فصلنامه مهندسی ترافیک، سال بیستم، شماره ۸۳، زمستان ۱۳۹۹، ص. ۲۸-۱۷

بهینه سازی تابلوهای هوشمند ترافیکی در اعلان چگالی جریان با استفاده از شبکه عصبی

شهریار افندی زاده (مسئول مکاتبات)، دانشیار راه وترابری، عضو هیت علمی دانشگاه علم و صنعت، تهران، ایران

محمد علی روستایی، کارشناس ارشد حمل و نقل، دانشگاه آزاد واحد علوم تحقیقات، تهران، ایران

حمیدرضا ثابتی، دانشجو کارشناسی ارشد حمل و نقل، سازمان حمل ونقل و بار و مسافر شهرداری کرج

الهام منشوری نیا، دانشجو کارشناسی ارشد حمل ونقل، دانشگاه آزاد واحد ملارد

محمد منیعات، دانشجو دکترای حمل ونقل، دانشگاه آزاد واحد علوم تحقیقات، تهران، ایران

E-mail: zargari@iust.ac.ir

چکیده

بهره گیری از پیش بینی های کوتاه مدت ترافیک و استفاده از آن در مدیریت ترافیک، مسدودی-های محتمل را کاهش خواهد داد و با پایین آوردن زمان سفرها و مسافت طی شده توسط خودروها، باعث کاهش آلودگی صوتی، آلودگی هوا و همچنین هزینه های مصرفی سوخت خواهد شد. با دانستن تردد در ساعات مختلف و پیش بینی آن می توان مدیریت و برنامه ریزی بهتری برای معبرها شهری داشت در این مطالعه با استفاده از ارزیابی ترافیک به‌وسیله شبکه عصبی به ساخت مدلی پیش‌بینی ارزیابی ترافیک پرداخته شد. همچنین به ارزیابی فنی و منافع اقتصادی آن پرداخته می‌شود.در این رابطه با استفاده شمارش تردد در بزرگراه‌های شهری و با استفاده مدل شبکه عصبی به پیش‌بینی ترافیک شهر تهران پرداخته شده است، که این پردازش می‌تواند در تابلوهای هوشمند اعلان ترافیکی در جهت انحراف ترافیک راهنمای انجام دهد. در این مطالعه ،شبکه عصبی به عنوان یک ابزار برای پیشبینی تراکم جریان با دقتی مناسب $r=0.93$ ***صورت گرفت است. داده ها گذشته تردد به دلیل آنکه با پردازش دوربین توسط محقق صورت گرفته است. شبکه عصبی توان پیش‌بینی براساس داده‌های گذشته را دارد، بنابراین چنانچه از ابزارها هوشمند در محوری استفاده نشده باشد نمیتوان به پیش بینی استفاده از آن پرداخت. در شبکه عصبی استفاده شد ٤ متغیر ورودی ،تعطیلی روز،بارندگی، روز های هفته،ساعت تردد و خروجی مدل پیشبینی سرعت و تردد است، تعداد ۱۰ نورون در لایه پنهان مورد استفاده قرار گرفت و در نهایت مدل عددی به صورت یک ماتریس عددی نمایش داده شد.***

واژه‌های کلیدی: پیش‌بینی، حمل و نقل هوشمند، شبکه عصبی

۱. مقدمه

با توجه به رشد روزافزون ترافیک مسیرها، شیوه‌های مرسوم مدیریت ترافیک ناکارآمد می‌باشند. حجم ترافیک بالا و تراکم خودروها، سبب ایجاد تأخیر زیاد در عبور و مرور خودروها و حتی رخداد تصادف می‌شود. به منظور برطرف کردن نیازهای رو به رشد سیستم حمل‌ونقل امروزی، نیاز به یک سیستم حمل‌ونقل هوشمند است. شبکه‌های بیسیم خودرویی می‌توانند در سیستم‌های حمل‌ونقل هوشمند بسیار مفید واقع شوند.نقش بسیار مهم حمل‌ونقل در زندگی روزمره و ناتوانی مسیرهای شبکه معابر در قبال پذیرش هر حجم از تردد و لزوم پیشگیری از حوادث ، اهمیت برنامه‌ریزی حمل‌ونقل را نمایان می‌کند. پروتکل‌های متعددی برای تشخیص مناطق شلوغ و پرتراکم و وضعیت واقعی ترافیک در داخل مناطق شهری و بزرگراه‌ها پیشنهاد شده است . هدف از این مطالعات بررسی برخی از ویژگی‌های ترافیک مناطق مورد بررسی مانند: شدت ترافیک، سرعت ترافیک، و یا برآورد زمان سفر است .به منظور بررسی این ویژگی‌های ترافیکی، داده‌های اولیه همچون موقعیت خودرو، سرعت، جهت، مقصد و غیره وسیله نقلیه در منطقه مورد نظر باید جمع‌آوری و تجزیه‌وتحلیل شود. امروزه ۵۵ درصد جمعیت جهان در مناطق شهری زندگی می‌کنند، پیش‌بینی می‌شود که تا سال ۲۰۵۰ به ٦٨ درصد افزایش یابد. امروزه مسائل و مشکلات حمل‌ونقل از قبیل آلودگی‌های زیست‌محیطی، کاهش منابع انرژی، افزایش خسارت‌های مادی و معنوی ناشی از سوانح و تصادفات، مشکلات نظارت و مدیریت در حمل‌ونقل برون‌شهری، افزایش زمان‌های تلف شده و روند رشد سریع تقاضای حمل‌ونقل به‌ویژه در ساعات اوج درکلان شهرهای دنیا به یک مشکل جدی تبدیل شده است. به‌علاوه با افزایش وسایل نقلیه نیاز برای ایجاد یک ترافیک روان ، سیستم‌های هشدار دهنده برخورد، سیستم‌های اخطاردهنده شرایط خطرناک بیشتر از پیش احساس می‌شود.

۲. پیشینه تحقیق

سیستمهای حمل‌ونقل هوشمند سیستمهای عملیاتی حمل‌ونقل، شامل مدیریت ترافیک، مدیریت ناوگان حمل‌ونقل همگانی و تجاری را متحول نموده و در عرضه مؤثرتر، کاراتر و قابل‌اعتمادتر تسهیلات حمل‌ونقل عملکرد غیرقابل پیش‌بینی داشته است. سیستم‌های حمل‌ونقل هوشمند، برنامه ریزان و سیاست گذران حمل‌ونقل را شگفت زده نموده است. بطوریکه هرچه واقعی‌تر می‌توانند از نحوه عملکرد سیستم مطلع شوند و در صورت مشاهده مشکل و کاستی در این بخش خیلی راحت‌تر از گذشته، نسبت به رفع آن اقدام کنند با افزایش جمعیت و رشد روزافزون ترددهای جاده‌ای، نیاز به استفاده از سیستم‌های هوشمند حمل‌ونقل بمنظور اطلاع رسانی دقیق و محاسبه شده زمان سفر جهت مدیریت بهینه و دقیق مسافران جاده‌ای و کاهش تلفات زمانی آن‌ها است که اثرات تجاری بسیار مهمی را نیز در پی خواهد داشت.

پروتکل‌های متعددی برای تشخیص مناطق شلوغ و پر تراکم و وضعیت واقعی ترافیک در داخل مناطق شهری و بزرگراه‌ها پیشنهاد شده است. هدف از این مطالعات بررسی برخی از ویژگی‌های ترافیک مناطق مورد بررسی مانند: شدت ترافیک، سرعت ترافیک، و یا برآورد زمان سفر می‌باشد.

به منظور بررسی این ویژگی‌های ترافیکی، داده‌های اولیه همچون موقعیت خودرو، سرعت، جهت، مقصد و غیره وسیله نقلیه در منطقه مورد نظر باید جمع‌آوری و تجزیه‌وتحلیل شود. در برخی از این پروتکل‌های پیشنهادی، برای جمع آوری اطلاعات زمان واقعی ترافیک وسایل نقلیه، از تجهیزاتی همچون سنسور مانند شناساگرهای حلقه، فن آوری مادون قرمز ، رادارهای مایکروویو و دستگاه های ضبط ویدئو استفاده شده است.

پیش بینی کوتاه مدت جریانهای ترافیکی بخش مهمی از سیستم های کنترل ترافیک و اطلاعات است. با برآورد درست تردد از آنچه جریان در نیم ساعت یا یک ساعت خواهد بود، می توان با

اتخاذ اقدامات مناسب در پیش از وقوع گرفتگی در راه اقدام های مناسب انجام داد. با الگوریتم ها و مدلهای مختلف پیش بینی دقیق تر ممکن است .در این فصل به بررسی این مدل ها پرداخته می شود.این الگوریتم ها شامل : فیلتر کالمن که توسط اوکتانی و استفاندس[1] مطالعات اولیه آن صورت گرفت. سری زمانی ،براساس مطالعات اولیه نیکولسون و سان[2] صورت گرفته است و مدلهای رگرسیون خطی، آریما،شبکه عصبی است.

اولین تلاش های تخمین جریان ترافیک در کوتاه مدت به سال های ابتدای دهه ۷۰میلادی باز می گردد، در آن زمان از داده های حاصل از شبیه سازی ترافیک استفاده می شد. گسترش ITS و افزایش شناسگرهای ترافیکی و سیستم های جمع آوری اطلاعات ترافیکی باعث شده است تا پیش بینی جریان ترافیک در دهه اخیر مورد توجه قرار گیرد.

از دهه ی۱۹۸۰، پیش بینی کوتاه مدت ترافیک به جز مهم در تحقیقات و کاربردهای سیستم های هوشمند حمل ونقل تبدیل شده است. از آن زمان تاکنون روش های مختلفی مورد بررسی قرار گرفته اند و محققین در صدد یافتن روش های مناسب و کارا بر آمده‌اند. این روشها بر ایجاد روش های جدید پیش بینی یا بهبود روش های موجود تمرکز دارند .بن آکیوا و همکاران با توجه به شباهت های بین این روش ها، آن ها را به سه دسته ی مدل های آماری، مدل های بزرگ مقیاس و انتخاب مسیر بر اساس تخصیص دینامیکی تقسیم بندی کرده اند. ولاهوگیانی و همکاران در مقاله ای مروری این روش ها را به سه دسته‌ی پارامتریک، غیر پارامتریک و هیبریدی تقسیم بندی کرده اند. چنگ و همکاران دسته بند ها را به صورت روش های میانگین تاریخچه ی زمانی، روشهای سری زمانی،روش‌های حالت –فضا و روش های غیر پارامتریک تعریف می کند. علیرغم دسته بندی های متفاوت، هدف همه روش ها یکسان است. در این فصل، از قالب دسته بندی ولاهوگیانی استفاده گردیده است.

یکی از نخستین استفاده‌های روش‌های پارامتریک توسط اکیوتی وستفاندس در سال ۱۹۸٤ صورت گرفت که در آن برای اولین بار از مدل فیلترهای کالمن برای پیش‌بینی حجم ترافیک در محدوده‌ی شهری و به‌طور خاص در رمپ ورودی آزادراهی مورد استفاده قرار گرفت.این روش توسط چن وچین و نیز استیون و همکاران برای تخمین زمان سفر استفاده گردید. ستیو پولس وکارلافتیس نشان دادند که این مدل در ساعت‌های مختلفی از شبانه‌روز می‌تواند نتایج بهتری نسبت به مدل آریما ارائه دهد. ینگ و همکاران نیز از فیلترهای کالمن برای پیش‌بینی سرعت ترافیک استفاده نمودند. گوو و همکاران نشان دادند که طبیعت شرایط ترافیکی ناهمسان است و انتظار می‌رود فیلترهای کالمن تطبیق‌پذیر با فرایند تطبیق واریانس متغیر با زمان نتایج بهتری نسبت به فیلترهای کالمن سنتی ارائه دهند. گوو وهمکاران در سال ۲۰۱٤ با استفاده از این روش کمی سازی غیرقطعی پیش‌بینی‌ها را لحاظ نمودند در ادامه به مطالعه چین ،چن اشاره می‌شود. دکتر می چین و دکتر استون چن از انستیتو نیو جرسی در سال ۲۰۰۱ مطالعه جهت پیش‌بینی زمان سفر انجام دادند. هدف این مطالعه به این منظور بود که سریع‌ترین مسیر به استفاده کننده‌گان از مسیر اطلاع‌رسانی کند. تفاوت این مطالعه با مطالعات دیگر در آن است که در تحقیقات دیگر ،زمان سفر به عنوان تابعی از حجم ،چگالی یا سرعت به صورت غیرمستقیم محاسبه می‌گردید ، اما در این تحقیق این پارامتر به‌صورت مستقیم محاسبه شده است.از معایب پیش‌بینی غیرمستقیم زمان سفر می‌توان به اختصاصی بودن روابط در مکان‌های مختلف و تغییرات احتمالی روابط در شرایط نزدیک به ظرفیت اشاره نمود.از آنجا که پیش‌بینی زمان سفر مستلزم تغییرات مستمر در مقادیر مشاهده شده است، روش فیلترهای کالمن به عنوان روش مورد استفاده در این تحقیق انتخاب شده است . به طور خاص ،در این روش با استفاده از زمان سفر خودروهای متحرک در مسیر به منظور پیش بینی زمان سفر در بازه ی زمانی بعدی استفاده شده است . در این مطالعه که بیشتر بر پایه مطالعات دکتر جین حا گو و همکاران است، جین حاگو وهمکاران پس اشاره به اینکه فیلتر کالمن همان مدل های ساریما[3] که با مدل های

گارچ[4] ترکیب شده است . در این مطالعه از داده‌های ۱۵ دقیقه استفاده شده است که مربوط به دو کشور انگلیس و آمریکاست، برای تابع خطا از تابع متوسط خطای مطق[5] و تابع متوسط خطای حاضر[6] و ریشه متوسط مربع خطا[7] استفاده شده است. در انتها به مقایسه بین روش های مختلف فیلتر کالمن با هم پرداخته شده است.دیگر مطالعه توسط ماروکو لیپی و همکاران صورت گرفته است که با سری زمانی به پیش بینی جریان ترافیک پرداخته است،نکته جالب در این تحقیق مقایسه بادیگر مدل ها مخصوصا روش های یادگیری ماشین است، تقریبا در این مطالعه اکثر روش های موفق در پیش بینی مانند :شبکه عصبی[8]، بردار پشتیبان،آریما[9]، ساریما، کالمن[10]، شبکه عصبی شعاعی[11] مورد بررسی قرار گرفته درقسمت نتیجه روش های ساریما و کالمن به عنوان روش های بهتری معرفی شده است ،که زمانی که مدل ساریما با کالمن ترکیب می گردد بهترین مدل و بهترین پیش بینی صورت گرفته است .روش های هیبریدی نیز در سالهای اخیر محبوبیت زیادی پیدا کرده اند. در مطالعه ای در دانشگاه کانادا دکتر زودو زنگ و همکاران توسط روش نزدیکترین همسایه حجم ترافیک راپیش بینی کرده اند و با روش فیلترینگ کالمن موفقیت آن مقایسه شده است .هرچند روش نزدیک ترین همسایه امتیاز های را نسبت به روش کالمن دارد اما در کل دقت پیش پیش بینی همچنان تغییر قابل ملاحضه ای نکرده است .روش های یادگیری عمیق[12] و یادگیری ماشین نیز در سال های اخیر باتوجه به رشد توانایی و قدرت محاسبات کامپیوتر مورد توجه زیادی قرار گرفته است.

۳. روش تحقیق

از آنجا که هدف این تحقیق بهینه‌سازی تابلوهای هوشمند ترافیکی در اعلان چگالی جریان با استفاده از شبکه عصبی است، به بررسی و ارزیابی مدل ساخته شده برای سنجش ترافیک با شبکه عصبی پرداخته می‌شود. در مدل ساخته شده که سنجش چگالی ترافیک را پیش می‌کند. پس از آن بررسی می‌گردد مزایای اقتصادی و ایمنی آن چگونه است . مراحل انجام تحقیق به این صورت است : که در گام اول به جمع آوری داده‌ها پرداخته می‌شود و در ادامه نیاز به‌به اصلاح و بازسازی داده‌ها است. در گام بعد مدل اولیه ساخته می‌شود. در گام بعد مدل کالیبره و با سعی و خطا توابع و ضرایب اصلاح می‌شود. در گام بعد مدل اجرا می‌گردد البته درصورتی که خطا مدل کاهش یافته باشد وگرنه این مرحله تکرار می‌گردد،تا ضریب رگرسیون به مقدار مناسب برسد.در گام بعد با استفاده از مدل پیش‌بینی صورت می‌گردد. و میزان خطا مدل مقایسه می‌شود . در انتها میزان صحت پیش‌بینی ارزیابی می‌گردد و در گام بعد به ارزیابی ایمنی و اقتصادی مدل ساخته شده پرداخته می‌شود. در ادامه اعتبار سنجی و نتیجه‌گیری صورت می‌گیرد.

متغیرها که در نرم‌افزار وارد می‌گردد:

- P1:تعطیلی روز
- P2:بارندگی
- P3:روزهای هفته
- P4: ساعت تردد، ساعت تردد در یک روز می‌باشد و بنابراین طبق ۲٤ ساعت در یک روز ، این متغیر از ۱تا ۲٤ می‌باشد.

۳-۱ خروجی مدل

خروجی این پژوهش چگالی است که درنهایت پیش‌بینی می‌گردد،برای بدست آوردن چگالی جریان ،نیاز است سرعت و تردد پیش‌بینی شود و با توجه به رابطه گرین‌برگ برهم تقسیم گردد تا چگالی جریان میزان تراکم جریان برای اعلام توسط تابلوهای هوشمند مشخص گردد.

- Y1: پیش‌بینی سرعت
- Y2: پیش‌بینی تردد

بدست آوردن مدل شبکه عصبی یک فرآیند رفت و برگشتی است و تا حدودی روشی بر اساس سعی و خطا است زیرا به عنوان مثلاً برای مشخص کردن تعداد مناسب نورون برای وزن‌ها از تعداد نورون کمتر به بیشتر در نرم‌افزار قرار داده گردیده و هر کدام که Rرگرسیون بیشتر و نزدیک ۱ دارد آن تعداد نورون

انتخاب می‌شود . بدیهی است که این ،فرآیند طولانی و جزییات آن در این مطالعه نمی‌آیند بلکه بهترین و آخرین نتیجه و مدل آورده می‌شود. برای تولید مدل شبکه عصبی معمولا" تعدادی شبکه را ساخته و مورد تست قرار داده می‌شود که در کل تعداد زیادی نرم‌افزار متلب اجرا[۱۳] می‌گردد و کارایی آن [۱۴] مورد بررسی قرار می‌گیرد. دوباره یادآوری این نکته ضروری است که برای بررسی این روش به دلیل ماهیت متفاوت روش شبکه عصبی (در کل روش‌های یادگیری ماشین) از روش‌های رگرسیون یا پارامتریک یا فیت کردن داده‌ها، توجه بر روی نوع توابع و تعداد نورون‌ها و تعداد متغیرهای ورودی توجه است . در این تحقیق از یک شبکه عصبی با دولایه پنهان استفاده شده است ،که در لایه اول از تابع سیگموید تانژانت استفاده شده است، متغیرها در وزن w1 ضرب می‌گردند و منهای بایاس (مشابه عرض از مبدأ در معادلات خطی) می‌گردد و سپس وارد تابع می‌گردند. بنابراین خروجی لایه اول پنهان ماتریس a1 است که وارد مرحله بعد و در لایه پنهان میگردد، دوباره همین فرایند برای لایه پنهان دوم اجرا می‌گردد و ماتریس a1 در ماتریس وزن w2 ضرب و منهای بایاس b2 می‌گردد و تابع خطی[۱۵] دران اعمال می‌گردد تا خروجی مدل به صورت یک عدد که تعداد تصادفات را نشان می‌دهد خارج گردد.

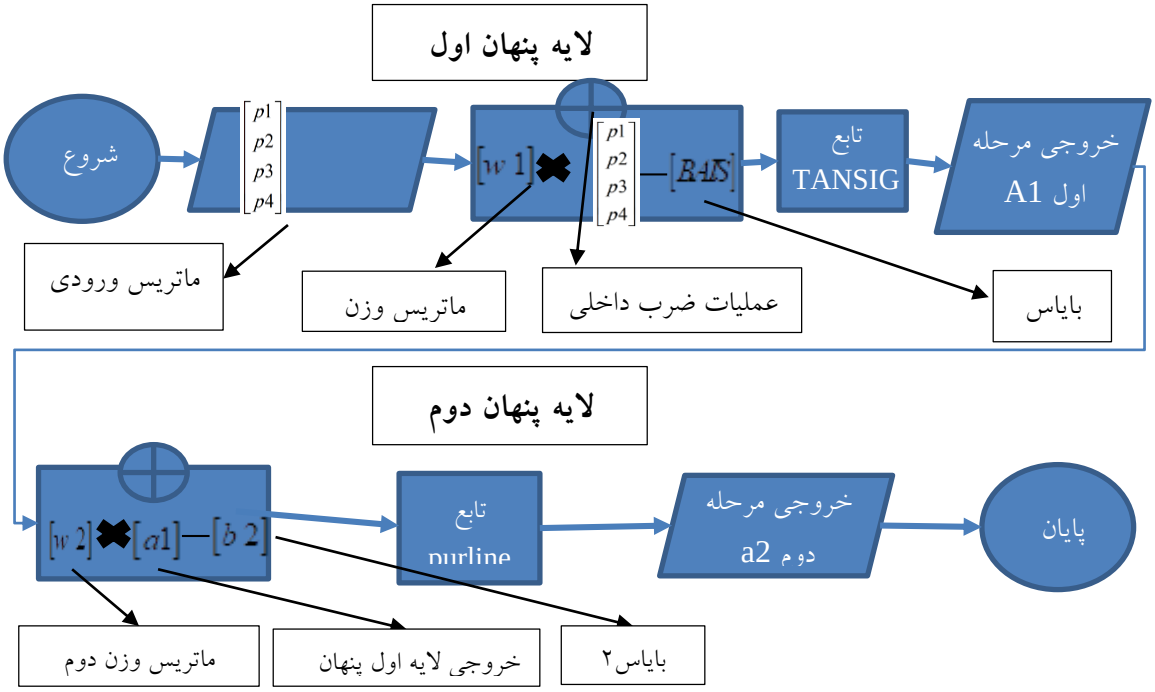

شکل ۱. مدل مفهمی این پژوهش

٤. مطالعه موردی

در تصویر۲ناحیه از مطالعه موردی در شهر تهران آمده است، مشخص شده است.

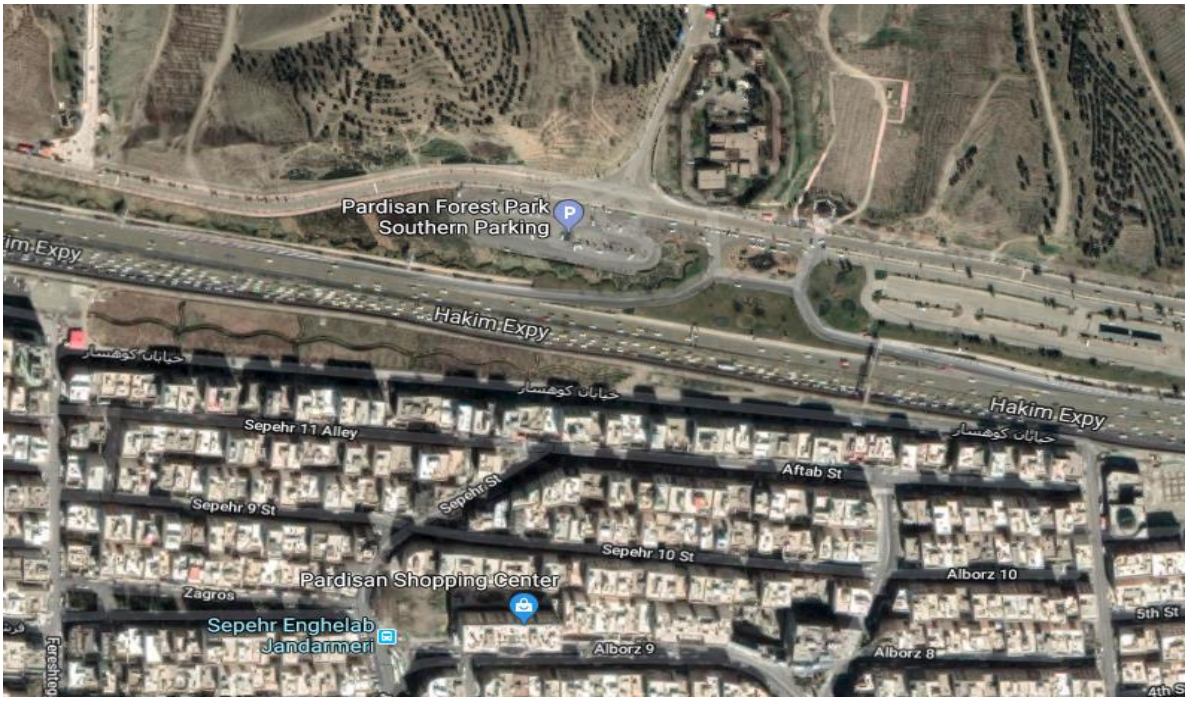

شکل ۲. تصویر هوایی از بزرگراه حکیم

بزرگراه آیت‌الله حکیم که در مرکز تهران واقع شده یکی از معابر اصلی پایتخت است و در موازات بزرگراه شهید همت قرار دارد. این بزرگراه که به نام آیت‌الله سید محمدباقر حکیم نام‌گذاری شده است، در مسیر شرق به غرب و بالعکس قرار دارد و از تونل رسالت در شرق آغاز و به بزرگراه علامه جعفری در غرب ختم می‌شود. این بزرگراه تقریباً ۹ کیلومتر مسافت دارد و از ٤ خط و در بعضی از مسیرها ۳ خط سرعت در دو باند تشکیل شده است. برای تحلیل و بدست آوردن پیش‌بینی نیاز است سرعت متوسط و تعداد تردد را برای وسایلی که در محور مورد مطالعه تردد می‌کنند را بدست آورده شود. توانای دوربین فیلم‌برداری در برداشت سرعت لحظه‌ای و شمارش تعداد وسایل است. بنابراین زمانی که از محور مورد مطالعه توسط دوربین فیلم‌برداری شد، نیاز است از روی فیلم مشاهده‌شده اطلاعات تردد و سرعت بدست آید. در نمودار تردد ٤-۳ حجم تردد وسایل نقلیه در این بزرگراه نشان داده شده است.تعداد تردد بین ساعات ۲-۵ صبح کمترین است در ساعت ۷صبح به بیشترین مقدار خود می‌رسید و سپس در یک محور تقریباً مستقیم با اندکی کم یا زیاد حرکت می‌کند.

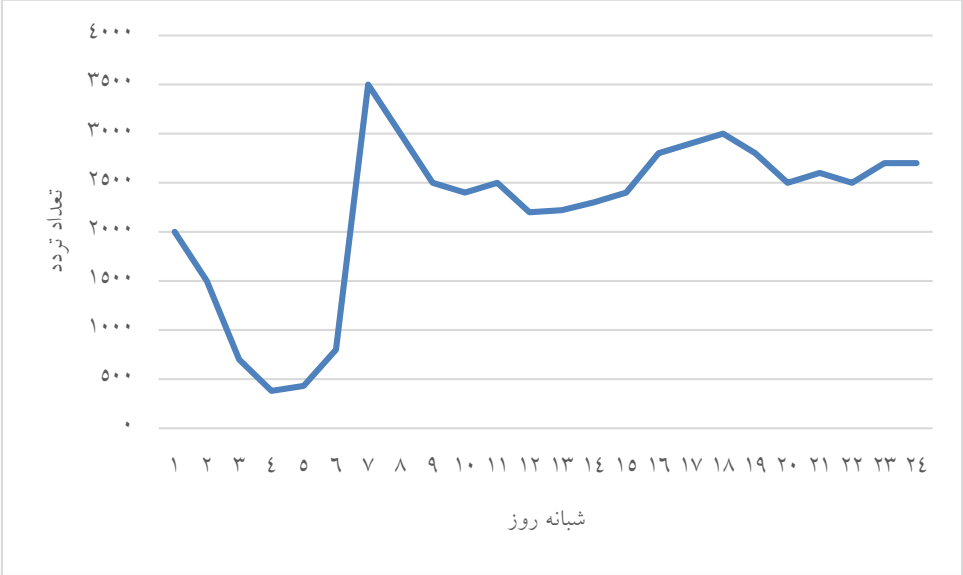

شکل ۳. نمودار تعداد تردد متوسط در شبانه‌روز برای بزرگراه حکیم(تهران)

در شکل ٤نمودار سرعت – چگالی آورده شده ،نمودار الگوی سهمی گرین شیلد را تقریباً رعایت کرده است، علت آن است که در بزرگراه رمپ‌های ورودی و خروجی زیادی وجود دارد، بنابراین تأثیرات ورودی و خروجی‌ها بر جریان تأثیر دارد که الگوی گرین شیلد این مهم مورد بررسی قرار نگرفته است. برای مثال ممکن است در یک حجم تردد کم ،سرعت پایینی به دلیل بازگشت جریان در رمپ‌ها خروجی بر مسیر اصلی به وجود آید، که متضاد با الگوی گرین شیلد است.

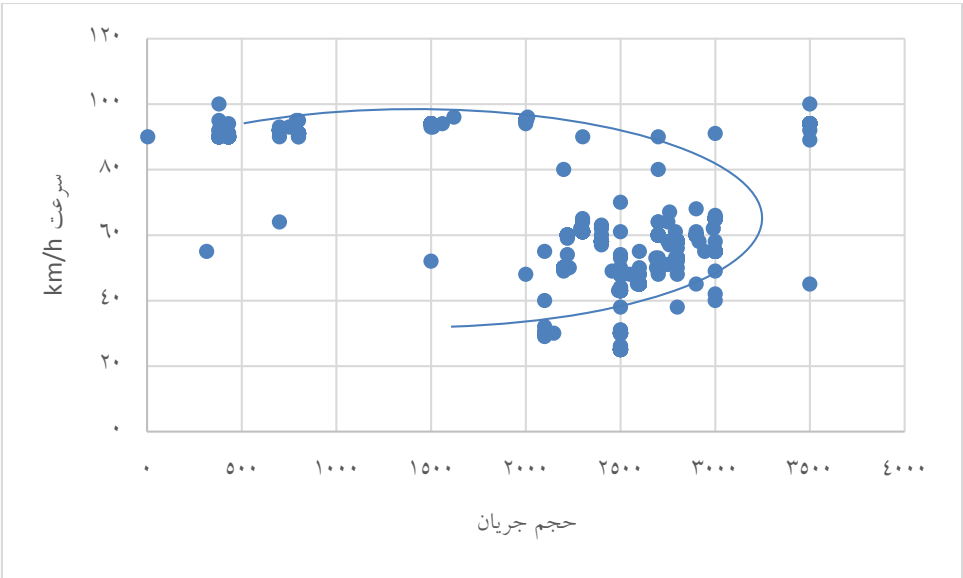

شکل ٤. نمودار سرعت – حجم بزرگراه حکیم (تهران)

برای ساخت مدل در شبکه عصبی از داده‌های گذشته استفاده می‌گردد در این مطالعه هدف پیش‌بینی چگالی جریان است تا به این وسیله برای تابلوهای هوشمند بتوان اعلام جریان کرد متغیر ورودی در مدل ٤ و تعداد نورون عصبی ۱۰ در لایه پنهان و تابع اصلی تانژانت هیپر بولیک سیگموئید است.

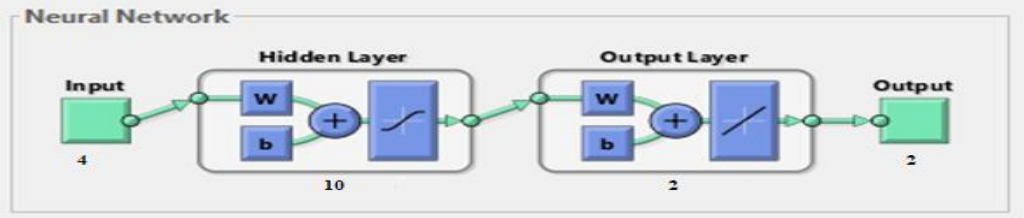

شکل ۵. مدل تصویری شبکه عصبی برای پیش‌بینی چگالی جریان

فلوچارت شکل ۵گویای این مطلب است، این فلوچارت که خروجی نرم‌افزار متلب است مدل استفاده شده را بیان می‌کند. عدد ۱۰ تعداد نورون استفاده شده است. در جدول ۱ مدل عددی ساخته شده برای پیش بینی بزرگراه حکیم است در قسمت ستون w(1,1) ماتریس وزن برای لایه پنهان (مرحله اول) که یک ماتریس است که به دلیل آنکه سه متغیر و ۱۰ نورون عصبی دارد. در ستون W(1,2)که یک ماتریس است و در ستون‌های بعدی بایاس مربوط به لایه اول و دوم است.

جدول ۱. مدل عددی ساخته شده برای پیش بینی چگالی

شماره نورون	وزن‌های مدل پرسپترون شبکه عصبی تردد						
	w(1,1)			w(1,2)	bias1	bias2
۱	0.0227	-0.138	0.58979	-8.0505	-1.963	0.0329	2.0656
۲	5.8736	-0.184	-10.513	3.74439	-9.187	-1.105	5.36
۳	0.0284	10.116	0.01711	-1.808	2.9135	0.8074	
٤	-0.129	5.3653	-0.1741	-2.379	2.9302	-0.554	
٥	0.0239	-7.648	2.36878	-3.357	2.6634	0.6407	
٦	0.1518	1.4948	1.98851	0.6304	-2.371	3.3821	
۷	3.90276	0.58979	-8.0505	0.01711	-6.4093	-6.4093	
۸	-0.036	-10.513	3.74439	-0.1741	-0.9393	-6.4093	
۹	-2.8004	6.95033	-3.1723	2.36878	9.46674	2.9302	
۱۰	-0.129	5.3653	-0.1741	0.8074	2.9135	9.46674	

در شکل ٦ چهار نمودار رگرسیون داده‌های هدف (target) برای آموزش و تست واعتبار سنجی است و میانگین آن در نمودار allاست. در هر نمودار خط رگرسیون نمایان گر سازگاری (fit) بین بهترین نتیجه خروجی شبکه (outputs) و داده‌های هدف (targets) که داده‌های هدف در اینجا همان تردد و سرعت دستگاه تردد شمار است.

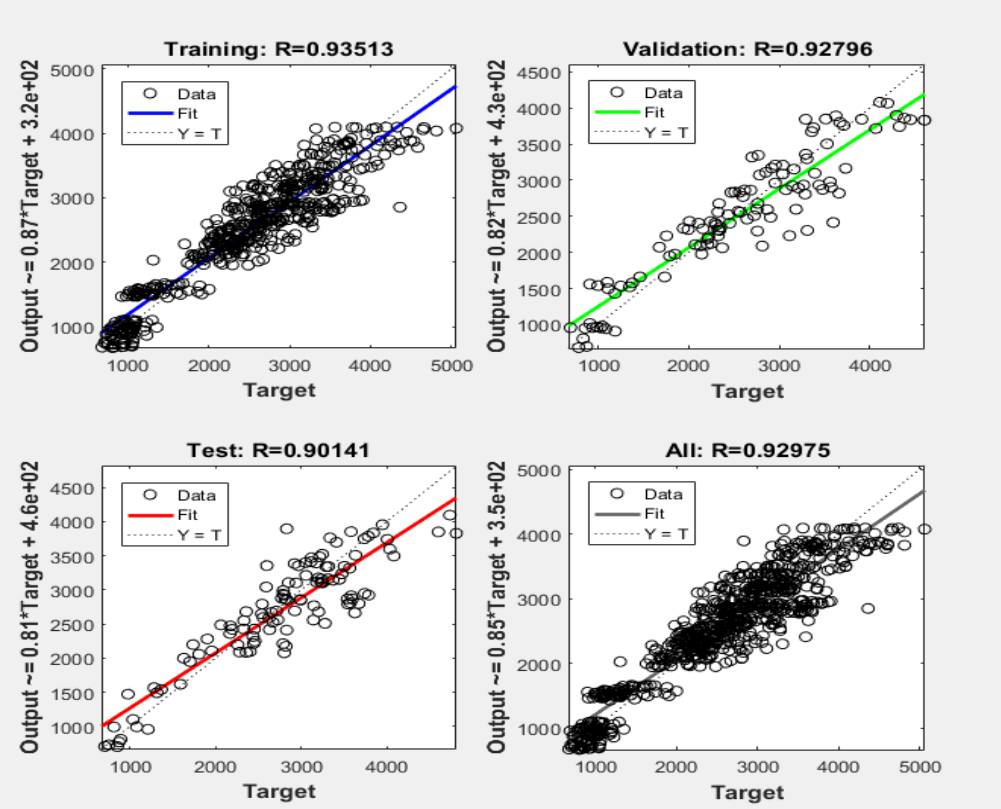

شکل ٦. نمودار رگرسیون ارزیابی مدل شبکه عصبی برای پیش‌بینی چگالی جریان

هر چه مقدار R به یک نزدیک‌تر باشد ارتباط بیشتری بین خروجی‌های شبکه عصبی و داده‌های هدف وجود دارد.مقدار R در همه نمودارها تقریباً یکسان است و تجمع داده‌ها بر روی خط رگرسیون نسبتاً خوب است که نشان از کارآمدی شبکه می‌دهد .که توانای مناسب شبکه عصبی جهت پیش‌بینی را نشان می‌دهد و که بطور متوسط رگرسیون R=0.92 است. در شکل ۷ نمودار خط چین پیش‌بینی حاصل از مدل است و نمودار ممتد داده‌های واقعی است که در مورد چگالی جریان بزرگراه حکیم است. نمودار عمودی چگالی جریان است. نمودار افقی ساعت تردد در هفته اول است، از آنجا که پیش بینی برای یک هفته است و تعداد ساعات در یک روز ٢٤ است، پس تعداد ساعات نمایش داده شده در محور افقی ١٦٨ است که البته نرم‌افزار اکسل تا ١٨٠ نمایش داده است. می‌توان دید که نمودار پیش‌بینی(خط‌چین) بر روی نمودار واقعی (خط ممتد) است در بعضی قسمت‌ها موج‌ها پیش‌بینی بر روی موج‌های آبی قرار نگرفته است این به دلیل ماهیت مقاومتی شبکه عصبی نسب به داده‌های غیرمعمول است. در شکل ۷ نمودار خط‌چین پیش‌بینی تردد حاصل از مدل است و نمودار خط ممتد داده‌های واقعی است که در مورد چگالی جریان است، که جهت مقایسه بهتر دریک جا آورده شده است.

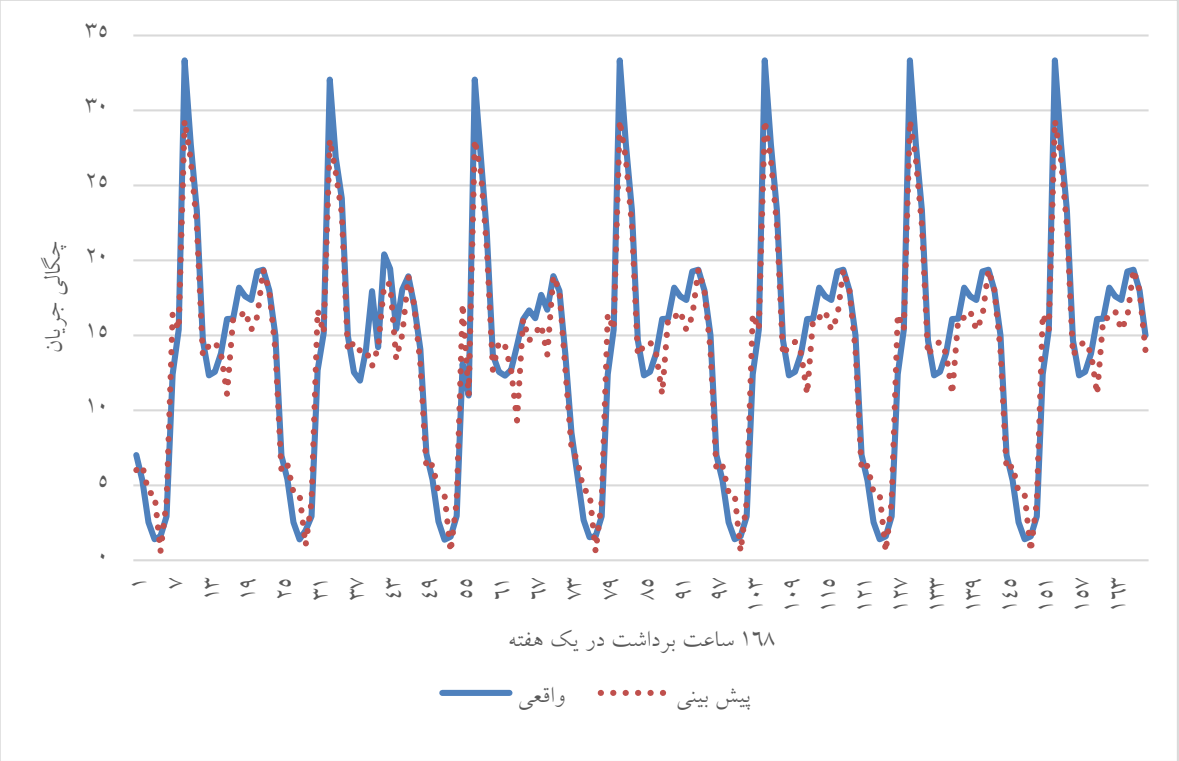

شکل ۷. مقایسه دو نمودار پیش‌بینی چگالی و داده‌های واقعی

۵. نتیجه‌گیری

مدل عصبی می‌تواند در حمل‌ونقل هوشمند به‌عنوان یک ابزار برای پیش‌بینی تراکم جریان با دقت مناسب که در اینجا با r=0.92 صورت گرفت کمک کند. شبکه عصبی توان پیش‌بینی بر اساس داده‌های گذشته را دارد، بنابراین چنانچه از ابزارها هوشمند در محوری استفاده نشده باشد نمی‌توان به پیش‌بینی استفاده از آن پرداخت. در این محور به‌جز دوربین ثبت تخلف سرعت و تابلو هوشمند اعلان ترافیک از ابزار دیگری استفاده نشده بنابراین ارزیابی کامل بدون داده‌های گذشته را دچار مشکل می‌کند.

در شبکه عصبی استفاده شد ٤ متغیر ورودی، تعطیلی روز،بارندگی، روزهای هفته،ساعت تردد و خروجی مدل پیش‌بینی سرعت و تردد است، تعداد ۱۰نورون در لایه پنهان مورد استفاده قرار گرفت و در نهایت مدل عددی به صورت یک ماتریس نمایش داده شد

در مورد پیش‌بینی ترافیک تاکنون مقالات و روش‌های مختلفی استفاده شده است و همچنان در حال توسعه است، این توسعه وابستگی زیادی به ابزارهای مکانیکی که تردد را برداشت می‌کند دارد. امروزه شرکت‌ها پیش رو درزمینه‌ی پیش بینی زمان سفر و میزان تردد چون گوگل از اطلاعات جی‌پی‌اس (GPS) که خودرو از طریق گوشی همراه خود ارسال می‌کند برای پیش‌بینی در مسیریاب‌ها استفاده می‌کنند. مقالات اخیر نشان داده است که پژوهشگران برای پیش‌بینی ازاین‌گونه ابزارها بهره برده‌اند و مسیر آینده محدود به تردد شمارها و دوربین‌ها و سنسورها جاده‌ای نیست. این محدودیت بر این مقاله بود و داده‌های جی‌پی‌اس قابل دسترس نبود در آینده، دسترسی به این داده‌های راحت‌تر خواهد بود بنابراین این مدل با این‌گونه داده‌ها می‌تواند دوباره‌نویسی شود و دقت بسیار بهتری بدست آید.

٦. پی‌نوشت‌ها

1. Okutani, YJ Stephanedes
2. H.NicholsonC.D.Swann
3. SARIMA

4. GARCH
5. Mean absolute error
6. Mean absolute percentage error
7. RMSE
8. ANN
9. ARIMA
10. KALMAN
11. RBF
12. Deep learning
13. Run
14. performance
15. Purline (در این مطالعه)

۷. مراجع

– نوادار, و. کاردان حلوایی, سیستم حمل و نقل هوشمند, سومین کنگره ملی مهندسی عمران. ۱۳۸٦, دانشگاه تبریز.

– پور باقر, شریف طهرانی، حاجی جعفری, بررسی و تحلیل اثرات اجرای ITS درکارایی سیستم حمل و نقل همگانی شهر مشهد، دومین همایش سیستم های حمل و نقل هوشمند جاده‌ای. ۱۳۹۵، سازمان راهداری و حمل و نقل جاده ای.

– معاضدی, اخلاصی نیا، بررسی عملکرد و سطح سرویس تقاطعات هوشمند مجهز به سیستم کنترل مرکزی SCATS مطالعه موردی: تقاطع گلستان نور، کلانشهر اهواز، دومین همایش سیستم‌های حمل‌ونقل هوشمند جاده ای. ۱۳۹۵، سازمان راهداری و حمل‌ونقل جاده ای.

- Bauza, R., J. Gozalvez, and J. Sanchez-Soriano. Road traffic congestion detection through cooperative vehicle-to-vehicle communications. in IEEE Local Computer Network Conference. 2010. IEEE.

- Fukumoto, J., et al. Analytic method for real-time traffic problems by using Contents Oriented Communications in VANET. in 2007 7th International Conference on ITS Telecommunications. 2007. IEEE.

- Dornbush, S. and A. Joshi. StreetSmart traffic: Discovering and disseminating automobile congestion using VANET's. in 2007 IEEE 65th Vehicular Technology Conference-VTC2007-Spring. 2007. IEEE.

- Morla, R., Vision of congestion-free road traffic and cooperating objects. Sentient Future Competition, 2005.

- Huang, D., S. Shere, and S. Ahn. Dynamic highway congestion detection and prediction based on shock waves. in Proceedings of the seventh ACM international workshop on VehiculAr InterNETworking. 2010. ACM.

- Pongpaibool, P., P. Tangamchit, and K. Noodwong. Evaluation of road traffic congestion using fuzzy techniques. in TENCON 2007-2007 IEEE Region 10 Conference. 2007. IEEE.

- Okutani, I. and Y.J. Stephanedes, Dynamic prediction of traffic volume through Kalman filtering theory. Transportation Research Part B: Methodological, 1984. 18(1): p. 1-11.

- Nicholson, H. and C. Swann, The prediction of traffic flow volumes based on spectral analysis. Transportation Research, 1974. 8(6): p. 533-538.

- Vlahogianni, E.I., M.G. Karlaftis, and J.C. Golias, Short-term traffic forecasting: Where we are and where we’re going. Transportation Research Part C: Emerging Technologies, 2014. 43: p. 3-19.

- Vlahogianni, E.I., J.C. Golias, and M.G. Karlaftis, Short-term traffic forecasting: Overview of objectives and methods. Transport reviews, 2004. 24(5): p. 533-557.

- Chen, M. and S. Chien, Dynamic freeway travel-time prediction with probe vehicle data: Link based versus path based. Transportation

enhanced by constrained linearly sewing principle component algorithm. Transportation Research Part C: Emerging Technologies, 2014. 43: p. 143-157.

- Polson, N.G. and V.O. Sokolov, Deep learning for short-term traffic flow prediction. Transportation Research Part C: Emerging Technologies, 2017. 79: p. 1-17.

- Lin, L., J.C. Handley, and A.W. Sadek, Interval Prediction of Short-Term Traffic Volume Based on Extreme Learning Machine and Particle Swarm Optimization. 2017.

- Yang, S., et al., Ensemble Learning for Short-Term Traffic Prediction Based on Gradient Boosting Machine. Journal of Sensors, 2017. 2017.

- Ling, X., et al. Short-term traffic flow prediction with optimized Multi-kernel Support Vector Machine. in Evolutionary Computation (CEC), 2017 IEEE Congress on. 2017. IEEE.

- Elhenawy, M., H.A. Rakha, and H. Chen. Traffic Stream Short-term State Prediction using Machine Learning Techniques. in VEHITS. 2016.

- Haykin, S., Neural networks: a comprehensive foundation. 1994: Prentice Hall PTR.

- Zhao, Z., et al., LSTM network: a deep learning approach for short-term traffic forecast. IET Intelligent Transport Systems, 2017. 11(2): p. 68-75.

Research Record: Journal of the Transportation Research Board, 2001(1768): p. 157-161.

- Yang, F., et al., Online recursive algorithm for short-term traffic prediction. Transportation Research Record: Journal of the Transportation Research Board, 2004(1879): p. 1-8.

- Guo, J., W. Huang, and B.M. Williams, Adaptive Kalman filter approach for stochastic short-term traffic flow rate prediction and uncertainty quantification. Transportation Research Part C: Emerging Technologies, 2014. 43: p. 50-64.

- Chang, G., et al., A summary of short-term traffic flow forecasting methods, in ICCTP 2011: Towards Sustainable Transportation Systems. 2011. p. 1696-1707.

- Lippi, M., M. Bertini, and P. Frasconi, Short-term traffic flow forecasting: An experimental comparison of time-series analysis and supervised learning. IEEE Transactions on Intelligent Transportation Systems, 2013. 14(2): p. 871-882.

- Lopez-Garcia, P., et al., A hybrid method for short-term traffic congestion forecasting using genetic algorithms and cross entropy. IEEE Transactions on Intelligent Transportation Systems, 2016. 17(2): p. 557-569.

- Shang, Q., et al., A hybrid short-term traffic flow prediction model based on singular spectrum analysis and kernel extreme learning machine. PLoS one, 2016. 11(8): p. e0161259.

- Lopez-Garcia, P., et al. Short-term traffic congestion forecasting using hybrid metaheuristics and rule-based methods: A comparative study. in Conference of the Spanish Association for Artificial Intelligence. 2016. Springer.
- Zheng, Z. and D. Su, Short-term traffic volume forecasting: A k-nearest neighbor approach