

برآورد زمان سفر حمل و نقل همگانی (اتوبوس) با بهره گیری از داده‌های نرم افزار SCATS و بلیط الکترونیک (مطالعه موردی شهر تهران)

شهریار افندی زاده، دانشیار، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران، تهران، ایران
امیرمسعود معمارنژاد، دانشجوی دکتری، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران، تهران، ایران
پست الکترونیکی نویسنده مسئول: memarnejad@civileng.iust.ac.ir

دریافت: 95/06/17 - پذیرش: 95/12/05

چکیده

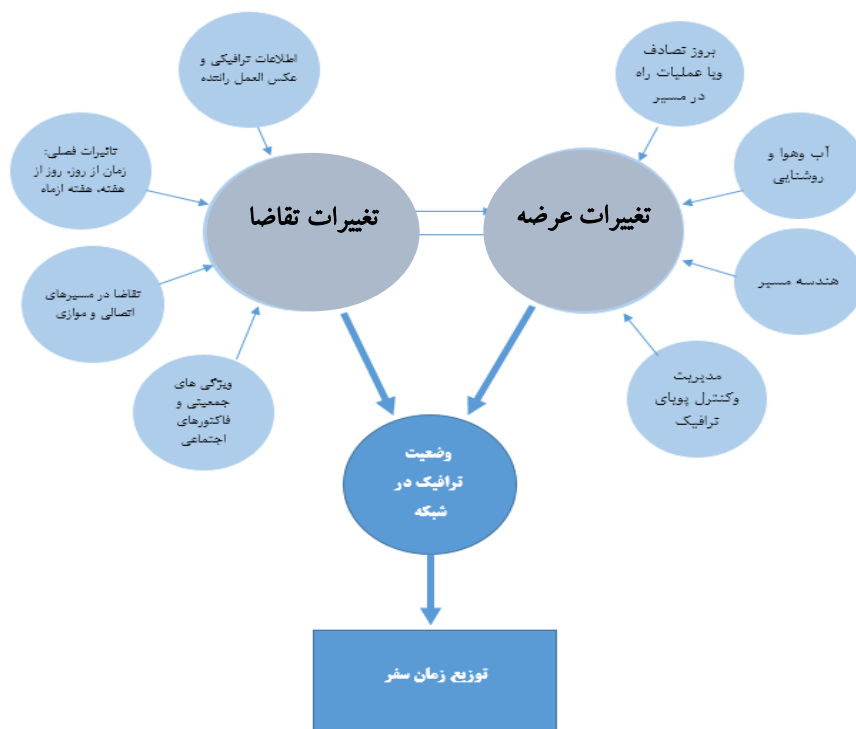
پیش‌بینی دقیق زمان سفر وسایل حمل و نقل همگانی نظیر اتوبوس برای استفاده کنندگان از این سیستم و گردانندگان آن دارای اهمیت است. تعیین این زمان سفر به متصدیان حمل و نقل همگانی اجازه می‌دهد تا در اجرای برنامه‌های مدیریتی نظیر تنظیم زمان‌بندی حرکت اتوبوس‌ها در ساعات مختلف شبانه روز و با توجه به تعداد ناوگان در شبکه اقدام مناسب را انجام دهند. بدیهی است تنظیم برنامه زمان‌بندی در سیستم می‌تواند حداقل زمان انتظار و افزایش مطلوبیت سیستم حمل و نقل را برای استفاده کنندگان در پی داشته باشد. زمان سفر اتوبوس‌ها تحت تاثیر عوامل مختلفی نظیر تقاضای مسافر، شرایط آب و هوایی و وضعیت جریان ترافیک قرار دارد که برای به دست آوردن یک زمان سفر دقیق لزوماً باید تمامی این عوامل تاثیر گذار در نظر گرفته شود. عمده مدل‌های توسعه یافته در زمینه برآورد زمان سفر اتوبوس‌ها صرفاً از داده‌های تاریخی وابسته به زمان استفاده نموده‌اند. در این تحقیق برپایه نگرشی نو علاوه بر در نظر گرفتن عامل وضعیت جریان ترافیک به عنوان عامل تاثیر گذار در تعیین زمان سفر اتوبوس‌ها، از اطلاعات مربوط به تقاضای سفر مسافران جهت برآورد زمان سفر استفاده گردیده است. همچنین مدلی براساس داده‌های تاریخی که صرفاً از متغیرهای زمانی (زمان از روز و روز از هفته) استفاده می‌کرد و مدلی با تمرکز بر روی وضعیت جریان ترافیک که فقط از احجام عبوری و درجه اشباع تقاطعات پایین دست استفاده می‌نمود نیز، جهت مقایسه توسعه یافتند. در نهایت مدل شبکه عصبی پیشنهادی در قالب یک مطالعه موردی ارزیابی گردید. نتایج نشان دهنده عملکرد بهتر مدل پیشنهادی در قالب شاخص میانگین درصد خطای مطلق و جذر میانگین مربعات می‌باشد.

واژه‌های کلیدی: وضعیت جریان ترافیک، برآورد زمان سفر، تقاضای مسافر، شبکه عصبی

1- مقدمه

توزیع زمان سفر می‌شوند. تا زمانی که تغییرات در این پارامترها ادامه دارند، به طور مکرر تنوع در زمان سفر تجربه خواهد شد. از نقطه نظر مسافران، کاهش در تغییرپذیری زمان سفر، عدم قطعیت در تصمیم‌گیری در مورد زمان حرکت و انتخاب مسیر و همچنین اضطراب و تنش ایجاد شده با چنین عدم قطعیتی را می‌کاهد.

عمده تغییرات در زمان سفر وسایل حمل و نقل همگانی، نتیجه تغییر در وضعیت جریان ترافیک می‌باشد که این تغییرات به برهمکنش بین ویژگی‌های تقاضای ترافیک و عرضه تسهیلات نسبت داده می‌شوند (Tu 2008). این ویژگی‌ها را می‌توان به صورت شماتیک در شکل 1 نشان داد. تقاضا و عرضه ترافیک، که در اکثر حالات وابسته به یکدیگرند، باعث



شکل 1. نمایی از طرح کلی فاکتورهای اثرگذار بر روی توزیع زمان سفر

خاصی از هفته پیش بینی قابل قبولی از شرایط بعدی را در همان زمان از روز و همان روز از هفته فراهم خواهد ساخت. بنابراین، این مدل‌ها تنها زمانی قابل قبولند که مانند نواحی برون شهری و روستایی، الگوهای ترافیکی در ناحیه مورد نظر نسبتاً پایدار باشد (Williams and Hoel 2003).

دسته دوم مدل‌های سری زمانی می‌باشند. این مدل‌ها فرض می‌کنند که فاکتورهای بیرونی تاثیرگذار بر روی سیستم دینامیکی یا ثابت باقی می‌مانند، یا اگر آنها در طول زمان تغییر کنند، می‌توان برای مدل اندازه‌گیری و محاسبه شوند. همان طور که (Chein et al 2002) نشان داده‌اند، صحت مدل‌های سری‌های زمانی تابعی از شباهت بین الگوهای ترافیکی زمان واقعی و تاریخی است. تغییر در داده‌های زمان سفر تاریخی یا تغییرات در ارتباط بین داده‌های زمان سفر واقعی و تاریخی به طور بارزی می‌تواند باعث ایجاد عدم قطعیت در نتایج پیش بینی شود. با توجه به تحقیقات صورت گرفته، تاکنون این مدل‌ها برای پیش بینی زمان سفر اتوبوس استفاده نشده‌اند. اما، این مدل‌ها نشان داده‌اند که برای پیش بینی زمان سفر در کمان‌های شبکه و حجم ترافیک در ترکیب با مدل‌های دیگر مانند فیلترینگ کالمن مؤثرند (Thomas et al 2010).

بنابراین، دانش نحوه تغییرات زمان سفر برای ارتقای اطمینان از سرویس‌های اطلاعاتی ترافیک و افزایش صحت پیش‌بینی‌های زمان سفر، ارزشمند است. لذا این تحقیق اساساً بر روی توسعه الگوریتمی برای پیش‌بینی زمان سفر برای اتوبوس‌ها با استفاده از داده‌های سیستم موقعیت یاب جهانی¹ و داده‌هایی در ارتباط با وضعیت ترافیک و تقاضای مسافر به منظور فراهم نمودن اطلاعات زمان سفر قابل اعتماد برای کاربران حمل و نقل تمرکز می‌نماید.

مدل‌های متنوعی برای پیش‌بینی پارامترهای معرف وضعیت ترافیک مانند زمان سفر و جریان ترافیک در طول سالیان متمادی توسعه یافته‌اند. چهار مورد از گسترده‌ترین مدل‌های مورد استفاده به شرح زیر ارایه می‌گردند. دسته اول مدل‌های بر اساس داده‌های تاریخی وابسته به زمان می‌باشند. این نوع از مدل‌های پیش‌بینی، زمان سفر فعلی و آینده اتوبوس را از زمان سفر تاریخی مسافرت‌های قبلی در یک دوره زمانی به دست می‌آورد. فرضیه اصلی این نوع از مدل‌ها اینست که حالت فعلی ترافیک ثابت و بدون تغییر باقی می‌ماند. از آنجا که شرایط ترافیک از الگوهای روزانه و هفتگی پیروی می‌کند، میانگین‌های تاریخی در یک زمان خاص و روز

مدل‌های رگرسیون خطی دسته دیگری از مدل‌های پیش بینی زمان سفر اتوبوس‌ها می‌باشند. این مدل‌ها متغیر وابسته را با یک تابع ریاضی تشکیل شده از مجموعه ای از متغیرهای مستقل پیش بینی کرده و توضیح می‌دهند. برخلاف مدل‌های پیش بینی بر مبنای داده‌های تاریخی، این مدل‌ها قادر به نشان دادن عملکرد رضایت بخش تحت شرایط ترافیکی ناپایدار می‌باشند. در مدل‌های رگرسیون معمولاً اثرات همزمان فاکتورهای گوناگون، نسبت به هم مستقل بوده و بر روی متغیر وابسته اثر می‌گذارند. (Jeong et al 2004) و (Ramakrishna et al 2006) مدل‌های رگرسیون خطی را با استفاده از مجموعه‌های مختلفی از ورودی‌ها توسعه دادند. هر دو مطالعه نشان دادند که مزیت عمده مدل رگرسیون خطی این است که این مدل‌ها نشان می‌دهد چه ورودی‌هایی برای پیش بینی دارای اهمیت کمتر یا بیشتری هستند. فیلترکالمن که سومین دسته از مدل‌های پیش بینی زمان سفر می‌باشد، به طور گسترده ای برای پیش بینی زمان ورود اتوبوس مورد استفاده قرار گرفته است. عملکرد اصلی این فیلترفراهم نمودن تخمین‌های حالت فعلی سیستم است. همچنین به عنوان مبنایی برای پیش بینی مقادیر بعدی یا ارتقای تخمین‌های متغیرهای قبلی نیز به کار گرفته می‌شود، یعنی دارای ظرفیتی برای فیلتر کردن نویز است (Kalman 1960).

(Shalaby and Farahan 2004) یک مدل پیش بینی زمان ورود اتوبوس را با استفاده از تکنیک فیلترینگ کالمن توسعه دادند. آنها دو الگوریتم فیلترینگ کالمن را برای پیش‌بینی زمان‌های حرکت و زمان‌های توقف به طور مجزا در نظر گرفتند. بر طبق تحقیق آنها فاصله بین دو ایستگاه بررسی زمانی² به عنوان کمان‌های شبکه تعریف شد. سپس برای توسعه یک مدل دینامیک بهنگام، زمان ورود و خروج پیش بینی شده اتوبوس را در نقاط بررسی زمانی بروز کردند. آنها ادعا کردند که تکنیک‌های فیلترینگ کالمن از مدل‌های تاریخی، مدل‌های رگرسیون و مدل‌های شبکه عصبی جواب‌های بهتری می‌دهند، چون این تکنیک قابلیت دینامیکی برای بروز کردن خودش بر اساس داده‌های جدیدی که تغییر ویژگی‌های محیط حمل و نقل را منعکس می‌سازد، را دارا می‌باشد.

در پی تلاش برای بدست آوردن یک فیلتر کالمن سازگار با پیش بینی زمان سفر اتوبوس پارامتری به عنوان پارامتر

فراموش شده در این فیلتر تعبیه شده است که وظیفه تقویت تاثیر گذاری داده‌های قدیمی بر روی مدل را بر عهده دارد (Wang et al 2012). همچنین این مدل فیلتر کالمن مانند مدل‌های قبلی قابلیت تصحیح پیش بینی‌ها را با آخرین داده‌های ورودی را دارا می‌باشد. نتایج اعتبار سنجی برتری این مدل در مقابل مدل‌های سنتی فیلترینگ کالمن نشان می‌داد.

روش‌های یادگیری ماشینی چهارمین دسته از مدل‌های یاد شده می‌باشند. این مدل‌ها برخی مزایا را نسبت به مدل‌های آماری ارائه می‌دهند: آنها قادر به برقراری ارتباطات پیچیده بین پارامترهای پیش بینی کننده‌ای که می‌توانند بین مقادیر زیادی از داده‌ها حاصل شوند، هستند و قادر به پردازش روابط غیرخطی بین متغیرهای پیش بینی کننده و پردازش داده‌های پیچیده و نویزدار هستند. این مدل‌ها می‌توانند برای پیش بینی زمان سفر بدون تعریف واضح فرآیندهای ترافیکی (فیزیکی) استفاده شوند (Hoogendoorn and Van Lint 2008).

یکی از ابزارهای حل مدل‌های یادگیری ماشینی روش شبکه عصبی مصنوعی³ می‌باشد. این روش اخیراً در پیش بینی زمان ورود اتوبوس‌ها به دلیل قابلیت آن برای حل روابط غیرخطی پیچیده عمومیت پیدا کرده است. شبکه‌های عصبی مصنوعی، با تقلید از قابلیت پردازش هوشمند داده‌ها توسط مغز انسان، با لایه‌های چندگانه‌ای از واحدهای پردازنده، با نام نورون‌های مصنوعی ایجاد می‌شوند. نورون‌ها شامل توابع فعالسازی (خطی یا غیرخطی) هستند و دارای ارتباطات بینابینی بسیاری با یکدیگر توسط وزن‌های سیناپسی می‌باشند. اطلاعات می‌تواند در یک جهت روبه جلو یا برگشتی از طریق توپولوژی‌های دارای ارتباطات کامل یا جزئی پردازش شوند. ضمناً وزن‌های سیناپسی می‌توانند خودکار از طریق یک فرآیند یادگیری تنظیم شوند [Hagal et al 1996].

یک مدل رگرسیون خطی چندگانه⁴ و یک مدل شبکه عصبی مصنوعی برای پیش بینی زمان‌های ورود اتوبوس با استفاده از داده‌های مبتنی بر داده‌های سیستم موقعیت یاب جهانی توسط (Ramakrishna et al 2006) توسعه پیدا کرده است. در این مقایسه نشان داده شد که مدل شبکه عصبی مصنوعی بهتر از مدل رگرسیون خطی چندگانه عمل نمود.

در مطالعه‌ای دیگر با در نظر گرفتن پارامترهای زمان سفر تاریخی (ساعت، روز و ماه از سال)، چسبندگی به برنامه زمانبندی و یکی از پارامترهای نشان دهنده وضعیت ترافیک

نرم افزار اسکتس⁵، به عنوان پارامترهای ورودی به توسعه یک شبکه عصبی مصنوعی پرداخته شد. آنها با در نظر گرفتن یکی از خطوط اتوبوس شهر سیدنی به عنوان مطالعه موردی به مقایسه مدل خود با مدل‌های براساس داده‌های تاریخی پرداخته و برتری مدل خود را نسبت به مدل شبکه عصبی بدون پارامتر جریان ترافیک ثابت نمودند. همچنین مدل شبکه عصبی بدون پارامتر نشان دهنده وضعیت جریان ترافیک عملکرد بهتری نسبت به مدل میانگین داشت.

دو مدل شبکه عصبی مصنوعی با استفاده از داده‌های سیستم موقعیت یاب جهانی و داده‌های سیستم جمع آوری خودکار کرایه⁶ در شهر جینان⁷ چین به توسعه پیدا کرد (Lin et al 2013). از آنجا که برای آنها استفاده از داده‌های وضعیت ترافیک که البته متاثر از تقاطعات چراغ دار نیز می‌باشد دشوار بود، به خوشه بندی داده‌های خود پرداختند و برای هر یک از این خوشه‌ها به توسعه شبکه عصبی سلسله مراتبی⁸ اقدام نمودند. نتایج مطالعه به وضوح برتری مدل شبکه عصبی را نسبت به مدل فیلتر کالمن نشان می‌داد.

(Gurmu et al 2014) با صرفاً استفاده از داده‌های سیستم موقعیت یاب جهانی و توسعه سه مدل شامل: مدل متوسط تاریخی، مدل فیلترینگ کالمن و یک مدل شبکه عصبی مصنوعی به مقایسه این سه مدل و ارزیابی آنها توسط دو پارامتر: دقت کلی پیش بینی و میزان نیرومندی⁹ پرداختند. نتایج برتری کامل مدل شبکه عصبی را نشان می‌داد.

وانگ و همکاران در سال 2014، با استفاده از یک شبکه عصبی شعاعی¹⁰ در ابتدا رابطه غیر خطی بین پارامترهای ورودی و خروجی را برقرار نمودند سپس از یک متد بهنگام سازی برای تصحیح پیش بینی‌های شبکه عصبی استفاده کردند. آنها مدل نهایی خود را با استفاده از داده‌های زمان سفر یکی از خطوط شهر دالیان¹¹ چین اعتبار سنجی نمودند که از هر دو مدل رگرسیون خطی و شبکه عصبی بدون بروز رسانی عملکرد بهتری داشت.

با توجه به مطالب بیان شده می‌توان استدلال کرد که مدل‌های شبکه عصبی مصنوعی که در زمره مدل‌های یادگیری ماشینی بشمار می‌روند

می‌توانند برای پیش بینی زمان سفر بهنگام کارآمدتر باشند. این مدل‌ها به شرطی که به خوبی به صورت آفلاین آموزش داده شوند در برآورد روابط غیرخطی بین فاکتورهایی که بر

روی توزیع زمان سفر اثر می‌گذارند، عملکرد بهتری را نسبت به سایر مدل‌ها از خود نشان می‌دهند.

در ادامه مقاله ابتدا مدل پیشنهادی ارائه می‌شود و سپس با مقایسه مدل با 2 مدل دیگر به بررسی نتایج تحقیق پرداخته می‌شود.

2- مدل پیش بینی زمان سفر

در سیستم‌های حمل و نقل همگانی، زمان سفر وسایل نقلیه تحت تأثیر سه عامل اساسی، نیروی انسانی، وسیله نقلیه و عامل محیطی قرار دارد (Lin & Zito 2005). اثر هر یک از عوامل ذکر شده بر زمان سفر با تعریف تعدادی متغیر قابل اندازه گیری بررسی می‌شود. دقت برآورد زمان سفر وسایل نقلیه وابسته به تعریف مناسب، اندازه‌گیری دقیق متغیرها و همچنین اندازه‌گیری تأثیر آنها بر زمان سفر است متغیرهایی مانند سن راننده، جنسیت راننده، سابقه رانندگی و ... از جمله متغیرهایی هستند که اثر خصوصیات راننده را بر زمان سفر نشان می‌دهند. همچنین ویژگی مسافران نظیر زمان مورد نیاز برای پیاده شدن هر مسافر در ایستگاه‌ها، همچنین تعداد مسافران پیاده شده در هر ایستگاه دیگر عامل انسانی است که در پیش بینی زمان سفر اتوبوس‌ها تأثیرگذار می‌باشد. نوع وسیله نقلیه، عمر وسیله، شتاب سرعت‌گیری، شتاب ترمزگیری آن و ... از جمله متغیرهای اندازه گیری تأثیر عامل وسیله نقلیه بر زمان سفر هستند. عامل محیطی را می‌توان به عوامل جزئی تری مانند شرایط آب و هوا و زمانی، وضعیت جریان ترافیک و وضعیت مسیر عبور اتوبوس تقسیم کرد. با توجه به ماهیت مسئله پیش بینی زمان سفر در سیستم حمل و نقل همگانی، بخشی از عامل‌ها و متغیرهای مؤثر بر زمان سفر که در حالت عام معرفی می‌شوند، به علت تغییرپذیری کمتری که در سیستم حمل و نقل همگانی دارند، از تأثیر کمتری بر زمان سفر وسایل نقلیه همگانی برخوردارند و می‌توان از در نظر گرفتن آنها در مدل پیش بینی چشم پوشی کرد.

مهارت و دقت مشابه رانندگان سیستم حمل و نقل همگانی با توجه به آموزش‌های یکسانی که می‌بینند و مسئولیت یکسانی که رانندگان در قبال مسافران دارند، اثر متغیرهای معرف عامل نیروی انسانی که تحت تأثیر خود راننده می‌باشد را در زمان سفر کمتر می‌نماید. اما تفاوت تعداد مسافران پیاده

شده در ایستگاه‌های مختلف و تفاوت در زمان مورد نیاز برای این فرآیند در ساعات اوج و غیر اوج ترافیک، پارامتر تقاضای مسافران در ایستگاه‌ها را جزء پارامترهای موثر در برآورد زمان سفر اتوبوس‌ها قرار می‌دهد. همچنین مشابهت فنی وسایل نقلیه همگانی در سیستم حمل و نقل اتوبوسرانی، اثر عامل وسیله نقلیه و متغیرهای مربوط به آن را بر زمان سفر ناچیز می‌نماید.

به دلیل عدم دسترسی به داده‌های متغیرهای جوی در بازه زمانی مورد بررسی، متغیرهای شرایط جوی در مدل پیش بینی این پژوهش در نظر گرفته نشده است. اما زمان انجام سفر (زمان از روز¹² و روز از هفته¹³) از میان متغیرهای شرایط زمانی و آب و هوایی، جهت بررسی تأثیر آن بر زمان سفر در مدل مقایسه‌ای توسعه یافته در نظر گرفته شده است.

از میان پارامترهای نشان دهنده وضعیت جریان ترافیک، دو متغیر درجه اشباع¹⁴ تقاطعات و حجم عبوری به عنوان متغیرهای مؤثر بر زمان سفر اتوبوس‌ها در نظر گرفته شده‌اند. در حالت کلی درجه اشباع برابر نسبت حجم عبوری به ظرفیت معبر می‌باشد که می‌توان آنرا برای هر خط، رویکرد و یا تقاطع تعریف نمود. در سیستم اسکتس⁵ درجه اشباع، توسط برخی پارامترهای ساده محاسبه می‌گردد و نتیجه آن برابر همان نسبت حجم تردد به ظرفیت می‌باشد. نهایتاً درجه اشباع در سیستم اسکتس⁵ برابر نسبت زمان سبز موثر به کل زمان سبز در هر سیکل می‌باشد. مقدار درجه اشباع براساس رابطه 1 تعریف می‌گردد.

$$DS = \frac{g - (TST - SS \times NS)}{g} \times 100 \quad (1)$$

که در این رابطه، DS: درجه اشباع تقاطع، TST: کل زمان خالی بودن شناساگر در دوره زمانی سبز بودن چراغ، SS: فاصله خودروها در زمان اشباع (فاصله غیر قابل اجتناب)، NS: تعداد دفعات خالی شدن شناساگر و g زمان سبز هر سیکل می‌باشد. مقدار درجه اشباع در شرایط عادی عددی بین 0 تا 100 می‌باشد ولی در شرایط همراه با تداخلات ترافیکی

(هنگامی که سرفاصله عبوری خودروها کمتر از مقدار این پارامتر در شرایط حداکثر جریان است) مقدار بیشتر از عدد 100 نیز می‌تواند داشته باشد.

در نظر گرفتن یکی از متغیرها به تنهایی میزان شلوغی مسیر را نشان نمی‌دهد. تصور کنید در خیابانی تمامی وسایل نقلیه با سرعت آهسته در حال حرکت باشند، در این حالت متغیر حجم مقدار کوچکی را نشان خواهد داد. این مقدار کم می‌تواند زمانی که خیابان خالی است و حرکتی در آن انجام نمی‌شود نیز اندازه‌گیری شود. چنین حالات خاصی برای سایر متغیرهای ترافیکی به تنهایی نیز ممکن است رخ دهد. اما اندازه‌گیری همزمان متغیرهای دیگر در کنار هم شلوغی و یا روانی جریان ترافیکی را نشان می‌دهد. به عنوان مثال، چنانچه متغیر حجم مقدار کمی باشد اما متغیر درجه اشباع زیاد باشد می‌توان نتیجه گرفت مسیر پرتراکم است و بالعکس.

مدل پیشنهاد شده در این مقاله، براساس پردازش سه پارامتر اصلی و موثر در پیش بینی زمان سفر استفاده می‌کند این پارامترها شامل: درجه اشباع تقاطعات بین دو ایستگاه، حجم عبوری از تقاطعات بین دو ایستگاه و تقاضای مسافر در ایستگاه‌ها می‌باشند.

2-1- اطمینان از تاثیرگذاری داده‌های ورودی

توسعه یک مدل کارآمد به شکل قابل توجه‌ای وابسته به نحوه انتخاب پارامترهای تاثیرگذار بر خروجی مدل است. انتخاب بهترین ترکیب از داده‌های ورودی می‌تواند تأثیرات محسوسی در دقت برآورد نهایی مدل داشته باشد. از میان روش‌های انتخاب داده‌های ورودی به نظر توسعه یک مدل خطی عمومی¹⁵ بهترین گزینه جایگزین برای تشخیص میزان تاثیرگذاری پارامترهای ورودی می‌باشد (Li, 2006). این روش زمان سفر را به صورت یک پارامتر وابسته به مجموعه‌ای از پارامترهای مستقل مدل می‌کند. شکل عمومی مدل‌های خطی عمومی مطابق رابطه 2 بیان می‌گردد.

$$t = a + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} x_i x_j x_k + \varepsilon$$

داده‌های مورد بررسی شامل داده‌های درجه اشباع که به صورت میانگین‌های k دقیقه‌ای قبل از لحظه رسیدن اتوبوس به ایستگاه زمانی اول از درجه اشباع تقاطعات پایین دست آن ایستگاه به دست می‌آید، احجام عبوری که به صورت میانگین‌های 15 دقیقه‌ای قبل از لحظه رسیدن اتوبوس به ایستگاه زمانی اول از احجام عبوری تقاطعات پایین دست آن ایستگاه به دست می‌آید، تقاضای مسافر که از مجموع k دقیقه‌ای قبل از لحظه رسیدن اتوبوس به ایستگاه زمانی اول از تقاضای مسافر در ایستگاه‌های پایین دست آن ایستگاه به دست می‌آید و داده‌های مربوط به مدل تاریخی وابسته به زمان نظیر زمان از روز که شامل بازه‌های 15 دقیقه‌ای می‌شود که روز به آنها تقسیم شده است و اتوبوس در یکی از این بازه‌ها به ایستگاه زمانی اول می‌رسد و روز از هفته که شامل 5 روز کاری از هفته می‌باشد. نحوه تاثیرگذاری داده‌های ورودی بالا به شرح جداول 2 و 3 ارایه می‌گردد.

با توجه به جداول 2 و 3 و با استناد به اینکه هر 2 پارامتر درجه اشباع و حجم عبوری پارامترهای تاثیرگذاری در برآورد زمان سفر می‌باشند، هر دو پارامتر را ما به عنوان پارامترهای ورودی مدل در نظر گرفته شد. اما ذکر این نکته لازم است که با توجه به مقادیر R^2 اصلاح شده برای 2 پارامتر به نظر تاثیر درجه اشباع بیشتر به نظر می‌باشد.

علت این امر آن است که درجه اشباع پارامتری است که هم متأثر از تغییرات عرضه (طول سیکل و زمان سبز) و تقاضا می‌باشد، این درحالی است که حجم عبوری صرفاً پارامتری است که با تغییرات تقاضا تغییر می‌کند. اما از آنجا که امکان وجود خطا در هر یک از این 2 پارامتر وجود دارد، حضور هم زمان آنها در مدل امکان پوشش خطای یکدیگر را فراهم می‌سازد. در جداول 2 و 3 تاثیر میانگین‌گیری از مقدار درجه اشباع در بازه‌های زمانی مختلف به وضوح دیده می‌شود. نتایج پیشنهاد می‌کنند که این متوسط‌گیری در بازه‌های زمانی 15 دقیقه انجام شوند. برای بازه زمانی بزرگتر (نظیر 30 دقیقه)

که در آن، t : زمان سفر مشاهده شده بین هر دو ایستگاه زمانی، a_i, a_{ij}, a_{ijk} : پارامترهای مدل، x_i, x_j, x_k : متغیرهای مستقل از قبیل چسبندگی به برنامه زمانبندی، درجه اشباع، حجم عبوری، پارامترهای وابسته به زمان، x_i, x_j, x_k : جمله نشان دهنده برهمکنش 2 طرفه، x_i, x_j, x_k : جمله نشان دهنده برهمکنش 3 طرفه می‌باشد.

در این مدل به علت حجم بالای داده‌های ورودی فقط روابط مستقیم داده‌های ورودی در نظر گرفته شد و از برهمکنش‌های 2 و 3 طرفه صرف نظر گردید. معادله 2 ساختاری خطی دارد و توانایی در نظر گرفتن تاثیرات غیر خطی متغیرها را بر روی زمان سفر ندارد. اگر برای هر یک از پارامترهای ورودی مقدار R^2 اصلاح شده بزرگتر از صفر باشد (به طور مثال مقدار A را داشته باشد). این نشان می‌دهد که آن پارامتر حداقل به اندازه A در توصیف متغیر مستقل حتی به صورت خطی مشارکت دارد. در حالتی که R^2 اصلاح شده برای این پارامتر صفر باشد این پارامتر هیچ تاثیری در توصیف پارامتر مستقل به صورت خطی نداشته، لذا به صورت غیر خطی نیز تاثیری نخواهد داشت.

از آنجا که جهت بررسی تاثیرگذاری داده‌های مورد استفاده نیاز به شناخت محدوده مورد مطالعه می‌باشد مقاطع مورد بررسی در این مقاله که در محدوده بلوار کشاورز در تهران می‌باشد مطابق با جدول 1 ارایه می‌گردد (اطلاعات کامل در بخش مطالعه موردی ارایه خواهد گشت).

جدول 1. مقاطع مورد بررسی

مسیر	شرق به غرب	غرب به شرق
کل مسیر	میدان ولیعصر - دژبان	بیمارستان امام - میدان ولیعصر
بخش 1	حجاب - کارگر	کارگر - ساسان
بخش 2	حجاب - دژبان	16 آذر - ساسان
بخش 3	16 آذر - پست (جمالزاده)	بیمارستان امام - ساسان

همبستگی بین زمان سفر و درجه اشباع کاهش پیدا می‌کند. زمانی نیز که این بازه کاهش پیدا می‌کند (نظیر 2 و 10 دقیقه) مقدار R^2 اصلاح شده به شدت کاهش می‌یابد. یکی از تبعات انتخاب بازه‌های زمانی کوتاه نظیر 2 دقیقه این است که در این بازه صرفاً 1 یا 2 سیکل چراغ راهنمایی طی خواهد شد که این امر می‌تواند موجب ایجاد نوسانات شدید در مقدار حجم عبوری و درجه اشباع میانگین‌گیری شده گردد که خود باعث ایجاد خطا در برآورد زمان سفر توسط این 2 پارامتر می‌گردد. هم چنین برآورد تعداد تقاضای مسافر در ایستگاه‌های پایین دست به صورت 15 دقیقه‌ای، بهترین ترکیب را جهت پیش-بینی زمان سفر ارائه می‌نماید.

به علت تعدد ایستگاه‌های پایین دست و تاثیر بیشتر زمان توقف در ایستگاه، تاثیرگذاری بیشتر این پارامتر در مقاطعی مانند بیمارستان امام- بیمارستان ساسان، بیمارستان امام - میدان ولیعصر، میدان ولیعصر- دژبان و حجاب- دژبان مشاهده می‌شود.

ضریب همبستگی اصلاح شده برای پارامترهای مدل داده‌های تاریخی نظیر زمان از روز و روز از هفته موثر بودن این پارامترها را در برآورد زمان سفر به وضوح نشان می‌دهد. با توجه به جداول 2 و 3 میزان تاثیر پارامتر زمان از روز به علت نوسانات جریان ترافیک در طول ساعات مختلف از روز به مراتب بیشتر از پارامتر روز از هفته می‌باشد. این امر نشان دهنده آن است که الگوی جریان ترافیک در روزهای کاری هفته تقریباً شبیه هم بوده و تفاوت زیادی نسبت به هم ندارد. اما با توجه به مثبت بودن R^2 اصلاح شده برای هر دو پارامتر، هر دو این متغیرها به عنوان پارامتر ورودی برای مدل مقایسه‌ای تاریخی استفاده می‌گردند.

2-2- توسعه شبکه عصبی پیشنهادی

شبکه‌های عصبی مصنوعی متعددی در چندین دهه اخیر برای اهداف پیش‌بینی پیشنهاد شده‌اند. عمومی‌ترین معماری شبکه عصبی پرسپترون چند لایه¹⁶ می‌باشد که در این مطالعه نیز انتخاب شده است.

این نوع از شبکه‌های عصبی اگر نورن‌های کافی در لایه‌های مخفی خود داشته باشند، می‌توانند تقریباً هر تابعی را

تخمین بزنند، یعنی دارای قابلیت خوبی در تطبیق داده‌های ورودی با خروجی‌های مدل هستند.

شکل 2 ساختار کلی شبکه عصبی پرسپترون چند لایه‌ای پیشنهادی را نشان می‌دهد. اگرچه دستورالعمل آموزش پایه‌ای شبکه‌های عصبی مصنوعی یکسان است، اما صحت نتیجه بسیار وابسته به نوع ترکیبات ورودی/خروجی است. این مطالعه نیز سه ترکیب ورودی - خروجی منحصر به فرد را برای هدف پیش‌بینی ارائه می‌دهد.

اولین ترکیب که زین پس پیش‌بینی کننده پیشنهادی نام برده می‌شود شامل میانگین 15 دقیقه‌ای درجه اشباع تقاطعات پایین دست تا ایستگاه زمانی بعدی (این میانگین گیره از درجه اشباع 15 دقیقه قبل از لحظه رسیدن اتوبوس به ایستگاه زمانی اول صورت می‌گیرد) (X_1)، میانگین 15 دقیقه‌ای احجام عبوری تقاطعات پایین دست تا ایستگاه زمانی بعدی (این میانگین گیره از احجام 15 دقیقه، قبل از لحظه رسیدن اتوبوس به ایستگاه زمانی اول صورت می‌گیرد) (X_2) و مجموع 15 دقیقه‌ای تقاضای سفر (این تجمیع از تقاضای سفر 15 دقیقه‌ای ایستگاه‌های پایین دست قبل از لحظه رسیدن اتوبوس به ایستگاه صورت می‌گیرد) (X_3).

خروجی مدل زمان سفری است که اتوبوس برای رسیدن به ایستگاه دوم طی می‌کند (Y).

دومین ترکیب که نشان دهنده مدل بر اساس پارامترهای نشان دهنده وضعیت جریان بدون در نظر گرفتن داده‌های تقاضای مسافر است، برای متغیرهای ورودی شامل میانگین 15 دقیقه‌ای درجه اشباع تقاطعات پایین دست تا ایستگاه زمانی بعدی (این میانگین گیره از درجه اشباع 15 دقیقه قبل از لحظه رسیدن اتوبوس به ایستگاه زمانی اول صورت می‌گیرد) (X_1)، میانگین 15 دقیقه‌ای احجام عبوری تقاطعات پایین دست تا ایستگاه زمانی بعدی (این میانگین گیره از احجام 15 دقیقه، قبل از لحظه رسیدن اتوبوس به ایستگاه زمانی اول صورت می‌گیرد) (X_2) و خروجی مدل زمان سفری است که اتوبوس برای رسیدن به ایستگاه دوم طی می‌کند (Y).

سومین مدل بر اساس داده‌های تاریخی وابسته به زمان می‌باشد. برای متغیرهای ورودی شامل زمان از روز (بازه 15 دقیقه‌ای که اتوبوس به ایستگاه زمانی اول رسیده است) (X_1) و روز از هفته (نشان دهنده یکی از 5 روز


هفته) (X_2) می باشد. لازم به ذکر است که ترکیبات دوم و سوم صرفاً جهت مقایسه با مدل اصلی استفاده شده‌اند.

جدول 2. تأثیر پارامترهای مختلف مدل با استفاده از شاخص R^2 اصلاح شده در مسیر غرب به شرق

پارامترهای ورودی						
روز از هفته	زمان از روز	تقاضای مسافر	حجم عبوری	درجه اشباع	بازه زمانی (دقیقه)	مقطع مسیر
0.049	0.128	0.021	0.329	0.017	2	16 آذر- بیمارستان ساسان
		0.053		0.206	10	
		<u>0.095</u>		<u>0.342</u>	15	
		0.032		0.208	30	
0.129	0.294	0.092	0.478	0.106	2	بیمارستان امام- بیمارستان ساسان
		0.191		0.262	10	
		<u>0.287</u>		<u>0.483</u>	15	
		0.165		0.261	30	
0.145	0.39	0.085	0.482	0.342	2	بیمارستان امام- میدان ولیعصر
		0.211		0.469	10	
		<u>0.252</u>		<u>0.583</u>	15	
		0.104		0.383	30	
0.044	0.161	0.043	0.364	0.086	2	کارگر- ساسان
		0.123		0.352	10	
		<u>0.185</u>		<u>0.48</u>	15	
		0.052		0.27	30	

جدول 3. تأثیر پارامترهای مختلف مدل با استفاده از شاخص R^2 اصلاح شده در مسیر شرق به غرب

پارامترهای ورودی						
روز از هفته	زمان از روز	تقاضای مسافر	حجم عبوری	درجه اشباع	بازه زمانی (دقیقه)	مقطع مسیر
0.037	0.153	0.035	0.316	0.064	2	حجاب- کارگر
		0.064		0.232	10	
		<u>0.155</u>		<u>0.395</u>	15	
		0.044		0.250	30	
0.152	0.314	0.083	0.399	0.124	2	حجاب- دژبان
		0.201		0.322	10	
		<u>0.272</u>		<u>0.421</u>	15	
		0.194		0.231	30	
0.161	0.37	0.095	0.452	0.356	2	میدان ولیعصر- دژبان
		0.231		0.478	10	
		<u>0.297</u>		<u>0.557</u>	15	
		0.151		0.343	30	
0.047	0.203	0.062	0.304	0.091	2	16 آذر- پست (جمالزاده)
		0.114		0.185	10	
		<u>0.164</u>		<u>0.348</u>	15	
		0.077		0.221	30	



شکل 2. ساختار کلی شبکه عصبی توسعه یافته

3-2- ساختار شبکه عصبی پیشنهادی

تعداد لایه‌های شبکه عصبی و تعداد نورون‌های هر لایه در فرآیند توسعه مدل به صورت آزمون و خطا به دست آمدند. در این مطالعه یک شبکه عصبی سه لایه استفاده شده است. یک لایه ورودی، یک لایه مخفی و یک لایه خروجی. به علت حجم بالای داده‌های ورودی لایه مخفی شامل 2 زیرلایه در نظر گرفته شد که تعداد نورون‌های هر لایه بر اساس انتخاب بهترین نتایج از مدل به شرح جداول 4 و 5 برای هر یک از مقاطع ارایه می‌گردد.

توابع فعالسازی¹⁷ برای لایه‌های مخفی مسئولیت غیرخطی بودن در شبکه را دارا می‌باشند. این تابع رابطه غیرخطی را بین ورودی‌ها و خروجی‌های یک شبکه تعیین می‌کند. با توجه به مطالعات قبلی صورت گرفته (Li 2006, Liu 2008, Mazloui et al 2011) بهترین توابع فعال سازی

در این مدل که توابع فعل سازی سیگموئید¹⁸ نظیر تانژانت‌هایپربولیک می‌باشند استفاده شده است. عمومی ترین الگوریتم آموزش که انتشار برگشتی¹⁹ می‌باشد نیز برای این مدل انتخاب گردیده است. شبکه عصبی انتشار برگشتی به طور مستدل عمومی ترین الگوریتم مورد استفاده برای استفاده در حمل و نقل است. هدف فرآیند آموزش یافتن یک ماتریس وزنی است که جذر میاتگین مربعات خطا²⁰ را به حداقل برساند که به صورت مجزور مربع خطای میانگین بین پیش بینی‌های شبکه عصبی مصنوعی و مقادیر واقعی زمان‌های سفر تعریف می‌شود. (Jeong 2004) تابع آموزش تنظیم بیسین²¹ و تابع آموزش انتشار برگشتی لونیبرگ - مارکواریت²² را بهتر از توابع آموزش دیگر یافتند. در این مقاله، از تابع آموزش انتشار برگشتی لونیبرگ مارکواریت که عموماً توسط اکثر محققان استفاده می‌شود، بهره برده شد.

جدول 4. تعداد نورون‌های لایه مخفی مسیر غرب به شرق

ترکیب سوم		ترکیب دوم		مدل اصلی		مقاطع
نورون لایه مخفی 2	نورون لایه مخفی 1	نورون لایه مخفی 2	نورون لایه مخفی 1	نورون لایه مخفی 2	نورون لایه مخفی 1	
7	8	7	8	7	8	16 آذر - بیمارستان ساسان
7	8	8	9	8	9	بیمارستان امام - بیمارستان ساسان
9	10	9	10	9	10	بیمارستان امام - میدان ولیعصر
9	8	8	8	8	8	کارگر - بیمارستان ساسان

جدول 5. تعداد نورون‌های لایه مخفی مسیر شرق به غرب

ترکیب سوم		ترکیب دوم		مدل اصلی		مقاطع
نورون لایه مخفی 2	نورون لایه مخفی 1	نورون لایه مخفی 2	نورون لایه مخفی 1	نورون لایه مخفی 2	نورون لایه مخفی 1	
8	6	9	6	9	6	حجاب- کارگر
8	6	9	8	9	8	حجاب- دژبان
6	5	6	5	6	5	میدان ولیعصر- پست (جمازاده)
8	7	8	7	8	7	16 آذر- پست (جمالزاده)

الکترونیک²⁶ می‌باشند. از داده‌های سیستم موقعیت یاب جهانی در راستای به دست آوردن زمان سفر تاریخی اتوبوس‌ها و زمان ورود به هر ایستگاه استفاده گردید، داده‌های نرم افزار اسکتس⁵ برای در دست داشتن برآوردی از وضعیت جریان ترافیک (درجه اشباع و حجم عبوری از تقاطعات) در مسیر مورد استفاده قرار گرفتند و اطلاعات بلیط الکترونیک هم تخمینی از میزان تقاضای مسافر در ایستگاه‌ها را ارائه نمود.

3-1- داده‌های سیستم موقعیت یاب جهانی

اطلاعات مورد نیاز در این خصوص از بخشی از مسیر اتوبوس خط 8308 شهر تهران جمع آوری گردید. این خط به طور کامل به صورت مختلط با جریان ترافیک عمل می‌کند. مسیر مورد بررسی با طول تقریبی 2.5 کیلومتر از 4 مقطع در مسیر رفت و 4 مقطع در مسیر برگشت با طول‌های متفاوت و تعداد تقاطعات میانی مختلف تشکیل گردیده است (شکل 3) (جدول 6). تمامی اتوبوس‌های این خط به سیستم موقعیت یاب جهانی متصل بوده و زمان ورود هر اتوبوس به ایستگاه توسط این سیستم ثبت می‌گردد. لذا داده‌های 1 ماه زمان سفر برای روزهای کاری در این مسیر جمع آوری گردید. در هر مقطع و بین هر دو ایستگاه زمانی بین 1000 تا 1800 مشاهده زمان سفر صورت گرفته است.

3-2- داده‌های معرف وضعیت جریان

از داده‌های مربوط به شناساگرهای متصل به نرم افزار اسکتس⁵ جهت به دست آوردن احجام عبوری از تقاطع استفاده گردید و در بازه‌های زمانی 15 دقیقه‌ای برای هر کدام از رویکردهای تقاطع در کل طول شبانه روز در اردیبهشت ماه سال 93 برای تقاطعات جدول 6 برداشت گردید.

2-4- وزن‌های ابتدایی

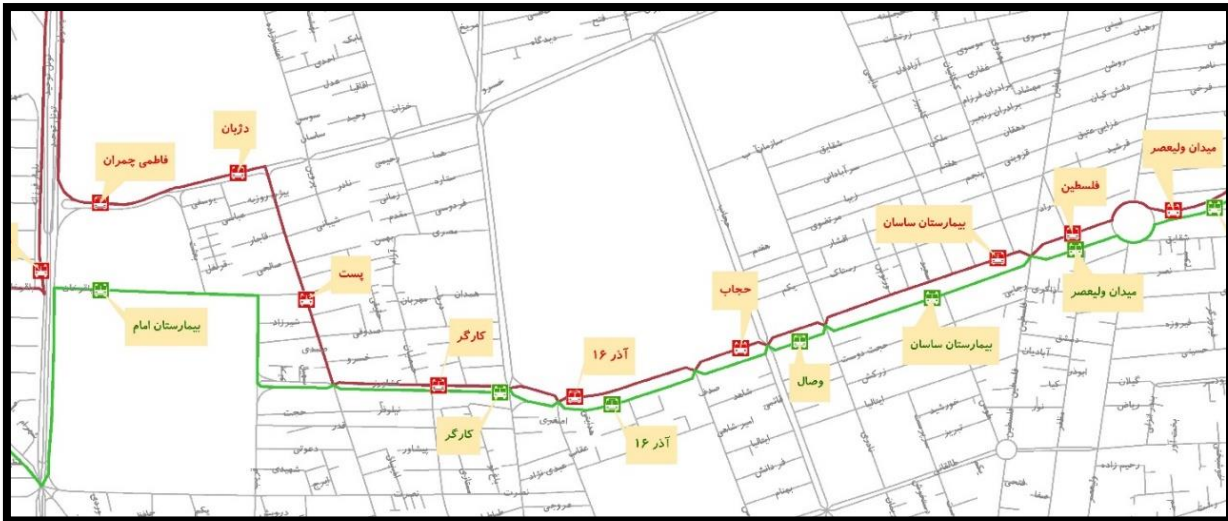
یکی از عوامل مهمی که در آموزش شبکه‌های عصبی و خروجی‌های آن موثر است، نقطه‌ی ابتدایی برای جستجو جهت به دست آوردن مقدار بهینه برای ضرایب مدل است. نقاط شروع متفاوت می‌توانند به اعداد بهینه متفاوتی برای پارامترهای مدل ختم شوند. در این مطالعه هریک از شبکه‌های عصبی با تعداد مشخصی نورون در لایه مخفی اول و دوم، 10 مرتبه آموزش دیده و نتایج آنها جمع‌آوری گردید. سپس نتایج میانگین آنها به عنوان خروجی مدل در نظر گرفته شده است. بنابراین نتایج ارائه شده در ادامه که نتایج مدل شبکه عصبی خوانده می‌شود، شامل نتایج میانگین می‌باشد.

2-5- شیوه عملکرد مدل

در این مطالعه 70٪ مجموعه داده‌ها به طور تصادفی به عنوان مجموعه آموزشی²³ در نظر گرفته شد و 30٪ بعدی مجموعه داده‌ها به عنوان مجموعه آزمایشی²⁴ اتخاذ شد. این تقسیم توسط اکثر محققان استفاده شده است. خارج از مجموعه آموزشی، 15٪ مجموعه داده‌ها به عنوان آزمایش اعتباری²⁵ گرفته می‌شوند. شایان ذکر است که ترکیبات درصدی مختلف مجموعه‌های آموزشی، آزمایشی و اعتباریابی بررسی شده‌اند و گرفتن حداقل خطای مربع میانگین با استفاده از ترکیبات فوق امکان پذیر بود.

3- مطالعه موردی

داده‌های در دسترس در این مطالعه به سه دسته از داده‌ها تقسیم می‌شوند که شامل: داده‌های سیستم موقعیت یاب جهانی، داده‌های مربوط به نرم افزار اسکتس⁵ و داده‌های بلیط



شکل 3. مسیر مورد مطالعه

الکترونیک صرفاً در هنگام خروج مسافر از ایستگاه رخ می‌دهد، لذا اطلاعات در دسترس به صرفاً به تقاضای مربوط به خروج از ایستگاه محدود می‌شود و برآوردی از زمان ورود مسافر به اتوبوس وجود ندارد. از آنجا که تأثیر میزان تقاضای مسافر در طول مسیر در مطالعات پیشین صورت گرفته در رابطه با برآورد زمان سفر مورد بررسی قرار نگرفته بود و با توجه به تأثیرگذار بودن این پارامتر هم در زمان توقف اتوبوس‌ها در ایستگاه‌ها و هم در کمک به تشخیص ساعات اوج ترافیک، در این پژوهش میزان تقاضای مسافر در ایستگاه‌های اتوبوس به عنوان دیگر پارامتر ورودی مدل در نظر گرفته شد. با توجه به اینکه داده‌های در اختیار فقط رخ داد یک تراکش را ثبت می‌کرد، رسیدن به تعداد تراکش‌ها در هر بازه زمانی نیازمند تفکیک داده‌ها براساس زمان از روز و روز از هفته داشت که خود نیازمند صرف وقت و انرژی بسیار بود.

4- تجزیه و تحلیل

در این بخش، نتایج محاسباتی مدل پیشنهادی با جزییات بیشتری ارائه می‌گردد و نتایج آن با سایر مدل‌های توسعه یافته مورد مقایسه قرار می‌گیرد. توجه به این نکته ضروری است که تمامی مراحل مربوط به مدل سازی نظیر آماده سازی داده‌های ورودی، تصحیح داده، ساخت شبکه مدل و تحلیل مدل در فضای نرم افزار متلب و با کد نویسی در این فضا رخ داده است.

جدول 6. تقاطعات برداشت شده

ردیف	تقاطع	ردیف	تقاطع
1	بلوار کشاورز- فلسطین	4	بلوار کشاورز- کارگر
2	بلوار کشاورز- قدس	5	بلوار کشاورز- وصال
3	بلوار کشاورز- جمال زاده		

همچنین داده‌های مربوط به درجه اشباع که خود به نحوی نشان دهنده زمان سبز موثر به کل زمان سبز می‌باشد و پارامتری است که نشان دهنده نسبت تقاضا به عرضه می‌باشد برای هر یک از رویکردهای تقاطعات به طور تفکیکی برای هر سیکل در طول دوره زمانی ذکر شده جمع آوری گردید.

3-3- داده‌های معرف تقاضای مسافر

جهت برآورد تقاضای مسافر در ایستگاه‌ها از سیستم بلیط الکترونیک استفاده گردید. این سیستم با ثبت تک تک تراکش‌های صورت گرفته که ناشی از ورود و یا خروج مسافر از وسایل حمل و نقل همگانی است علاوه بر ایجاد تسهیلات رفاهی برای استفاده کنندگان از این سیستم، اطلاعات بسیار مفیدی را در اختیار متخصصان حمل و نقل قرار می‌دهد. در سیستم اتوبوس رانی تهران با توجه به اینکه استفاده از بلیط

4-1- ارزیابی عملکرد مدل

اکنون پس از این که مدل‌های پیش بینی توسعه یافتند، ارزیابی آنها برحسب صحت پیش بینی ضروری است. 2 معیار به عنوان پارامترهای سنجش عملکرد مدل استفاده می‌گردند جذر میانگین مربعات خطا²⁷ مطابق رابطه 2 به عنوان اولین معیار سنجش عملکرد مدل استفاده شد. در این معادله جذر میانگین مربعات را بین مقدار مشاهده شده (در این حالت زمان سفر مشاهده شده بین 2 ایستگاه زمانی) و مقدار پیش بینی شده (در این حالت زمان سفر پیش بینی شده بین 2 ایستگاه زمانی) محاسبه می‌شود.

$$RMSE = \sqrt{\frac{1}{n} \sum_i^n (Y_{obs} - Y_p)^2} \quad (2)$$

که در آن Y_p زمان سفر پیش بینی شده بین 2 ایستگاه زمانی است. Y_{obs} زمان سفر مشاهده شده بین 2 ایستگاه زمانی است. n تعداد مجموعه‌های آزمایش است. میانگین در صد خطای مطلق²⁸ مطابق رابطه 3 به عنوان دومین معیار عملکرد مدل مورد بررسی قرار گرفت. در این معادله میانگین در صد خطای مطلق بین مقادیر مشاهده شده و مقادیر پیش بینی شده به دست می‌آید.

$$MAPE = \frac{1}{n} \sum_1^n \frac{|(Y_{obs} - Y_p)|}{Y_{obs}} \quad (3)$$

که در آن Y_p زمان سفر پیش بینی شده بین 2 ایستگاه زمانی است. Y_{obs} زمان سفر مشاهده شده بین 2 ایستگاه زمانی است. n تعداد مجموعه‌های آزمایش است. نتایج مقایسه‌ای بین مدل پیشنهادی با 2 مدل دیگر که جهت مقایسه توسعه یافته اند به طور خلاصه مطابق جداول 7 و 8 ارائه می‌گردد.

در تمامی مقاطع ذکر شده که شامل مقاطع مسیر رفت و برگشت می‌باشد، مدل وضعیت جریان ترافیک عملکرد بهتری نسب به مدل داده‌های تاریخی وابسته به زمان دارد. این پیشرفت هم در مقادیر جذر میانگین مربعات خطا و هم در میانگین درصد خطای مطلق مشاهده می‌شود.

در مقاطعی که بین هر دو ایستگاه زمانی تعداد بیشتری تقاطع چراغ دار موجود است، به طبع آن تعداد داده‌های موثر ورودی مدل وضعیت جریان ترافیک نیز بیشتر خواهد بود، که

نتیجه ی آن خروجی‌های دقیق تر در مدل وابسته به وضعیت جریان ترافیک است.

در تمامی مقاطع مورد بررسی دقت پیش بینی مدل بر اساس وضعیت جریان ترافیک و تقاضای مسافر که مدل پیشنهادی این تحقیق می‌باشد از هر دو مدل مقایسه‌ای بهتر بوده و عملکرد مناسب‌تری را در مقایسه با سایر مدل‌ها از خود نشان می‌دهد.

کیفیت بهبود این مدل نیز به میزان زیادی وابسته به حضور ایستگاه‌های اتوبوس بین 2 ایستگاه زمانی دارد. هرچه تعداد این ایستگاه‌ها در مسیر بیشتر باشد درک بهتری از تعداد تقاضای مسافر در مسیر به دست می‌آید که نتیجه‌ی آن دقت بیش تر مدل در پیش بینی زمان سفر خواهد بود.

در ادامه به ترتیب در اشکال 4 تا 6 به بررسی یکی مقاطع مسیر غرب به شرق و تحلیل نمودارهای زمان سفر پیش بینی شده توسط هریک از مدل‌ها و زمان سفر مشاهده شده پرداخته می‌شود.

مطابق با نتایج، مدل وضعیت جریان ترافیک (ترکیب دوم) پیشرفت محدودی را نسبت به مدل داده‌های تاریخی از خود نشان می‌دهند. این بدان معناست که وضعیت ترافیک در روزهای مختلف هفته در مقطع مذکور نزدیک به هم بوده لذا وضعیت جریان به خوبی توسط مدل تاریخی قابل پیش بینی می‌باشد. اما نکته اینجاست که مدل تاریخی توانایی پیش بینی زمان سفرها را هنگامی که تداخل ترافیکی پیش بینی نشده‌ای رخ می‌دهد را دارا نمی‌باشد.


نمونه این اتفاق در شکل 5 نمایش داده شده است هم چنین این مدل در پیش بینی زمان سفرهای طولانی در ساعات اوج ضعیف عمل می‌کند. مدل پیشنهادی علاوه بر دارا بودن برتری‌های مدل وضعیت جریان ترافیک دارای قابلیت بیشتری در پیش بینی زمان سفر حتی در ساعات غیر اوج است. با توجه به اینکه در ساعات غیر اوج زمان توقف اتوبوس در ایستگاه درصد بیشتری از کل زمان سفر را نسبت به ساعات اوج به خود اختصاص می‌دهد، مدل پیشنهادی با در نظر گرفتن این پارامتر دقت پیش بینی بیشتری در ساعات غیر اوج از خود نشان می‌دهد.

جدول 7. عملکرد مدل‌های توسعه یافته - خطای جذر میانگین مربعات بر حسب ثانیه و (درصد خطای مطلق) - غرب به شرق

ردیف	مقطع	مدل بر اساس وضعیت جریان ترافیک و تقاضای مسافر (پیشنهادی)	مدل بر اساس وضعیت جریان ترافیک (ترکیب دوم)	مدل بر اساس داده‌های تاریخی (ترکیب سوم)
1	16 آذر - بیمارستان ساسان	38.7 (% 13.7)	40.83 (% 14.5)	46.03 (% 15.4)
2	کارگر - بیمارستان ساسان	53.9 (% 12.8)	57.7 (% 13.6)	63.4 (% 14.6)
3	بیمارستان امام - بیمارستان ساسان	70.1 (% 9.2)	75.8 (% 9.7)	84.8 (% 10.9)
4	بیمارستان امام - میدان ولیعصر	73.3 (% 7.1)	81.6 (% 7.9)	93.6 (% 9.1)

جدول 8. عملکرد مدل‌های توسعه یافته - خطای جذر میانگین مربعات بر حسب ثانیه و (درصد خطای مطلق) - شرق به غرب


ردیف	مقطع	مدل بر اساس وضعیت جریان ترافیک و تقاضای مسافر (پیشنهادی)	مدل بر اساس وضعیت جریان ترافیک (ترکیب دوم)	مدل بر اساس داده‌های تاریخی (ترکیب سوم)
1	حجاب - کارگر	51.2 (% 15.9)	53.6 (% 16.9)	57.7 (% 17.7)
2	16 آذر - پست (جمالزاده)	53.1 (% 13.8)	55.9 (% 15.4)	58.1 (% 16.1)
3	حجاب - دژبان	70.3 (% 10.9)	76.9 (% 12.2)	80.1 (% 12.8)
4	میدان ولیعصر - پست (جمالزاده)	95.3 (% 9.4)	103.5 (% 10.7)	116.6 (% 11.6)




شکل 4. زمان سفر مشاهده شده و پیش بینی شده توسط مدل داده‌های تاریخی - مقطع 2 - غرب به شرق

پیشرفت برای مقاطع 3 و 4 مسیر غرب به شرق که به ترتیب دارای 3 و 4 ایستگاه میانی هستند ، 5.7 و 8.3 ثانیه می‌باشد. این مقادیر به ترتیب شامل 5.1٪ ، 6.6٪ ، 7.5٪ و 10.2٪ از کل مقدار جذر میانگین مربعات خطا را نشان می‌دهند.

میزان برتری مدل پیشنهادی نسبت به مدل وضعیت جریان ترافیک به شکل قابل توجهی به تعداد ایستگاه‌های بین 2 ایستگاه زمانی وابسته می‌باشد. به طوری که در مقاطع 1 و 2 مسیر غرب به شرق که به ترتیب 1 و 2 ایستگاه میانی دارند مقدار پیشرفت در مقدار جذر میانگین مربعات خطا به ترتیب 2.1 و 3.8 ثانیه می‌باشد ، این درحالی است که مقدار این



شکل 5. زمان سفر مشاهده شده و پیش بینی شده توسط مدل وضعیت جریان - مقطع 2- غرب به شرق



شکل 6. زمان سفر مشاهده شده و پیش بینی شده توسط مدل وضعیت جریان و تقاضای مسافر - مقطع 2- غرب به شرق

نکته قابل ذکر دیگر آنکه پارامترهای درجه اشباع، حجم و تقاضای مسافر صرفاً می‌توانند بخشی از تغییرات زمان سفر را مدل نمایند. به طور مثال در نمودار 6 زمان سفر مشاهده شده در بازه زمانی 14:00 – 15:00 بین 200 ثانیه تا 450 ثانیه متغیر است. اما زمان سفر پیش‌بینی شده توسط مدل پیشنهادی بین 250 تا 380 ثانیه می‌باشد. این اختلاف ناشی از عدم در نظر گرفتن سایر پارامترهای توضیح دهنده زمان سفر اتوبوس نظیر تغییرات در زمان بندی تقاطعات چراغ دار در مسیر می‌باشد.

از میان مقاطع مورد بررسی در مسیر غرب به شرق، مقطع شماره 4 (بیمارستان امام- ولیعصر) بهترین نتایج را در پیش بینی زمان سفر از خود نشان داد. این مقطع با دارا بودن 4 ایستگاه میانی و 5 تقاطع چراغ دار از کامل‌ترین داده‌های ورودی جهت پیش‌بینی زمان سفر توسط مدل پیشنهادی برخوردار بود. مشابه مسیر غرب به شرق، در مسیر شرق به غرب نیز خروجی‌های مدل پیشنهادی از 2 مدل مورد مقایسه نتایج دقیق‌تری را ارائه می‌کرد. در این مسیر مقطع میدان ولیعصر - جمال زاده به علت دارا بودن 4 ایستگاه میانی و 5 تقاطع چراغ دار از کامل‌ترین داده‌های ورودی جهت پیش‌بینی زمان سفر توسط مدل پیشنهادی برخوردار بود.

5- نتیجه گیری

در این مقاله یک مدل شبکه عصبی برای پیش بینی زمان سفر تحت تاثیر مولفه‌هایی که موثر بودن آنها را توسط مدل رگرسیون خطی سنجیده شده بود، توسعه یافت. براساس نتایج مدل رگرسیون خطی، پس از هر 15 دقیقه داده‌های مربوط به درجه اشباع تقاطعات بین 2 ایستگاه، حجم عبوری از آن تقاطعات و داده‌های حاصل از تجمیع تراکنش‌های بلیط الکترونیکی جمع‌آوری شده و به عنوان پارامترهای ورودی مدل در نظر گرفته می‌شود. نتایج مقایسه مدل توسعه یافته در این مطالعه با نتایج حاصل از 2 مدل دیگر به شرح زیر مقایسه گردید. مدل داده‌های تاریخی و مدل پیشنهادی: مدل پیشنهادی این تحقیق نتایج به مراتب بهتری را در مقایسه با مدل داده‌های تاریخی وابسته به زمان ارائه می‌نماید. مدل پیشنهادی علاوه بر پیش بینی‌های دقیق تر در تمامی ساعات روز، توانایی بیشتری در پیش بینی زمان‌های سفر در ساعات اوج دارد. ذکر این نکته

ضروری است که مدل براساس داده‌های تاریخی توانایی پیش بینی زمان سفر هنگام رخ داد یک تغییر ناگهانی در وضعیت جریان ترافیک را دارا نمی‌باشد که این نواسانات در مدل پیشنهادی کاملاً قابل پیش بینی می‌باشد. مدل وضعیت جریان و مدل پیشنهادی: در مدل وضعیت جریان ترافیک با در نظر گرفتن پارامتر درجه اشباع، مشکل مدل داده‌های تاریخی در پیش بینی تاثیر رخ داده‌های ناگهانی در زمان سفر مرتفع می‌گردد. اما این مدل‌ها در پیش بینی زمان سفر در ساعات غیر اوج عملکرد ضعیف‌تری را نسبت به مدل پیشنهادی این تحقیق از خود نشان می‌دهند. مدل پیشنهادی این مطالعه علاوه بر پیش بینی صحیح زمان سفر در شرایط متغیر ترافیک، در ساعات غیر اوج نیز برآوردهای دقیق‌تری از زمان سفر را نسبت به هر 2 مدل مقایسه‌ای ارائه می‌نماید. دلایل برتری مدل پیشنهادی را می‌توان در موارد زیر عنوان کرد:

- دخالت دادن پارامترهای درجه اشباع تقاطع و حجم عبوری از تقاطع امکان پیش بینی‌های دقیق در شرایط متغیر وضعیت جریان ترافیک را برای مدل فراهم نمود. به علت آنکه مقادیر درجه اشباع و حجم در انتهای هر سیکل جمع‌آوری می‌شوند تغییر در هر لحظه از زمان تاثیر خود را بروی مقدار درجه اشباع و حجم عبوری آن سیکل نشان می‌دهد.

- در نظر گرفتن تعداد تراکنش‌های بلیط الکترونیکی در ایستگاه‌های میانی برآورد نسبتاً دقیقی را از میزان تقاضای مسافر در مسیر و به تبع آن زمان توقف اتوبوس‌ها در ایستگاه‌ها ارائه می‌نماید. در اختیار داشتن برآوردی از زمان توقف در ایستگاه‌ها به خصوص در ساعات غیر اوج به پیش بینی زمان سفر کمک شایان توجهی می‌نماید.

- نهایتاً مد نظر قرار دادن همزمان درجه اشباع و حجم با داده‌های تراکنش بلیط الکترونیکی برآورد دقیق‌تری را هم در ساعات اوج و هم در ساعات غیر اوج ارائه می‌نماید.

6- پی‌نوشت‌ها

- 1- Global Positioning System
- 2- Time Point
- 3- Artificial Neural Network
- 4- Multiple Linear Regression
- 5- SCATS(Sydney Coordinated Adaptive Traffic System)
- 6- Automatic Fare Collection
- 7- Jinan City
- 8- Hierarchical Artificial Neural Network

- Lin, H.-E. and Zito., R. (2005), "A review of travel time prediction in transport and logistics", In Proceeding of the Asia Society for Transportation Studies, Vol. 5, pp. 1433-1448.
- Liu, H. (2008), "Travel time prediction for urban networks." Ph.D. thesis, Delft Univ. of Technology, Delft, Netherlands.
- Mazloumi, E., Rose, G., Currie, G., and Moridpour, S. (2011), "Prediction intervals to account for uncertainties in neural network predictions: Methodology and application in bus travel time prediction." Eng. Appl. Artif. Intell., 24(3), pp.534–542.
- Ramakrishna Y, Ramakrishna P, Sivanandan R (2006), "Bus Travel Time Prediction Using GPS Data", proceedings, Map india 2006.
- Shalaby, A., and A. Farhan.(2004), "Bus Travel Time Prediction for Dynamic Operations Control and Passenger Information Systems". CD-ROM. 82nd Annual Meeting of the Transportation Research Board, National Research Council, Washington D.C.
- T. Thomas, W.A.M. Weijermars and E.C. Van Berkum (2010), "Predictions of Urban Volumes in Single Time Series, IEEE Transactions on intelligent transportation systems, vol. 11, no1, pp. 71-80.
- Tu, H. (2008), "Monitoring Travel Time Reliability on Freeways". Transportation and Planning. Delft, Delft University of Technology.
- J.W.C. van Lint, S.P. Hoogendoorn and H.J. van Zuylen (2003), "Accurate freeway travel time prediction with state-space neural networks under missing data", Delft University of Technology, The Netherlands.
- Lei Wang , Zhongyi Zuo , Junhao Fu (2014), "Bus Arrival Time Prediction Using RBF Neural Networks Adjusted by Online Data" The 9th International Conference on Traffic and Transportation Studies (ICTTS 2014), 14 July 2014, Volume 138, pp. 67–75.
- Williams, B. and Hoel, L. (2003), Modeling and forecasting vehicle traffic flow as a seasonal arima process: Theoretical basis and empirical results. Journal of Transportation Engineering, 129(6): pp.664–672.

- 9- Robustness
- 10- Radial Bases Neural Network
- 11- Dalian City
- 12- Time Of Day (TOD)
- 13- Day Of Week(DOW)
- 14- Degree Of Saturation
- 15- General Linear Model
- 16- Multilayer Perception
- 17- Activation Function
- 18- Sigmoid Function
- 19- Back-Propagation
- 20- Root Mean Square Error
- 21- Bayesian Train Function
- 22- Levenberg-Marquardt
- 23- Train Data
- 24- Test Data
- 25- Validation Data
- 26- Electronic Ticket
- 27- Root Mean Square Error
- 28- Mean Absolute Percentage Error

7- مراجع

- Chien, S.I.J., Ding, Y. and Wei, C. (2002). "Dynamic Bus Arrival Time Prediction with Artificial Neural Networks." Journal of Transportation Engineering, Volume 128, Number 5, pp. 429-438.
- ZK Gurmu and wei Fan (2014), "Dynamic Travel Time Prediction Models for Buses Using Only GPS Data" .Transportation Research Broad Annual meeting 2014, 14-0378.
- Hagan, M. T., Demuth, H. B., and Beale, M. (1996). "Neural network design", PWS, Boston.
- Hoogendoorn, S. & Van Lints, H (2008), Reistijdvoorspellingen en reistijdbetrouwbaarheid . NM Magazine, 2008, 3.
- Jeong R.H.(2004), "The Prediction of Bus Arrival time Using Automatic Vehicle Location Systems Data", A Ph.D. Dissertation at Texas A&M University.
- (Li 2006) Li, R. (2006), "Enhancing motorway travel time prediction models through explicit incorporation of travel time variability." Ph.D. thesis, Monash Univ., Melbourne, Australia.
- Lin, Y., Yang, X., Zou, N., and Jia, L. (2013), "Real-Time Bus Arrival Time Prediction: Case Study for Jinan, China." J. Transp. Eng., 139(11), pp.1133–1140.