

پیش‌بینی زمان ورود اتوبوس به ایستگاه با استفاده از سیستم استنتاج فازی-

عصبی تطبیقی

علیرضا گنج خانلو، دانشجوی دکتری، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران
مجتبی رجیبی بهاء‌آبادی (مسئول مکاتبات)، استادیار، دانشکده مهندسی عمران، دانشگاه یزد، یزد، ایران

E-mail: mojtaba.rajabi@yazd.ac.ir

پذیرش: ۱۴۰۲/۰۳/۲۰

دریافت: ۱۴۰۱/۱۱/۲۴

چکیده

پیش‌بینی دقیق زمان ورود اتوبوس به ایستگاه و اطلاع‌رسانی آن به مسافران در بهبود کیفیت خدمات حمل‌ونقل همگانی موثر است. افزایش کیفیت خدمات در یک سیستم اتوبوس‌رانی موجب افزایش مطلوبیت این شیوه سفر و به تبع آن ترغیب مسافران به استفاده از این شیوه حمل و نقلی می‌شود. در این راستا در این پژوهش، مدلی مبتنی بر «سیستم استنتاج عصبی-فازی انطباقی» برای پیش‌بینی زمان رسیدن اتوبوس به ایستگاه ارائه می‌شود. برای پرداخت و اعتبارسنجی مدل پیشنهادی از داده‌های تاریخچه‌زمانی زمان سفر حاصل از سامانه موقعیت‌یاب اتوبوس‌های خط آزادی-ونک شرکت اتوبوس‌رانی تهران استفاده شده است. نتایج این مطالعه نشان می‌دهد که مدل مبتنی بر «سیستم استنتاج عصبی-فازی انطباقی» قادر است در بیش‌تر از ۸۶ درصد موارد با خطای حداکثر برابر با ۲۰ درصد، زمان ورود اتوبوس به ایستگاه را پیش‌بینی کند. در مطالعه حاضر، به منظور مقایسه نتایج، مدل پیش‌بینی دیگری مبتنی بر رگرسیون خطی ایجاد شد. نتایج، مقایسه دو مدل، بیانگر برتری اندک مدل مبتنی بر «سیستم استنتاج فازی-عصبی تطبیقی» نسبت به مدل رگرسیون خطی است.

واژه‌های کلیدی: زمان سفر، استنتاج فازی، شبکه عصبی، پیش‌بینی زمان رسیدن اتوبوس

۱. مقدمه

[Choudhary, 2019]. بنابراین، فراهم کردن اطلاعات دقیق از

زمان رسیدن اتوبوس به مسافران، اهمیت زیادی دارد [Xu and Ying, 2017].

زمان رسیدن اتوبوس به ایستگاه یک پدیده تصادفی^۱ است؛ زیرا، زمان سفر کمان‌ها در شبکه، «زمان توقف»^۲ در ایستگاه‌ها و تأخیر در تقاطعات به صورت زمانی^۳ و مکانی^۴ در حال تغییر هستند. به‌بیانی دیگر، عوامل غیرقابل پیش‌بینی زیادی همچون شرایط ترافیکی و شرایط آب‌وهوایی می‌توانند زمان سفر اتوبوس‌ها را تحت تأثیر قرار دهند [Xu and Ying, 2017]. از این رو، ایجاد یک مدل پیش‌بینی زمان رسیدن به ایستگاه که قادر به پیش‌بینی زمان ورود اتوبوس به ایستگاه با دقت قابل قبول باشد از اهمیت بسزایی برخوردار است.

امروزه، با توجه به پیشرفت فناوری در حوزه سیستم‌های ارتباطی، روش‌های نوینی برای یکپارچه‌سازی اطلاعات به‌لحظه^۵ به منظور استفاده در «سیستم‌های اطلاع‌رسانی به مسافران»^۶ به وجود آمده است [Balasubramanian and Rao, 2015]. یکی از این فناوری‌ها، «سامانه موقعیت‌یاب جهانی»^۷ است. امروزه در اغلب شهرهای جهان، اتوبوس‌ها مجهز به سامانه موقعیت‌یاب هستند. سامانه‌های موقعیت‌یاب اتوبوس‌ها، اغلب از گیرنده‌های «سامانه موقعیت‌یاب جهانی» برای تعیین موقعیت اتوبوس‌ها استفاده می‌کند. بر اساس داده‌های موقعیت بدست‌آمده از «سامانه موقعیت‌یاب جهانی» می‌توان زمان سفر هر اتوبوس بین هر دو ایستگاه و زمان توقف اتوبوس در هر ایستگاه را تعیین نمود.

هدف از این مطالعه، ارائه مدلی برای پیش‌بینی زمان رسیدن اتوبوس به ایستگاه است. این مدل مبتنی بر «سیستم استنتاج فازی-عصبی تطبیقی»^۸ است. در پژوهش حاضر، برای پرداخت و اعتبارسنجی مدل ارائه‌شده از داده‌های سامانه موقعیت‌یاب نصب‌شده در اتوبوس‌ها استفاده شده است. برای ارزیابی میزان توانایی مدل ارائه‌شده، مدل دیگری مبتنی بر رگرسیون خطی

توسعه شهرنشینی و افزایش تقاضای سفر ناشی از آن، فشار زیادی را متوجه سیستم‌های حمل‌ونقل همگانی کرده است. در این راستا، پیچیده بودن شرایط ترافیکی، عدم قطعیت در مورد زمان رسیدن اتوبوس‌ها به ایستگاه‌ها را افزایش می‌دهد [Zhou et al., 2017]. عدم قطعیت در زمان رسیدن اتوبوس‌ها می‌تواند سهم قابل توجهی در مقدار زمان انتظار افراد برای استفاده از سیستم‌های حمل و نقل همگانی داشته باشد. از این رو، پیش‌بینی دقیق زمان رسیدن اتوبوس به ایستگاه می‌تواند مسافران را در برنامه‌ریزی‌هایشان برای انجام سفر کمک کند و علاوه بر صرفه جویی در زمان سفر [Ramkumar and Chaudhari, 2019] کاهش ترکم ترافیکی و کاهش مصرف سوخت را نیز به دنبال داشته باشد. همچنین، برای جذب کاربران وسایل نقلیه شخصی به استفاده از وسایل نقلیه همگانی، نیاز به بهبود کیفیت خدمت‌دهی سیستم‌های حمل‌ونقل همگانی است [Xu and Ying, 2017]. بدون شک یکی از شاخص‌های کیفیت خدمت‌دهی این نوع از شیوه‌های سفر، اطلاع‌رسانی دقیق به مسافران از زمان ورود اتوبوس‌ها به ایستگاه‌های مختلف است. امروزه سیستم‌های حمل‌ونقل همگانی، جدول زمانبندی حرکت ناوگان خود را به‌صورت به‌لحظه در وب‌سایت‌های اینترنتی مربوطه یا در تابلوهای نصب‌شده در محل ایستگاه‌های اتوبوس قرار می‌دهند. علاوه‌براین، با استفاده از اپلیکیشن‌های مختلف تلفن‌های هوشمند، امکان دریافت برنامه زمانی حرکت اتوبوس‌ها فراهم است. با این حال، اطلاعات ارائه‌شده همواره محدود بوده است و به‌موقع به‌روزرسانی نمی‌شوند [Xu and Ying, 2017]. فارغ از اینکه اتوبوس مطابق با برنامه زمان‌بندی شده حرکت می‌کند یا خیر، مسافران تمایل دارند تا از موقعیت اتوبوس در زمان‌های مختلف آگاهی یابند؛ زیرا، بر این اساس مسافران می‌توانند تصمیم بگیرند که آیا با اتوبوس سفر کنند یا شیوه دیگری را برای سفر خود برگزینند [Khamparia, and

همکاران [Sun et al., 2007] از داده‌های تاریخچه‌زمانی سرعت حاصل از سامانه موقعیت‌یاب اتوبوس‌ها برای پیش‌بینی زمان‌رسیدن اتوبوس‌ها استفاده کردند. ژو و همکاران [Zhu et al., 2011] مدل پویایی برای پیش‌بینی زمان‌رسیدن اتوبوس به ایستگاه با استفاده از حجم زیادی از داده‌های تاریخچه‌زمانی ارائه کردند. در این راستا، اطلاعات اتوبوس ماقبل از اتوبوس مورد نظر برای پیش‌بینی زمان‌رسیدن اتوبوس مورد نظر استفاده شد. در مطالعه دیگری، شو و یینگ [Xu and Ying, 2017] زمان‌رسیدن اتوبوس به ایستگاهی را پیش‌بینی کردند که آن ایستگاه لزوماً اولین (نزدیکترین) ایستگاهی نیست که اتوبوس به آن می‌رسد. برای این منظور از اطلاعات (۱) فاصله اتوبوس تا نزدیکترین ایستگاهی که می‌خواهد به آن برسد (۲) سرعت اتوبوس در لحظه‌ای که می‌خواهد پیش‌بینی انجام شود (۳) زمان سفر پیوندها در همان ساعت از همان روز در هفته قبل (با توجه به داده‌های تاریخچه‌زمانی) و (۴) زمان توقف در هر یک از ایستگاه‌ها (با توجه به داده‌های تاریخچه‌زمانی) استفاده می‌شود. مقایسه نتایج بدست آمده با نتایج حاصل از روش شبکه عصبی و روش «ماشین بردار پشتیبان»^{۱۳} دقت مناسب مدل ارائه‌شده را نشان داد.

(مدل‌های آماری) خود به سه دسته کلی (۱) مدل‌های رگرسیونی، (۲) مدل‌های مبتنی بر فیلتر کالمن^{۱۴} و (۳) مدل‌های مبتنی بر سری-های زمانی^{۱۵} تقسیم‌بندی می‌شوند. «مدل‌های رگرسیونی» از مجموعه‌ای از متغیرهای توصیفی (متغیرهای مستقل) برای پیش-بینی زمان رسیدن اتوبوس استفاده می‌کنند. به بیانی دیگر، در این مدل‌ها، مقدار متغیر وابسته بر اساس یک رابطه خطی تعیین می-شود [Treethidtapath et al., 2017]. مدل‌های رگرسیونی همانند مدل‌های مبتنی بر داده‌های تاریخچه‌زمانی از داده‌های تاریخچه‌زمانی استفاده می‌کنند. از این رو، در مواجهه با شرایط متغیر ممکن است دقت مقادیر پیش‌بینی شده پایین باشد. در مطالعات پیشین، پژوهشگرانی از مدل‌های رگرسیونی برای مقایسه با مدل‌های پیشنهادی خود استفاده کرده‌اند. به عنوان

ایجاد می‌شود و نتایج مدل ارائه‌شده با نتایج مدل مبتنی بر رگرسیون خطی مقایسه می‌شود.

در ادامه در این مقاله، ابتدا در بخش دوم، مروری بر مدل‌های پیشین در زمینه پیش‌بینی زمان‌رسیدن اتوبوس به ایستگاه ارائه می‌شود. جزئیات سیستم استنتاج فازی-عصبی تطبیقی و ساختار مدل در بخش سوم تشریح می‌شود. بخش چهارم به توصیف داده‌ها و محدوده مورد مطالعه اختصاص دارد. در بخش پنجم، نتایج پرداخت و اعتبارسنجی مدل پیشنهادشده ارائه می‌شود. در نهایت، در بخش ششم، به نتیجه‌گیری و پیشنهاد برای مطالعات آتی پرداخته می‌شود.

۲. ادبیات پژوهش

در پژوهش‌های پیشین، مدل‌های مختلفی به منظور پیش‌بینی زمان رسیدن اتوبوس به ایستگاه ارائه شده است. ترتیدتاپات و همکاران [Treethidtapath et al., 2017] این مدل‌ها را در سه گروه کلی دسته‌بندی کردند. این سه دسته عبارتند از: (۱) «مدل‌های مبتنی بر داده‌های تاریخچه‌زمانی»^۹، (۲) «مدل‌های آماری»^{۱۰} و (۳) «مدل‌های یادگیری ماشین»^{۱۱}. در ادامه، پژوهش‌های مرتبط با هر یک از سه دسته از مدل فوق تشریح می‌شود.

«مدل‌های مبتنی بر داده‌های تاریخچه‌زمانی» از داده‌های تاریخچه‌زمانی زمان سفر متوسط یا سرعت متوسط پیوندهای^{۱۲} شبکه برای پیش‌بینی زمان رسیدن اتوبوس استفاده می‌کنند [Ramkumar and Chaudhari, 2019]. بکارگیری این مدل‌ها آسان بوده و سرعت محاسباتی بالایی دارند. این مدل‌ها برای سطوح تراکم پایین و شرایط ترافیکی پایدار مناسب هستند. برای شرایط ازدحام ممکن است استفاده از این مدل‌ها مناسب نبوده و نیاز به مدل‌های دیگر باشد. [Treethidtapath et al., 2017]. همچنین، در این مدل‌ها برای ذخیره داده‌ها به زیرساخت‌هایی با حافظه بزرگتر نیاز است [Altinkaya and Zontu, 2013] در زمینه به کارگیری مدل‌های دسته اول، ویگان و همکاران [Weigang et al., 2002] و سان و

باقی خواهد ماند. این مدل‌ها به شدت به رابطه بین الگوی تاریخیچه‌زمانی و الگوی به‌لحظه ترافیک وابسته هستند [Li et al., 2017]. در این مدل‌ها، تغییر الگوهای داده‌های تاریخیچه-زمانی و یا عدم مشابهت داده‌های به‌لحظه با داده‌های تاریخیچه-زمانی می‌تواند منجر به ایجاد خطا در نتایج شود [Xu and Ying, 2017]. ساپانکویچ و سانکار [Sapankevych and Sankar, 2009] و ژو و همکاران [Zhu et al., 2011]. سوواردو و همکاران [Suwardo et al., 2010]، چن و همکاران [Chen et al., 2011]، کومار و ونجاکشی [Kumar and Vanajakshi, 2012] از سری‌های زمانی برای ارائه مدلی به منظور پیش‌بینی زمان رسیدن اتوبوس بهره گرفته‌اند.

«مدل‌های مبتنی بر یادگیری ماشین» برای شرایطی مناسب هستند که حجم داده‌ها قابل توجه باشد. ساختار این مدل‌ها پیچیده‌تر است و با روابط غیرخطی بین متغیرها در ارتباط هستند (تریثیدتاپات و همکاران، ۲۰۱۷). این مدل‌ها خود به سه گروه (۱: شبکه عصبی مصنوعی، ۲: ماشین بردار پشتیبان و ۳: روش‌های ترکیبی^{۱۷} تقسیم‌بندی می‌شوند، [Treethidataphat et al., 2017]. یک شبکه عصبی مصنوعی گروهی به‌هم پیوسته از گره‌هایی است که از شبکه عظیمی از نرون‌ها در یک مغز تقلید می‌کنند. این شبکه می‌تواند با استفاده از داده‌هایی که به عنوان نمونه به آن ارائه می‌شود اقدام به یادگیری کنند و قوانین و الگوهای پنهان در داده‌ها را فرا بگیرند. هرچه تعداد نمونه‌های آموزشی بیشتر باشد دقت این مدل نیز در ارائه نتایج افزایش خواهد یافت. آموزش یک شبکه عصبی معمولاً با استفاده از داده‌های تاریخیچه‌زمانی صورت می‌گیرد [Treethidataphat et al., 2017]. چین و همکاران [Chien et al., 2002]. کاتی و دایلی [Cathey and Dailey, 2003]، از مدل شبکه عصبی برای پیش‌بینی زمان رسیدن اتوبوس استفاده کرده‌اند. جونگ و ریلیت [Jeong and Rilett, 2004] مدلی مبتنی بر شبکه عصبی برای پیش‌بینی زمان رسیدن اتوبوس ارائه کردند.

نمونه، در مطالعه جونگ و ریلیت [Jeong and Rilett, 2004] و راماکریشنا و همکاران [Ramakrishna et al., 2006]، مدل‌های ارائه‌شده توانسته‌اند دقت بالاتری نسبت به مدل رگرسیونی در پیش‌بینی زمان رسیدن اتوبوس داشته باشند. آمیتا و همکاران [Amita et al., 2015] یک مدل رگرسیونی و یک مدل شبکه عصبی^{۱۶} (با همان ورودی‌های مدل رگرسیونی) برای پیش‌بینی زمان رسیدن اتوبوس به یک ایستگاه با توجه به زمان رسیدن به ایستگاه قبلی ارائه دادند. به طور کلی، هر دو مدل، سه نوع ورودی را دریافت می‌کنند که عبارتند از: (۱) زمان توقف در ایستگاه (۲) تأخیر و (۳) فاصله بین ایستگاه‌های اتوبوس. نتایج این مطالعه نشان می‌دهد که دقت روش مبتنی بر شبکه عصبی در مقایسه با روش رگرسیونی دقت بیشتری دارد.

«مدل‌های مبتنی بر فیلتر کالمن» با توجه به قابلیت‌هایی که در پالایش خطاها و استفاده از اطلاعات به‌لحظه دارند به طور پیوسته می‌توانند متغیر حالت را به‌روزرسانی کنند [Ramkumar and Chaudhari, 2019]. از این‌رو، در مطالعات مختلفی مانند مطالعه چین و کوچیپودی [Chien and Kuchipudi, 2003]، چن و همکاران [Chen et al., 2004]، یانگ [Yang, 2005]، ونجاکشی و همکاران [Vanajakshi et al., 2009]، پادمانابان و همکاران [Padmanaban et al., 2010]، سان و همکاران [Sun et al., 2011] و گورمو و فان [Gurmu and Fan, 2014] از فیلتر کالمن برای پیش‌بینی زمان سفر استفاده شده است. رامکومار و چادهاری [Ramkumar and Chaudhari, 2019] یک مدل رگرسیونی و یک مدل مبتنی بر فیلتر کالمن برای پیش‌بینی زمان رسیدن اتوبوس به اولین (نزدیکترین) ایستگاهی که به آن خواهد رسید ارائه دادند. مقایسه زمان سفرهای پیش‌بینی‌شده توسط هر دو مدل با مقادیر واقعی، برتری مدل فیلتر کالمن نسبت به مدل رگرسیونی را نشان داد.

«مدل‌های مبتنی بر سری‌های زمانی» بر این فرض استوار هستند که الگوی تاریخیچه‌زمانی ترافیک در آینده نیز به همان شکل خود

پیش‌بینی زمان ورود اتوبوس به ایستگاه با استفاده از سیستم استنتاج فازی-عصبی تطبیقی

[2018] با ارائه مدل‌های مبتنی بر ماشین بردار پشتیبان و همچنین روش شبکه عصبی، زمان رسیدن اتوبوس به یک ایستگاه را در حالتی که اتوبوس در حال رسیدن به ایستگاه قبلی باشد، پیش-بینی می‌کنند. همچنین، بین و همکاران [Yin et al., 2017] با ارائه یک مدل مبتنی بر ماشین بردار پشتیبان، زمان رسیدن اتوبوس از یک ایستگاه به ایستگاهی دیگر را در صورت وجود چند ایستگاه میانی بین دو ایستگاه مورد بررسی پیش‌بینی می‌کنند.

در «مدل‌های ترکیبی»، پیش‌بینی زمان رسیدن اتوبوس به ایستگاه با ترکیب دو یا چند مورد از روش‌های پیشگفته انجام می‌شود. در این راستا، چن و همکاران [Chen et al., 2004] با یکپارچه‌سازی الگوریتم‌های شبکه عصبی مصنوعی و فیلتر کالمن و با استفاده از داده‌های مکانی اتوبوس، مدلی پویایی برای پیش‌بینی زمان رسیدن اتوبوس به ایستگاه پیشنهاد دادند. یو و همکاران [Yu et al., 2010] یک مدل ترکیبی ارائه کردند. نتایج مطالعه آنها نشان داد که مدل ترکیبی عملکرد بهتری نسبت به مدل شبکه عصبی معمولی در پیش‌بینی زمان‌های سفر واقعی دارد. زکی و همکاران [Zaki et al., 2013] مدل ترکیبی (ترکیب شبکه عصبی و فیلتر کالمن) برای پیش‌بینی زمان رسیدن اتوبوس پیشنهاد دادند. مزیت مدل آنها این بود که در کنار شبکه عصبی از فیلتر کالمن استفاده می‌کرد که از این طریق می‌توانست خود را با داده‌های به‌لحظه ورودی انطباق داده و زمان رسیدن اتوبوس را پیش‌بینی کند. لین و همکاران [Lin et al., 2013] و ختارپائول و همکاران [Khetarpaul et al., 2015] مدل‌های ترکیبی برای پیش‌بینی زمان رسیدن اتوبوس ارائه کردند. در هر دو مطالعه از ترکیب دو روش شبکه عصبی و روش خوشه-بندی استفاده شده است تا بتوان تغییرات شرایط ترافیکی را اعمال نمود.

بسیاری از پژوهش‌های پیشین در زمینه پیش‌بینی زمان ورود اتوبوس به ایستگاه مبتنی بر تکنیک‌های هوش مصنوعی هستند که به صورت یک جعبه سیاه^{۱۸} عمل می‌کنند. به بیانی دیگر،

آنها چهار متغیر در مدل خود به‌کار بردند که عبارتند از: زمان رسیدن اتوبوس به ایستگاه، زمان توقف در ایستگاه، فاصله و برنامه‌زمانی حرکت اتوبوس‌ها. خامپاریا و [Khamparia, and Choudhary, 2019] مدلی مبتنی بر شبکه عصبی برای پیش‌بینی زمان رسیدن اتوبوس به ایستگاه ارائه دادند. ورودی‌های مدل مذکور عبارتند از: طول و عرض جغرافیایی موقعیت اتوبوس و ایستگاه‌ها، زمان ثبت هر داده، سرعت اتوبوس، زمان ورود و خروج اتوبوس در هر ایستگاه. پان و همکاران [Pan et al., 2012] مدلی بر مبنای شبکه عصبی برای پیش‌بینی زمان رسیدن اتوبوس به ایستگاه ارائه دادند. مدل آنها متغیرهای موقعیت اتوبوس، موقعیت ایستگاه‌ها، فاصله و سرعت اتوبوس در لحظه پیش‌بینی را به عنوان ورودی دریافت می‌کند. کومار و همکاران [Kumar et al., 2014] در راستای پیش‌بینی زمان رسیدن اتوبوس، عملکرد مدل مبتنی بر فیلتر کالمن و مدل مبتنی بر شبکه عصبی را مورد مقایسه قرار دادند. نتایج این مطالعه نشان داد که برای داده‌های با حجم زیاد، مدل مبتنی بر شبکه عصبی دقت بالاتری در مقایسه با مدل مبتنی بر فیلتر کالمن دارد.

در زمینه پیش‌بینی زمان رسیدن اتوبوس با استفاده از «مدل‌های ماشین بردار پشتیبان» نیز چندین مطالعه انجام شده است. برای مثال، بین و همکاران [Bin et al., 2006] با ساخت یک مدل ماشین بردار پشتیبان سعی کردند تا امکان‌پذیری و قابلیت کاربرد مدل‌های مبتنی بر ماشین بردار پشتیبان را در پیش‌بینی زمان رسیدن اتوبوس ارزیابی کنند. ژنگ و همکاران [Zheng et al., 2012] با استفاده از روش ماشین بردار پشتیبان مدلی را برای پیش‌بینی زمان رسیدن اتوبوس پیشنهاد دادند. این مدل به نحوی توسعه یافته بود که بتواند در یک لحظه، زمان رسیدن اتوبوس مورد نظر به چندین ایستگاه مختلف را پیش‌بینی نماید. نتایج مطالعه پیشگفته، قابلیت مناسب مدل پیشنهادشده در پیش-بینی یک‌مرحله‌ای زمان رسیدن اتوبوس به چند ایستگاه مختلف را نشان داد. در مطالعه‌ای دیگر، هوا و همکاران [Hua et al.,

روابط و نحوه عملکرد مدل در این حالت کاملاً مشخص نیست. «سیستم استنتاج فازی-عصبی تطبیقی» یک سیستم استنتاج فازی است که قواعد آن کاملاً مشخص هستند. به بیانی دیگر، برخلاف برخی از تکنیک‌های هوش مصنوعی، عملکرد یک مدل پیش‌بینی مبتنی بر «سیستم استنتاج فازی-عصبی تطبیقی» به صورت یک جعبه سیاه نبوده و قواعد آن کاملاً مشخص است [Saxena and Kumar]. بنابراین، با عنایت به اینکه توانایی «سیستم استنتاج فازی-عصبی تطبیقی» جهت پیش‌بینی زمان ورود اتوبوس به ایستگاه تاکنون مورد بررسی قرار نگرفته است، لذا، در پژوهش حاضر تلاش می‌شود مدلی جهت پیش‌بینی زمان ورود اتوبوس به ایستگاه مبتنی بر «سیستم استنتاج فازی-عصبی تطبیقی» ارائه شود.

استنتاج فازی با دو ورودی x_1 و x_2 و خروجی y^* فرض شود که در آن قوانین استنتاج فازی شامل دو قانون اگر-آنگاه فازی تاکاگی-سوگنو هستند به طوریکه [Khademi et al., 2016] قاعده اول: اگر x_1 متعلق به مجموعه فازی A_1 باشد و x_2 متعلق به مجموعه فازی B_1 باشد آنگاه $y = f_1(x)$ قاعده دوم: اگر x_1 متعلق به مجموعه فازی A_2 باشد و x_2 متعلق به مجموعه فازی B_2 باشد آنگاه $y = f_2(x)$ در قواعد فوق، $f_1(x)$ و $f_2(x)$ می‌تواند به صورت ذیل تعریف شود (توابع خطی):

$$f_1(x) = m_{11}x_1 + m_{12}x_2 + m_{13} \quad (1)$$

$$f_2(x) = m_{21}x_1 + m_{22}x_2 + m_{23} \quad (2)$$

در روابط فوق، m_{ij} پارامترهای ثابتی هستند که طی آموزش سیستم استنتاج فازی-عصبی تطبیقی تنظیم می‌شوند.

شکل ۱، ساختار ANFIS را برای یک سیستم با دو ورودی و یک خروجی نشان می‌دهد. همانطور که در شکل ۱ مشاهده می‌شود، هر «سیستم استنتاج فازی-عصبی تطبیقی» مشتمل بر پنج لایه است. هر لایه، شامل تعدادی گره است. گره‌های این سیستم را می‌توان به دو گروه کلی تقسیم بندی کرد: (۱) گره‌های تطبیقی: دارای پارامترهای قابل تنظیم هستند و (۲) گره‌های ثابت: یک سری محاسبات ریاضی را انجام می‌دهند و داری پارامترهای قابل تنظیم نیستند. ورودی گره‌های هر لایه، خروجی گره‌های لایه قبل است. به طور کلی، عملکرد هر لایه و گره‌های آن به صورت زیر است (شکل ۲):

لایه اول-فازی‌سازی: گره‌های این لایه گره‌های تطبیقی هستند. اگر ورودی $x = (x_1, x_2)$ به لایه اول اعمال گردد آنگاه خروجی گره‌های لایه اول عبارت خواهند بود با:

$$\begin{aligned} O_{11} &= A_1(x_1), & O_{12} &= A_2(x_1), \\ O_{13} &= B_1(x_2), & O_{14} &= B_2(x_2). \end{aligned} \quad (3)$$

در روابط فوق، $A_1(x_1)$ ، $A_2(x_1)$ ، $B_1(x_2)$ و $B_2(x_2)$ درجه عضویت ورودی‌های x_1 و x_2 در مجموعه‌های فازی A_1 ، A_2 ، B_1 و B_2 هستند. پارامترهای قابل تنظیم در این لایه، پارامترهای توابع درجه عضویت فازی هستند. این پارامترها را پارامترهای

۳. روش شناسی پژوهش

در این بخش، ابتدا، سیستم استنتاج فازی-عصبی تطبیقی تشریح می‌شود. در ادامه، چارچوب و ساختار مدل ارائه شده برای پیش‌بینی زمان رسیدن اتوبوس به ایستگاه ارائه می‌شود.

۳-۱ سیستم استنتاج فازی-عصبی تطبیقی

«سیستم استنتاج فازی-عصبی تطبیقی» (ANFIS)، یک روش جهت تخمین توابع مبتنی بر شبکه‌های عصبی مصنوعی است [Karayiannis and Venetsanopoulos, 1993]. این سیستم توسط جانگ [Jang, 1993] ارائه شد. با توجه به اینکه سیستم استنتاج فازی-عصبی تطبیقی از قابلیت‌های منطق فازی و شبکه‌های عصبی به صورت توأم استفاده می‌نماید، این سیستم ابزاری توانمند جهت برآورد توابع است [Buragohain and Mahanta, 2008; Nguyen et al., 2003]. به عبارت دیگر، ANFIS یک سیستم استنتاج فازی است که پارامترهای قوانین آن، همانند شبکه‌های عصبی با استفاده از مشاهدات واقعی تنظیم می‌شود [Nguyen et al., 2003].

سیستم استنتاج فازی-عصبی تطبیقی، بر اساس قوانین اگر-آنگاه فازی عمل می‌کند. برای تشریح ساختار ANFIS، سیستم

۳-۲ ساختار مدل ارائه شده

همانطور که پیشتر در بخش مقدمه بیان شد، هدف از این مقاله، پیش‌بینی زمان ورود اتوبوس به یک ایستگاه، پس از مشخص شدن زمان رسیدن اتوبوس به ایستگاه قبلی آن ایستگاه است. بدین منظور فرض شود که DT_s^i بیانگر زمان ترک کردن اتوبوس i از ایستگاه s باشد. همچنین، $TT_{s,s+1}^i$ نشان‌دهنده زمان سفر اتوبوس i بین ایستگاه‌های s و $s+1$ باشد. زمان رسیدن اتوبوس i به ایستگاه $s+1$ را می‌توان به صورت زیر نوشت:

$$AT_{s+1}^i = DT_s^i + TT_{s,s+1}^i \quad (9)$$

از آنجایی که زمان اعزام اتوبوس i از ایستگاه s مشخص است، بنابراین، با پیش‌بینی زمان سفر اتوبوس i بین ایستگاه‌های s و $s+1$ می‌توان زمان رسیدن اتوبوس i به ایستگاه $s+1$ را پیش‌بینی کرد.

در این پژوهش، زمان سفر اتوبوس i بین ایستگاه‌های s و $s+1$ با استفاده از سیستم استنتاج فازی-عصبی تطبیقی پیش‌بینی می‌شود. متغیرهای ورودی سیستم استنتاج فازی-عصبی تطبیقی، به صورت زیر در نظر گرفته شده‌اند:

$$TT_{s,s+1}^i = f(\alpha, TT_{s,s+1}^{i-1}, MTT_{s,s+1}) \quad (10)$$

در رابطه فوق، منظور از $TT_{s,s+1}^{i-1}$ ، زمان سفر اتوبوس $i-1$ بین ایستگاه‌های s و $s+1$ است. همچنین، $MTT_{s,s+1}$ بیانگر زمان سفر متوسط بین ایستگاه‌های s و $s+1$ است که توسط اتوبوس‌های عبوری پیشین تجربه شده است. متغیر α نیز به صورت زیر تعریف شده است:

$$\alpha = TT_{s-1,s}^i / TT_{s-1,s}^{i-1} \quad (11)$$

که در آن، $TT_{s-1,s}^{i-1}$ و $TT_{s-1,s}^i$ ، به ترتیب، بیانگر زمان سفر اتوبوس‌های i و $i-1$ بین ایستگاه‌های $s-1$ و s هستند.

لازم به ذکر است متغیر $MTT_{s,s+1}$ بیانگر میانگین وزنی زمان سفر بین ایستگاه‌های s و $s+1$ است که توسط اتوبوس‌های پیشین (δ اتوبوس قبل از اتوبوس i) تجربه شده است. متغیر پیشگفته در پژوهش‌های پیشین مانند یو و همکاران [Yu et

مقدم^{۱۹} می‌نامند. برای مثال، برای تابع درجه عضویت زیر، a و c پارامترهای قابل تنظیم هستند که توسط ANFIS تنظیم می‌شود:

$$A(x) = \exp\left\{-\left(\frac{x-c}{a}\right)^2\right\} \quad (4)$$

لایه دوم-«و» فازی: هر گره در این لایه، یک گره ثابت است که با برچسب Π نمایش داده شده‌اند. خروجی گره‌های لایه دوم، به صورت رابطه شماره ۵ محاسبه می‌شود:

$$(O_{21}, O_{22}) = (A_1(x_1)B_1(x_2), A_2(x_1)B_2(x_2)) \quad (5)$$

لایه سوم-نرمالیزه سازی: هر گره در این لایه، یک گره ثابت است که با برچسب N نمایش داده شده‌اند. خروجی گره‌های لایه سوم، مقادیر نرمالیزه شده خروجی گره‌های لایه دوم است به طوریکه:

$$(O_{31}, O_{32}) = \left(\frac{O_{21}}{O_{21} + O_{22}}, \frac{O_{22}}{O_{21} + O_{22}}\right) \quad (6)$$

لایه چهارم-استنتاج فازی: هر گره در این لایه، یک گره تطبیقی است که با برچسب F نمایش داده شده‌اند. خروجی گره‌های لایه چهارم، به صورت رابطه شماره ۷ است:

$$\begin{aligned} O_{41} &= O_{31}(m_{11}x_1 + m_{12}x_2 + m_{13}) \\ O_{42} &= O_{32}(m_{21}x_1 + m_{22}x_2 + m_{23}) \end{aligned} \quad (7)$$

در رابطه شماره ۷، m_{23} ، m_{22} ، m_{21} ، m_{13} ، m_{12} ، m_{11} ، پارامترهای قابل تنظیمی هستند که پارامترهای تالی^{۲۰} نامیده می‌شوند.

لایه پنجم-فازی زدایی: گره این لایه، یک گره ثابت است که با برچسب Σ نمایش داده شده‌است. خروجی آن برابر است با:

$$y^* = O_{41} + O_{42} \quad (8)$$

برای تنظیم پارامترهای مدل ANFIS، اغلب از یک الگوریتم آموزش ترکیبی^{۲۰} استفاده می‌شود. در الگوریتم آموزش ترکیب پارامترهای مقدم با الگوریتم پس‌انتشار خطا^{۲۱} و پارامترهای تالی به روش مینیمم مربعات^{۲۲} تنظیم می‌گردند. برای مطالعه بیشتر درباره نحوه آموزش ANFIS، به پژوهش جانگ (۱۹۹۳) (Jang, 1993) مراجعه شود.

۴. تحلیل داده‌ها و محدوده مورد مطالعه

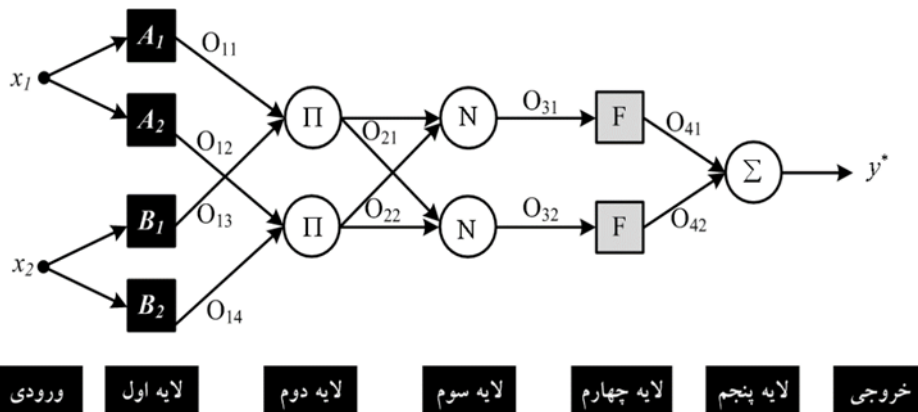
در این مطالعه برای آموزش مدل و اعتبارسنجی آن از داده‌های سامانه موقعیت‌یاب نصب‌شده بر روی اتوبوس‌های شهر تهران استفاده شد. از داده‌های خام موقعیت اتوبوس‌ها می‌توان زمان ورود هر اتوبوس به ایستگاه و زمان خروج اتوبوس از ایستگاه را تعیین نمود. داده‌های مورد استفاده در این پژوهش مربوط به خط ۳۶۹-رفت شرکت واحد اتوبوس‌رانی شهر تهران است که در یک بازه‌زمانی سه‌ماهه از تاریخ ۱۳۹۵/۸/۱ تا ۱۳۹۵/۱۰/۳۰ جمع‌آوری شده‌اند.

[al., 2011] نیز استفاده شده است و به صورت ذیل محاسبه می‌شود:


$$MTT_{s,s+1} = \sum_{k=1}^{\delta} \frac{1/(AT_s^i - AT_s^{i-k})}{\Gamma} TT_{s,s+1}^{i-k} \quad (12)$$

$$\Gamma = \sum_{k=1}^{\delta} \frac{1}{AT_{s+1}^{i-1} - AT_{s+1}^{i-k}} \quad (13)$$

لازم به ذکر است که در مطالعه حاضر، برای تعیین متغیرهای ورودی، عملکرد متغیرهای مختلفی مانند فاصله بین ایستگاه‌ها، روز هفته بررسی شد و در نهایت، متغیرهای فوق به عنوان متغیر ورودی در نظر گرفته شدند.



شکل ۱. ساختار ANFIS برای دو ورودی و یک خروجی



شکل ۲. چهارچوب نظری ANFIS برای دو ورودی و یک خروجی

مدل‌ها، متفاوت است. بنابراین، انتخاب مناسب این مشخصه‌ها و ویژگی‌ها به منظور افزایش توانایی این مدل‌ها، امری ضروری تلقی می‌شود. براساس پژوهش‌های پیشین، مشخصه‌هایی همچون تعداد قوانین، شکل توابع درجه عضویت متغیرهای ورودی، شکل توابع خروجی (ثابت یا خطی)، تعداد تکرار الگوریتم آموزش اهمیت قابل توجهی ممکن است بر کارایی مدل ANFIS داشته باشد. در راستای تعیین مقادیر مناسب برای مشخصه‌های پیشگفته، سطوح مختلفی برای هر یک از آن‌ها در نظر گرفته شد. جدول ۱ سطوح مورد بررسی برای هر مشخصه را نشان می‌دهد. با توجه به جدول ۱، تعداد ترکیب‌های ممکن برای مشخصه‌های مورد بررسی برابر با $2 \times 3 \times 2 \times 6 \times 6$ ترکیب است. در ادامه، مدل ANFIS به ازای هر ترکیب از مشخصه‌های مورد بررسی، آموزش داده شد. سپس، به ازای هر ترکیب، مقدار خطای پیش‌بینی برای «مجموعه داده‌های اعتبارسنجی» با استفاده از شاخص «جذر میانگین مربعات خطا» (RMSE) بر اساس رابطه ذیل محاسبه شد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i^m - y_i^o)^2}{n}} \quad (14)$$

در رابطه فوق، n ، نشان‌دهنده تعداد داده‌ها است. همچنین، y_i^m بیانگر مقدار پیش‌بینی شده توسط مدل برای i امین داده و y_i^o بیانگر مقدار مشاهده شده متناظر با i امین داده است.

جدول ۲، نتایج تحلیل واریانس را برای شاخص «جذر میانگین مربعات خطا» نشان می‌دهد. در جدول ۲، هرچه میزان F-Value برای یک مشخصه بیشتر باشد، آن مشخصه، تاثیر بیشتری بر دقت (کارایی) مدل ANFIS دارد. همانطور که در جدول ۲ مشاهده می‌شود، شکل توابع درجه عضویت متغیرهای ورودی و تعداد قوانین، بیشترین تاثیر را بر دقت مدل ANFIS دارند. شکل ۳ متوسط مقدار شاخص «جذر میانگین مربعات خطا» را برای سطوح مختلف هر مشخصه نشان می‌دهد. براساس شکل ۳ نیز نوع توابع درجه عضویت متغیرهای ورودی و تعداد قوانین، بیشترین تاثیر را بر دقت مدل (مقدار شاخص جذر

خط اتوبوس مذکور از میدان آزادی شروع شده و در میدان ونک پایان می‌یابد. طول این خط حدود ۱۳ کیلومتر است و دارای ۹ ایستگاه است. لازم به ذکر است خط مذکور از قطعات شریانی اصلی (بزرگراهی) و جمع‌کننده -پخش‌کننده تشکیل شده است و نوع راه در طول مسیر ثابت نیست. همچنین، داده‌های مورد استفاده در این مطالعه مربوط به یک بازه زمانی سه ماهه است. دلیل انتخاب یک بازه زمانی سه ماهه این است که تغییرات روز-به-روز زمان سفر ناشی از نوسانات در تقاضای سفر و عدم قطعیت‌های موثر بر ظرفیت راه (به دلیل وقوع حوادث ترافیکی، شرایط جوی متفاوت و غیره) در مجموعه داده‌های زمان سفر در نظر گرفته شود. شایان ذکر است که در پالایش اولیه داده‌ها، ابتدا داده‌های مربوط به روزهای غیرکاری از مجموعه داده‌ها حذف شد و سپس آموزش، پرداخت و اعتبارسنجی مدل با استفاده از داده‌های روزهای کاری صورت گرفت.

۵. نتایج

در ادبیات مدل‌های مبتنی بر «سیستم استنتاج عصبی-فازی انطباقی»، از پرداخت این مدل‌ها به عنوان آموزش این سیستم یاد می‌شود. در این پژوهش، برای پیاده‌سازی و آموزش مدل ANFIS، از جعبه ابزار منطق فازی نرم افزار Matlab.7 استفاده شده است. در این راستا، در وهله اول، ابتدا مجموعه کل داده‌ها به صورت تصادفی به دو زیر مجموعه «مجموعه داده‌های پرداخت»^{۲۴} و «مجموعه داده‌های اعتبارسنجی»^{۲۵} افراز می‌شود. شایان ذکر است که از «مجموعه داده‌های پرداخت» برای پرداخت مدل و از مجموعه دیگر، فقط برای اعتبارسنجی مدل استفاده شده است بر اساس پیشنهاد مطالعات پیشین، «مجموعه داده‌های پرداخت»، ۸۰ درصد کل داده‌ها و «مجموعه داده‌های اعتبارسنجی» ۲۰ درصد مجموعه کل داده‌ها را تشکیل می‌دهند [Iphar et al., 2008; Moayedi et al. 2020; Saif et al. 2021]

دقت و کارایی مدل‌های ANFIS در پیش‌بینی و تخمین توابع، بر حسب مشخصه‌ها و ویژگی‌های مولفه‌های تشکیل‌دهنده این

اعتبارسنجی» برابر با $72/8$ ثانیه است. شکل ۴، نتایج مقایسه داده‌های مشاهداتی اعتبارسنجی با نتایج حاصل از مدل را نشان می‌دهد. همانطور که در شکل ۴ نیز مشخص است، مدل ANFIS توانسته است با دقت قابل‌قبولی (در ۸۶ درصد موارد کمتر از ۲۰ درصد)، زمان‌سفر بین دو ایستگاه را پیش‌بینی نماید.


میانگین مربعات خطا) دارند. با توجه به نتایج جدول ۲ و شکل ۳، در مطالعه حاضر، مشخصه‌های مدل نهایی منطبق بر موارد مندرج در جدول ۳ در نظر گرفته می‌شوند. شاخص «جذر میانگین مربعات خطا» مدل نهایی برای «مجموعه داده‌های پرداخت» برابر با ۶۸ ثانیه برای «مجموعه داده‌های

جدول ۱. مشخصه‌های مدل ANFIS

نام مشخصه قابل تنظیم	سطوح مورد بررسی
تعداد قوانین	{۲، ۳، ۴، ۵، ۷ و ۱۰}
نوع تابع درجه عضویت متغیرهای ورودی	{مثلثی (trimf)، دوزنقه (trapmf)، اختلاف دو تابع سیگموئید (dsigmf)، ضرب دو تابع سیگموئید (psigmf)، پای‌سان (pimf) و زنگوله‌ای (gbellmf)}
نوع تابع خروجی	{خطی، ثابت}
تعداد تکرار الگوریتم آموزش	{۲۵، ۵۰}

جدول ۲. نتایج تحلیل واریانس

نام مشخصه	درجه آزادی	مجموع مربعات اصلاح شده (SS)	میانگین مربعات (MS)	F-Value	P-Value
تعداد قوانین	۵	۳۲۲۸۲	۶۴۵۶	۳۹/۸	۰/۰۰۰
نوع تابع درجه عضویت ورودی	۵	۲۴۶۴	۴۹۲	۳/۰۴	۰/۰۱
نوع تابع خروجی	۱	۷۸۳۴۱	۷۸۳۴۱	۴۸۳	۰/۰۰۰
تعداد تکرار الگوریتم آموزش	۲	۷۹۳	۳۹۶	۲/۴۴	۰/۰۹
خطا	۳۶۴	۵۹۰۳۳	۱۶۲		
مجموع	۳۷۷	۱۹۴۲۱۶			




شکل ۳. متوسط شاخص «جذر میانگین مربعات خطا» به ازای سطوح مختلف هر مشخصه

پیش‌بینی زمان ورود اتوبوس به ایستگاه با استفاده از سیستم استنتاج فازی-عصبی تطبیقی

جدول ۳. ساختار و مشخصه‌های مدل ANFIS

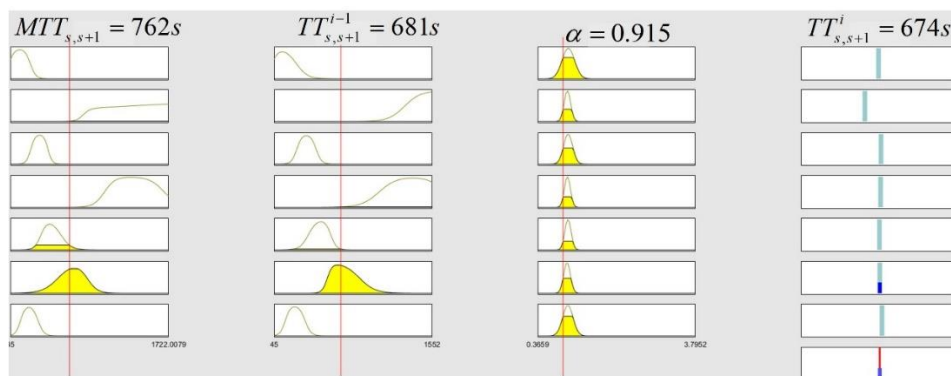
مقدار	الف) مشخصه ثابت
۵	تعداد لایه‌ها
۲	تعداد متغیر ورودی
۱	تعداد متغیر خروجی
مقدار یا نوع	ب) مشخصه قابل تنظیم
۷	تعداد قوانین
ضرب دو تابع سیگموئید	نوع تابع درجه عضویت متغیر ورودی
خطی	نوع تابع خروجی
۵۰	تعداد تکرار الگوریتم آموزش



شکل ۴. مقایسه داده‌های مشاهداتی و خروجی مدل

اتوبوس‌های پیشین بین ایستگاه‌های s و $s+1$ ($MTT_{s,s+1}$) برابر با ۷۶۲ باشد؛ آنگاه بر اساس مدل ارائه‌شده، اتوبوس i پس از ۶۷۴ ثانیه بعد از ترک ایستگاه s به ایستگاه $s+1$ می‌رسد.

شکل ۵، قوانین استنتاج فازی مدل ANFIS پرداخت‌شده را در نرم افزار Matlab نمایش می‌دهد. طبق این شکل، اگر مقدار متغیر α برابر با ۰/۹۱۵، زمان سفر اتوبوس $i-1$ بین ایستگاه‌های s و $s+1$ ($TT_{s,s+1}^{i-1}$) برابر با ۶۸۱ ثانیه و متوسط زمان سفر



شکل ۵. قوانین استنتاج فازی در مدل ارائه‌شده

«مجموعه داده‌های اعتبارسنجی» برابر با ۷۲/۸ ثانیه و برای مدل رگرسیون خطی برابر با ۷۵/۱ ثانیه است. از این رو، می‌توان نتیجه گرفت که مدل ANFIS، دقت بیشتری در پیش‌بینی زمان رسیدن اتوبوس به ایستگاه در مقایسه با مدل رگرسیونی دارد. لازم به ذکر است رابطه نسبتاً خطی بین متغیر وابسته و متغیرهای مستقل در داده‌های استفاده‌شده جهت آموزش و اعتبارسنجی مدل پیشنهادی وجود دارد. ماهیت خطی داده‌ها سبب شده است که دقت پیش‌بینی مدل مبتنی بر «سیستم استنتاج فازی-عصبی تطبیقی» نسبت به مدل خطی اندک باشد.

برای مقایسه مدل حاضر، با استفاده از داده‌های موجود، چندین مدل رگرسیون خطی مختلفی برآورد شد. در نهایت، از بین مدل‌های برآوردشده، بهترین مدل انتخاب شد. جدول ۴، متغیرهای مورداستفاده در مدل رگرسیونی، ضریب متناظر با هر متغیر و مقدار p -value آزمون تی (t -test) متناظر با هر متغیر را نشان می‌دهد. همانطور که در جدول مشاهده می‌شود، تمامی متغیرهای مدل براساس آزمون تی معنی‌دار هستند ($p < 0/05$ value). جهت مقایسه مدل ANFIS و مدل خطی از شاخص «جذر میانگین مربعات خطا» استفاده شده است. میزان شاخص «جذر میانگین مربعات خطا» متناظر با مدل ANFIS برای

جدول ۴. نتایج مدل رگرسیون خطی

متغیر مستقل	میزان ضریب برآوردشده	مقدار آماره تی	p -value آزمون تی
$MTT_{s,s+1}$	۰/۲۷	۱۴/۶	۰/۰۰۰
$TT_{s,s+1}^{i-1}$	۰/۶۸	۳۶/۲	۰/۰۰۰
α	۱۶/۳۵	۱۵/۹	۰/۰۰۰

عملکرد مدل ارائه شده، نتایج حاصل از مدل ارائه‌شده با نتایج بدست‌آمده از مدل رگرسیون خطی مقایسه شد. نتایج این مقایسه بیانگر بهبود اندک مدل مبتنی بر «سیستم استنتاج فازی-عصبی تطبیقی» نسبت به مدل رگرسیون خطی است.

برای پژوهش‌های آتی پیشنهاد می‌شود که متغیرهای بیشتری نسبت به مطالعه حاضر از قبیل تراکم ترافیک و زمان‌بندی چراغ-های راهنمایی در مدل‌سازی پیش‌بینی زمان رسیدن اتوبوس در نظر گرفته شود. علاوه بر این، به منظور افزایش دقت پیش‌بینی مدل، ترکیب مدل پیشنهادی در این پژوهش با سایر روش‌های موجود مانند فیلتر کالمن پیشنهاد می‌شود. همچنین، به‌کارگیری الگوریتم‌های فراابتکاری جهت آموزش سیستم استنتاج فازی-عصبی تطبیقی ممکن است بتواند منجر به افزایش دقت پیش‌بینی مدل شود. علاوه بر موارد پیشگفته، پیشنهاد می‌شود مدل ارائه‌شده در این پژوهش توسعه داده شود تا بتوان زمان ورود به تمامی ایستگاه‌های اتوبوس پایین دست یک ایستگاه اتوبوس را پیش‌بینی کرد. لازم به ذکر است یکی از محدودیت‌های این

۶. نتیجه‌گیری

پیش‌بینی زمان رسیدن اتوبوس به ایستگاه چه از منظر مسافران به عنوان استفاده‌کنندگان سیستم حمل‌ونقل همگانی و چه از منظر گردانندگان این سیستم، حائز اهمیت بسیار زیادی است. پیش‌بینی دقیق زمان رسیدن اتوبوس به ایستگاه می‌تواند افراد را در تصمیم‌گیری و برنامه‌ریزی‌شان برای انجام سفر کمک کرده و زمان انتظار مسافران در محل ایستگاه‌ها را کاهش دهد. بنابراین، پیش‌بینی دقیق‌تر زمان رسیدن اتوبوس به ایستگاه‌ها می‌تواند کیفیت خدمت‌دهی سیستم حمل‌ونقل همگانی را بهبود داده و رضایت استفاده‌کنندگان را تامین کند تا بدین وسیله با تشویق افراد به استفاده از سیستم‌های حمل‌ونقل همگانی به جای وسایل نقلیه شخصی، کاهش مصرف سوخت و کاهش آلودگی هوا را نیز به دنبال داشته باشد. بدین منظور در این پژوهش از سیستم استنتاج فازی-عصبی تطبیقی برای مدل‌سازی زمان رسیدن اتوبوس به ایستگاه استفاده شد. همچنین به منظور ارزیابی

-Amita, J., Singh, J. S., & Kumar, G. P. (2015). Prediction of bus travel time using artificial neural network. *International Journal for Traffic and Transport Engineering*, 5(4), 410-424.

-Balasubramanian, P., & Rao, K. R. (2015). An adaptive long-term bus arrival time prediction model with cyclic variations. *Journal of Public Transportation*, 18(1), 6.

-Bin, Y., Zhongzhen, Y., & Baozhen, Y. (2006). Bus arrival time prediction using support vector machines. *Journal of Intelligent Transportation Systems*, 10(4), 151-158.

-Buragohain, M., & Mahanta, C. (2008). A novel approach for ANFIS modelling based on full factorial design. *Applied Soft Computing*, 8(1), 609-625.

-Cathey, F., & Dailey, D. J. (2003). A prescription for transit arrival/departure prediction using automatic vehicle location data. *Transportation Research Part C: Emerging Technologies*, 11(3-4), 241-264.

-Chen, G., Yang, X., An, J., & Zhang, D. (2011). Bus-arrival-time prediction models: Link-based and section-based. *Journal of transportation engineering*, 138(1), 60-66.

-Chen, M., Liu, X., Xia, J., & Chien, S. I. (2004). A dynamic bus-arrival time prediction model based on APC data. *Computer-Aided Civil and Infrastructure Engineering*, 19(5), 364-376.

-Chien, S. I.-J., Ding, Y., & Wei, C. (2002). Dynamic bus arrival time prediction with artificial neural networks. *Journal of transportation engineering*, 128(5), 429-438.

-Chien, S. I.-J., & Kuchipudi, C. M. (2003). Dynamic travel time prediction with real-time and historic data. *Journal of transportation engineering*, 129(6), 608-616.

مطالعه، وجود رابطه نسبتاً خطی بین متغیر وابسته و متغیرهای مستقل در داده‌های استفاده‌شده جهت آموزش و اعتبارسنجی مدل پیشنهادی است. ماهیت خطی داده‌ها سبب شده است که دقت پیش‌بینی مدل مبتنی بر «سیستم استنتاج فازی-عصبی تطبیقی» نسبت به مدل خطی اندک باشد. بنابراین، پیشنهاد می‌شود، دقت مدل پیشنهادی برای چندین خط اتوبوس با شرایط ترافیکی مختلف بررسی شود.

۷. پی‌نوشت‌ها

1. Stochastic
2. Dwell time
3. Temporally
4. Spatially
5. Real-time
6. Passenger Information System (PIS)
7. Global Positioning System (GPS)
8. Adaptive neuro-fuzzy inference system (ANFIS)
9. Historical data based models
10. Statistical models
11. Machine learning models
12. Links
13. Support Vector Machine (SVM)
14. Kalman filter
15. Time series
16. Artificial Neural Network (ANN)
17. Hybrid models
18. Black-box
19. Premise parameters
20. Consequent parameters
21. Back Propagation Algorithm
22. Least Squares Method
23. Matlab Fuzzy Logic Toolbox
24. Training Data Set
25. Test Data Set

۸. مراجع

-Altinkaya, M., & Zontul, M. (2013). Urban bus arrival time prediction: A review of computational models. *International Journal of Recent Technology and Engineering (IJRTE)*, 2(4), 164-169.

- Khamparia, A., & Choudhary, R. (2019). Prediction of Bus Arrival Time Using Intelligent Computing Methods. In *Pervasive Computing: A Networking Perspective and Future Directions* (pp. 127-143): Springer.
- Khetarpaul, S., Gupta, S., Malhotra, S., & Subramanian, L. V. (2015). Bus arrival time prediction using a modified amalgamation of fuzzy clustering and neural network on spatio-temporal data. Paper presented at the Australasian Database Conference.
- Kumar, S. V., & Vanajakshi, L. (2012). Application of multiplicative decomposition and exponential smoothing techniques for bus arrival time prediction.
- Kumar, V., Kumar, B. A., Vanajakshi, L., & Subramanian, S. C. (2014). Comparison of model based and machine learning approaches for bus arrival time prediction. Paper presented at the Proceedings of the 93rd Annual Meeting.
- Li, J., Gao, J., Yang, Y., & Wei, H. (2017). Bus arrival time prediction based on mixed model. *China Communications*, 14(5), 38-47.
- Lin, Y., Yang, X., Zou, N., & Jia, L. (2013). Real-time bus arrival time prediction: Case study for Jinan, China. *Journal of transportation engineering*, 139(11), 1133-1140.
- Moayedi, H., Raftari, M., Sharifi, A. et al. (2020). Optimization of ANFIS with GA and PSO estimating α ratio in driven piles. *Engineering with Computers* 36, 227–238
- Nguyen, H. T., Prasad, N. R., Walker, C. L., & Walker, E. A. (2003). *A First Course in Fuzzy and Neural Control* (Ch. 7, pp.229-247): Chapman & Hall/CRC.
- Padmanaban, R., Divakar, K., Vanajakshi, L., & Subramanian, S. C. (2010). Development of a real-time bus arrival prediction system for
- Gurmu, Z. K., & Fan, W. D. (2014). Artificial neural network travel time prediction model for buses using only GPS data. *Journal of Public Transportation*, 17(2), 3.
- Hua, X., Wang, W., Wang, Y., & Ren, M. (2018). Bus arrival time prediction using mixed multi-route arrival time data at previous stop. *Transport*, 33(2), 543–554-543–554.
- Iphar, M., Yavuz, M. & Ak, H. (2008). Prediction of ground vibrations resulting from the blasting operations in an open-pit mine by adaptive neuro-fuzzy inference system. *Environ Geol* 56, 97–107.
- Jang, J. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on systems, man and cybernetics*, 23(3), 665-685.
- Jeong, R., & Rilett, L. (2004). The prediction of bus arrival time using AVL data. Paper presented at the 83rd Annual General Meeting, Transportation Research Board, National Research Council, Washington DC, USA.
- Jeong, R., & Rilett, R. (2004). Bus arrival time prediction using artificial neural network model. Paper presented at the Proceedings. The 7th International IEEE Conference on Intelligent Transportation Systems (IEEE Cat. No. 04TH8749).
- Karayiannis, N. B., & Venetsanopoulos, A. N. (1993). *Artificial neural networks: learning algorithms, performance evaluation and applications*: Kluwer Academic Publishers Group.
- Kademi, N., Rajabi, M., Mohaymani, S.A., and Samadzad, M. (2016). Day-to-day travel time perception modeling using an adaptive-network-based fuzzy inference system (ANFIS). *EURO Journal on Transportation and Logistics*. Vlo.5. No.1, pp.25-52

- Sun, D., Luo, H., Fu, L., Liu, W., Liao, X., & Zhao, M. (2007). Predicting bus arrival time on the basis of global positioning system data. *Transportation Research Record*, 2034(1), 62-72.
- Suwardo, W., Napiah, M., & Kamaruddin, I. (2010). ARIMA models for bus travel time prediction. *Journal of the institute of engineers Malaysia*, 49-58.
- Takagi, T., & Sugeno, M. (1985). Derivation of fuzzy control rules from human operator's control actions. Paper presented at the Proc. IFAC Symp. Fuzzy Inform., Knowledge Representation and Decision Analysis
- Treethidaphat, W., Pattara-Atikom, W., & Khaimook, S. (2017). Bus arrival time prediction at any distance of bus route using deep neural network model. Paper presented at the 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC).
- Vanajakshi, L., Subramanian, S. C., & Sivanandan, R. (2009). Travel time prediction under heterogeneous traffic conditions using global positioning system data from buses. *IET intelligent transport systems*, 3(1), 1-9.
- Weigang, L., Koendjibiharie, W., de M Juca, R., Yamashita, Y., & MacIver, A. (2002). Algorithms for estimating bus arrival times using GPS data. Paper presented at the Proceedings. The IEEE 5th International Conference on Intelligent Transportation Systems.
- Xu, H., & Ying, J. (2017). Bus arrival time prediction with real-time and historic data. *Cluster Computing*, 20(4), 3099-3106.
- Yang, J.-S. (2005). Travel time prediction using the GPS test vehicle and Kalman filtering techniques. Paper presented at the Proceedings Indian traffic conditions. *IET intelligent transport systems*, 4(3), 189-200.
- Pan, J., Dai, X., Xu, X., & Li, Y. (2012). A self-learning algorithm for predicting bus arrival time based on historical data model. Paper presented at the 2012 IEEE 2nd International Conference on Cloud Computing and Intelligence Systems.
- Ramakrishna, Y., Ramakrishna, P., Lakshmanan, V., & Sivanandan, R. (2006). Bus travel time prediction using GPS data. *Proceedings Map India*.
- Ramkumar, N., & Chaudhari, A. (2019). Urban Bus Arrival Time Prediction Using Linear Regression and Kalman Filter—A Comparison. In *Soft Computing and Signal Processing* (pp. 279-287): Springer.
- Saif, S., Das, P. & Biswas, S. (2021). A Hybrid Model based on mBA-ANFIS for COVID-19 Confirmed Cases Prediction and Forecast. *J. Inst. Eng. India Ser. B* 102, 1123–1136.
- Sapankevych, N. I., & Sankar, R. (2009). Time series prediction using support vector machines: a survey. *IEEE Computational Intelligence Magazine*, 4(2), 24-38.
- Saxena, N. K., & Kumar, A. (2016). Reactive power control in decentralized hybrid power system with STATCOM using GA, ANN and ANFIS methods. *International Journal of Electrical Power & Energy Systems*, 83, 175-187.
- Sun, C., Sun, M., & Cui, Q. (2011). Bus arrival time prediction based on error weighted of historical and real-time data. Paper presented at the International Conference on Information Technology and Computer Science, 3rd (ITCS 2011).

Joint IFIP Wireless and Mobile Networking Conference (WMNC 2011).

of the 2005, American Control Conference, 2005.

-Yin, T., Zhong, G., Zhang, J., He, S., & Ran, B. (2017). A prediction model of bus arrival time at stops with multi-routes. *Transportation research procedia*, 25, 4623-4636.

-Yu, B., Yang, Z. Z., Chen, K., & Yu, B. (2010). Hybrid model for prediction of bus arrival times at next station. *Journal of Advanced Transportation*, 44(3), 193-204.

Yu, Bin, William HK Lam, and Mei Lam Tam. Bus arrival time prediction at bus stop with multiple routes. *Transportation Research Part C: Emerging Technologies* 19.6 (2011): 1157-1170.

-Zaki, M., Ashour, I., Zorkany, M., & Hesham, B. (2013). Online bus arrival time prediction using hybrid neural network and Kalman filter techniques. *International Journal of Modern Engineering Research*, 3(4), 2035-2041.

-Zheng, C.-J., Zhang, Y.-H., & Feng, X.-J. (2012). Improved iterative prediction for multiple stop arrival time using a support vector machine. *Transport*, 27(2), 158-164.

-Zhou, X., Peng, C., Song, X., & Yang, X. (2011). Prediction model of dynamic bus arrival time based on the front bus data. *Traffic & Transportation*, 12, 52-56.

-Zhou, Y., Yao, L., Chen, Y., Gong, Y., & Lai, J. (2017). Bus arrival time calculation model based on smart card data. *Transportation Research Part C: Emerging Technologies*, 74, 81-96.

-Zhu, T., Ma, F., Ma, T., & Li, C. (2011). The prediction of bus arrival time using global positioning system data and dynamic traffic information. Paper presented at the 2011 4th

پیش‌بینی زمان ورود اتوبوس به ایستگاه با استفاده از سیستم استنتاج فازی-عصبی تطبیقی

علیرضا گنج‌خانلو، درجه کارشناسی در رشته مهندسی عمران را در سال ۱۳۹۴ از دانشگاه زنجان اخذ نمود. ایشان در سال ۱۳۹۷ موفق به کسب درجه کارشناسی ارشد در رشته مهندسی عمران گرایش مهندسی برنامه ریزی حمل و نقل از دانشگاه علم و صنعت ایران گردید. زمینه‌های پژوهشی مورد علاقه ایشان، برآورد زمان سفر، لجستیک، زنجیره تامین و شبیه‌سازی و اقمیت مجازی است. ایشان در حال حاضر دانشجوی دکتری مهندسی عمران در دانشگاه تهران است.



مجتبی رجیبی بهاء‌آبادی، درجه کارشناسی در رشته مهندسی عمران را از دانشگاه شهید باهنر کرمان در سال ۱۳۸۷، درجه کارشناسی ارشد و دکتری در رشته مهندسی عمران گرایش مهندسی برنامه ریزی حمل و نقل را به ترتیب در سال‌های ۱۳۹۰ و ۱۳۹۸ از دانشگاه علم و صنعت ایران اخذ نمودند. زمینه‌های پژوهشی مورد علاقه ایشان برنامه‌ریزی حمل و نقل و قابلیت اطمینان زمان سفر است. ایشان در حال حاضر عضو هیأت علمی دانشگاه یزد است.

