمک نماید (Z. Liu & Sharma, 2006). لیو و شارما (Z. Liu & Sharma, 2006) در خصوص اثرات تعطیلات بر حجم ترافیک مطالعه‌ای را در آلبرتای کانادا انجام دادند. داده‌های مورد استفاده در مطالعه آن‌ها با استفاده از ترددشمارهای مستقر در مسیر مورد مطالعه در بزرگراه‌های اصلی آلبرتا کانادا در سال‌های ۲۰۰۶-۱۹۸۶ جمع آوری شده است. بررسی داده‌ها

نشـــان می‌دهد که اثرات هر تعطیلی در حجم ترافیک به همان روز محـدود نمی‌شـــود بلکـه بـه روزهـای مجـاور قبل و بعد گســـترش می‌یابد. این مطالعه نشـــان داد که تعطیلات به طور معناداری بر تغییرات حجم ترافیک اثر دارد. شـناسایی الگوهای تصـادفات در ایام تعطیل به‌منظور ارتقای ایمنی ترافیک رویکرد دیگری اسـت که در بعضـی کشـورها مورداسـتفاده قرار گرفته اســـت. به‌عنوان‌مثال، اداره ایمنی حمل‌ونقل اســـترالیا مطالعاتی انجام داده اسـت که بر تصـادفات در تعطیلات متمرکز بوده‌اند. هدف این مطالعات، بررسی ویژگی‌های تصادف‌های کشنده بود کـه در طول دوره‌هـای تعطیلات ملی رخ می‌دهنـد. رونـدهای سـالانه در تعداد تلفات جاده‌ای برای دو دوره تعطیلات رسمی، یعنی کریسـمس و عید پاک، مورد بررسـی قرار گرفت و با بقیه سـال مقایسـه شـد (Anowar et al., 2013). این مطالعات نشـان دادند که تفاوت‌های مشـاهده شـده نرخ مرگ‌ومیر بین دوره‌هـای تعطیلات و غیر تعطیلات، جزئی بودنـد و از نظر آماری معنی‌دار نبودند. در یک طرح پژوهشـی مشـابه توسـط ایـالـت میســوری آمریکـا (Missouri State Highway Patrol & Statistical Analysis Center, 2005) برای شـناسـایی اندازه، شـدت و ویژگی‌های تصـادف‌های ترافیک تعطیلات، تصـــادف‌هـایی تجزیـه‌وتحلیل شـــدند که در طول تعطیلات قـانونی روز یـادبود، چهـارم ژوئیـه، روز کارگر، روز شکرگزاری، کریسمس و روز سال نو رخ داده بودند. با این‌حال، هیچ مقایســه‌ای بین تصــادف‌های تعطیلات و غیر تعطیلات یا تعطیلات و آخر هفته صورت نگرفت. همچنین در مطالعه بلاچ و همکاران (Bloch et al., 2004) تصـادفات ۱۴ تعطیلات اصـلی در کالیفرنیا برای مقایسـه افزایش در مرگ‌ومیر و آسیب ناشی از مصرف الکل حین رانندگی در طول دوره‌های تعطیلات و غیر تعطیلات بررســی شـــدند که در آن روش مدل‌ســازی رگرسیون پواسون، با کنترل تفاوت‌های فصلی از نظر روز هفته و ماه‌های سـال اسـتفاده شـد. نتیجه این مطالعه نشـان داد که نوشـیدن الکل و رانندگی در تعطیلات فصـل زمستان بیش‌تر از تعطیلات تابسـتانه، یک نگرانی محسـوب می‌شـود. در مطالعه فـارمـر و ویـلـیـمـامز (Farmer & Williams, 2005) در آمریکا محققان با بررسـی داده‌های مربوط به سال‌های ۱۹۸۶ تـا ۲۰۰۲ دریافتند که شـــش روز از ده روز با بیش‌ترین تعداد مرگ‌ومیر نزدیـک بـه این تعطیلات اصـــلی آمریکایی رخ داده اسـت: روز اسـتقلال، کریسـمس، سال جدید و روز کارگر. در مطالعه آلســـوپ و لانگلی (Alsop & Langley, 2000) در نیوزلنـد تعـداد مرگ‌ومیر در طول جشـــن‌هـای تعطیلات کریسـمس بررسی شد و نتایج نشان داد که با وجود عدم بهبود عوارض جاده در طول چندین سـال، افزایش شدید در جمعیت و تعـداد اتومبیل‌ها، عدم افزایش آماری قابل‌توجه در مرگ‌ومیر در کریســـمس می‌تواند به‌عنوان یک نتیجه مثبت در نظر گرفته شـــود. محققان تعداد زیاد مرگ‌ومیر ناشـــی از تصـــادف در ایام تعطیل را به ترکیب محتمل افزایش سـفرهای تفریحی، مصـرف الکل، و ســـرعت بیش از حد در طول روزهای تعطیلات مرتبط دانســـته‌اند (Anowar et al., 2013). در میان ســـایر دلایل احتمـالی برای افزایش مرگ‌ومیر در طول تعطیلات، مواردی نظیر ســـفر در جاده‌های ناآشـــنای روســـتایی، حواس‌پرتی و خســـتگی راننده که همه منجر به افزایش احتمال خطای راننده می‌شـوند، مطرح شده است (Anowar et al., 2013). انوار و همکـاران (Anowar et al., 2013) پژوهشـــی به‌منظور شناسایی الگوی تصادفات در تعطیلات رسمی در آلبرتای کانادا انجام دادند. در این مطالعه یک مدل رگرسـیون لجسـتیک برای برآورد عوامـل مؤثر در تصـــادف‌هـا در طول تعطیلات و آخر هفته‌های طولانی برآورد شده است. به طور خاص، هدف آن‌ها تعیین این بود که آیا تصادف در طول تعطیلات عمومی شدیدتر از تعطیلات عادی است و آیا عوامل مؤثر در تصادف‌ها در طول تعطیلات عمومی، نسـبت به عوامل مؤثر در تصـادف‌های آخر هفته متفاوت هستند یا نه. از همه مهم‌تر، نتایج این مطالعه بینش ارزشـــمندی در مورد این موضـــوع ارائه می‌دهند که آیا افزایش فعـالیت‌های اجرایی و کمپین‌های تبلیغاتی در طول تعطیلات به طور مؤثر برای رسـیدگی به مشـکلات ایمنی جاده مورداستفاده قرار می‌گیرد یا نه. متغیرهای مسـتقل اصـلی در مطالعه انوار و همکاران عبارت‌اند از شـدت تصـادف، مسـتی راننده، سـرعت نـاامن و اســـتفـاده از کمربنـد. نتـایج نشـــان داد که پیامدهای مرگ‌ومیر و آســـیب در طول تعطیلات رســـمی بیش‌تر از آخر هفته شـایع هستند و این نتیجه با این باور کلی مطابقت دارد که جـاده‌ها در طول تعطیلات رســـمی بیش‌تر خطرناک هســـتند. در یک رویکرد دیگر، ژنگ و همکاران (Zeng et al., 2013) با اسـتفاده از رسانه‌های اجتماعی به پیش‌بینی جریان ترافیک در ایام تعطیل در چین پرداختند. تجزیه‌وتحلیل شبکه‌های اجتماعی می‌تواند برای مدیریت ترافیک اسـتفاده شـود و از تصـمیم‌های مسـئولان حمل‌ونقل پشـتیبانی نماید. رسـانه اجتماعی همچنین

می‌تواند توزیع جغرافیایی گردشگران بالقوه را پیش‌بینی کند. به‌عنوان رویکردی دیگر می‌توان به عوارض بر راه‌های برون‌شهری با هدف مدیریت جریان ترافیک در ایام تعطیل در ژاپن اشاره کرد. در مطالعه‌ای که آکاهانه و همکاران (Akahane et al., 2000) در ژاپن انجام دادند، این امکان که سیستم‌های رزرو سفر می‌توانند با اصلاح نوسانات زمان تقاضای ترافیک، تراکم ترافیکی تعطیلات را در بزرگراه‌هایی که به مناطق شهری متصل می‌شوند، کاهش دهند یا از بین ببرند، بررسی شد. تقاضای ترافیک، با تنظیم زمان خروج مسافران در بزرگراه‌ها به نحوی مشابه با رزرو صندلی، طوری مدیریت می‌شود که از ظرفیت جاده عبور نکند. درآمد و هزینه این سیستم‌ها می‌تواند با تخفیف عوارضی برای افرادی که زمان خروج را تغییر می‌دهند و افزودن برای دیگران، متعادل شود. نتایج این مطالعه نشان داد که ویژگی‌های اقتصادی اجتماعی و ویژگی‌های مطرح در سیستم رزرو مهم‌ترین عوامل در تصمیم افراد برای مشارکت در سیستم است. در ادامه این بخش به بررسی انواع مختلف مدل‌های مورداستفاده برای پیش‌بینی حجم ترافیک در شرایط مختلف (از جمله تعطیلات) پرداخته می‌شود. پژوهش‌های انجام شده در خصوص پیش‌بینی حجم ترافیک شامل دو دسته کلی است: پیش‌بینی تحت شرایط عادی و پیش‌بینی تحت شرایط غیرعادی (W. Zhang et al., 2021). شرایط غیرعادی شامل تعطیلات، شرایط بد آب‌وهوایی، تصادفات رانندگی و غیره است. روش‌های مختلفی برای پیش‌بینی حجم ترافیک مورداستفاده قرار گرفته است. این روش‌ها را می‌توان در سه دسته پارامتریک، غیر پارامتریک و یادگیری عمیق[2] جای داد (Y. Liu, Wu, et al., 2022). روش‌های پارامتریک داده‌های ترافیکی را به‌صورت سری زمانی در نظر گرفته (Y. Liu, Wu, et al., 2022) و با مدل‌هایی مانند ARIMA[3] (Du et al., 2020; C. Xu et al., 2016) و تحلیل wavelet (Jeong et al., 2011) به پیش‌بینی حجم ترافیک در آینده می‌پردازد. یائو و همکاران (Yao et al., 2020) از مدل مارکف ، کی و ایشک (Qi & Ishak, 2014) از مدل مارکف پنهان و رسکار و نما (Raskar & Nema, 2022) از مدل مارکف پنهان اصلاح شده برای پیش‌بینی حجم ترافیک استفاده کردند. زمانی که الگوی حجم ترافیک شامل تغییرات نامنظم باشد، روش‌های پارامتریک دارای خطای زیادی خواهند بود (Y. Liu, Wu, et al., 2022). در این موارد روش‌های غیر پارامتریک مانند شبکه بیزین[4] (Li et al., 2019; Sun et al., 2006)، شبکه عصبی مصنوعی (Kumar et al., 2013; Qian et al., 2020; W. S. Zhang et al., 2020)، رگرسیون بردار پشتیبان[5] (Castro-Neto et al., 2009; Tang et al., 2019)، k–نزدیکترین همسایه[6] (Xiao et al., 2020; D. Xu et al., 2020) کاربرد بیشتری دارند. لین و همکاران (Lin et al., 2022) با ترکیب دو مدل هوش مصنوعی رگرسیون بردار پشتیبان و k–نزدیک‌ترین همسایه، به پیش‌بینی حجم ترافیک پرداختند. مدل‌های یادگیری عمیق نیز از توانایی مناسبی برای پیش‌بینی حجم ترافیک برخوردارند. از جمله این مدل‌ها می‌توان به شبکه عصبی پیچشی[7] (Y. Liu, Song, et al., 2022; Y. Liu, Wu, et al., 2022; Zheng et al., 2019)، شبکه عصبی گراف[8] (GNN) (Cui et al., 2020; Li et al., 2022)، شبکه عصبی LSTM[9] (Xia et al., 2021)، MLP (Ma et al., 2020) و RNN[10] (Chen et al., 2021) اشاره کرد. دسته دوم پژوهش‌های انجام شده در خصوص پیش‌بینی حجم ترافیک، به انجام پیش‌بینی در شرایط ترافیکی غیرعادی می‌پردازد. این شرایط، از جمله تعطیلات و وضعیت بد آب‌وهوایی، تأثیر قابل‌توجهی بر الگوی جریان ترافیک دارند (W. Zhang et al., 2021). بای (Bai, 2017) با استفاده از مدل ARIMA و متغیرهای مجازی و ژای و همکاران (Xie et al., 2020) با توسعه مدل شبکه عصبی به پیش‌بینی حجم مسافران در تعطیلات پرداختند. همچنین ژی و جی (Ji & Ge, 2020) با ترکیب مدل رگرسیون بردار پشتیبان و شبکه عصبی LSTM، روشی برای پیش‌بینی حجم ترافیک بزرگراه‌ها در تعطیلات ارائه کردند. لو و همکاران (Luo et al., 2019) نیز با ترکیب DFT[11] و رگرسیون بردار پشتیبان روشی برای پیش‌بینی حجم ترافیک در تعطیلات پیشنهاد کردند. ژنگ و همکاران (W. Zhang et al., 2021) با استفاده از روش‌های شبکه عصبی پیچشی (CNN)، GRU[12] و شبکه عصبی ConvLSTM[13] به توسعه مدل‌هایی برای پیش‌بینی حجم ترافیک در شرایط عادی، تعطیلات و نیز در شرایط بد آب‌وهوایی پرداختند. لیو و همکاران (Y. Liu, Wu, et al., 2022) با به کار گیری مدل شبکه عصبی پیچشی خاکستری[14] (G-CNN)، روشی برای پیش‌بینی حجم ترافیک تحت شرایط رخ دادن تصادفات رانندگی توسعه دادند. الجویدی و همکاران (Aljuaydi et al., 2022).

al., 2022) نیز از روش‌های مختلف یادگیری ماشین[۱۵] برای توسعه مدل‌هایی به منظور پیش‌بینی حجم ترافیک در شرایط تصادفات رانندگی و بارش باران بهره بردند. همان‌طور که پیش‌تر اشاره شد، تعطیلات، الگوی حجم تردد را دچار تغییر می‌کند که خود باعث تغییر در شرایط ایمنی ترافیک می‌گردد؛ بنابراین بررسی شرایط ایمنی در ایام تعطیل اهمیت قابل‌توجهی دارد. دراین‌خصوص رویکردهای مختلفی اتخاذ شده که به برخی از آن‌ها اشاره گردید. این رویکردها شامل بررسی رابطه حجم تردد و شمار تصادفات، بررسی الگوی حجم تردد در تعطیلات، بررسی الگوی تصادفات در تعطیلات، استفاده از رسانه‌های اجتماعی به‌منظور پیش‌بینی جریان ترافیک در ایام تعطیل و تعیین عوارض بر راه‌های برون‌شهری است. علاوه بر این، انواع مختلف مدل‌های مورداستفاده برای پیش‌بینی حجم ترافیک در شرایط مختلف بررسی گردید. در ادامه، ساختار مدل‌های توسعه‌یافته در پژوهش حاضر و نتایج حاصل از آن‌ها بیان می‌گردد.

۳-روش‌شناسی

در بخش گذشته نتیجه بررسی ادبیات موضوع نشان داد که بررسی الگوی تغییرات جریان تردد در تعطیلات در راه‌های برون‌شهری در ایران می‌تواند بسیار حائز اهمیت باشد. در این پژوهش این بررسی‌ها با استفاده از روش‌های آمار توصیفی صورت گرفت. در ادامه مدلی جهت پیش‌بینی حجم تردد در ایام تعطیل با استفاده از الگوریتم شبکه عصبی مصنوعی توسعه داده شده است. از خروجی این مدل می‌توان در مدل‌های شمار و شدت تصادفات استفاده کرد و بدین ترتیب، الگوی نوع و شدت تصادفات در تعطیلات در ایران را شناسایی کرد. همچنین می‌توان تأثیر سیاست‌های محتمل را در خصوص تعطیلات بر ایمنی راه بررسی نمود.

۳-۱- پیش‌بینی حجم تردد با استفاده از مدل شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یکی از زیرمجموعه‌های یادگیری ماشین است که با الگوریتم‌هایی سروکار دارد که از ساختار شبکه عصبی مغز الهام گرفته شده تا با افزودن هوش به ماشین کمک کند. این برنامه‌ها از صدها، هزاران یا میلیون‌ها سلول مغز مصنوعی تشکیل شده‌اند و در ساختاری شبیه به مغز انسان، عمل یادگیری و رفتاری را انجام می‌دهند. شبکه‌های عصبی مصنوعی در طبقه‌بندی اسناد و اطلاعات در شبکه‌های کامپیوتری، پیش‌بینی نتایج آزمایش‌ها، تشخیص بیماری‌ها باتوجه‌به نتایج آزمایش پزشکی و تصویربرداری، پیش‌بینی قیمت سهام و شاخص بورس، مدل‌سازی و پیش‌بینی پدیده‌های زیستی و محیطی و بسیاری دیگر از حوزه‌ها کاربرد دارند. انواع مختلفی از شبکه‌های عصبی مصنوعی توسعه داده شده است که باتوجه‌به ماهیت مسائل قابل‌استفاده هستند. ساده‌ترین نوع شبکه‌های عصبی مصنوعی که از جمله مهم‌ترین آنها نیز هست، شبکه‌های عصبی مصنوعی چندلایه هستند. در این نوع شبکه عصبی، رفتار شبکه‌ای مغز انسان و انتشار سیگنال در آن بیشتر مدنظر بوده است و ازاین‌رو، گهگاه با نام شبکه‌های پیشرو نیز خوانده می‌شوند. در ادامه در شکل ۱ ساختار این نوع شبکه‌ها ارائه شده است.

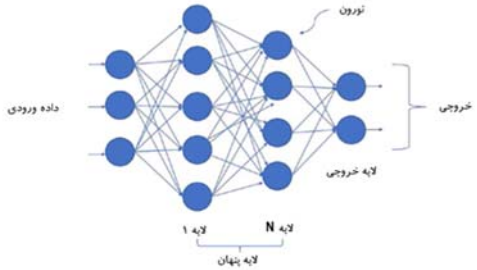

شکل ۱. تصویری از ساختار شبکه عصبی مصنوعی پیشرو

ساختار شبکه عصبی از شمار زیادی عناصر (سلول‌های عصبی) پردازشی متصل به یکدیگر در یک ساختار سلسله‌مراتبی به نام نورون تشکیل شده است. نورون‌ها باتوجه‌به ورودی دریافت شده یک پیام یا سیگنال را به سلول‌های عصبی دیگر منتقل می‌کنند و یک شبکه پیچیده را تشکیل می‌دهند که به کمک برخی از سازوکارهای بازخورد دارای قابلیت یادگیری است. یک شبکه عصبی مصنوعی، از سه نوع لایهٔ ورودی، خروجی و پردازش تشکیل می‌شود. هر لایه شامل گروهی از سلول‌های عصبی (نورون) است که عموماً با کلیهٔ نورون‌های لایه‌های دیگر در ارتباط هستند، مگر این که کاربر ارتباط بین نورون‌ها را محدود کند؛ ولی نورون‌های هر لایه با سایر نورون‌های همان لایه، ارتباطی ندارند.

شبکه عصبی مصنوعی سعی می‌کند با استفاده از یک رویکرد ریاضی، از فرایند مغز انسان تقلید کند. داده‌های ورودی توسط سلول‌های عصبی (نورون‌ها) در اولین لایه پنهان پردازش می‌شوند. یک عملیات ریاضی روی آنها انجام شده و بر اساس یک قانون ساده خروجی هر نورون به نورون بعدی انتقال می‌یابد. این فرایند چندین بار تکرار شده و در نهایت یک شبکه با ساختار پیچیده را تشکیل می‌دهد. وقتی داده‌های ورودی در ساختار تعریف شده ارائه می‌شود، خروجی نهایی یک پیش‌بینی است که می‌تواند درست یا نادرست باشد. بر اساس خروجی به‌دست‌آمده اگر به سیستم بازخورد داده شود تا باتوجه‌به یک سری شاخص‌ها پیش‌بینی بهتری داشته باشد، سیستم با به‌روز کردن وزن اتصالات میان نورون‌ها عمل یادگیری را انجام می‌دهد. برای ارائه بازخورد و تعیین قدم بعدی تغییرات در جهت درست، معمولاً از یک الگوریتم ریاضی با عنوان بازگشت به عقب[16] استفاده می‌شود. تکرار این روند به‌صورت مرحله‌به‌مرحله و با داده‌های زیاد به شبکه کمک می‌کند وزن‌ها را به‌درستی بروز کرده و سیستمی ایجاد شود تا بتواند بر اساس قوانینی که برای خود از طریق وزن‌ها و اتصالات ایجاد کرده است، پیش‌بینی درستی از خروجی داشته باشد. در پژوهش حاضر، پیاده‌سازی مدل شبه عصبی مصنوعی به زبان پایتون انجام شده و از رابط برنامه‌نویسی کراس استفاده گردید. کراس یک رابط برنامه‌نویسی سطح بالا شبکه عصبی مصنوعی است که به زبان پایتون نوشته شده است و می‌تواند در تهیه یک مدل شبکه عصبی مصنوعی بسیار کمک‌کننده باشد.

٤- داده

هدف این پژوهش توسعه مدل شبکه عصبی مصنوعی برای پیش‌بینی حجم تردد در تعطیلات است. بدین منظور اطلاعات تردد موردنیاز است. جمع‌آوری داده‌های تردد غالباً با استفاده از ترددشمارهای حلقه‌ای صورت می‌گیرد. اطلاعات آفلاین ریز تردد وسایل نقلیه (شامل مشخصات تردد تک‌تک وسایل نقلیه عبوری شامل خط عبوری، سرعت، طول وسیله نقلیه و کلاس‌بندی آن) توسط شرکت‌های مجری از دستگاه‌ها جمع‌آوری‌شده و به ادارات کل تحویل می‌گردد تا در صورت نیاز مورد بهره‌برداری قرار گیرد. در پایگاه‌داده ایجاد شده از داده‌های سال‌های ۱۳۹۵ الی ۱۳۹۸ استفاده شد. علت اتکا به این داده‌ها عدم شمار کافی از دستگاه‌های تردد شمار در کشور قبل از سال ۱۳۹٤ بود. اطلاعات تعطیلات نیز استخراج شده و به روش‌های گوناگونی (مدت تعطیلات و چندین متغیر مجازی) مورد استفاده قرار گرفت. برای استخراج اطلاعات آب‌وهوایی از داده‌های تصادفات ثبت شده توسط پلیس استفاده گردید. این داده‌ها شامل شرایط آب‌وهوایی در زمان وقوع تصادف نیز هستند. از میان تمام داده‌های تصادفات مربوط به هر روز، آن شرایط آب‌وهوایی که بیشترین فراوانی را داشته به‌عنوان وضعیت آب‌وهوایی آن روز در استان در نظر گرفته شده است.

٤-۱-بررسی الگوی تغییرات جریان تردد در راه‌های برون‌شهری در تعطیلات در ایران

با اقتباس از مطالعه لیو و شارما (Z. Liu & Sharma, 2006) در ایالت آلبرتای کانادا، یکی از روش‌های توصیف و شناسایی الگوی تغییرات جریان تردد در راه‌های برون‌شهری در تعطیلات، بررسی تفاوت حجم تردد طی هفته‌های دارای تعطیلی و هفته‌های قبل و بعد از آن است. به همین دلیل به طور نمونه سه مجموعه از تعطیلات کشور طی سال‌های ۱۳۹۷-۱۳۹۵ شامل تعطیلی شنبه ۹ مرداد ۱۳۹۵ به مناسبت شهادت امام جعفر صادق (ع)، تعطیلات ۱٤ ام و ۱۵ ام خرداد ۱۳۹٦ به مناسبت رحلت امام خمینی (ره) و قیام ۱۵ خرداد و چهارشنبه ۱۲ اردیبهشت ۱۳۹۷ به مناسبت نیمه شعبان مورد بررسی قرار گرفتند. شکل ۲، شکل ۳ و شکل ٤، روند تغییرات حجم تردد روزانه در سراسر کشور را باتوجه‌به روزهای تعطیل نشان می‌دهند.

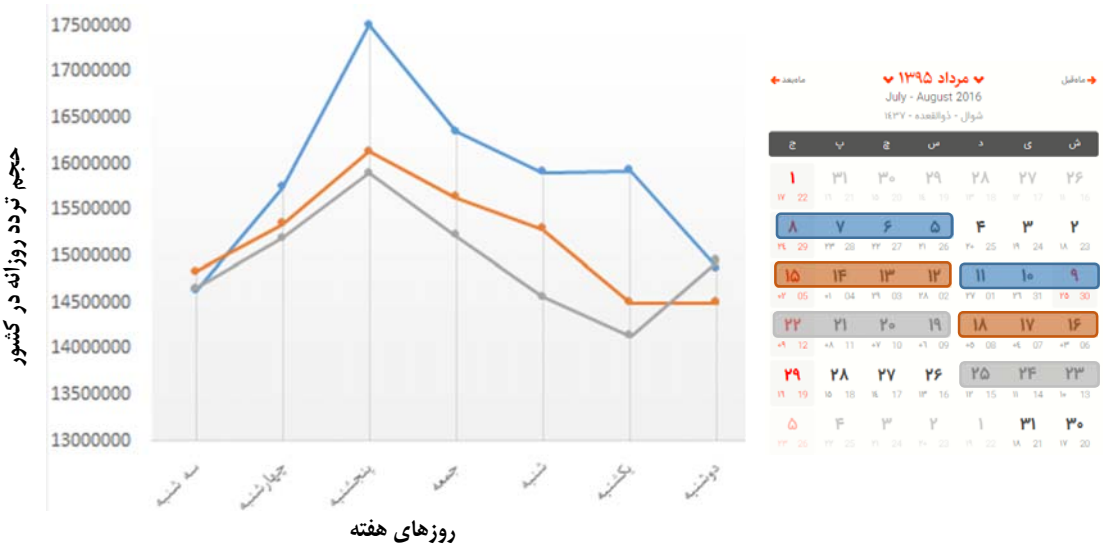

شکل ۲. تغییرات حجم تردد روزانه طی تعطیلی ۹ مرداد ۱۳۹۵

شکل ۳. تغییرات حجم تردد روزانه طی تعطیلی ۱۴ و ۱۵ خرداد ۱۳۹۶

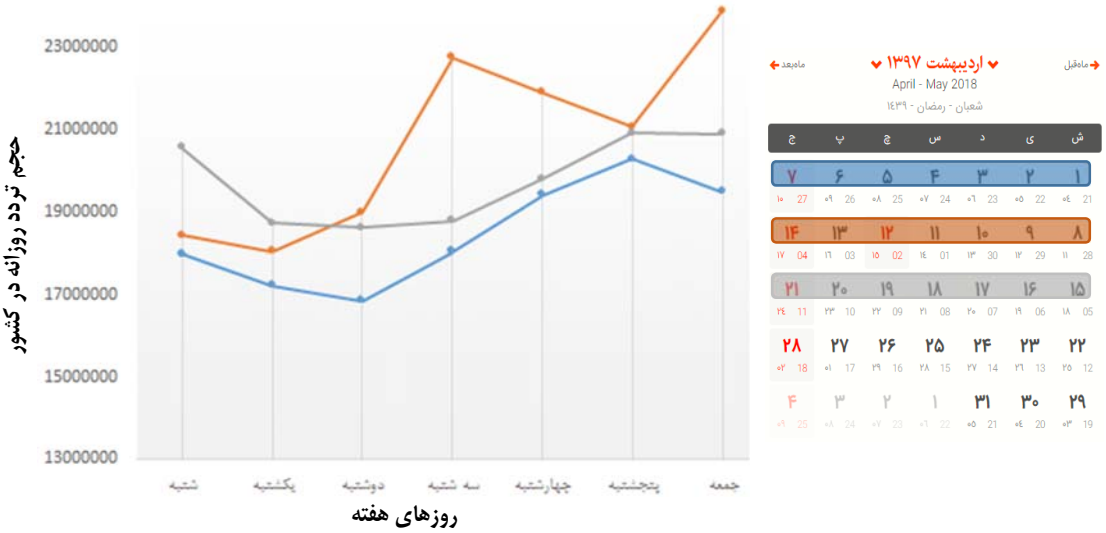

شکل ٤- تغییرات حجم تردد روزانه طی تعطیلی ۱۲ اردیبهشت ۱۳۹۷

نمودارهای ارائه شده در شکل‌های ۲، ۳ و ٤ دید کلی بسیار خوبی در خصوص الگوی تغییرات جریان تردد در تعطیلات ایجاد نمود که در توسعه محاسبات شبکه عصبی مورداستفاده قرار گرفت. به‌عنوان‌مثال بررسی نمودارها نشان می‌دهد حجم تردد در روز قبل از شروع تعطیلات به‌هم‌پیوسته نظیر روز ٦ مرداد ۱۳۹۵ یا ۱۰ و ۱۱ خرداد ۱۳۹٦ یا سه‌شنبه ۱۱ خرداد ۱۳۹۷ بسیار متأثر از تعطیلات بوده است. به‌طورکلی می‌توان گفت بیشترین تغییرات در حجم تردد در روزهای پیش از شروع تعطیلات و روز پایانی تعطیلات روی می‌دهد. نخستین روز پس از تعطیلات نیز عموماً روزهای پرحجمی برای راه‌های برون‌شهری کشور است. یکی دیگر از شاخص‌های قابل‌بررسی به‌خصوص جهت شناسایی الگوی تغییرات جریان تردد در ایام تعطیل در استان‌های کشور، میزان تغییرات متوسط تردد ساعتی در راه‌های برون‌شهری استان‌های کشور در روزهای مربوط به تعطیلات نسبت به روزهای بدون تعطیلی است. شکل ۵ حجم متوسط تردد ساعتی به تفکیک استان‌های کشور در روزهای مربوط به تعطیلات و روزهای بدون تعطیلی را نشان می‌دهد.

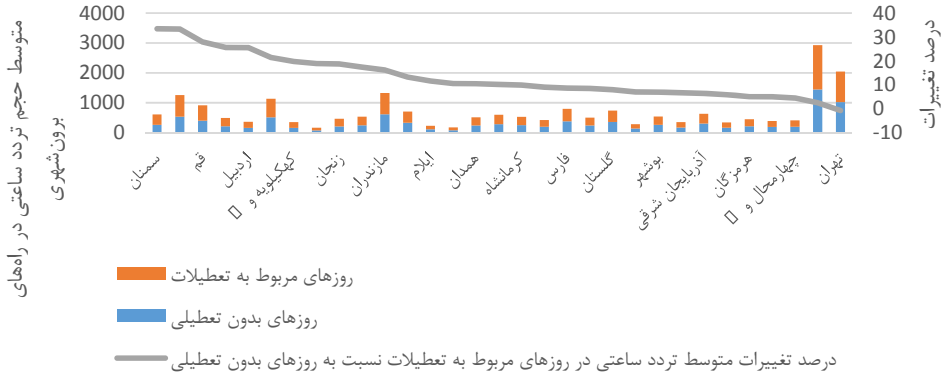

شکل ۵. حجم متوسط تردد ساعتی به تفکیک استان‌های کشور در تعطیلات

همان‌طور که در شکل ۵ نشان داده شده است، بیشترین تغییرات بین حجم تردد ایام تعطیل و ایام غیر تعطیل در راه‌های مربوط به استان‌های سمنان، قزوین و قم روی می‌دهد. اما استان‌های تهران و البرز علی‌رغم تغییر در میزان تردد در ایام تعطیل، کمترین میزان تغییر در این شاخص را دارا هستند. یکی از دلایل این مشاهده، هدف سفر در ترددهای مربوط به این استان‌ها است. دو پدیده تمرکز سیاسی و اداری و همچنین وجود سکونتگاه‌های اقماری در اطراف تهران منجر به وجود تقاضای همیشگی و کاری در محورهای استان‌های مذکور است که در نتیجه در ایام تعطیل تقاضای سفر کاری جای خود را به تقاضای سفر تفریحی خواهد داد. این موضوع در سایر استان‌ها کمتر پدیدار است و استفاده از راه‌های برون‌شهری به‌صورت تفریحی سهم چشمگیرتری دارد.

٤-۲-پیش‌بینی حجم تردد با استفاده از شبکه عصبی مصنوعی

جهت پیش‌بینی حجم تردد با استفاده از شبکه عصبی مصنوعی از مدل ترتیبی یا همان پیشرو استفاده شد. مدل توسعه داده شده علاوه بر لایه ورودی دارای دو لایه پنهان نوع متراکم و سپس لایه خروجی متراکم است. لایه‌های متراکم از متداول‌ترین نوع لایه‌ها در شبکه عصبی مصنوعی هستند و در آن‌ها هر نورون به تمامی نورون‌های لایه قبل متصل است. پس از هر لایهٔ متراکم لایه حذف تصادفی نیز قرار داده شد تا از بیش برازش شدن مدل اجتناب شود. در مدل شبکه عصبی مصنوعی پیشنهادی در تمامی لایه‌ها جز لایه آخر ۳۰۰ نورون در نظر گرفته شد. باتوجه‌به آنکه لایه آخر یک خروجی باید داشته باشد (خروجی نهایی پیش‌بینی حجم ترافیک است)، این لایه دارای یک نورون در نظر گرفته شد. اطلاعات ورودی مدل شبکه عصبی مصنوعی توسعه داده شده شامل اطلاعات تاریخ روز، وضعیت آب‌وهوایی، وضعیت تعطیلات روز و روزهای قبل و بعد برای تاریخ ابتدای فروردین ۱۳۹۵ تا انتهای آذرماه ۱۳۹۷ بوده است. ازآنجایی‌که مدل‌های شبکه عصبی تنها قادر به تفسیر متغیرهای عددی هستند، متغیرهای توصیفی به متغیرهای صفر و یک تبدیل شدند. از طرف دیگر برای حصول نتیجه بهتر در ابتدا داده‌ها مقیاس می‌شوند. مدل‌های مختلفی برای تبدیل داده‌ها وجود دارد. در اینجا همگی داده‌ها بر بیشینه خود تقسیم شدند و در بازه مقدار صفر و یک قرار گرفتند. متغیرهای ورودی مدل در جدول ۱ ارائه شده‌اند.

جدول ۱. متغیرهای ورودی مدل شبکه عصبی مصنوعی جهت پیش‌بینی حجم ترافیک

ردیف	عنوان متغیر	نوع متغیر	شرح متغیر
۱	سال	عدد صحیح	۱۳۹۵، ۱۳۹٦ و ۱۳۹۷
۲-۱۳	ماه	صفر و یک	هر یک از ۱۲ ماه سال به صورت یک متغیر بولین درنظر گرفته شد. در صورتی که روز مذکور در ماه مشخصی بوده باشد، مقدار متغیر مربوط به آن ماه یک و مقدار متغیر سایر ماه‌ها صفر خواهد بود.
۱٤-۱۹	وضعیت آب‌وهوایی	صفر و یک	شامل شش وضعیت، برفی، بارانی، صاف، مه‌آلود، غبارآلود و ابری
۲۰	مدت تعطیلی	عدد	منظور مدت بازه تعطیلی است. درصورتی‌که چند روز پشت‌هم تعطیلی باشد، این بازه مقداری بزرگ‌تر از یک خواهد داشت. مقدار مدت تعطیلی برای تمام روزهای (رکوردهای) در طول بازه در نظر گرفته شد. روزهای پنج‌شنبه و جمعه تعطیل رسمی در نظر گرفته شدند. همچنین روزهای بین دو تعطیلی در مدت تعطیلی ۰,۵ درنظر گرفته شدند.
۲۱	روز قبل از تعطیلی	صفر و یک	درصورتی‌که روز مورد بررسی قبل از شروع بازه تعطیلی باشد این متغیر یک و در غیر این صورت صفر خواهد بود.
۲۲	اولین روز تعطیلی	صفر و یک	درصورتی‌که روز مورد بررسی اولین روز بازه تعطیلی باشد این متغیر یک و در غیر این صورت صفر خواهد بود.
۲۳	یکی به آخرین روز تعطیلی	صفر و یک	درصورتی‌که روز مورد بررسی قبل از آخرین روز بازه تعطیلی باشد این متغیر یک و در غیر این صورت صفر خواهد بود.
۲٤	آخرین روز تعطیلی	صفر و یک	درصورتی‌که روز مورد بررسی آخرین روز بازه تعطیلی باشد این متغیر یک و در غیر این صورت صفر خواهد بود.
۲۵	روز بعد از تعطیلی	صفر و یک	درصورتی‌که روز مورد اولین روز پس از پایان بازه تعطیلی باشد این متغیر یک و در غیر این صورت صفر خواهد بود.
۲٦	نوروز	صفر و یک	این متغیر برای مدت‌زمان تعطیلات نوروز یک در نظر گرفته شد.
۲۷	اربعین	صفر و یک	این متغیر در طول هفته قبل و پس از اربعین یک در نظر گرفته شد.

در مدل شبکه عصبی مصنوعی توسعه داده شده از تابع فعال‌سازی[۱۷] relu در تمامی لایه‌ها جز لایه آخر استفاده شد. در لایه خروجی از تابع فعال‌سازی linear استفاده شد. تابع فعال‌سازی خطی linear همان‌طور که از نامش مشخص است، مجموع وزن‌دار ورودی‌ها است. دلیل انتخاب این تابع در لایه آخر، امکان پیش‌بینی قابل‌قبول برای مقادیر بالاتر حجم ترافیک نسبت به داده‌های آموزش داده شده به مدل است. تابع زیان[۱۸] شاخصی است که به شبکه کمک می‌کند تا تشخیص دهد یادگیری در جهت صحیح انجام می‌شود. در واقع به کمک این شاخص مدل خواهد دانست که روند یادگیری در طول تکرارها در حال بهبود است. تابع زیان استفاده شده در مدل میانگین خطای مطلق[۱۹] است؛ بنابراین مدل در تلاش است تا در طول تکرارهای مختلف اجرای الگوریتم مقدار متوسط خطای مطلق را کاهش دهد. انتظار می‌رود درصورتی‌که مقدار این شاخص را برای تکرارهای مختلف رسم کنیم، یک نمودار نزولی حاصل شود. در شکل ٦ مقدار تابع زیان در طول تکرارهای مختلف برای استان مازندران به‌عنوان یک نمونه ارائه شده است.

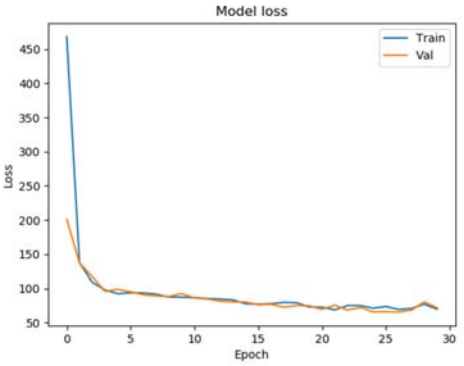

شکل ٦. نمودار تابع زیان برای استان مازندران در طول تکرارهای مختلف شبکه عصبی مصنوعی

شاخص[۲۰] مشابه تابع زیان تعریف می‌شود. تنها تفاوت بین شاخص‌ها و تابع زیان در این است که از نتایج شاخص‌ها در آموزش مدل استفاده نمی‌شود. آن‌ها فقط برای تأیید نتایج آزمایش در هنگام گزارش استفاده می‌شوند. متوسط قدرمطلق درصد خطای پیش‌بینی به‌عنوان شاخص برای تمامی استان‌ها محاسبه شده است که در ادامه یک نمونه از آن در شکل ۷ برای استان مازندران نشان داده شده است.

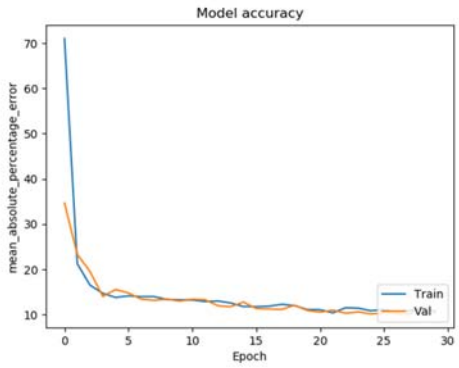

شکل ٦. نمودار شاخص درصد خطای مطلق برای استان مازندران در طول تکرارهای مختلف شبکه عصبی

داده‌ها به سه دسته تقسیم شدند و از ۷۰ درصد برای آموزش مدل و ۱۵ درصد تست و ۱۵ درصد اعتبارسنجی استفاده شد. در ادامه یک نمونه از نحوه پیش‌بینی مدل بر اساس اطلاعات ورودی را مشاهده می‌کنید. در شکل ۸ این نمودار برای داده‌های تست در استان مازندران رسم شده است.

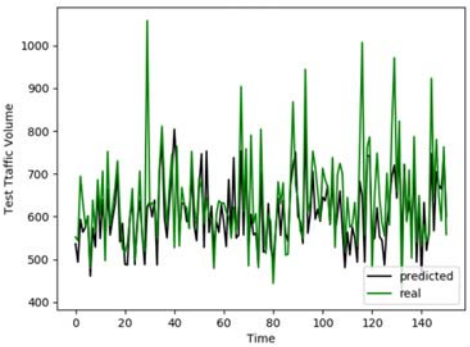

شکل ۷. نحوه پیش‌بینی داده‌های تست مربوط به استان مازندران توسط مدل شبکه عصبی مصنوعی

مقادیر تابع زیان (میانگین خطای مطلق) و شاخص (میانگین درصد خطای مطلق) برای داده‌های تست در جدول ۲ ارائه شده است. همان‌طور که از جدول مشخص است، متوسط شاخص برای تمام استان‌ها برابر با ۹/۲۸ درصد محاسبه شده است.

جدول ۲. مقادیر تابع زیان و شاخص برای داده‌های تست

استان	میانگین خطای مطلق	میانگین درصد خطای مطلق
آذربایجان غربی	۱۷/۵۸	۹/۰۲
اردبیل	۲۰/۰۱	۱۱/٦۷
البرز	۹٦/۰۹	۷/۱۳
آذربایجان شرقی	۳۸/۲٦	۱۲/۰۸
بوشهر	۲٤/۸۹	۹/۳۰
اصفهان	۳٤/۵۸	۱۰/۳۹
خراسان شمالی	۲۳/۹۱	۹/۹٦
تهران	۷۲/۲۳	٦/۷۸
لرستان	۲٤/۵٤	۱۰/۸۹
مازندران	۵۹/۷۱	۸/۸۹
گیلان	۵۳/۲٤	۹/۳۲
گلستان	۳۷/۱۹	۰/۱٦
سیستان و بلوچستان	۷/٦۲	۷/۷۵
سمنان	۲۹/۸۸	۱۰/۳۱
یزد	۱۱/۳٤	۷/۲۹
خراسان جنوبی	۷/۱۸	۸/۱۰
خراسان رضوی	۲۷/۰۸	۹/۷۰
هرمزگان	۱۹/۱۰	۸/۷۱
چهارمحال‌وبختیاری	۱٤/۷۷	٦/٦۸
کرمان	۱۳/۵۸	۷/۱۱
زنجان	۲۷/۱۳	۱۱/۱۸
قزوین	٦۳/۵۰	۱۱/۸۸
خوزستان	۲۰/۰۵	۸/۱۰
کرمانشاه	۲۵/۸۷	۹/۸۵
ایلام	۱۲/۸۸	۹/٦۸
همدان	٤۰/۲۹	۱۷/۰۵
فارس	۲۷/۵۸	٦/۹۰
قم	٤۸/۳۰	۱۰/۱۸
کهگیلویه و بویراحمد	۲۳/۹٤	۱۲/۸۰
مرکزی	۳٤/٦۹	۹/۳۹

٤-۳- استفاده از مدل توسعه یافته برای انجام پیش‌بینی در سناریوهای فرضی

در بخش‌های قبل مدل شبکه عصبی پیش‌بینی حجم تردد در راه‌های برون‌شهری کشور که به نوع و مدت روزهای تعطیل حساس است به تفکیک استان‌های کشور و در بازه زمانی روزانه توسعه یافت. به‌این‌ترتیب پژوهش حاضر ابزاری جهت پیش‌بینی حجم تردد در چینش‌های مختلف ایام تعطیل سال ارائه نموده است. در این بخش یک سناریو فرضی از سیاست‌های چینش تعطیلات در کشور مورد بررسی قرار گرفته است و نتایج حاصل از مدل توسعه‌یافته در این پژوهش شبیه‌سازی شده‌اند. در طرح حاضر سناریو فرضی به‌صورت تعطیلی هفته آخر آذرماه سال ۱۳۹٦ به مدت پنج روز از تاریخ ۲۵ آذر لغایت ۲۹ آذر در نظر گرفته شد. علت این امر توزیع شدت آلودگی هوا در ماه‌های مختلف سال و سهم چشمگیر آذرماه بود. نتایج شبیه‌سازی نشان داد چنانچه هفته آخر آذرماه سال ۱۳۹٦ به مدت پنج روز تعطیل رسمی در کشور اعلام می‌شد، حجم تردد برون‌شهری از چهارشنبه ۲۲ آذر ۱۳۹٦ دچار تغییرات جدی می‌شد. شکل ۹ میزان حجم تردد در راه‌های برون‌شهری کشور در ایام مذکور را در دو حالت با و بدون اجرای سناریو پیشنهادی بر اساس خروجی‌های محاسبات شبکه عصبی مصنوعی نشان می‌دهد. بر اساس پیش‌بینی‌های مدل شبکه عصبی مصنوعی بیشترین افزایش حجم تردد ساعتی در صورت پیاده‌سازی طرح در استان‌های قزوین، خراسان شمالی و سمنان روی خواهد داد. خروجی‌های محاسبات شبکه عصبی مصنوعی می‌تواند به‌عنوان ورودی مدل پیش‌بینی شمار تصادفات راه‌های برون‌شهری مورداستفاده قرار گیرد و تأثیر اجرای سناریو فرضی بر تعداد تصادفات فوتی و جرحی شناسایی شود.

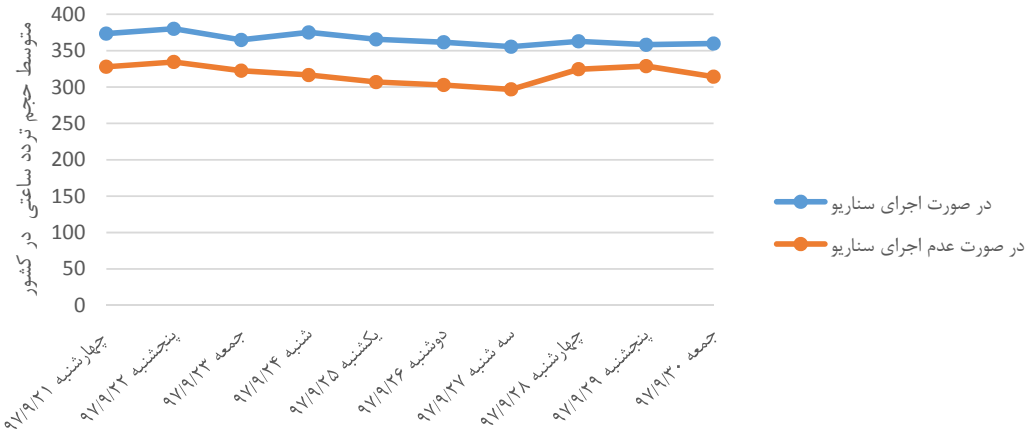

شکل ۸. حجم تردد برون‌شهری در صورت اجرا/عدم اجرای سناریو

در پژوهش حاضر، مدل‌های شبکه عصبی مصنوعی برای پیش‌بینی حجم ترافیک در تعطیلات به تفکیک استان‌های کشور توسعه داده شدند. این مدل‌ها با استفاده از متغیرهای تقویمی، وضعیت آب‌وهوایی و نیز متغیرهای نمایانگر مناسبت‌های خاص (نوروز و اربعین) به انجام پیش‌بینی می‌پردازند. همان‌طور که از جدول ۲ مشخص است، این مدل‌ها توانایی مناسبی برای پیش‌بینی حجم ترافیک در ایام تعطیل با دقت قابل‌قبول دارند؛ به طوری که متوسط شاخص ارزیابی مدل‌ها برابر با ۹/۲۸ درصد است. در ادبیات، مدل‌های ترکیبی نیز به‌منظور پیش‌بینی حجم ترافیک در تعطیلات به کار رفته‌اند. به‌عنوان‌مثال، لو و همکاران (Luo et al., 2019) با ترکیب DFT و رگرسیون بردار پشتیبان، روشی ابتکاری ارائه کردند. آن‌ها برای مقایسه بهتر، مدل‌های دیگری را در کنار مدل پیشنهادی (از جمله مدل ARIMA) توسعه داده و میانگین درصد خطای مطلق را به‌عنوان شاخص ارزیابی مدل‌ها به کار بردند. نتایج نشان داد که مدل پیشنهادی (ترکیب DFT و SVR) با میانگین درصد خطای مطلق ۹/۶ درصد، عملکرد بهتری نسبت به سایر مدل‌ها داشت. در پژوهش دیگری، ژنگ و همکاران (W. Zhang et al., 2021) به توسعه مدل‌های ترکیبی مختلفی برای پیش‌بینی حجم ترافیک در تعطیلات و در شرایط بد آب‌وهوایی پرداختند. در پژوهش آن‌ها نیز مدل‌های متعددی توسعه داده شده و با یکدیگر مقایسه گردیدند. مدل‌های ترکیبی پیشنهادی آن‌ها، میانگین درصد خطای مطلقی بین ۹/۰۸ تا ۹/۲۰ داشتند.

باتوجه‌به موارد ذکر شده، می‌توان اذعان داشت که مدل‌های توسعه داده شده در پژوهش حاضر، علی‌رغم این‌که نسبت به مدل‌های ترکیبی ساده‌تر بوده و آموزش آن‌ها نیز به زمان کمتری نیاز دارد، از توانایی مناسبی برای پیش‌بینی برخوردار هستند.

۵-نتیجه‌گیری

در طول سال به دلایل مختلف روزهای تعطیل وجود دارد. اثرات تعطیلات را می‌توان از ابعاد مختلف مورد بررسی قرار داد. یکی از این ابعاد، اثر تعطیلات بر ایمنی راه‌ها است. با ساخت مدل‌های شمار و شدت تصادفات، می‌توان به این پرسش پاسخ داد که آیا تعطیلات باعث افزایش تلفات جاده‌ای می‌شود یا خیر؟ یکی از متغیرهای مورداستفاده در این مدل‌ها حجم تردد است. هدف این پژوهش، بررسی الگوی تغییرات حجم تردد در ایام تعطیل و نیز ارائه مدلی برای پیش‌بینی حجم تردد در تعطیلات است. بدین منظور، مدل شبکه عصبی مصنوعی توسعه داده شد که نسبت به تعطیلات حساس است. مقیاس زمانی مدل‌ها، روزانه است و به تفکیک استان‌های کشور ساخته شده‌اند. از خروجی این مدل‌ها (که همان حجم تردد پیش‌بینی شده است) می‌توان در مدل‌های شمار و شدت تصادفات استفاده کرد. پیاده‌سازی مدل شبکه عصبی مصنوعی به زبان پایتون انجام شد و از رابط برنامه‌نویسی کراس استفاده گردید. مدل توسعه داده شده علاوه بر لایه ورودی دارای دو لایه پنهان نوع متراکم و سپس لایه خروجی متراکم است. در مدل شبکه عصبی مصنوعی پیشنهادی در تمامی لایه‌ها جز

لایه آخر ۳۰۰ نورون در نظر گرفته شد. باتوجه‌به آنکه لایه آخر یک خروجی باید داشته باشد (خروجی نهایی پیش‌بینی حجم ترافیک است)، این لایه دارای یک نورون در نظر گرفته شد.

بر اساس تحلیل‌های انجام شده در این پژوهش، بیشترین تغییرات در حجم تردد در روزهای پیش از شروع تعطیلات و روز پایانی تعطیلات روی می‌دهد. نخستین روز پس از تعطیلات نیز عموماً روزهای پرحجمی برای راه‌های برون‌شهری کشور است. براین‌اساس بهتر تدابیر و تحلیل‌های مربوط به ایام تعطیل شامل روزهای قبل و بعد از تعطیلات نیز باشد. بیشترین تغییرات بین حجم تردد ایام تعطیل و ایام غیرتعطیل در راه‌های مربوط به استان‌های سمنان، قزوین و قم روی می‌دهد. اما استان‌های تهران و البرز علی‌رغم تغییر در میزان تردد در ایام تعطیل، کمترین میزان تغییر در این شاخص را دارا هستند. یکی از دلایل این مشاهده، هدف سفر در ترددهای مربوط به این استان‌ها است. دو پدیده تمرکز سیاسی و اداری و همچنین وجود سکونتگاه‌های اقماری در اطراف تهران منجر به وجود تقاضای همیشگی و کاری در محورهای استان‌های مذکور است که در نتیجه در ایام تعطیل تقاضای سفر کاری جای خود را به تقاضای سفر تفریحی خواهد داد. این موضوع در سایر استان‌ها کمتر پدیدار است و استفاده از راه‌های برون‌شهری به‌صورت تفریحی سهم چشمگیرتری دارد. این نکته می‌تواند به پلیس راهور در استقرار نیروهای گشت عملیاتی در ایام تعطیل کمک نماید. به‌طوری‌که انتظار می‌رود در استان‌هایی که تغییرات حجم سفر در آن‌ها چشمگیرتر است از کمک نیروهای اضافی استفاده شود. به بیان دیگر راهداران و راهوران استانی مانند سمنان که در ایام تعطیل به یکباره با افزایش ۳۵ درصدی حجم تردد مواجه می‌شوند نیازمند کمک پرسنلی و عملیاتی بیشتری نسبت استانی مانند استان کرمان هستند. مطالعه حاضر ابزاری را برای بررسی تصمیمات مرتبط با ایمنی ترافیک از جمله تصمیمات مربوط به تعطیلات در سال فراهم آورد و نمونه آن در سناریو فرضی تعطیلی آخرین هفته آذرماه که هم اوج آلودگی هوای کلان‌شهرها را در بر دارد و هم منتهی به شب یلداست مورد بررسی قرار گرفت. خروجی‌های محاسبات شبکه عصبی مصنوعی می‌تواند به‌عنوان ورودی مدل پیش‌بینی شمار تصادفات راه‌های برون‌شهری مورداستفاده قرار گیرد و تغییرات تعداد تصادفات فوتی و جرحی (نسبت به حالتی که تعطیلات نیست) محاسبه گردد.

۶-پی‌نوشت‌ها

1. Artificial Neural Network
2. Deep Learning
3. Autoregressive Integrated Moving Average
4. Bayesian Network
5. Support Vector Regression
6. K-Nearest Neighbors
7. Convolutional Neural Network
8. Graph Neural Network
9. Long Short-Term Memory
10. Recurrent Neural Network
11. Discrete Fourier Transform
12. Gated Recurrent Unit
13. Convolutional Long Short-Term Memory
14. Grey Convolutional Neural Network
15. Machine Learning
16. Backpropagation
17. Activation Function
18. Loss Function
19. Mean Absolute Error
20. Metric

۷- مراجع

-Akahane, H., Kuwahara, M., & Sato, T. (2000). a basic study on trip reservation systems for recreational trips on motorways. *Doboku Gakkai Ronbunshu*, *2000*(660). **doi.org/10.2208/jscej.2000.660_79**

-Aljuaydi, F., Wiwatanapataphee, B., & Wu, Y. H. (2022). Multivariate machine learning-based prediction models of freeway traffic flow under non-recurrent events. *Alexandria Engineering Journal*. **doi.org/10.1016/J.AEJ.2022.10.015**

-Alsop, J. C., & Langley, J. D. (2000). Dying to go on holiday. *Australian and New Zealand Journal of Public Health*, *24*(6). **doi.org/10.1111/j.1467-842X.2000.tb00525.x**

-Anowar, S., Yasmin, S., & Tay, R. (2013). Comparison of crashes during public holidays and regular weekends. *Accident Analysis and Prevention*, *51*.
doi.org/10.1016/j.aap.2012.10.021

-Bai, L. (2017). Urban rail transit normal and abnormal short-term passenger flow forecasting method. *Jiaotong Yunshu Xitong Gongcheng Yu Xinxi/Journal of Transportation Systems Engineering and Information Technology*, *17*(1).
doi.org/10.16097/j.cnki.1009-6744.2017.01.019

-Bloch, S. A., Shin, H. C., & Labin, S. N. (2004). Time to Party: A Comparative Analysis of Holiday Drinking and Driving. *Bloch, S., Shin, H., & Labin, S. (2004). Time to Party: A Comparative Analysis of Holiday Drinking and Driving. In Proceedings of the 17th*

-Li, Z., Jiang, S., Li, L., & Li, Y. (2019). Building sparse models for traffic flow prediction: an empirical comparison between statistical heuristics and geometric heuristics for Bayesian network approaches. *Transportmetrica B*, *7*(1). **doi.org/10.1080/21680566.2017.1354737**

-Li, Z., Lu, C., Yi, Y., & Gong, J. (2022). A Hierarchical Framework for Interactive Behaviour Prediction of Heterogeneous Traffic Participants Based on Graph Neural Network. *IEEE Transactions on Intelligent Transportation Systems*, *23*(7). **doi.org/10.1109/TITS.2021.3090851**

-Lin, G., Lin, A., & Gu, D. (2022). Using support vector regression and K-nearest neighbors for short-term traffic flow prediction based on maximal information coefficient. *Information Sciences*, *608*, 517–531. **doi.org/10.1016/J.INS.2022.06.090**

-Liu, Y., Song, Y., Zhang, Y., & Liao, Z. (2022). WT-2DCNN: A convolutional neural network traffic flow prediction model based on wavelet reconstruction. *Physica A: Statistical Mechanics and Its Applications*, *603*, 127817. **doi.org/10.1016/J.PHYSA.2022.127817**

-Liu, Y., Wu, C., Wen, J., Xiao, X., & Chen, Z. (2022). A grey convolutional neural network model for traffic flow prediction under traffic accidents. *Neurocomputing*, *500*, 761–775. **doi.org/10.1016/J.NEUCOM.2022.05.072**

-Liu, Z., & Sharma, S. (2006). Statistical Investigations of Statutory Holiday Effects on Traffic Volumes. *Transportation Research Record: Journal of the Transportation Research Board*, *1945*(1). **doi.org/10.1177/0361198106194500106**

-Luo, X., Li, D., & Zhang, S. (2019). Traffic flow prediction during the holidays based on DFT and SVR. *Journal of Sensors*. **doi.org/10.1155/2019/6461450**

-Ma, T., Antoniou, C., & Toledo, T. (2020). Hybrid machine learning algorithm and statistical time series model for network-wide traffic forecast. *Transportation Research Part C: Emerging Technologies*, *111*. **doi.org/10.1016/j.trc.2019.12.022**

-Missouri State Highway Patrol, & Statistical Analysis Center. (2005). *Missouri Holiday Crashes Report 2005*.

-Organização Mundial da Saúde. (2018). Global Status Report on Road Safety 2018 Summary. *World Health Organization*, *1*, 20. http://apps.who.int/bookorders.

International Conference on Alcohol, Drugs and Traffic Safety.

-Castro-Neto, M., Jeong, Y. S., Jeong, M. K., & Han, L. D. (2009). Online-SVR for short-term traffic flow prediction under typical and atypical traffic conditions. *Expert Systems with Applications*, *36* (3 PART 2). **doi.org/10.1016/j.eswa.2008.07.069**

-Chen, X., Chen, H., Yang, Y., Wu, H., Zhang, W., Zhao, J., & Xiong, Y. (2021). Traffic flow prediction by an ensemble framework with data denoising and deep learning model. *Physica A: Statistical Mechanics and Its Applications*, *565*. **doi.org/10.1016/j.physa.2020.125574**

-Cui, Z., Henrickson, K., Ke, R., & Wang, Y. (2020). Traffic Graph Convolutional Recurrent Neural Network: A Deep Learning Framework for Network-Scale Traffic Learning and Forecasting. *IEEE Transactions on Intelligent Transportation Systems*, *21*(11). **doi.org/10.1109/TITS.2019.2950416**

-Du, S., Li, T., Gong, X., & Horng, S. J. (2020). A hybrid method for traffic flow forecasting using multimodal deep learning. *International Journal of Computational Intelligence Systems*, *13*(1). **doi.org/10.2991/ijcis.d.200120.001**

-Elvik, R., Høye, A., Vaa, T., & Sørensen, M. (2009). The Handbook of Road Safety Measures. *The Handbook of Road Safety Measures*. **doi.org/10.1108/9781848552517**

-Farmer, C. M., & Williams, A. F. (2005). Temporal factors in motor vehicle crash deaths. *Injury Prevention*, *11*(1). **doi.org/10.1136/ip.2004.005439**

-Hauer, E. (1997). Observational before/after studies in road safety. Estimating the effect of highway and traffic engineering measures on road safety. *In Pergamon*.

-Jeong, Y. S., Castro-Neto, M., Jeong, M. K., & Han, L. D. (2011). A wavelet-based freeway incident detection algorithm with adapting threshold parameters. *Transportation Research Part C: Emerging Technologies*, *19*(1). **doi.org/10.1016/j.trc.2009.10.005**

-Ji, X., & Ge, Y. (2020). Holiday Highway Traffic Flow Prediction Method Based on Deep Learning. *Xitong Fangzhen Xuebao / Journal of System Simulation*, *32*(6). **doi.org/10.16182/j.issn1004731x.joss.19-0565**

-Kumar, K., Parida, M., & Katiyar, V. K. (2013). Short Term Traffic Flow Prediction for a Non Urban Highway Using Artificial Neural Network. *Procedia - Social and Behavioral Sciences*, *104*. **doi.org/10.1016/j.sbspro.2013.11.170**

-Xu, C., Li, Z., & Wang, W. (2016). Short-term traffic flow prediction using a methodology based on autoregressive integrated moving average and genetic programming. *Transport*, *31*(3). **doi.org/10.3846/16484142.2016.1212734**

-Xu, D., Wang, Y., Peng, P., Beilun, S., Deng, Z., & Guo, H. (2020). Real-time road traffic state prediction based on kernel-KNN. *Transportmetrica A: Transport Science*, *16*(1). **doi.org/10.1080/23249935.2018.1491073**

-Yao, R., Zhang, W., & Zhang, D. (2020). Period division-based markov models for short-term traffic flow prediction. *IEEE Access*, *8*. **doi.org/10.1109/ACCESS.2020.3027866**

-Zeng, K., Liu, W., Wang, X., & Chen, S. (2013). Traffic congestion and social media in China. *IEEE Intelligent Systems*, *28*(1). **doi.org/10.1109/MIS.2013.23**

-Zhang, W. S., Hao, Z. Q., Zhu, J. J., Du, T. T., & Hao, H. M. (2020). BP Neural Network Model for Short-time Traffic Flow Forecasting Based on Transformed Grey Wolf Optimizer Algorithm. *Jiaotong Yunshu Xitong Gongcheng Yu Xinxi/Journal of Transportation Systems Engineering and Information Technology*, *20*(2). **doi.org/10.16097/j.cnki.1009-6744.2020.02.029**

-Zhang, W., Yao, R., Du, X., & Ye, J. (2021). Hybrid Deep Spatio-Temporal Models for Traffic Flow Prediction on Holidays and under Adverse Weather. *IEEE Access*, *9*. **doi.org/10.1109/ACCESS.2021.3127584**

-Zheng, Z., Yang, Y., Liu, J., Dai, H. N., & Zhang, Y. (2019). Deep and Embedded Learning Approach for Traffic Flow Prediction in Urban Informatics. *IEEE Transactions on Intelligent Transportation Systems*, *20*(10). **doi.org/10.1109/TITS.2019.2909904**

-Qi, Y., & Ishak, S. (2014). A Hidden Markov Model for short term prediction of traffic conditions on freeways. *Transportation Research Part C: Emerging Technologies*, *43*. **doi.org/10.1016/j.trc.2014.02.007**

-Qian, Y. S., Zeng, J. W., Zhang, S. F., Xu, D. J., & Wei, X. T. (2020). Short-term traffic prediction based on genetic algorithm improved neural network. *Tehnicki Vjesnik*, *27*(4). **doi.org/10.17559/TV-20180402112949**

-Raskar, C., & Nema, S. (2022). Metaheuristic enabled modified hidden Markov model for traffic flow prediction. *Computer Networks*, *206*. **doi.org/10.1016/j.comnet.2022.108780**

-Sun, S., Zhang, C., & Yu, G. (2006). A Bayesian network approach to traffic flow forecasting. *IEEE Transactions on Intelligent Transportation Systems*, *7*(1). **doi.org/10.1109/TITS.2006.869623**

-Tang, L., Zhao, Y., Cabrera, J., Ma, J., & Tsui, K. L. (2019). Forecasting Short-Term Passenger Flow: An Empirical Study on Shenzhen Metro. *IEEE Transactions on Intelligent Transportation Systems*, *20*(10). **doi.org/10.1109/TITS.2018.2879497**

-Xia, D., Zhang, M., Yan, X., Bai, Y., Zheng, Y., Li, Y., & Li, H. (2021). A distributed WND-LSTM model on MapReduce for short-term traffic flow prediction. *Neural Computing and Applications*, *33*(7). **doi.org/10.1007/s00521-020-05076-2**

-Xiao, W., Zhu, S., & Chen, Q. (2020). Prediction of traffic flow with small time granularity at intersection based on probabilistic network. *Journal of Intelligent and Fuzzy Systems*, *39*(2). **doi.org/10.3233/JIFS-179939**

-Xie, B., Sun, Y., Huang, X., Yu, L., & Xu, G. (2020). Travel characteristics analysis and passenger flow prediction of intercity shuttles in the pearl river delta on holidays. *Sustainability (Switzerland)*, *12*(18). **doi.org/10.3390/SU12187249**

Holidays Traffic Volume Prediction Using Neural Network (Case Study: Iran Rural Roads)

Sina Sahabi, Assistant Professor, Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran.

Mana Meskar, Ph.D., Student, Industrial Engineering, Sharif University of Technology, Tehran, Iran.

Mohammad Bafandeh, M.Sc., Student, Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran.

E-mail: s_sahebi@sbu.ac.ir

Received: November 2024- Accepted: February 2025

ABSTRACT

Traffic volume represents one of the most critical parameters in transportation analyses, influencing various aspects such as design, planning, policy-making, and model development. During holidays, characterized by a peak in out-of-town trips, significant changes occur in the traffic volume pattern across the country's rural road network. In Iran, holidays follow different patterns based on lunar and solar occasions, resulting in notable fluctuations in traffic volume on suburban roads. This study aims to investigate the pattern of changes in traffic volume during holidays and to provide a model for predicting traffic volume during such periods. For this purpose, an artificial neural network model was developed to forecast traffic volume on the suburban roads of the country's provinces, with sensitivity to holidays. The models are designed on a daily time scale and are developed separately for each province. The evaluation metric used for the models is the mean absolute percentage error. The average of this metric across all models was 9.28%, with an example from Mazandaran province showing 8.89%. The results of this research aid policymakers in predicting traffic volume in the transportation networks of the country at the province-day level during different times of the year and enable them to take proactive measures to address traffic congestion during special occasions and holidays. Moreover, the developed model allows for the examination of the effect of different holiday scenarios on the country's traffic volume.

Keywords: Traffic Volume Prediction, Holidays, Artificial Neural Network