

تخمین زمان سفر وسایل نقلیه جمع‌آوری پسماند درمانی با استفاده از الگوریتم‌های شبکه عصبی مصنوعی مکانی زمانی (مطالعه موردی: شهر تهران)

کیوان باقری- دانشجوی دکتری سیستم‌های اطلاعات جغرافیایی و سنجش‌ازدور، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران
نجمه نیسانی سامانی - دانشیار گروه سیستم‌های اطلاعات جغرافیایی و سنجش‌ازدور، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران
محمد رضا جلوخانی نیارکی - دانشیار گروه سیستم‌های اطلاعات جغرافیایی و سنجش‌ازدور، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران
آرا تومانیان - دانشیار گروه سیستم‌های اطلاعات جغرافیایی و سنجش‌ازدور، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران
لیلا حاجی بابایی - استادیار گروه مهندسی صنایع، دانشگاه ایالات کارولینای شمالی، کارولینای شمالی، ایالات متحده آمریکا

تأیید مقاله: ۱۳۹۹/۰۹/۰۵

پذیرش مقاله: ۱۳۹۹/۰۴/۰۹

چکیده

رشد جمعیت و افزایش نیاز بشر به بهداشت و درمان، سبب افزایش تولید پسماندهای پزشکی شده است. در این میان جمع‌آوری و انتقال به مراکز دفن این پسماندها در کمترین زمان ممکن لازم است. یکی از ضروری‌ترین فاکتورهای مسیریابی وسایل نقلیه جمع‌آوری پسماند زمان سفر است. محاسبه زمان سفر به پارامترهای فراوانی بستگی دارد. رویکردی که همه پارامترهای تأثیرگذار در این امر را لحاظ و همچنین میزان تأثیر آن‌ها را تعیین می‌کند، می‌تواند به محاسبه دقیق زمان سفر و به تبع آن یافتن مسیر مناسب منجر شود. هدف اصلی این مقاله، تخمین دقیق زمان سفر با به کارگیری همه پارامترهای تأثیرگذار در بیمودن یک معبر برای وسایل نقلیه جمع‌آوری پسماند پزشکی است که با توجه به نیاز به یادگیری مکانی زمانی از الگوریتم‌های شبکه عصبی مصنوعی استفاده شده است که به نوعی نوآوری پژوهش نیز است. در واقع علاوه بر پارامترهای ایستا، به منظور به دست آوردن داده‌های پویا که یکی از محدودیت‌های اصلی این رویکرد است، از داده‌های لحظه‌ای دوربین‌های سازمان کنترل ترافیک و گوگل استفاده شده است. از داده‌های واقعی زمان سفر که وسایل نقلیه به منظور جمع‌آوری پسماند درمانی صرف کرده‌اند، به عنوان خروجی شبکه عصبی استفاده شده است. مدل پیشنهادی استفاده شده شبکه عصبی مکانی-زمانی (ST-ANN) نام دارد؛ زیرا لحظه حرکت وسیله نقلیه دو پارامتر زمان و مکان مشخص است. از پارامتر مکان ویژگی‌های ایستا و از پارامتر زمان ویژگی‌های پویای مربوط به آن گذر مشخص می‌شود. در این پژوهش، از بازه‌های زمانی 30 دقیقه‌ای استفاده شد. سپس این نتایج بر پایه زمان روز ترکیب تا زمان سفر پیش‌بینی شدند. در اجرای ST-ANN به منظور تعیین معماری مناسب 24 ترکیب متفاوت از اجزای آن اجرا شد و از تعداد 937 یال، 70، 15 و 15 درصد آن به ترتیب برای نمونه آموزشی، اعتبار سنجی و کالیبره کردن مدل استفاده و در نهایت با ضریب هم‌بستگی 91 درصد زمان سفر هر یال برآورد شد. از طرفی نتایج پژوهش با مدل‌های دیگر و با دو معیار ضریب هم‌بستگی (R^2) و خطای میانگین مربعات (MSE) بررسی و مشاهده شد R^2 به مقادیر 0.11، 0.08 و 0.02 و MSE به مقادیر 278، 190 و 26 بهبود یافته‌اند.

واژه‌های کلیدی: پسماند پزشکی، زمان سفر، شبکه عصبی مصنوعی مکانی زمانی، مسیریابی.

مقدمه

زمان سفر که از داده‌های ضروری برای بیشتر مسائل مسیریابی وسایل نقلیه (VRP)^۱ می‌باشد به منظور مدل‌سازی محدودیت‌های زمانی مانند پنجره زمان مشتری و همچنین اهداف زمانی، مانند به حداقل رساندن زمان سفر و زمان انتظار مورد نیاز است. بیشتر مدل‌های ارائه شده در این حوزه، زمان مسافت را برای همه سفرها ثابت در نظر می‌گیرند (Ma et al., 2019: 1-21). به عبارت دیگر معمولاً کوتاه‌ترین مسیرها در یک شبکه جاده‌ای بین انبار و مشتری‌ها با زمان سفر ثابت در هر یال، به دست می‌آید. این فرض ممکن است دور از واقعیت باشد؛ به‌ویژه برای مناطق شهری که زمان مسافت به‌طور معمول در طول روز به دلیل ازدحام در ساعات شلوغ متفاوت است. با ورود وسایل نقلیه بیشتر به مناطق شهری، ازدحام ترافیک در بسیاری از شهرها به موضوعی مهم تبدیل شده است. یکی از راه‌حل‌های اقتصادی برای کاهش آلودگی و فشار ترافیک، توسعه سیستم‌های حمل‌ونقل هوشمند (ITS)^۲ است. تخمین زمان سفر وسیله نقلیه یکی از مؤلفه‌های مهم ITS است. بدون اطلاع از زمان سفر وسایل نقلیه بین ایستگاه‌ها/مشتریان و پیش‌بینی دقیق آن، برنامه‌ریزی سیستم‌های حمل‌ونقل ناممکن یا منجر به برنامه‌های غیرواقعی خواهد شد (Ma et al., 2019: 1-21). با وجود این پدیده شناخته شده، تاکنون شناخت و میزان تأثیرگذاری پارامترهای مهم بر زمان سفر و پیش‌بینی آن در ادبیات VRP کمتر مدنظر قرار گرفته است.

از مزایای مهم زمان‌های سفر دقیق در VRP‌ها، کاهش کل زمان سفر و افزایش قابلیت اطمینان مسیر ارائه شده است که با داده‌های سفر زمان دقیق‌تر، محدودیت‌های زمانی را بهتر برآورده می‌کند (ناصری و برادران، ۱۳۸۸: ۶۹-۹۵؛ Liu et al., 2020: 11917-11929). دلایل آشکار برای به‌کارنگرفتن زمان سفر متغیر در VRP به سه عامل مرتبط است: الف. الگوریتم‌های معمول VRP بدون تغییرات اساسی ساختاری قادر به در نظر گرفتن زمان متغیر سفر نیستند. ب. عموماً همه پارامترهای تأثیرگذار بر زمان سفر استفاده نمی‌شوند. ج. جمع‌آوری داده‌های مورد نیاز بسیار مشکل است (Ma et al., 2019: 1-21)؛ از این رو طراحی مدل‌های مناسبی که از دقت کافی در پیش‌بینی زمان سفر براساس متغیرهای مؤثر بر آن برخوردار باشند، ضرورتی در فرایند برنامه‌ریزی حمل‌ونقل است. در واقع در این پژوهش زمان سفر دقیق برای وسایل نقلیه جمع‌آوری پسماند درمانی تعیین شد؛ طوری که بتوان آن را به سایر کاربردها و همچنین همه سازمان‌های مربوط به حمل‌ونقل تعمیم داد. این موضوع در نهایت می‌تواند به سیاست‌گذاران، مدیران و برنامه‌ریزی شهری کمک کند.

تخمین زمان سفر یکی از عوامل اصلی ایجاد سامانه حمل‌ونقل بهینه و هوشمند است. انگیزه این پژوهش نیز حل این مسئله برای مراکز تولید پسماند درمانی کلان‌شهر تهران است. در شهر تهران بیش از ۱۸۰۰ مرکز درمانی وجود دارد که شامل بیمارستان‌ها، کلینیک‌ها، مطب‌ها و غیره هستند. هنوز جمع‌آوری پسماند این مراکز به‌طور منظم و هوشمند سازمان‌دهی نشده است. برای این کار سازمان مدیریت پسماند با چالش‌های بسیاری مواجه است که یکی از آن‌ها تخمین زمان سفر است. در حال حاضر، شرکت‌های وابسته به سازمان مدیریت پسماند از نظرات انسانی براساس تجربه و گزینه برای مدیریت زمان سفر میان مراکز تولید پسماند استفاده می‌کنند که ممکن است این تجربه‌ها به بهینگی مسیریابی منجر نشود.

در این مقاله، متغیرهای مناسب برای اندازه‌گیری تأثیر عامل‌های زمانی، ترافیکی و مکانی بر زمان سفر وسایل نقلیه

جمع‌آوری پسماند درمانی در یک مسیر، تعریف و با بررسی و اجرای مدل پیشنهادی میزان تأثیر این متغیرها بر زمان سفر اندازه‌گیری شده است. مدل پیشنهادی برای تخمین زمان سفر، شبکه عصبی مکانی-زمانی (ST-NN)^۱ نام دارد که میزان تأثیر متغیرها بر زمان سفر در هر لحظه را بررسی می‌کند. منطقه مورد مطالعه شامل کل شبکه معابر شهری کلان‌شهر تهران است. ابتدا داده‌های مورد نیاز به‌عنوان ورودی‌های مدل ST-NN، پیش‌پردازش شد و مدل با معماری‌های متفاوت اجرا شد. در نهایت یکی از این معماری‌ها به‌عنوان بهترین تخمین انتخاب شدند. بخش دوم به مرور ادبیات موضوع و روش‌های پیش‌بینی زمان سفر اختصاص دارد. به‌منظور تشریح متدولوژی پژوهش، بخش سوم به معرفی نحوه جمع‌آوری داده‌ها و روش پژوهش پیشنهادی پرداخته است که در آن ویژگی‌های منطقه مورد مطالعه، توضیحاتی درباره مدل پیشنهادی پژوهش، یعنی شبکه عصبی و مفاهیم مورد استفاده در طراحی آن متناسب با پارامترهای تأثیرگذار بیان شده است. بخش چهارم یافته‌های پژوهش و شامل تعیین تعداد لایه‌های پنهان شبکه عصبی و اجرای نهایی و ارزیابی مدل است.

پیشینه پژوهش

دلیل اصلی اینکه روش‌های تخمین و پیش‌بینی موجود نمی‌توانند به دقت بسیار خوبی برسند، این است که زمان سفر از عوامل مختلفی تأثیر می‌پذیرد. از جمله عوامل موجود، تغییرات زمانی ساعات اوج و غیر اوج (Ma et al., 2017; Kumar et al., 2017; Brakewood et al., 2015: 59-75; Yang et al., 2016: 205-221; Zhou et al., 2017: 17-29; Cheng et al., 2017: 453-466; Rahman et al., 2018: 389-394) و عرض مسیر (Goldberg and Listowsky, 1994: 589-602) هستند. Pahlavani و همکاران (۲۰۱۳) در مسیریابی، معیارهایی چون زمان، مسافت و درجه سختی مسیر را به‌عنوان فاکتورهای مؤثر بر مسیریابی مدنظر قرار دادند. خیراللهی و همکاران (۱۳۹۵) در پژوهش خود، پارامترهای ترافیک، کیفیت مسیر، شیب، نوع مسیر و میزان مستقیم‌بودن و شرایط آب‌وهوایی مسیر را به‌عنوان معیارهای مؤثر بر زمان سفر بررسی کردند. بر مبنای مقایسه انجام‌شده در این مقاله، روش ارائه‌شده در مقایسه با روش‌های ساده فعلی برتری فراوانی داشت. نتایج مقاله‌ای دیگر که بر تجزیه و تحلیل تأثیر داده‌های سرعت خودرو تمرکز داشت، به بهبود دقت محاسبات شد (Watkins et al., 2011: 839-848). در مطالعه‌ای دیگر، گزارشی از وضعیت ترافیک با استفاده از اطلاعات توپیتتری به‌عنوان پشتیبانی داده‌افزایی برای پیش‌بینی زمان سفر بیان شد (He et al., 2013). نتایج نشان می‌دهد آگاهی از شرایط ترافیک در زمان واقعی به افزایش دقت تخمین کمک می‌کند.

طراحی مدل‌های مناسبی که از دقت کافی در پیش‌بینی زمان سفر براساس متغیرهای مؤثر بر آن برخوردار باشند، ضرورتی در فرایند برنامه‌ریزی حمل‌ونقل است. به‌طورکلی زمان سفر وسایل نقلیه در یک مسیر با دو دسته روش مستقیم و غیرمستقیم تعیین می‌شود (Cheng et al., 2019: 51 - 65). در روش‌های مستقیم، با استفاده از فناوری‌های ردیابی وسایل نقلیه، موسوم به شناسه‌گرهای خودکار وسایل نقلیه، مانند خواندن پلاک خودروها به‌کمک دوربین‌ها و نرم‌افزارهای پردازش تصویر و فناوری RFID تلفن همراه رانندگان، وسایل نقلیه خاص در دو نقطه از مسیر ردیابی می‌شوند و زمان واقعی سفر آن‌ها در فاصله‌ای از مسیر در هر لحظه از روز اندازه‌گیری می‌شود (Woodard et al., 2013).

مؤثر بر آن مانند متغیرهای ترافیکی با استفاده از سنسورهای ترافیکی یا دوربین‌های ویدئویی در خیابان‌ها و بزرگراه‌ها و استفاده از مدل‌های پیش‌بینی تخمین زده می‌شود (Lu et al., 2017: 2-11; Cheng et al., 2019: 51-65). برآورد زمان سفر در روش‌های غیرمستقیم به دلیل هزینه‌ها و مشکلات کمتری که در مقایسه با روش‌های مستقیم دارند، در بسیاری از مطالعات مدنظر بوده است (Lin and Zito, 2005: 1433-1448).

طی چند دهه گذشته، بسیاری از مدل‌ها برای تخمین زمان سفر ایجاد شده‌اند، از جمله مدل‌هایی که براساس آمار ریاضی و مدل‌های مبتنی بر هوش مصنوعی هستند. به دلیل اجرای آسان و تلاش محاسباتی کم، از مدل‌هایی که براساس آمار ریاضی استفاده می‌شوند، استفاده گسترده‌ای می‌شود. با این حال، به‌طور کلی دقت کم است (Cheng et al., 2019: 51-65). طیف وسیعی از مطالعات گذشته برای برآورد زمان سفر از توزیع‌های احتمالی در یک بازه زمانی کوتاه استفاده شده است (Dessouky, 2003: 145-164)، اما تغییر پیوسته متغیرهای مؤثر بر زمان سفر مانند تغییر شرایط ترافیکی در یک مسیر، بر توزیع احتمالی آن تأثیر مستقیم دارد؛ بنابراین نمی‌توان با اطمینان در طول روز، یک توزیع احتمالی ثابت با پارامترهای مشخص برای متغیر زمان سفر در نظر گرفت. مطالعه زمان سفر در سیستم حمل‌ونقل شهر تهران در پژوهش‌های قبلی نشان داده است که حتی با ثابت‌بودن شکل توزیع زمان سفر در ساعات اوج، پارامترهای توزیع آماری با تغییر شرایط تغییر می‌کنند. در واقع پیش‌بینی زمان سفر وابستگی فراوانی به الگوهای قابل توجه روزانه و هفتگی ترافیک و همچنین به ویژگی‌های متغیر زمانی مانند شرایط آب و هوایی و حوادث ترافیکی دارد؛ برای مثال، هوای بد یا تصادف در جاده سرعت وسایل نقلیه را کند می‌کند و سبب طولانی‌شدن زمان سفر می‌شود (ناصری و برادران، ۱۳۸۸). در نتیجه برآورد زمان سفر در یک مسیر از توزیع آماری ثابت بدون در نظر گرفتن تغییرات متغیرهای مؤثر بر آن، نتیجه‌های غیرواقعی خواهد داشت.

در مدل‌های مبتنی بر الگوریتم‌های هوش مصنوعی و استنتاج تقریبی، مدل ریاضی یا آماری دقیقی از داده‌ها حاصل نمی‌شود، اما نتایج تخمینی تطابق فراوانی با واقعیت دارند؛ به‌ویژه در حالت تغییر شرایط. برخی مدل‌های موفق، استنتاج فازی (Li and McDonald, 2002: 932 - 937)، یادگیری ماشین با الگوریتم EM^۱ (Hofleitner et al., 2012: 1097-1122) و مدل ترکیبی را که تلفیقی از روش k-NN در داده‌کاوی با روش KF^۲ (Kumar et al., 2017, 308 - 332) است، شامل می‌شوند. در پژوهشی، یک مدل سه‌لایه شبکه عصبی مصنوعی (ANN) برای تخمین زمان سفر ارائه شد. نتایج این پژوهش با مدل هلنگا^۳ که مدلی برای تحلیل و تخمین یک پارامتر با استفاده از دیگر پارامترهاست (Hellings et al., 2008: 768-782) مقایسه شد که این قیاس نشان داد، مدل ANN در شرایط مختلف ترافیکی بسیار خوب عمل می‌کند (Zheng and van Zuylen, 2013: 145-157). در پژوهشی دیگر به‌منظور بهبود دقت برآورد زمان سفر، یک مدل تخمین براساس جنگل‌های تصادفی^۴ ارائه شد (Cheng et al., 2019: 51-65). در این پژوهش از هفت متغیر تأثیرگذار به‌عنوان ورودی مدل استفاده شد که نتایج آن میزان اهمیت این متغیرها را نشان می‌دهد. در واقع این

1. Expectation-Maximization Algorithm
 2. Kalman Filtering
 3. Hellings
 4. Random Forests

پژوهش ادعا کرد که تأثیر متغیرها در زمان سفر را می‌توان با استفاده از جنگل‌های تصادفی به‌دست آورد. در همان سال، پژوهشی دیگر با رویکردی مبتنی بر قطعه جدید برای پیش‌بینی زمان سفر انجام شد. مدل ساخته‌شده قادر بود با ترکیب فاکتورهای مختلف تأثیر ترافیک را بر زمان سفر پیش‌بینی کند (Ma et al., 2019: 1-21).

بررسی پژوهش‌های مرتبط نشان می‌دهد طیف گسترده‌ای از مدل‌ها برای برآورد زمان سفر توسعه یافته‌اند. اگرچه این مدل‌ها مزایای خاص خود را دارند، تعداد متغیرهای مستقل انتخاب‌شده محدود است و تأثیر متغیرهای جریان ترافیک در زمان سفر کاملاً مدنظر قرار نگرفته است. در سال‌های اخیر، پیشرفت داده‌کاوی و یادگیری ماشین به تدریج به چشم می‌خورد. توسعه فناوری کسب اطلاعات ترافیک (مانند داده‌های GPS) مقدار فراوانی از داده‌های ترافیک را در اختیار ما قرار داده است که فرصتی برای توسعه دقیق‌تر تخمین زمان سفر براساس داده‌کاوی فراهم می‌کند. در این پژوهش همه پارامترهای تأثیرگذار، اعم از مکانی و غیرمکانی یا پویا و ایستا تعیین و تخمین میزان تأثیر آن‌ها بر زمان سفر به‌صورت پویا با استفاده از روش آزمون و خطا با ۲۴ ترکیب متفاوت از اجزای شبکه عصبی بررسی شده است.

محدوده مورد مطالعه و داده‌ها

فاکتورها و معیارهای فراوانی در محاسبه زمان سفر تأثیرگذار هستند. برخی فاکتورها در همه کاربردهای زمان سفر مؤثر و برخی دیگر در یک رویکرد خاص دخالت دارند. ممکن است یک معیار در زمان سفر وسایل نقلیه جمع‌آوری پسماند فاکتور اصلی و در مسیریابی اورژانس بی‌اثر باشد. معیارهایی که در این پژوهش در الگوریتم پیشنهادی اعمال شده‌اند، از دید نحوه تغییرات به دو دسته پویا و ایستا تقسیم می‌شوند. ممکن است برخی از آن‌ها به‌ظاهر کم‌اهمیت باشند، اما با توجه به حساسیت عملیات وسایل نقلیه جمع‌آوری پسماند درمانی شهری نیاز است تا مدنظر قرار گیرند. در ادامه به بررسی معیارهای اولیه مؤثر بر زمان سفر وسایل نقلیه جمع‌آوری پسماند پرداخته شده است.

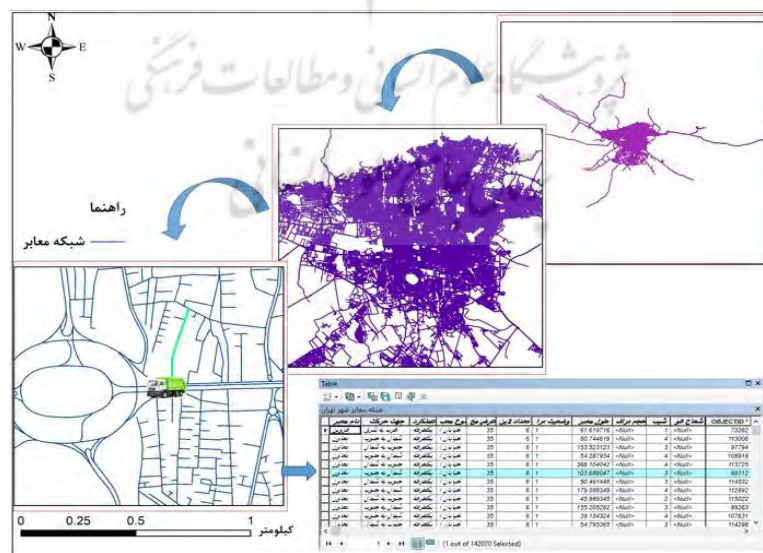
برای این پژوهش از دو نوع داده استفاده شده است: داده‌های زمان سفر و داده‌های شبکه معابر و ترافیک. مورد اول شامل مدت‌زمانی است که وسیله نقلیه جمع‌آوری پسماند درمانی در مکان و زمان خاص مسیری را می‌پیماید. داده دوم شامل داده‌های ترافیکی و ویژگی‌های شرایط جوی و مکانی شبکه معابر و متناظر با داده‌های زمان سفر است. داده‌های ترافیکی از شرکت کنترل ترافیک و داده‌های شبکه معابر همراه با ویژگی‌های آن از شهرداری تهران گرفته شده است (شکل ۱). ویژگی‌های شبکه معابر شامل نام، جهت حرکت، عملکرد (یک‌طرفه و دوطرفه بودن)، نوع، طبقه‌بندی، طول، عرض، تعداد لاین، حداکثر سرعت مجاز، شیب، شعاع قوس افقی، وضعیت آب‌وهوا و خطوط لرزاننده معبر است. در ادامه توضیح مختصری برای هر ویژگی ذکر شده است (خیراللهی، ۱۳۹۵: ۴۵-۵۹؛ Goldberg and Listowsky, 1994: 589-602):

میزان ترافیک: نشان‌دهنده مقدار ازدحام و ترافیک در طول ساعات شبانه‌روز است و به شش نوع مسدود، ترافیک بسیار سنگین، سنگین، سنگین در حال حرکت، اختلال در حرکت و روان تفکیک شده است.

طول مسیر: مسافت طی‌شده برای گذر از یک قطعه مسیر است.

نوع مسیر: تقسیم‌بندی راه‌های شهری براساس استانداردهای شهرسازی که به پنج دسته کوچک، پیاده‌رو، خیابان فرعی، خیابان اصلی و بزرگراه تقسیم می‌شود.

- حداکثر سرعت: میزان حداکثر سرعت مجاز خودرو (از صفر تا ۱۱۰ کیلومتر بر ساعت) در گذر از یک قطعه مسیر است.
- عرض و تعداد لاین معبر: میزان عرض یک معبر که برای خودروها قابل استفاده باشد که از ۳ متر تا ۳۵ متر متغیر است و همچنین تعداد لاین‌ها از ۱ تا ۸ متغیر است.
 - تقاطع: به محل اتصال سه راه، چهارراه یا یک میدان با ۶، ۵، ۴، ۳ و ۲ راه متصل به آن گفته می‌شود. شیب: متوسط شیب در امتداد مسیر است.
 - چراغ‌های راهنمایی: به مدت‌زمانی گفته می‌شود که یک چراغ راهنمایی در یک تقاطع می‌تواند در حرکت خودرو تأخیر ایجاد کند.
 - کیفیت مسیر: به تعداد سرعت‌شکن‌های ایمنی در یک مسیر گفته می‌شود.
 - آب‌وهوا: به پایداری و ناپایداری هوا گفته می‌شود.
 - سطح سرویس (LOS): در همه کشورهای، آیین‌نامه محاسبه ظرفیت راه‌ها برای ارزیابی کفایت شرایط فیزیکی راه در مقایسه با جریان ترافیک استفاده می‌شود. این آیین‌نامه شش سطح سرویس از A تا F را معرفی می‌کند (طرح مطالعات جامع حمل‌ونقل کشور، اسفند ۱۳۸۶).
 - میزان مستقیم‌بودن معبر: همان شعاع قوس افقی معبر است که از صفر تا ۶۰ درجه متغیر و مشخص‌کننده میزان مستقیم‌بودن یا پیچ‌خوردگی راه است.
 - در میان ۱۲ پارامتر بیان‌شده، چهار مورد از آن‌ها، یعنی میزان ترافیک، چراغ‌های راهنمایی و رانندگی، آب‌وهوا و سطح سرویس معیارهایی پویا و بقیه ایستا هستند. معیارهای پویا ممکن است تحت شرایط گوناگون تغییر کنند، اما معیارهای ایستا همواره ثابت هستند و دچار تغییر نخواهند شد. پارامترهای میزان ترافیک، نوع مسیر، کیفیت مسیر، آب‌وهوا، سطح سرویس کیفی و بقیه پارامترها کمی هستند. در جدول ۱ تبدیل لایه‌های کیفی به کمی مشخص شده است.



شکل ۱. شبکه معابر و ویژگی‌های محدوده مورد مطالعه

جدول ۱. تبدیل ارزش لایه‌های کیفی به کمی

نام متغیر	نام عامل	نوع عامل	تبدیلات کیفی به کمی	نام متغیر	نام عامل	نوع عامل	تبدیلات کیفی به کمی
میزان ترافیک	ترافیکی	کیفی	1: روان 2: اختلال در حرکت و روان 3: سنگین در حال حرکت 4: سنگین 5: ترافیک بسیار سنگین 6: مسدود	سطح سرویس مکانی	کیفی	کیفی	1 A: 2 B: 3 C: 4 D: 5 E: 6 F:
نوع مسیر	مکانی	کیفی	1: بزرگراه 2: کوچه 3: خیابان اصلی 4: خیابان فرعی	آب‌وهوا جوی	کیفی	کیفی	1: پایدار 2: نیمه پایدار 3: ناپایدار 4: به شدت ناپایدار
چراغ‌های راهنمایی	مکانی	کمی	0: ندارد 1: دارد	تقاطع	مکانی	کمی	0: ندارد 1: دارد
طول مسیر	مکانی	کمی	----	تعداد لاین معبر	مکانی	کمی	----
حداکثر سرعت	ترافیکی	کمی	----	شیب	مکانی	کمی	----
عرض معبر	مکانی	کمی	----	مستقیم بودن معبر	مکانی	کمی	----
کیفی مسیر	مکانی	کیفی	1: خوب 2: متوسط 3: کم				

روش پژوهش

مدل پیشنهادی - شبکه عصبی مصنوعی مکانی زمانی (ST-ANN)

همان‌طور که از شکل ۲ مشخص است، به منظور اجرای مدل پیشنهادی، ابتدا داده‌ها به عنوان مرحله پیش پردازش نرمال و آماده سازی شدند که این مرحله شامل دو نوع داده مستقل و وابسته است. داده یا متغیر وابسته همان زمان سفر است که در اینجا به عنوان داده واقعی از آن یاد می‌شود و بقیه داده‌ها شامل پارامترهای تأثیرگذار بر زمان سفر هستند. در ادامه اجزای شبکه عصبی (همان معماری شبکه است) تعیین و بیان شده است.

شبکه عصبی پس انتشار خطا^۱ به صورت فزاینده‌ای در انواع مسائل مهندسی و پیش‌بینی مدنظر قرار گرفته و استفاده شده است. توانایی شبکه‌های عصبی مصنوعی در کشف پیش‌بینی روابط غیرخطی میان متغیرها و در نتیجه افزایش دقت آن مهم‌ترین مزیت استفاده از آن‌ها بر استفاده از روش‌های آماری مانند رگرسیون و آنالیز سری‌های زمانی است (ناصری و برادران، ۱۳۸۸: ۶۹-۹۵).

شبکه‌های عصبی مصنوعی الهام‌گرفته از شبکه‌های عصبی بیولوژیکی، دارای ساختار و انواع مختلفی هستند. نرون کوچک‌ترین واحد پردازش اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد. هر شبکه از یک لایه ورودی، یک لایه خروجی و تعدادی لایه میانی با تعدادی نرون درون هر لایه تشکیل شده است و نرون‌های هر لایه با


وزن‌هایی به نرون‌های لایه بعد متصل شده‌اند. طی فرایند آموزش این وزن‌ها برای دستیابی به شبکه‌هایی با خطای پیش‌بینی کمتر پیوسته تغییر می‌کنند. همچنین خروجی‌های هر نرون بعد از عبور از توابع تبدیل لایه به نرون‌های بعد منتقل می‌شوند (Zakaria et al., 2014: 7-12). شبکه عصبی انواع مختلفی دارد که در این پژوهش از روش پرسپترون چندلایه^۱ با الگوریتم پس‌انتشار خطا^۲ استفاده شده است.

طراحی معماری شبکه

طراحی معماری شبکه‌های عصبی یکی از بخش‌های مهم و تأثیرگذار بر عملکرد و نتایج شبکه است. منظور از معماری شبکه عصبی تعیین پارامترهایی مانند تعداد لایه‌های پنهان، تعداد نرون‌ها در هر لایه و توابع انتقال و پیش‌پردازش در شبکه است (شکل ۲).

تابع پیش‌پردازش: نرمال‌سازی داده‌های ورودی، به معنای انجام یک عملیات ریاضی روی داده‌های ورودی قبل از آموزش شبکه عصبی برای تسهیل در فرایند یادگیری شبکه، اجتناب از پیچیدگی‌های محاسباتی و بهبود عملکرد شبکه است (ناصری و برادران، ۱۳۸۸: ۶۹-۹۵). از رابطه ۱ برای نرمال‌سازی داده‌ها استفاده شده است. y ارزش نرمال‌شده لایه مدنظر، x ارزش لایه ورودی، X_0 کمترین ارزش لایه و X_1 بیشترین ارزش لایه مدنظر است. X_0 و X_1 برای هر لایه با توجه به توزیع داده‌ها تعیین می‌شوند و لزوماً مقدار کمینه و بیشینه نیستند.

$$y = \frac{x - x_0}{x_1 - x_0} \quad \begin{matrix} x & x_0 \\ x_0 & x & x_1 \\ x & x_1 \end{matrix} \quad (1)$$



شکل ۲. نمایی از اجزای شبکه عصبی چندلایه

1. Multilayer Perceptron
2. Back-propagation

تعداد لایه‌های پنهان: لایه‌های پنهان نقش مهمی در توصیف روابط غیرخطی حاکم بر ورودی‌ها و خروجی شبکه دارند. پژوهشگران روابط مختلفی را برای تعداد لایه‌های پنهان پیشنهاد دادند، اما هیچ‌کدام از آن‌ها برای تمام مسائل کارایی ندارند. بهترین روش برای تعیین تعداد لایه‌های پنهان استفاده از روش سعی و خطاست، اما استفاده از یک و دو لایه پنهان در طراحی شبکه در بسیاری از پژوهش‌ها پیشنهاد شده است (باقری و همکاران، ۱۳۹۶: ۳۶-۴۸). در این پژوهش نیز ارزیابی شبکه با یک و دو لایه پنهان آموزش داده شده تا بهترین نتیجه حاصل شود.

تعداد نرون‌های هر لایه: پژوهشگران از روابط مختلفی برای تعیین تعداد نرون‌های لایه‌های پنهان استفاده کرده‌اند که هیچ‌کدام از روابط فوق برای تمامی مسائل کارایی ندارد؛ بنابراین بهترین روش برای تعیین تعداد نرون‌های هر لایه آزمون سعی و خطا است و این زمانی ایجاد می‌شود که طی مراحل آموزش و ارزیابی شبکه، خطای شبکه به حداقل ممکن برسد (همان).

تابع تبدیل: تابع تبدیل ارتباط میان ورودی و خروجی یک نرون و شبکه را تعیین می‌کند. می‌توان از توابع مختلف در لایه‌های پنهان و با توجه به محدوده تغییر متغیر خروجی از تابع خطی در لایه خروجی استفاده کرد.

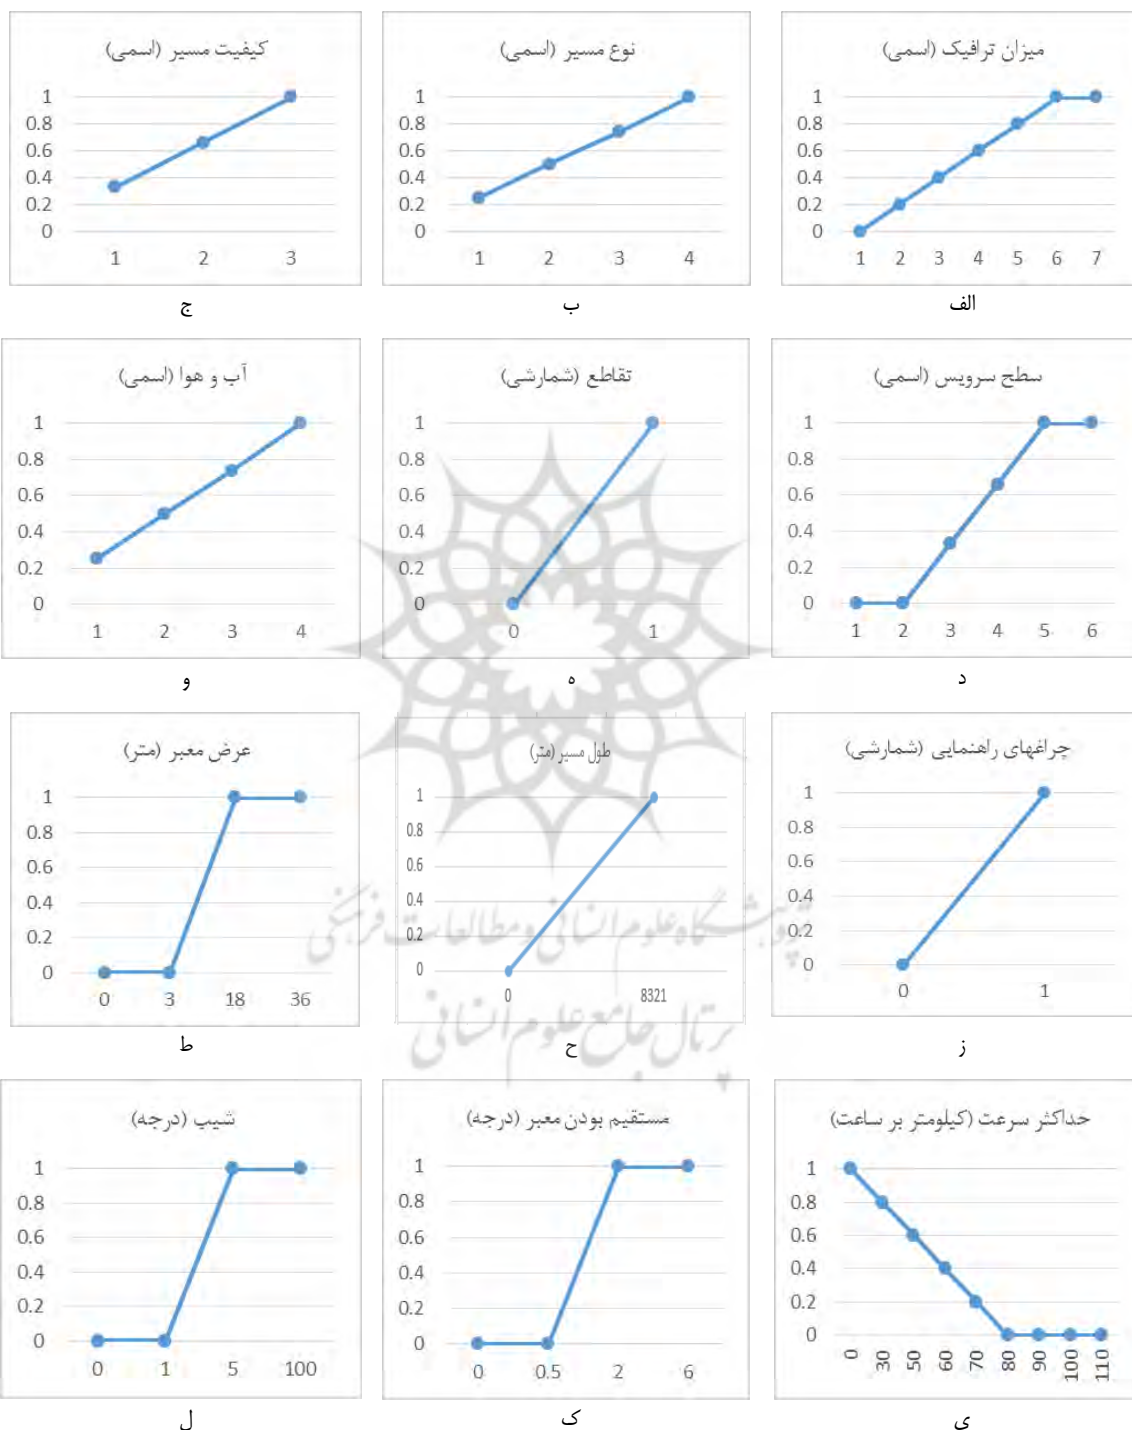
تابع آموزش: آموزش شبکه عصبی مصنوعی یک بهینه‌سازی غیرخطی بدون محدودیت است که در آن اوزان در دفعات متعدد اصلاح می‌شوند تا میانگین یا جمع مربعات خطای بین خروجی شبکه و مقادیر مدنظر به حداقل برسد. مدل پیشنهادی استفاده شده شبکه عصبی مکانی-زمانی (ST-ANN) نام دارد؛ زیرا لحظه حرکت وسیله نقلیه دو پارامتر زمان و مکان مشخص است. از پارامتر مکان ویژگی‌های ایستا و از پارامتر زمان ویژگی‌های پویای مربوط به آن گذر مشخص می‌شود. برای کار با شبکه عصبی مصنوعی، ابتدا باید پارامترهای مؤثر در زمان سفر به‌عنوان لایه‌های ورودی در اختیار شبکه قرار بگیرد. سپس تعدادی یال به‌عنوان نقاط تعلیمی باید به شبکه داده شود تا شبکه با استفاده از نقاط تعلیمی میزان تأثیر هر یک از لایه‌های ورودی را تعیین کند؛ درواقع شبکه با این کار آموزش لازم را برای روبه‌رو شدن با یال‌های جدید به‌دست آورده است. درنهایت کل شبکه معابر شهری تهران در اختیار شبکه تعلیم‌دیده قرار گرفته است و در آخر شبکه عصبی با استفاده از آنچه پیش از این آموخته است، میزان زمان سفر هر یال را مشخص می‌کند.

یافته‌های پژوهش

آماده‌سازی داده‌ها و نرم‌افزارهای استفاده شده

با توجه به شکل ۳، به‌منظور اجرای مدل، ابتدا داده‌ها به‌عنوان مرحله پیش‌پردازش و با استفاده از جدول ۱ نرمال و آماده‌سازی شدند. به‌منظور تقسیم‌بندی زمانی داده‌های ترافیکی در طول شبانه‌روز، ابتدا ۲۴ ساعت را به ۴۸ بازه زمانی ۳۰ دقیقه‌ای تقسیم کردیم، اما به‌دلیل حجیم‌بودن این آمار این بازه‌های زمانی ادغام شدند. درنهایت با توجه به تغییرات ترافیکی در طول شبانه‌روز حاصل از داده‌های روزانه شرکت کنترل ترافیک و نظر کارشناسان، پارامتر زمان به بازه‌های زمانی ۳۰، ۶۰ و ۱۲۰ دقیقه تفکیک شد. درواقع می‌توان گفت معمولاً در ساعات پیک ترافیک به بازه زمانی ۳۰ دقیقه‌ای، ساعات ۲۲ شب تا ۵ صبح به بازه زمانی ۱۲۰ دقیقه‌ای و بقیه موارد به بازه زمانی ۶۰ دقیقه‌ای تفکیک شدند.

داده‌های واقعی: این داده‌ها زمان سفر وسایل نقلیه در تاریخ‌های مشخصی است. بعد از تجزیه مسیر به قسمت‌های مختلف (استاندارد شده با یال‌های شبکه معابر سازمان کنترل ترافیک) مقدار زمان سفر هر یال مشخص شد. در واقع در این پژوهش زمان سفر روی هر یال بررسی شده است.



شکل ۳. نمودار نرمال‌سازی داده‌ها: الف) میزان ترافیک، ب) نوع مسیر، ج) کیفیت مسیر، د) سطح سرویس، ه) تقاطع، و) آب‌وهوا، ز) چراغ‌های راهنمایی، ح) طول مسیر، ط) عرض معبر، ی) حداکثر سرعت، ک) مستقیم‌بودن معبر، ل) شیب

سناریوی اجرا ST-ANN

در ادامه بعد از تهیه و پیش‌پردازش داده‌های ورودی حدود ۹۳۷ یال به‌عنوان نقاط آموزشی انتخاب شد که این نقاط به سه بخش تقسیم شدند. بخش نخست به آموزش شبکه مربوط است. بخش دوم برای توقف محاسبات است، هنگامی که خطا افزایش می‌یابد و بخش سوم برای ارزیابی شبکه است. از این تعداد نمونه آموزشی، ۷۰ درصد نقاط در آموزش شبکه، ۱۵ درصد برای اعتبارسنجی که به‌منظور کالیبره‌کردن مدل استفاده می‌شود و ۱۵ درصد باقی‌مانده برای ارزیابی و نتیجه‌گیری استفاده می‌شود (Jalili Ghazi Zade and Noori, 2010: 13; Kiartzis et al., 1995: 1-6). برای اجرای شبکه عصبی پرسپترون چندلایه از نرم‌افزار MATLAB استفاده شده است.


طراحی شبکه عصبی یکی از بخش‌های مهم و تأثیرگذار بر عملکرد و نتایج شبکه عصبی است. شکل ۳ بیانگر پارامترهای تأثیرگذار و نشان‌دهنده سطوح مختلف هریک از این پارامترها در این پژوهش است. هرچقدر تعداد لایه‌های پنهان و تعداد نرون‌ها بیشتر شود، به دلیل فرایند آموزش بیش‌ازاندازه شبکه، خطای شبکه عصبی در پیش‌بینی بیشتر می‌شود. توابع انتقال از نوع غیرخطی هستند. در این پژوهش هدف برآورد زمان سفر نسبت به برخی پارامترهای ورودی است و ممکن است جواب برآوردشده الزاماً در میان جواب‌های معلوم نباشد. شبکه‌های عصبی در این موارد، باید به‌گونه‌ای باشند که قابلیت تولید مجموعه نامتناهی از پاسخ‌ها را داشته باشند. از توابع غیرخطی Tansig و Logsig استفاده و با آزمون سعی و خطا، مناسب‌ترین تابع انتقال انتخاب شده است. از توابع آموزش Trainlm و Traingdx به دلیل اینکه در تعداد تکرارهای کمتری نسبت به سایر روش‌های گرادینان شیب و نیوتن همگرا می‌شوند، استفاده شده است این دو تابع سریع‌ترین الگوریتم آموزش شبکه‌های عصبی با تعداد پارامترهای مؤثر متوسط می‌باشند. سرعت یادگیری و سرعت حرکت در هر تکرار تغییرپذیر است تا آنکه درصد زمان یادگیری را کاهش دهد. برای دستیابی به معماری مناسب شبکه عصبی به عبارت دیگر باید دانست که چه ترکیبی از سطوح مختلف هر پارامتر تأثیرگذار بر شبکه (عوامل تأثیرگذار جدول ۲) باید با هم ترکیب شوند تا بتوان با آزمون سعی و خطا به بهترین معماری شبکه عصبی مصنوعی برای پیش‌بینی و برآورد زمان سفر دست یافت. برای این منظور با توجه به جدول ۲ و با در نظر گرفتن مقدار سطح هر پارامتر حدود $2 \times 2 \times 6 \times 1 = 24$ روش برای فهمیدن بهترین معماری شبکه عصبی وجود دارد که با تست آن‌ها بهترین معماری برآورد می‌شود.

جدول ۲. اجزا و سطوح هر جزء بکار گرفته شده در شبکه عصبی

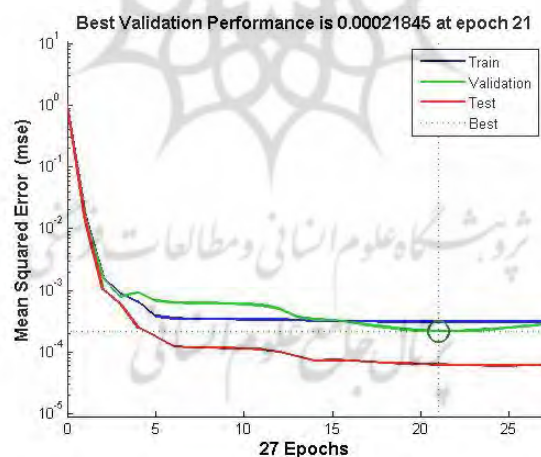
تعداد سطوح	مختلف تأثیرگذاری	پارامترهای طراحی سطوح
۱	۱ لایه	لایه‌های پنهان
۶	متغیر بین ۴ تا ۹	نرون‌های هر لایه
۲	Logsig و Tansig	تابع تبدیل
۲	Trainlm و Traingdx	تابع آموزش

بعد از ۲۴ بار اجرا با ترکیبات مختلف از سطوح پارامترهای جدول ۲، شبکه عصبی طراحی شد و با داده‌های آموزشی، آموزش داده شد. بعد از مقایسه نتایج این اجراها به‌منظور یافتن بهترین جواب، عملکرد شبکه‌های حاصل از هر ترکیب فوق با معیار ضریب هم‌بستگی میان مقدار خروجی شبکه و زمان واقعی سفر برای داده‌های آموزش ارزیابی شد. معماری

نهایی شبکه عصبی با ترکیبی از یک لایه پنهان و تعداد ۷ نرون در هر لایه، تابع انتقال Tansig و تابع آموزش Trainlm به بهترین جواب رسید (شکل ۴). شکل ۵ تعداد دفعات تکرار برای یادگیری الگوهای آموزشی و ارزیابی شبکه را نشان می‌دهد. همان‌طور که مشخص است شبکه بعد از ۲۱ بار تکرار متوقف شد و به آموزش‌های لازم دست یافت. مشاهده می‌شود که در این تکرار به بهینه‌ترین حالت ممکن، یعنی بیشترین هم‌بستگی و کمترین خطا رسیده است.




شکل ۴. بهترین معماری انتخاب شده اجزای شبکه عصبی بعد از اجرا و آزمون خطا



شکل ۵. روند یادگیری الگوهای آموزشی و ارزیابی شبکه عصبی

در شکل ۶ نمودار برازش و ضرایب رگرسیون مراحل آموزش، صحت‌سنجی و آزمون نهایی شبکه عصبی نشان داده شده که بیانگر مقادیر فراوانی است که برای این مراحل به دست آمد. در شبکه عصبی مصنوعی جلوگیری از یادگیری بیش از حد شبکه بسیار مهم است؛ زیرا در این حالت شبکه به جای یادگیری و درک روابط پارامترها، اطلاعاتی را که در اختیار آن گذاشته می‌شود، در حافظه ذخیره می‌کند (Gomez et al., 2002). بخش دوم داده‌های آموزشی برای همین امر در شبکه تعبیه شده است که با توجه به ضریب ۰/۹۷ این مرحله می‌توان اطمینان حاصل کرد که به خوبی از یادگیری

بیش از حد شبکه جلوگیری شده است. در نهایت ضریب رگرسیون کلی شبکه که حاصل شرکت داده‌ها در شبکه است، ۹۶ درصد حاصل شد. بعد از انجام تمام این مراحل شبکه آموزش‌های لازم را برای مواجه شدن با یال‌های جدید کسب می‌کند و می‌تواند مناطق جدید را براساس آنچه آموخته ارزش‌دهی کند. به عبارت دیگر همان‌طور که اشاره شد، از ۱۵ درصد کل داده‌های جمع‌آوری شده برای ارزیابی دقت مدل شده استفاده شد. نتایج نشان می‌دهد ST-ANN با مقدار ضریب هم‌بستگی ۰/۹۱ نتیجه قابل قبولی ارائه می‌دهد. در شبکه عصبی چون کل پارامترهای ورودی هم‌زمان به درون شبکه وارد می‌شوند و ساختار شبکه عصبی طوری است که خطای شبکه به کل داده‌ها محاسبه می‌شود. در ادامه پس از محاسبه خطای شبکه، وزن‌های هر پارامتر به خطای شبکه تغییر می‌یابند تا به جواب ایده‌آل برسند. فرایند تکرار تغییر وزن‌های هر پارامتر برای رسیدن به جواب ایده‌آل سبب شده است که دقت روش شبکه عصبی بیشتر شود.



شکل ۶. نمودار برازش و ضریب هم‌بستگی در مراحل مختلف شبکه: الف) مرحله آموزش، ب) مرحله صحت‌سنجی، ج) مرحله آزمون و د) مجموع هر سه مرحله

ارزیابی و اعتبارسنجی مدل

از داده‌های اعتبار که ۲۰ درصد کل داده‌های جمع‌آوری شده است، برای ارزیابی و مقایسه دقت شبکه عصبی طراحی شده در پژوهش با مدل‌های پیش‌بینی رگرسیون خطی، رگرسیون چندجمله‌ای و شبکه عصبی طراحی شده با معیارهای آن توسط ناصری و برادران (۱۳۸۸) استفاده شده است. هریک از داده‌های آموزش (که قبلاً به مدل جهت آموزش وارد نشده است) به‌عنوان ورودی و به‌طور جداگانه به هریک از مدل‌های رگرسیون خطی و چندجمله‌ای، مدل ناصری و برادران (۱۳۸۸) و شبکه عصبی پیشنهادی پژوهش وارد شده و مقدار پیش‌بینی متناظر آن به‌عنوان خروجی از مدل‌های مذکور اخذ شده است. دقت پیش‌بینی هر مدل با دو معیار ضریب هم‌بستگی (R^2) میان مقادیر واقعی (x_i) و پیش‌بینی (y_i) در رابطه ۲ و خطای میانگین مربعات (MSE) در رابطه ۳ بررسی شده است. بعد از اجرا، نتایج آن‌ها در جدول ۳ مشخص شد.

$$MSE = \frac{1}{n} \left[\sum_{i=1}^n (x_i - x)^2 \right] \quad (2)$$

$$R(x, y) = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{\left[n \sum x_i^2 - (\sum x_i)^2 \right]^{\frac{1}{2}} \left[n \sum y_i^2 - (\sum y_i)^2 \right]^{\frac{1}{2}}} \quad (3)$$

جدول ۳. مقایسه نتایج پیش‌بینی شده توسط مدل پژوهش با روش‌های دیگر

معیار ارزیابی	رگرسیون خطی	رگرسیون چندجمله‌ای	شبکه عصبی (ناصری و برادران، ۱۳۸۸)	شبکه عصبی
R2	۰/۸۰	۰/۸۳	۰/۸۹	۰/۹۱
MSE	۷۱۱	۶۲۳	۴۵۹	۴۳۳

مقدار معیار ضریب هم‌بستگی برای رگرسیون خطی ۰/۸۰، برای رگرسیون چندجمله‌ای ۰/۸۳ و مدل ناصری و برادران (۱۳۸۸)، ۰/۸۹ است که در مقایسه با آن‌ها این مقدار برای مدل شبکه عصبی پیشنهادی ۰/۹۱ است. در واقع مشخص شد مدل پیشنهادی توانسته است به‌ترتیب ۰/۱۱، ۰/۰۸ و ۰/۰۲ مقدار هم‌بستگی را بهبود داده باشد. برای معیار دیگر که خطای میانگین مربعات است، مدل پیشنهادی به مقادیر ۲۷۸، ۱۹۰ و ۲۶ واحد خطا را کاهش داده است. به عبارت دیگر از مقادیر موجود در جدول ۳ می‌توان استنباط کرد اگر برای پیش‌بینی زمان سفر وسایل نقلیه جمع‌آوری پسماند از مدل پیشنهادی این پژوهش استفاده شود، تصمیم‌گیران، سیاست‌گذاران و مدیران برنامه‌ریزی شهری می‌توانند با دقت بیشتری نسبت مدل‌های مذکور از زمان سفر واقعی را پیش‌بینی شده استفاده کنند. این دقت ناشی از هم‌بستگی بالا میان مقدار برآوردشده با مقدار واقعی زمان سفر، پراکندگی مناسب داده‌های برآوردشده حول محور زمان سفر واقعی و همچنین استفاده از معیارهای تأثیرگذار بیشتر (در مقایسه با مدل ناصری و برادران) است که در نهایت خطای پیش‌بینی هم کاهش یافته است.

زمان سفر وسایل نقلیه جمع‌آوری پسماند درمانی به عوامل مختلفی مانند حجم ترافیک، طول، عرض، تعداد لاین، حداکثر سرعت مجاز، شیب، شعاع قوس افقی، وضعیت آب‌وهوا و غیره بستگی دارد. همه این عوامل مدل‌سازی زمان سفر را به یک مسئله پیچیده و غیرخطی تبدیل می‌کنند؛ بنابراین مدل‌های خطی دقت مناسبی برای برآورد زمان سفر ندارند. از طرفی دیگر مقدار خطایی که در پیش‌بینی زمان سفر وجود دارد، علاوه بر مدل انتخابی برای اجرا، به پارامترهای

متنوع و تأثیرگذار بر زمان سفر بستگی دارد. اول اینکه در یک پژوهش به‌کارگیری همه پارامترها کار بسیار سختی دشواری و دوم اینکه نحوه استفاده از خود پارامتر بسیار مهم است؛ برای طول یک گذر. اگر طول گذر (یال) کوتاه باشد، آماری و داده‌هایی که از آنجا گرفته شده دقیق‌تر و با قطعیت بیشتر است، اما اگر طول آن گذر (یال) زیاد باشد، ممکن است داده‌های اخذشده از آن یال نماینده کل یال نباشد؛ برای مثال میزان ترافیک وسط یال با ابتدا و انتهای آن یکسان نیست. این قضیه برای شیب هم صدق می‌کند. مثال دیگر تأثیر پارامتر کیفیت مسیر بر خودروهای مختلف، بر راننده‌های مختلف و حتی بر میزان باری است که در خودرو وجود دارد و تأثیر متفاوتی دارد؛ در بعضی از آن‌ها تأثیر کم و بر بعضی بیشتر است؛ بنابراین با توجه به این توضیحات همیشه عدم قطعیتی درباره داده وجود دارد که بر نتایج تأثیرگذار است.

نتیجه‌گیری

زمان سفر نقش اساسی بر فرایندهای برنامه‌ریزی سیستم‌های حمل‌ونقل دارد. به‌منظور محاسبه زمان سفر باید به‌دنبال سازوکاری بود که بتواند تأثیر هر یک از پارامترها را بر کل فرایند تشخیص دهد و بتواند مؤثر و مفید واقع شود. به‌صورت دقیق‌تر مسائلی که برای تخمین دقیق زمان سفر هر یال در بستر زمان وجود دارد، شامل تعیین کل پارامترهای تأثیرگذار بر زمان سفر، جمع‌آوری داده‌های مورد نیاز و تعیین ساختار مناسبی برای الگوریتم‌هاست. در این پژوهش همه پارامترهای تأثیرگذار موجود و میزان تأثیر آن‌ها بر زمان سفر برای وسایل نقلیه جمع‌آوری پسماند درمانی بررسی شد که هم از پارامترهای ایستا و هم پویا استفاده شد. همچنین از داده‌های واقعی زمان سفر که وسایل نقلیه به‌منظور جمع‌آوری پسماند درمانی صرف کرده‌اند، به‌عنوان خروجی مدل پیشنهادی ST-ANN استفاده شد. بعد از اجرای ۲۴ ترکیب مختلف (آزمون خطا) از اجزای مدل ST-ANN معماری مناسب مدل انتخاب شد. نتایج حاکی از آن بود که مدل پیشنهادی قادر است با ضریب هم‌بستگی ۹۱ درصد زمان سفر هر یال برآورد شد که این دقت ناشی از بهره‌گیری از پارامترهای گوناگون و تأثیرگذار بر زمان سفر و همچنین مدل مناسب است. دقت مدل ST-ANN ناشی از فرایند تکرار تغییر وزن‌های هر پارامتر برای رسیدن به جواب ایده‌آل است. به‌منظور ارزیابی مدل پیشنهادی، نتایج پژوهش با دو مدل رگرسیون خطی، رگرسیون چندجمله‌ای و مدل پیشنهادی ناصری و برادران (۱۳۸۸) مقایسه شد. معیارهای ارزیابی، ضریب هم‌بستگی (R^2) و خطای میانگین مربعات (MSE) بود که در نهایت مشاهده شد R^2 به مقادیر ۰/۱۱، ۰/۰۸ و ۰/۰۲ و MSE به مقادیر ۲۷۸، ۱۹۰ و ۲۶ بهبود یافته‌اند.

علاوه بر نتایج ذکرشده از دستاوردهای دیگر مدل پیشنهادی، انعطاف‌پذیری بودن اجزای معماری آن برای یافتن بهترین شبیه‌سازی است به عبارت دیگر اگر داده‌های ورودی آن تغییر (محدوده مورد مطالعه دیگر یا کاربرد دیگر) کند، با استفاده از آزمون خطا در تکرارهای حل مدل و یافتن بهترین معماری می‌توان به یک شبیه‌سازی مناسب دست یافت. از طرف دیگر با توجه به اینکه موضوع پژوهش، برای وسایل نقلیه جمع‌آوری پسماند درمانی است و همچنین سازمان پسماند تهران به‌منظور سازمان‌دهی ناوگان جمع‌آوری پسماند درمانی نیاز به یافتن مسیر مناسب برای هر وسیله نقلیه مربوط دارد؛ پس برای نیل به این هدف به زمان دقیق سفر وسایل نقلیه مربوطه برای هر یال نیاز است. از طرفی دیگر می‌توان ادعا کرد که این رویکرد را می‌توان به سایر کاربردهای حمل‌ونقل هوشمند شهری تعمیم داد؛ برای مثال تعیین زمان‌بندی

سرویس‌دهی ناوگان‌های حمل‌ونقل عمومی با توجه به مبدأ، مقصد و زمان حرکت، یا بهینه‌کردن هزینه ناوگان شرکت‌های توزیع کالا مانند توزیع فراورده‌های لبنیاتی، گوشتی و غیره. با توجه به موارد ذکر شده این پژوهش به‌عنوان یک دستاورد پایه در حوزه حمل‌ونقل می‌تواند به مدیران، برنامه‌ریزان و سیاست‌گذاران شهری کمک کند. به دلیل استفاده از سیستم اطلاعات مکانی در تهیه داده‌های مکان‌محور می‌توان هر داده مکانی دیگری را به پایگاه داده اضافه کرد؛ زیرا ممکن است پارامتری در این پژوهش استفاده نشده، ولی در کاربردهای دیگر به آن نیاز باشد.



منابع

- خیراللهی، مصطفی، نادى، سعید و نجمه نيسانى سامانى (۱۳۹۵). «تلفیق معیارهای کیفی و کمی با استفاده از مدل‌های مکان مبنا به‌منظور مسیریابی بهینه خودروهای اورژانس در محیط‌های شهری»، مجله سپهر، شماره ۱۰۰، صص ۴۵-۵۹.
- ناصری، محمدرضا و وحید برادران (۱۳۸۸). «بررسی عوامل موثر بر زمان سفر در سیستم حمل و نقل عمومی و پیش بینی زمان سفر مورد کاوی: سیستم اتوبوسرانی شهر تهران». پژوهشنامه حمل و نقل، شماره ۳، صص ۲۱۹-۲۳۲.
- باقری، میلاد، جلوخانی نیارکی، محمدرضا و کیوان باقری (۱۳۹۶). «بررسی پتانسیل اراضی استان کرمانشاه جهت کشت گندم دیم با استفاده از شبکه عصبی مصنوعی»، سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی، شماره ۴، صص ۳۶-۴۸.
- Naseri, M. R., & Baradaran, V. (2009). Study of Factors Affecting Travel Time in Public Transport System and Predicting Travel Time Case Study: Tehran Bus System. *Journal of Transportation*, No. 3, pp. 219-232. (In Persian)
- Bagheri, M., Jaloukhani Niaraki, M. R., & Bagheri, K. (2017). Assessing the Potential of Lands in Kermanshah Province for Rainfed Wheat Cultivation Using Artificial Neural Network. *Remote Sensing and Geographic Information System in Natural Resources*, (4), 36- 48. (In Persian)
- Brakewood, C., Macfarlane, G. S., & Watkins, K. (2015). The Impact of Real-Time Information on Bus Ridership in New York City. *Transportation Research Part C: Emerging Technologies*, 53, 59-75.
- Cheng, J., Li, G., & Chen, X. (2019). Developing a Travel Time Estimation Method of Freeway Based on Floating Car Using Random Forests. *Journal of Advanced Transportation*, 63, 51-65.
- Cheng, Z., Chow, M. Y., Jung, D., & Jeon, J. (2017). A Big Data Based Deep Learning Approach for Vehicle Speed Prediction. In *26th International Symposium on Industrial Electronics (ISIE)* (pp. 389-394). IEEE.
- Dessouky, M., Hall, R., Zhang, L., & Singh, A. (2003). Real-Time Control of Buses for Schedule Coordination at a Terminal. *Transportation Research Part A: Policy and Practice*, 37(2), 145-164.
- Goldberg, R., & Listowsky, P. (1994). Critical Factors for Emergency Vehicle Routing Expert Systems. *Expert Systems with Applications*, 7(4), 589-602.
- He, J., Shen, W., Divakaruni, P., Wynter, L., & Lawrence, R. (2013, June). Improving traffic prediction with tweet semantics. In *Twenty-Third International Joint Conference on Artificial Intelligence*.
- Hellinga, B., Izadpanah, P., Takada, H., & Fu, L. (2008). Decomposing Travel Times Measured by Probe-Based Traffic Monitoring Systems to Individual Road Segments. *Transportation Research Part C: Emerging Technologies*, 16(6), 768-782.
- Hofleitner, A., Herring, R., & Bayen, A. (2012). Arterial Travel Time Forecast with Streaming Data: A Hybrid Approach of Flow Modeling and Machine Learning. *Transportation Research Part B: Methodological*, 46(9), 1097-1122.
- Khairullahi, M., Nadi, S., & Nissani Samani, N. (2016). Integration of Qualitative and Quantitative Criteria Using Base Location Models in Order to Optimally Route Emergency Vehicles in Urban Environments. *Sepehr Magazine*, 25(100), 45-59. (In Persian)
- Kiartzis, S. K., Bakirtzis, A. G., & Petridis, V. (1992). Short-Term Load Forecasting Using Neural Networks. *Electric Power Systems Research*, 33, 1-6.
- Kumar, B. A., Vanajakshi, L., & Subramanian, S. C. (2017). Bus Travel Time Prediction Using a Time-Space Discretization Approach. *Transportation Research Part C: Emerging Technologies*, 79, 308-332.

- Kumar, B. A., Vanajakshi, L., & Subramanian, S. C. (2018). A Hybrid Model Based Method for Bus Travel Time Estimation. *Journal of Intelligent Transportation Systems*, 22(5), 390-406.
- Li, Y., & McDonald, M. (2002). Link Travel Time Estimation Using Single GPS Equipped Probe Vehicle. In *Proceedings the IEEE 5th International Conference on Intelligent Transportation Systems* (pp. 932-937). *IEEE*
- Lin, H. E., Zito, R., & Taylor, M. (2005, September). A review of travel-time prediction in transport and logistics. In *Proceedings of the Eastern Asia Society for transportation studies* (Vol. 5, pp. 1433-1448).
- Liu, H., Xu, H., Yan, Y., Cai, Z., Sun, T., & Li, W. (2020). Bus Arrival Time Prediction Based on LSTM and Spatial-Temporal Feature Vector. *IEEE Access*, 8, 11917-11929.
- Lu, L., Wang, J., He, Z., & Chan, C. Y. (2017). Real-time estimation of freeway travel time with recurrent congestion based on sparse detector data. *IET Intelligent Transport Systems*, 12(1), 2-11.
- Ma, Z., Koutsopoulos, H. N., Ferreira, L., & Mesbah, M. (2017). Estimation of Trip Travel Time Distribution Using a Generalized Markov Chain Approach. *Transportation Research Part C: Emerging Technologies*, 74, 1-21.
- Pahlavani, P., Delavar, M. R., & Frank, A. U. (2012). Using a Modified Invasive Weed Optimization Algorithm for a Personalized Urban Multi-Criteria Path Optimization Problem. *International Journal of Applied Earth Observation and Geoinformation*, 18, 313-328.
- Rahman, M. M., Wirasinghe, S. C., & Kattan, L. (2018). Analysis of Bus Travel Time Distributions for Varying Horizons and Real-Time Applications. *Transportation Research Part C: Emerging Technologies*, 86, 453-466.
- Rahmani, M., Jenelius, E., & Koutsopoulos, H. N. (2015). Non-Parametric Estimation of Route Travel Time Distributions from Low-Frequency Floating Car Data. *Transportation Research Part C: Emerging Technologies*, 58, 343-362.
- Watkins, K. E., Ferris, B., Borning, A., Rutherford, G. S., & Layton, D. (2011). Where Is My Bus? Impact of Mobile Real-Time Information on the Perceived and Actual Wait Time of Transit Riders. *Transportation Research Part A: Policy and Practice*, 45(8), 839-848.
- Woodard, D., Nogin, G., Koch, P., Racz, D., Goldszmidt, M., & Horvitz, E. (2017). Predicting Travel Time Reliability Using Mobile Phone GPS Data. *Transportation Research Part C: Emerging Technologies*, 75, 30-44.
- Yang, M., Chen, C., Wang, L., Yan, X., & Zhou, L. (2016). Bus Arrival Time Prediction Using Support Vector Machine with Genetic Algorithm. *Neural Network World*, 26(3), 205-217.
- Zakaria, M., Al-Shebany, M., & Sarhan, S. (2014). Artificial neural network: a brief overview. *International Journal of Engineering Research and Applications*, 4(2), 7-12.
- Zheng, F., & Van Zuylen, H. (2013). Urban Link Travel Time Estimation Based on Sparse Probe Vehicle Data. *Transportation Research Part C: Emerging Technologies*, 31, 145-157.
- Zhou, M., Wang, D., Li, Q., Yue, Y., Tu, W., & Cao, R. (2017). Impacts of Weather on Public Transport Ridership: Results from Mining Data from Different Sources. *Transportation research part C: Emerging Technologies*, 75, 17-29.