

الگوریتم ترکیب فازی مدل‌های پیش‌بین جریان ترافیک در حضور داده‌های اغتشاشی

سیدهدادی حسینی^۱، استادیار؛ بابک نجار اعرابی^۲، دانشیار؛ بهزاد مشیری^۲، استادا؛ اشکان رحیمی کیان^۲، دانشیار

۱- گروه مهندسی برق - دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران - تهران - ایران - sh_hosseini@itrc.ac.ir

۲- گروه مهندسی کنترل - دانشکده مهندسی برق و کامپیوتر - دانشگاه تهران - تهران - ایران - {araabi, moshiri, arkian}@ut.ac.ir

چکیده: پیش‌بینی جریان ترافیک یکی از راه‌حل‌های جلوگیری بروز ازدحام در بزرگراه‌ها است. با توجه به مطالعات انجام‌یافته، تاکنون یک مدل جامعی برای پیش‌بینی جریان ترافیک ایجاد نشده است که بتواند مانع وقوع ازدحام در شرایط مختلف ترافیکی شود. یک ایده جالب برای حل این مسئله، استفاده از ترکیب چندین مدل پیش‌بین متفاوت برای کاهش خطای پیش‌بینی است. در این مقاله یک الگوریتم ترکیب جدید بر اساس منطق فازی جهت پیش‌بینی جریان ترافیک ارائه شده است و با انواع مختلف الگوریتم‌های ترکیب و مدل‌های پیش‌بین سابق مورد مقایسه قرار گرفته است. عملکرد کنترل‌کننده‌های فازی به صورت انتخاب نرم است و انتظار می‌رود که این الگوریتم ترکیب جدید دارای دقت بالایی نسبت به سایر الگوریتم‌ها باشد. در ادامه برای نشان دادن عملکرد این الگوریتم ترکیب جدید، شبیه‌سازی‌هایی بر اساس داده‌های واقعی در نرم‌افزار MATLAB انجام شده است. با توجه به متفاوت بودن الگوهای رفتاری جریان ترافیک در واقعیت، عملکرد الگوریتم ترکیب جدید در حضور داده‌های ترافیکی آلوده شده تحت شرایط مختلف آب و هوایی نظیر بارش باران یا برف و دیگر شرایط ترافیکی مانند وقوع ازدحام و تصادف در جاده، ارزیابی شده است که حاکی از مقاوم بودن این الگوریتم در حضور انواع مختلف داده‌های اغتشاشی است.

واژه‌های کلیدی: ترکیب فازی، پیش‌بینی جریان ترافیک، سیستم حمل‌ونقل هوشمند، داده‌های اغتشاشی.

Fuzzy Fusion Algorithm for Traffic Flow Prediction besides Noisy Data

Seyyed Hadi Hosseini¹, Assistant Professor; Babak Najjar Araabi², Associate Professor; Behzad Moshiri², Professor; Ashkan Rahimi-Kian², Associate Professor

1- Department of Electrical Engineering, Islamic Azad University of Science and Research Branch, Tehran, Iran, Email: sh_hosseini@itrc.ac.ir

2- Control and Intelligent Processing Center of Excellence, School of Electrical and Computer Engineering, University of Tehran, Tehran, Iran, Email: {araabi, moshiri, arkian}@ut.ac.ir

Abstract: Traffic flow prediction is one of the methods of congestion avoidance in highways. According to the previous researches, no comprehensive model has been developed for traffic flow prediction which can reduce the congestion in all of traffic conditions. Using the hybrid of any predictor models to reduce prediction error is an interesting idea to solve this problem. In this paper, a new hybrid algorithm based on fuzzy logic for traffic flow prediction will be offer and compare with various types of old hybrid algorithms and predictor models. The fuzzy logic controller working as soft switching and as expected this new hybrid algorithm have high precision in comparison with others. Simulations will be implemented based on real data in MATLAB environment as a performance demonstration of new hybrid algorithm. Due to different traffic flow behavioral patterns, performance investigations of new hybrid algorithm will be done in presence of polluted traffic data in different climatic conditions such as rain/snow fall or other traffic conditions like congestions and accidents on the road, indicating robustness of this algorithms to different types of disturbance data.

Keywords: Fuzzy fusion, Traffic flow prediction, Intelligent transportation system, Noisy data.

تاریخ ارسال مقاله: ۱۳۹۴/۰۳/۱۶

تاریخ اصلاح مقاله: ۱۳۹۴/۰۵/۰۶ و ۱۳۹۴/۰۵/۱۸

تاریخ پذیرش مقاله: ۱۳۹۴/۰۷/۲۶

نام نویسنده مسئول: سیدهدادی حسینی

نشانی نویسنده مسئول: ایران - تهران - پونک - انتهای بلوار اشرفی اصفهانی - دانشگاه آزاد اسلامی - واحد علوم و تحقیقات - گروه مهندسی برق.

۱- مقدمه

به شبکه‌های عصبی مانند MLP^۱، RBF^۲ و TDNN^۳ [۱۱، ۱۲]، مدل نزدیک‌ترین همسایه^۴ (KNN) [۱۳] و مدل SVM^۵ [۱۴] اشاره نمود.

۱-۱- بیان مسئله

با پیشرفت علم و هم‌زمان با افزایش فعالیت‌های اجتماعی، مشکلات سیستم حمل‌ونقل مخصوصاً سیستم حمل‌ونقل جاده‌ای در بزرگراه‌های داخل شهرهای بزرگ و جاده‌های متصل به آن‌ها، یکی از مسائل مهم به حساب می‌آید. سیستم‌های حمل‌ونقل جهت ارتقای بهره‌وری و افزایش کارایی خود نیازمند یک سیستم مدیریت هوشمندانه می‌باشند تا با استفاده از فناوری‌های پیشرفته علمی مسائل پیچیده خود را کنترل، پیش‌بینی و مدیریت نمایند. به همین منظور در سال‌های اخیر سیستم حمل‌ونقل هوشمند^۱ (ITS) ابداع گردیده است که با استفاده از فناوری‌های اطلاعات، مخابرات، کنترل، مهندسی سیستم منجر به بهبود وضعیت سیستم حمل‌ونقل می‌شود. از نتایج مؤثر استفاده از ITS در سیستم حمل‌ونقل جاده‌ای می‌توان به کاهش مصرف سوخت، کاهش آلودگی هوا، کاهش ازدحام جاده‌ای، کاهش زمان سفر و افزایش کارایی فعالیت‌های اجتماعی و اقتصادی اشاره کرد. مسئله پیش‌بینی جریان ترافیک یکی از راه‌حلهایی است که ITS برای جلوگیری از بروز ازدحام در بزرگراه‌ها ارائه نموده است [۱، ۲].

۱-۲- پژوهش‌های پیشین در زمینه پیش‌بینی جریان ترافیک

جریان ترافیک یکی از مشخصه‌های ماکروسکوپی ترافیک محسوب می‌شود و کاملاً غیرخطی بوده و یک فرآیند تصادفی غیر ایستا محسوب می‌گردد. با توجه به پژوهش‌های انجام‌یافته در زمینه پیش‌بینی جریان ترافیک، امروزه اکثر روش‌های پیش‌بینی جریان ترافیک به صورت روش‌های تجربی و داده محور هستند و به سه گروه عمده پارامتری، غیر پارامتری و ترکیبی تقسیم‌بندی می‌شوند [۵-۳].

۱-۲-۱- روش‌های پیش‌بینی پارامتری

در اغلب روش‌های پیش‌بینی پارامتری با استفاده از مدل‌های رگرسیون [۶]، مدل حداکثر شباهت^۲ [۷] و مدل‌های سری زمانی مانند ARIMA^۲ [۸، ۹] و SARIMA^۴ [۱۰، ۱۱]، داده‌های گذشته مدل شده و جریان ترافیک چند گام بعد پیش‌بینی می‌گردد. از مزایای این روش‌ها می‌توان به ساده بودن مدل پیش‌بین اشاره نمود و عمده‌ترین عیب اغلب این روش‌ها وابستگی آن‌ها به میزان بسیار زیاد داده‌های گذشته و همچنین عملکرد ضعیف آن‌ها در حضور نویز، اغتشاش و تغییرات شدید و ناگهانی جریان ترافیک است.

۱-۲-۲- روش‌های پیش‌بینی غیر پارامتری

در روش‌های پیش‌بینی غیر پارامتری وقایع خاص ترافیکی مثل ازدحام یا وقوع تصادف در جاده، با دقت بیشتری قابل پیش‌بینی می‌باشند. پیچیده بودن مدل و وابستگی شدید آن‌ها به حجم زیاد داده از معایب عمده این روش‌ها هستند. از مشهورترین روش‌های غیر پارامتری که برای پیش‌بینی جریان ترافیک مورد استفاده قرار گرفته است می‌توان

۱-۲-۳- روش‌های پیش‌بینی ترکیبی

معمولاً هرکدام از روش‌های فوق فقط در شرایط خاصی از ترافیک جواب خوبی را ارائه می‌کنند و در صورت تغییر شرایط ترافیکی، نسبت به این تغییرات غیر مقاوم بوده و بازدهی بالایی در پیش‌بینی جریان ترافیک نخواهند داشت. در سال‌های اخیر محققان برای افزایش دقت پیش‌بینی، از ترکیب خطی و یا غیرخطی روش‌های پیش‌بینی پارامتری و غیر پارامتری استفاده نموده و روش‌های پیش‌بینی ترکیبی را ابداع نموده‌اند که میزان دقت آن‌ها بستگی به نوع عملیات ترکیب و نوع روش‌های پارامتری و غیر پارامتری استفاده‌شده دارد. البته این روش‌ها دارای پیچیدگی زیادی نسبت به دو گروه قبلی می‌باشند و پیاده‌سازی آن‌ها هزینه بالاتری نیز خواهد داشت [۳]. نمونه‌ای از این روش‌ها، ترکیبی از یک شبکه عصبی با سایر مدل‌های پیش‌بین مانند مدل فازی [۱۵، ۱۶]، مدل موجک [۱۷] و مدل ARIMA [۱۸] می‌باشند. البته تاکنون یک روش کامل و جامعی برای پیش‌بینی جریان ترافیک ایجاد نشده است که بتواند در تمامی شرایط ترافیکی، جواب خیلی دقیقی را ارائه نماید [۱۵، ۱۹].

۱-۳- ترکیب چندین مدل پیش‌بین جریان ترافیک

یک مدل پیش‌بین به‌تنهایی و در شرایط خاص ترافیکی می‌تواند دارای کیفیت پیش‌بینی بالایی باشد ولی احتمالاً در شرایط ترافیکی دیگر، دارای عملکرد مناسبی نباشد و می‌توان با ترکیب چندین مدل پیش‌بین متفاوت که هرکدام در شرایط مختلف ترافیکی دارای عملکرد خوبی باشند، این مشکل را حل نمود [۲۰]. معمولاً مدل‌های پیش‌بین ترکیبی می‌توانند در اکثر شرایط مختلف ترافیکی و با هر نوع داده‌ای، دقت بالایی را از خود نشان بدهند. از مزایای دیگر آن‌ها، انعطاف‌پذیر بودن ساختار آن‌ها است و می‌توان انواع مختلف مدل‌های پیش‌بین ساده پارامتری، غیر پارامتری و حتی ترکیبی را با استفاده از الگوریتم‌های ترکیب مختلف، باهم ترکیب نموده و یک مدل ترکیبی جدیدی را ابداع نمود.

اولین الگوریتم‌های ترکیب چندین مدل پیش‌بین که به صورت یک ترکیب خطی، چندین مدل پیش‌بین را باهم ترکیب می‌نمودند، مربوط به اواخر دهه هفتاد میلادی است که به‌طور جداگانه توسط آقایان چانگ و اسپایر^۱، بر روی فیلترهای کالمن گسترده بهینه انجام یافته [۲۱، ۲۲] و بعداً به صورت یک مدل متحد درآمد [۲۳]. سپس در اواخر دهه هشتاد میلادی، الگوریتم‌های ترکیبی بر روی سیستم‌های غیرخطی نیز توسعه یافتند [۲۴، ۲۵]. الگوریتم‌های میانگین حسابی^{۱۱} (AA)، میانگین حسابی وزن‌دار^{۱۲} (WA)، میانگین حسابی وزن‌دار مرتبه‌یافته^{۱۳} (OWA) و میانگین حسابی وزن‌دار بر اساس خطا^{۱۴} (EWA) نمونه‌هایی از الگوریتم‌های ترکیب می‌باشند [۲۶، ۲۷].

ترکیبی استفاده می‌کنیم. داده‌های ترافیکی مورد استفاده در این مقاله مربوط به جریان ترافیکی با فاصله زمانی پانزده دقیقه‌ای بین داده‌ها است. با توجه به گسسته بودن داده‌ها می‌توان سری زمانی $\{X_t\}$ را به‌عنوان داده‌های جریان ترافیک (مشاهدات) فرض کرده و مسئله پیش‌بینی یک گام به جلو را به‌صورت رابطه (۱) در نظر گرفت که در شکل ۱ نیز قابل مشاهده است.

$$\hat{X}_t = f(X_{t-1}, X_{t-2}, X_{t-3}, \dots) \quad (1)$$

که ماتریس \hat{X}_t بیانگر جریان ترافیک پیش‌بینی شده است.

۱-۲ - مدل‌های پیش‌بین پارامتری

با توجه به استفاده فراوان از مدل‌های سری زمانی ARIMA و SARIMA برای پیش‌بینی ترافیک در اکثر پژوهش‌ها، ما نیز از آن‌ها برای پیش‌بینی کوتاه‌مدت و گام بعدی جریان ترافیک استفاده می‌نماییم. چون جریان ترافیک یک فرآیند غیر ایستا و دارای انحراف معیار متغیر است، می‌توان آن را به‌راحتی با استفاده از این سری‌های زمانی مدل‌سازی نمود [۸]. در این مقاله با توجه به سری زمانی جریان ترافیک موجود، مدل ARIMA (2,2,0) انتخاب شده است که در رابطه (۲) مشاهده می‌شود. در این رابطه با توجه به فاصله زمانی ۱۵ دقیقه‌ای داده‌ها، برای پیش‌بینی جریان ترافیک لحظه t فقط از چهار داده مربوط به یک ساعت قبل آن استفاده شده است.

$$\hat{X}_t = \varnothing_1 X_{t-1} + \varnothing_2 X_{t-2} + \varnothing_3 X_{t-3} + \varnothing_4 X_{t-4} + \varepsilon_t \quad (2)$$

که در این رابطه متغیر ε_t بیانگر نویز سفید با میانگین صفر و انحراف معیار یک است.

برخی از سری‌های زمانی دارای یک شباهت زمانی ویژه‌ای بین داده‌های خود می‌باشند که با شناسایی میزان این زمان (و یا فصل)، می‌توان اثر آن را در مدل‌سازی لحاظ نمود. چون جریان ترافیک معمولاً در هر شبانه‌روز و حتی در هر هفته به‌طور مشابه تکرار می‌شود بنابراین برای مدل‌سازی آن می‌توان از مدل سری زمانی SARIMA و با در نظر گرفتن میزان فصل تکرار شونده $S=24$ و $S=7 \times 24$ استفاده نمود [۱۰]. در این مقاله با توجه به فاصله زمانی پانزده دقیقه‌ای داده‌های ترافیکی، برای مدل SARIMA(Day) میزان فصل تکرار شونده $S=96$ بوده و مدل پیشنهادی $SARIMA(2,2,0)(2,1,0)_{96}$ است که در رابطه (۳) مشاهده می‌شود. همچنین برای مدل SARIMA(Week) میزان فصل تکرار شونده $S=7 \times 96 = 672$ بوده و مدل پیشنهادی SARIMA $(2,2,0)(2,1,0)_{672}$ است که در رابطه (۴) قابل مشاهده است.

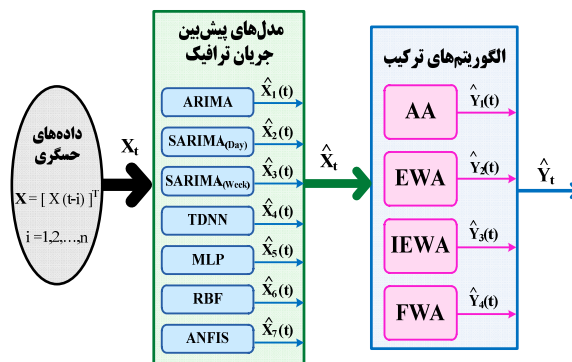
$$\hat{X}_t = \varnothing_1 X_{t-1} + \dots + \varnothing_4 X_{t-4} + \varnothing_{96} X_{t-96} + \dots + \varnothing_{100} X_{t-100} + \varnothing_{192} X_{t-192} + \dots + \varnothing_{196} X_{t-196} + \varnothing_{288} X_{t-288} + \dots + \varnothing_{292} X_{t-292} + \varepsilon_t \quad (3)$$

$$\hat{X}_t = \varnothing_1 X_{t-1} + \dots + \varnothing_4 X_{t-4} + \varnothing_{672} X_{t-672} + \dots + \varnothing_{676} X_{t-676} + \varnothing_{1344} X_{t-1344} + \dots + \varnothing_{1348} X_{t-1348} + \varnothing_{2016} X_{t-2016} + \dots + \varnothing_{2020} X_{t-2020} + \varepsilon_t \quad (4)$$

در این مقاله از الگوریتم ترکیب AA که فقط نتایج مدل‌های پیش‌بینی را میانگین‌گیری حسابی می‌کند و همچنین از الگوریتم‌های ترکیب EWA و IEWA که از میزان خطای پیش‌بینی هر کدام از مدل‌های پیش‌بین جهت تعیین مقادیر ضرایب وزنی آن‌ها در مدل ترکیبی استفاده می‌کنند، به‌عنوان مدل مقایسه‌ای استفاده شده است. با توجه به معایب هر کدام از این الگوریتم‌ها و جهت رفع آن‌ها، الگوریتم ترکیب جدید FWA^{۱۵} که با استفاده از منطق فازی مقادیر ضرایب وزنی مدل‌های پیش‌بینی را تعیین می‌نماید، پیشنهاد داده شده و مورد تحلیل قرار می‌گیرد. استفاده از سیستم فازی مناسب در هر ترکیب و نسبت به نوع مدل‌های پیش‌بینی ورودی، باعث افزایش کیفیت پیش‌بینی خواهد شد.

در ادامه مقاله با استفاده از داده‌های مربوط به شرایط خاص ترافیکی مانند وقوع ازدحام و تصادف در جاده و شرایط بد آب و هوایی مانند بارش برف و باران شدید، پیش‌بینی جریان ترافیک را با الگوریتم ترکیب ابداع‌شده انجام داده و نتایج به‌دست‌آمده را تحلیل خواهیم نمود. در شکل ۱ ساختار کلی این چهار الگوریتم ترکیب به‌همراه هفت مدل پیش‌بینی جریان ترافیک مشاهده می‌گردد.

در ادامه این مقاله و در بخش دوم، مدل‌های پیش‌بینی جریان ترافیک استفاده‌شده بیان می‌گردد. در بخش سوم، الگوریتم‌های ترکیب مدل‌های پیش‌بینی شرح داده شده و الگوریتم ترکیب جدیدی بر اساس منطق فازی معرفی می‌شود. در بخش چهارم، مطالعه موردی بر روی داده‌های ترافیکی و پیش‌بینی جریان ترافیک به‌همراه انجام شبیه‌سازی‌ها مطرح گردیده و در نهایت نتیجه‌گیری این مقاله در بخش پنجم ارائه خواهد شد.



شکل ۱: ساختار کلی چهار الگوریتم ترکیب به‌همراه هفت مدل پیش‌بینی جریان ترافیک

۲- مدل‌های پیش‌بینی جریان ترافیک

در این مقاله برای بررسی کیفیت الگوریتم‌های ترکیب، از مدل‌های پیش‌بینی ARIMA، SARIMA(Day)، SARIMA(Week) به‌عنوان مدل‌های پارامتری، از مدل‌های پیش‌بین (شبکه‌های عصبی) MLP، TDNN و RBF به‌عنوان مدل‌های مقایسه‌ای غیر پارامتری و از مدل پیش‌بین (شبکه عصبی-فازی) ANFIS به‌عنوان مدل مقایسه‌ای

۲-۲- مدل های پیش بین غیر پارامتری

با توجه به قدرت بالای یادگیری و تطبیق پذیری شبکه های عصبی نسبت به داده های متفاوت و مخصوصاً در سیستم های غیر خطی و شرایط محیطی خاص، استفاده از آن ها برای امر پیش بینی مفید خواهد بود. سری های زمانی اغلب دارای نویزهای قوی در خود می باشند که برخلاف سایر روش های پیش بینی، شبکه های عصبی به راحتی قادر به غلبه بر این نویزها می باشند [۲۸]. در اکثر پژوهش ها علی رغم پیچیدگی شبکه های عصبی، از انواع مختلف آن برای پیش بینی جریان ترافیک استفاده زیادی شده است که بیانگر کارایی بالای آن ها است.

با توجه به این موارد در این مقاله از شبکه های عصبی TDNN، MLP و RBF، به عنوان مدل های پیش بین غیر پارامتری استفاده شده است. با توجه به شکل های ۲ و ۳ هر سه شبکه عصبی دارای سه لایه ورودی، مخفی و خروجی می باشند که بر اساس مدل پیش بینی روابط (۵) و (۶)، تعداد نرون های لایه ورودی و خروجی به ترتیب برابر چهار و یک عدد در نظر گرفته شده است. تعداد نرون های لایه مخفی به طور تجربی و پس از تکرار آزمایش های مکرر بین یک تا بیست عدد نرون، ده عدد در نظر گرفته شده است. همچنین با استفاده از ۸۵ درصد داده های نرمالیزه شده، نرون های شبکه عصبی را آموزش داده و سپس با استفاده از ۱۵ درصد باقی داده ها و به صورت خارج خط، آن ها را مورد ارزیابی و تست قرار می دهیم. الگوریتم آموزشی نیز روش Levenberg-Marquardt است که ترکیبی از دو الگوریتم آموزشی پایه گرادینان نزولی و نیوتن بوده و یک روش سریع محسوب می گردد.


$$\hat{X}_t = f(X_{t-1}, X_{t-2}, X_{t-3}, X_{t-4}) \quad (3)$$

در مدل پیش بین TDNN که در شکل ۲ مشاهده می شود، طبق رابطه (۵) و با استفاده از داده های جریان ترافیک چهار گام قبل، مقدار جریان ترافیک گام بعد را پیش بینی می نمایم. مدل پیش بین MLP که بسیار پرکاربرد است تقریباً شبیه مدل پیش بین TDNN بوده و در شکل ۳ قابل مشاهده است. برخلاف مدل پیش بین TDNN و برای کاهش حجم محاسبات، در مدل پیش بین MLP به جای استفاده از تمامی داده های مربوط به شش ماه گذشته فقط از داده های چهار گام قبل مربوط به چهار روز اخیر و سه روز مشابه هفته های قبل استفاده می کنیم که در رابطه (۶) بیان شده است. این داده ها به عنوان یک انتخاب فصلی مطرح هستند که در آن، هر دو فاصله زمانی فصلی شبانه روزی و فاصله زمانی فصلی برابر یک هفته را در نظر می گیریم.


نتایج پیش بینی مدل MLP قابل مقایسه با مدل پارامتری SARIMA خواهد بود. معمولاً شبکه عصبی RBF دارای توان بیشتری در تقریب زدن توابع غیر خطی است. همچنین برخلاف شبکه عصبی MLP سرعت آموزش شبکه عصبی RBF بسیار زیاد است؛ بنابراین در این مقاله برای پیش بینی جریان ترافیک از شبکه عصبی RBF نیز استفاده نموده ایم که ساختار آن مشابه مدل پیش بین MLP بوده و در شکل ۳ قابل مشاهده است. داده های آموزش و تست مدل پیش بین RBF نیز طبق رابطه (۶) و دقیقاً مشابه مدل پیش بین MLP است. با

توجه به شکل های ۲ و ۳، W و Z ماتریس های وزنی ورودی و میانی شبکه های عصبی می باشند.

$$\hat{X}_t = \begin{bmatrix} f(X_{t-s-1}, X_{t-s-2}, X_{t-s-3}, X_{t-s-4}); \forall s = 0 \\ f(X_{t-s-1}, X_{t-s-2}, X_{t-s-3}, X_{t-s-4}); \forall s = 1 \times 96 \\ f(X_{t-s-1}, X_{t-s-2}, X_{t-s-3}, X_{t-s-4}); \forall s = 2 \times 96 \\ f(X_{t-s-1}, X_{t-s-2}, X_{t-s-3}, X_{t-s-4}); \forall s = 3 \times 96 \\ f(X_{t-s-1}, X_{t-s-2}, X_{t-s-3}, X_{t-s-4}); \forall s = 7 \times 96 \\ f(X_{t-s-1}, X_{t-s-2}, X_{t-s-3}, X_{t-s-4}); \forall s = 14 \times 96 \\ f(X_{t-s-1}, X_{t-s-2}, X_{t-s-3}, X_{t-s-4}); \forall s = 21 \times 96 \end{bmatrix} \quad (4)$$



شکل ۲: مدل پیش بین شبکه عصبی سه لایه TDNN



شکل ۳: مدل پیش بین شبکه عصبی سه لایه MLP و RBF

۳-۲- مدل های پیش بین ترکیبی

هر کدام از مدل های پیش بین پارامتری و غیر پارامتری قادر هستند به تنهایی جریان ترافیک را در شرایط خاص ترافیکی به خوبی پیش بینی نمایند ولی در شرایط ترافیکی دیگر معمولاً کیفیت پیش بینی آن ها جالب نخواهد بود و مدل های پیش بین ترکیبی تا حدی می توانند این مسئله را بهبود بدهند. سیستم های عصبی-فازی در شناسایی سیستم های غیر خطی و مسائل پیش بینی مخصوصاً در حضور انواع مختلف اغتشاش ها، دارای عملکرد خوبی نسبت به شبکه های عصبی می باشند؛ بنابراین در این مقاله از مدل ANFIS که یکی از متداول ترین مدل های عصبی-فازی است به عنوان یک مدل پیش بین ترکیبی (ترکیب منطق فازی با شبکه عصبی) استفاده نموده ایم.

ساختار کلی مدل پیش بین ANFIS در شکل ۴ نشان داده شده است که یک مدل ساده سوگنو با پنج پایه و چهار ورودی است [۲۹]. در لایه اول این مدل، هر کدام از ورودی ها شامل سه تابع تعلق مثلثی مطابق شکل ۵ فرض شده است. داده های استفاده شده مشابه مدل های

که در این رابطه، متغیر m بیانگر تعداد مدل‌های پیش‌بین بوده و در این مقاله $m=7$ فرض شده است.

۲-۳- الگوریتم ترکیب EWA

برخلاف الگوریتم ترکیب AA، در الگوریتم ترکیب میانگین وزن دار EWA، ارزش هر کدام از مدل‌های پیش‌بین متفاوت بوده و بر اساس میزان خطای آن‌ها در عمل ترکیب شرکت می‌نماید. با توجه به رابطه (۸) برای هر کدام از مدل‌های پیش‌بین یک ضریب وزنی $w_i(t)$ لحاظ نموده و ارزش آن‌ها را نسبت به هم به صورت متفاوتی در نظر می‌گیریم. روند محاسبات ضرایب وزنی الگوریتم EWA نیز در رابطه (۹) بیان شده است [۳۲]. بنابراین هر مدل پیش‌بین که دارای انحراف معیار خطای پیش‌بینی بیشتری باشد با وزن کمتری در عملیات ترکیب، شرکت می‌نماید و بالعکس.

$$\hat{Y}(t) = \sum_{i=1}^m w_i(t) \hat{X}_i(t) \quad (6)$$

$$a_i(t) = \frac{I}{\sigma_i^2(t)} \Rightarrow w_i(t) = \frac{a_i(t)}{\sum_{j=1}^m a_j(t)}; \forall i=1,2,\dots,m \quad (7)$$


در رابطه (۹) عبارت $\sigma_i^2(t)$ بیانگر میزان انحراف معیار خطای پیش‌بینی مدل i ام در زمان t است. در حالت خاصی که تمامی ضرایب وزنی به صورت عدد ثابت باشند $\left(a_i(t) = I \rightarrow w_i(t) = \frac{I}{m}\right)$ ، الگوریتم EWA به الگوریتم AA تبدیل خواهد شد. در الگوریتم EWA، ضرایب وزنی هر مدل پیش‌بین فقط به میزان انحراف معیار خطای پیش‌بینی همان مدل بستگی دارد و نتایج سایر مدل‌های پیش‌بین تأثیر زیادی در این امر نخواهند داشت که این موضوع، مهم‌ترین عیب الگوریتم EWA است [۳۳].

۳-۳- الگوریتم ترکیب IEWA


برای رفع ایراد الگوریتم EWA، آن را بهبود داده و الگوریتم جدید IEWA^{۱۶} را پیشنهاد می‌کنیم. این الگوریتم یک روش مشابه و جدید برای محاسبه ضرایب وزنی است که در آن، تأثیر نتایج سایر مدل‌ها بر روی یک مدل پیش‌بین، بیشتر نشان داده می‌شود. روند محاسبات ضرایب وزنی الگوریتم IEWA در رابطه (۱۰) بیان شده است. پس از تعیین ضرایب وزنی $a_i(t)$ ، طبق رابطه (۱۱) ضرایب $w_i(t)$ نیز محاسبه شده و در نهایت آن‌ها در رابطه اصلی مدل ترکیبی WA (رابطه (۸)) جایگذاری می‌شوند.

$$a_i(t) = \frac{\left(\prod_{j=1, j \neq i}^m \sigma_j^2(t)\right)}{\sigma_i^2(t)} = \prod_{j=1, j \neq i}^m \sigma_j^2(t); \forall i=1,2,\dots,m \quad (10)$$

پیش‌بین MLP و RBF بوده و مطابق رابطه (۶) است. همچنین میزان داده‌ها برای آموزش و تست این مدل نیز به ترتیب ۸۵ درصد و ۱۵ درصد بوده و الگوریتم آموزش پارامترهای مقدم و تالی این مدل، الگوریتم پس‌انتشار خطا است.



شکل ۴: ساختار سوگنو پنج لایه برای مدل پیش‌بین ANFIS



شکل ۵: توابع تعلق ورودی‌ها برای مدل پیش‌بین ANFIS

۳- الگوریتم‌های ترکیب مدل‌های پیش‌بین

در این قسمت، ابتدا الگوریتم‌های ترکیب AA، EWA و IEWA را بیان نموده و سپس با توجه به معایب هر کدام و جهت رفع آن‌ها، الگوریتم ترکیب جدید FWA را پیشنهاد داده و بررسی خواهیم نمود.

۱-۳- الگوریتم ترکیب AA

ساده‌ترین الگوریتم ترکیب نتایج مدل‌های پیش‌بین، استفاده از میانگین حسابی آن‌ها است که به دلیل پیچیدگی محاسبات پائین آن، در اکثر پژوهش‌ها به عنوان مدل مقایسه‌ای و مرجع از این الگوریتم استفاده شده است [۳۰]. در این الگوریتم ارزش تمامی مدل‌های پیش‌بین برابر در نظر گرفته شده و مطابق رابطه (۷)، میانگین حسابی عملکرد آن‌ها به عنوان نتیجه نهایی ترکیب به دست می‌آید؛ بنابراین اگر یکی از مدل‌های پیش‌بین دارای عملکرد مناسبی نباشد در نتیجه عملکرد نهایی الگوریتم ترکیب نیز نامناسب خواهد بود؛ بنابراین مهم‌ترین عیب الگوریتم AA، قادر نبودن آن در تشخیص دقت مدل‌های پیش‌بین بوده و برابر در نظر گرفتن ارزش همه آن‌ها در عملیات ترکیب است [۳۱].

$$\hat{Y}(t) = \frac{\sum_{i=1}^m \hat{X}_i(t)}{m} \quad (5)$$

طبق شکل ۶، پس از دریافت نتایج m مدل پیش‌بینی از رابطه (۱۲) به دست می‌آید. با توجه به این که برای محاسبه خطای پیش‌بینی، نیازمند داشتن مقدار واقعی (که رخ داده است) هستیم، بنابراین در این رابطه، محاسبات برای یک گام قبل صورت می‌گیرد. همچنین برای بزرگ‌نمایی میزان خطا (که دارای مقادیر کوچکی می‌باشند) در رابطه (۱۲) مقدار خطای محاسبه شده را صد برابر بزرگ می‌کنیم. سپس مقادیر خطای پیش‌بینی مدل‌ها را بر اساس متغیرهای زبانی خاصی و با استفاده از یکسری توابع عضویت فازی ساز، به مقادیر فازی تبدیل می‌نماییم. توابع عضویت فازی ساز و توابع عضویت خروجی سیستم فازی به صورت توابع مثلثی بوده و به ترتیب به فرم‌های $\mu_w(t-l) = [u_1, u_2, u_3, u_4, u_5]$ و $\mu_e(t-l) = [L, M, H]$ تقسیم‌بندی می‌شوند که در شکل‌های ۷ و ۸ قابل مشاهده می‌باشند.

$$e_{i(t-l)} = \frac{|\hat{X}_i(t-l) - Y(t-l)|}{Y(t-l)} \times 100; \quad \forall i = 1, \dots, m \quad (9)$$

۳-۴-۲- تعیین قوانین فازی

بعد از عمل فازی‌سازی، جهت تعیین ضرایب وزنی مدل‌های پیش‌بینی باید قوانین فازی درستی را در نظر بگیریم. تعداد قوانین فازی مورد استفاده در الگوریتم FWA برابر k^m خواهد بود که m بیانگر تعداد مدل‌های پیش‌بینی و k بیانگر تعداد توابع عضویت فازی ساز است که در این مقاله طبق شکل ۷، مقدار $k = 3$ فرض شده است. برای تعیین ضریب وزنی مدل پیش‌بینی i ام (w_i)، با در نظر گرفتن توابع عضویت فازی ساز (μ_{e_i}) و توابع عضویت خروجی (μ_{w_i})، از الگوریتم تعیین قوانین فازی استفاده می‌کنیم.

الگوریتم تعیین قوانین فازی

- فرض کنیم خطای مدل i ام به صورت $(e_i = L)$ باشد:
 - اگر خطای تمامی مدل‌های دیگر نیز به صورت $(e_j = L; j \neq i)$ باشد، در آن صورت $(w_i = u_3)$.
 - اگر حداقل یکی از خطاهای مدل‌های دیگر به صورت $(e_j = H; j \neq i)$ باشد، در آن صورت $(w_i = u_5)$.
 - و در غیر این صورت $(w_i = u_4)$.
- فرض کنیم خطای مدل i ام به صورت $(e_i = M)$ باشد:
 - در آن صورت $(w_i = u_3)$.
- فرض کنیم خطای مدل i ام به صورت $(e_i = H)$ باشد:
 - اگر خطای تمامی مدل‌های دیگر نیز به صورت $(e_j = H; j \neq i)$ باشد، در آن صورت $(w_i = u_3)$.
 - اگر حداقل یکی از خطاهای مدل‌های دیگر به صورت $(e_j = L; j \neq i)$ باشد، در آن صورت $(w_i = u_1)$.
 - و در غیر این صورت $(w_i = u_2)$.

$$w_i(t) = \frac{a_i(t)}{\sum_{j=1}^m a_j(t)}; \quad \forall i = 1, 2, \dots, m \quad (8)$$

به عنوان نمونه برای حالت $m = 3$ ضرایب وزنی $a_i(t)$ به صورت $a_1(t) = \sigma_1^2 \sigma_3^2$; $a_2(t) = \sigma_1^2 \sigma_2^2$; $a_3(t) = \sigma_1^2 \sigma_2^2$ هستند. الگوریتم IEWA با در نظر گرفتن میزان انحراف معیار خطای تمامی مدل‌های پیش‌بینی و به طور هم‌زمان، قادر به محاسبه ضرایب وزنی دقیق‌تری بوده و نسبت به تغییرات لحظه‌ای مدل‌های پیش‌بینی ورودی دارای حساسیت بالایی است.

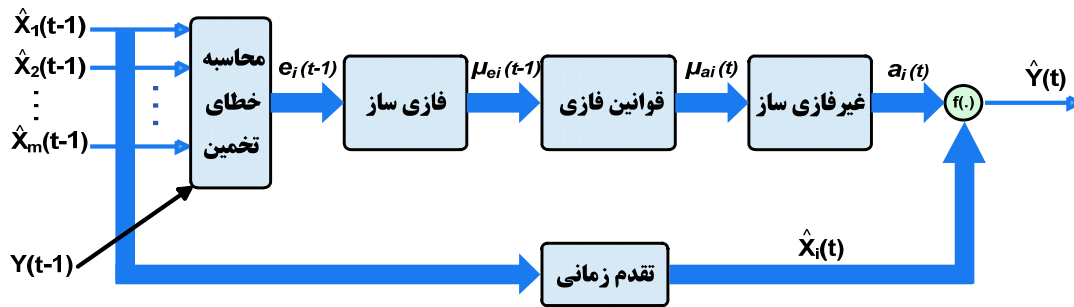
۳-۴-۳- الگوریتم ترکیب جدید FWA

یک الگوریتم ترکیب فازی با استفاده از منطق فازی می‌تواند نتایج چندین مدل پیش‌بینی پارامتری و یا غیر پارامتری را با هم ترکیب نموده و تحت شرایط مختلف ترافیکی نتایج بهتری را ارائه نماید. در این الگوریتم ترکیب که آن را FWA می‌نامیم، ضرایب وزنی هر مدل پیش‌بینی با استفاده از منطق فازی و به صورت محاسبات انتخاب نرم^{۱۷} و از روی میزان خطای پیش‌بینی تمامی مدل‌های پیش‌بینی ورودی تعیین می‌گردند. برخلاف انتخاب سخت که در آن، سیستم انتخاب‌کننده از بین چندین ورودی، فقط اثر یک ورودی را در هر لحظه در نظر گرفته و آن را انتخاب می‌نماید (مثلاً فقط ورودی که دارای کمترین خطای پیش‌بینی است انتخاب می‌شود) و به نتایج و اثرات سایر ورودی‌ها توجهی ندارد، در انتخاب نرم سیستم انتخاب‌کننده اثر سایر ورودی‌ها را نیز در انتخاب خود در نظر می‌گیرد. هر قدر به اثر سایر ورودی‌ها توجه بشود میزان نرم بودن آن انتخاب بیشتر خواهد شد و برعکس.

الگوریتم FWA نیز برای تعیین ضریب وزنی هر کدام از مدل‌های ورودی خود، ابتدا تمامی مدل‌های ورودی را در نظر گرفته و بر اساس میزان خطای پیش‌بینی آن‌ها و بر اساس قوانین فازی استفاده شده برای هر مدل ورودی یک ضریب وزنی را محاسبه می‌نماید که نشئت گرفته از اثر سایر مدل‌های ورودی خواهد بود. دقت این الگوریتم به قوانین استفاده شده در سیستم فازی، توابع عضویت فازی‌سازی^{۱۸} و معیار غیر فازی‌سازی^{۱۹} بستگی دارد [۳۶-۳۴]. در الگوریتم FWA از یک مدل فازی ممدانی با توابع عضویت مثلثی جهت فازی‌سازی و غیر فازی‌سازی استفاده می‌شود و با تعیین قوانین فازی بین متغیرهای زبانی، مقادیر ضرایب وزنی $a_i(t)$ و در نهایت $w_i(t)$ در هر گام به دست می‌آید.

۳-۴-۳-۱- فازی‌سازی

در الگوریتم FWA طبق شکل ۶ و با توجه به این که برای تعیین ضرایب وزنی حتماً به نتایج پیش‌بینی یک گام قبل مدل‌ها نیاز داریم، ابتدا نتایج تمامی مدل‌های پیش‌بینی $\hat{X}_i(t-l)$ را به عنوان ورودی، وارد یک سیستم فازی می‌نماییم و در نهایت بهترین مقدار پیش‌بینی $\hat{Y}(t)$ از بین مدل‌های پیش‌بینی $\hat{X}_i(t-l)$ انتخاب می‌شود.



شکل ۶: ساختار الگوریتم ترکیب جدید FWA

COG^۲ و طبق رابطه (۱۴)، توابع فازی $\mu_{w_i}(t-1)$ به ضرایب وزنی $w_i(t)$ تبدیل می‌شوند.

$$\mu_{w_i}(t-1) = \max_{i=1,2,3} \left[\min_{i=1,2,3} (\mu_{e_i}(t-1)) \right]; \forall i = 1, 2, \dots, m \quad (10)$$


$$w_i(t) = \frac{\sum_{i=1}^m (\text{weight}_i(t-1)) (\mu_{w_i}(t-1))}{\sum_{i=1}^m (\mu_{w_i}(t-1))}; i = 1, 2, \dots, m \quad (11)$$

در رابطه (۱۴)، متغیرهای μ_{w_i} و weight_i به ترتیب بیانگر محورهای عمودی و افقی نمودار توابع عضویت خروجی در شکل ۸ می‌باشند. پس از به دست آوردن مقادیر ضرایب وزنی $w_i(t)$ ، مقدار نهایی الگوریتم ترکیب FWA طبق رابطه (۸) محاسبه می‌شود. الگوریتم FWA با تعریف قوانین فازی مناسب، محاسبات خود را به صورت انتخاب نرم انجام می‌دهد؛ یعنی هنگام تعیین ضرایب وزنی یک مدل، فقط به آن مدل پیش‌بین توجه نکرده و عملکرد سایر مدل‌ها را نیز به‌طور هم‌زمان در نظر می‌گیرد. همچنین این الگوریتم با توجه به تعیین درست قوانین فازی، نسبت به تغییرات لحظه‌ای و سریع جریان ترافیک حساسیت بالایی داشته و در لحظه وقوع اغتشاش دارای عملکرد خوبی است.


۴- پیش‌بینی عملی جریان ترافیک و شبیه‌سازی‌ها

در این مقاله برای بررسی و تأیید عملکرد الگوریتم ترکیب جدید FWA در پیش‌بینی جریان ترافیک و مقایسه آن با روش‌های پیشین، دو شبیه‌سازی را در شرایط عادی و غیرعادی ترافیک و در محیط نرم‌افزاری MATLAB انجام می‌دهیم و قدرت الگوریتم ترکیب جدید را در تشخیص این شرایط و غلبه بر آن‌ها نشان می‌دهیم. شرایط غیرعادی ترافیک مطرح در این مقاله مربوط به ترافیک سنگین در اثر وقوع تصادف و بارش شدید باران یا برف است. به‌منظور مقایسه عددی الگوریتم‌ها و مدل‌های پیش‌بینی، مقدار خطای پیش‌بینی را با استفاده از دو معیار خطای MAPE و VAPE که بیانگر میزان میانگین و انحراف معیار خطای پیش‌بینی برحسب درصد می‌باشند، به دست می‌آوریم.

$$\text{MAPE} = \text{mean} \left(\frac{\sum |Y(t) - \hat{Y}(t)|}{Y(t)} \right) \times 100\% \quad (12)$$



شکل ۷: نمونه‌ای از توابع عضویت فازی ساز برای الگوریتم FWA



شکل ۸: نمونه‌ای از توابع عضویت خروجی برای الگوریتم FWA

نمونه‌ای از قوانین فازی به‌ازای $m=3$ و $k=3$ و تعداد توابع عضویت خروجی برابر ۵، در جدول ۱ مشاهده می‌شود که ۲۷ قانون فازی را برای ضرایب وزنی $[w_1, w_2, w_3]$ تولید نموده است.

جدول ۱: نمونه‌ای از قوانین فازی برحسب سه تابع عضویت فازی ساز و پنج تابع عضویت غیر فازی ساز و به‌ازای سه مدل پیش‌بین.

قوانین فازی	$e_2 = L$			$e_2 = M$			$e_2 = H$		
	w_1	w_2	w_3	w_1	w_2	w_3	w_1	w_2	w_3
$e_1 = L$	$e_3 = L$	u_3	u_3	u_4	u_3	u_4	u_5	u_1	u_5
	$e_3 = M$	u_4	u_4	u_3	u_4	u_3	u_5	u_1	u_3
	$e_3 = H$	u_5	u_5	u_1	u_5	u_3	u_1	u_5	u_1
$e_1 = M$	$e_3 = L$	u_3	u_4	u_4	u_3	u_4	u_3	u_1	u_5
	$e_3 = M$	u_3	u_4	u_3	u_3	u_3	u_3	u_2	u_3
	$e_3 = H$	u_3	u_5	u_1	u_3	u_3	u_2	u_3	u_2
$e_1 = H$	$e_3 = L$	u_1	u_5	u_5	u_1	u_3	u_5	u_1	u_5
	$e_3 = M$	u_1	u_5	u_3	u_2	u_3	u_2	u_2	u_3
	$e_3 = H$	u_1	u_5	u_1	u_2	u_3	u_2	u_3	u_3

۳-۴-۳- غیر فازی سازی

در مدل فازی ممدانی برای تعیین مقادیر توابع غیر فازی، طبق رابطه (۱۳) از روش بیشینه-کمینه استفاده می‌شود. همچنین برای به دست آوردن نتیجه نهایی و مقادیر غیر فازی ضرایب وزنی، با استفاده از روش

به سه روز اخیر و همچنین سه روز مشابه در هفته‌های قبل به‌عنوان چند نمونه از کل داده‌های یک ماه استفاده می‌نماییم. به‌عنوان مثال در این شبیه‌سازی برای پیش‌بینی جریان ترافیک مربوط به روز جمعه ۲۹ ژوئن از داده‌های مربوط به سه روز اخیر ۲۸، ۲۷ و ۲۶ و سه روز جمعه هفته‌های قبل یعنی روزهای ۲۲، ۲۱ و ۱۵ و ۸ ماه ژوئن استفاده می‌کنیم.

در ادامه، نتایج به‌دست‌آمده از هفت مدل پیش‌بین ARIMA، SARIMA_(day)، SARIMA_(week)، TDNN، MLP، RBF و ANFIS را با استفاده از الگوریتم‌های ترکیب AA، EWA و FWA به‌طور هم‌زمان ترکیب نموده و نتایج همه آن‌ها را باهم مقایسه می‌نماییم. الگوریتم ترکیب AA هم‌زمان با تولید نتایج پیش‌بینی توسط هفت مدل پیش‌بین در هر گام، از آن‌ها میانگین حسابی گرفته و در نهایت جریان ترافیک را برای گام بعدی پیش‌بینی می‌نماید. الگوریتم ترکیب EWA نیز با اندازه‌گیری میزان انحراف معیار خطای پیش‌بینی این هفت مدل پیش‌بین در هر گام، الگوریتم محاسباتی خود را اجرا نموده و با توجه به میزان انحراف معیار خطای هر کدام از آن‌ها، ضرایب وزنی مدل مربوطه را تولید نموده و در نهایت با ترکیب وزن‌دار آن‌ها، جریان ترافیک را پیش‌بینی می‌نماید. الگوریتم ترکیب FWA به‌عنوان یک مدل انتخاب‌گر نرم، در هر لحظه نتایج خروجی هفت مدل پیش‌بین را در نظر گرفته و ضرایب وزنی مناسبی را با کمک منطق فازی برای آن‌ها تعیین نموده و آن‌ها را باهم ترکیب می‌نماید که منجر به ارائه خروجی پیش‌بینی شده بهتری می‌شود. نتیجه اجرای این شبیه‌سازی در شکل ۱۰ و جدول ۲ قابل مشاهده است.

در شبیه‌سازی ۱ به پیش‌بینی جریان ترافیک با استفاده از داده‌های عادی پرداخته و عملکرد مدل‌های پیش‌بینی سری زمانی، شبکه عصبی و شبکه عصبی-فازی را با الگوریتم‌های ترکیب ارائه‌شده در این مقاله، مورد بررسی قرار دادیم. آن طوری که انتظار می‌رفت و از نتایج عددی جدول ۲ نیز قابل مشاهده است، تمامی الگوریتم‌های ترکیب در مقایسه با مدل‌های پیش‌بین، بهترین ردیابی را با کاهش خطای پیش‌بینی انجام داده‌اند.

در بین سه مدل سری زمانی، مدل SARIMA_(week) دارای عملکرد خوبی نسبت به دو مدل مشابه خود است و کمترین میزان خطای پیش‌بینی را ارائه نموده است. دلیل آن را می‌توان در استفاده از داده‌های زیاد و مخصوصاً داده‌های مربوط به روزهای مشابه روز پیش‌بینی (جمعه) در هفته‌های قبل دانست. همچنین در بین سه مدل شبکه عصبی، با توجه به عادی بودن داده‌ها و تبعیت شبکه عصبی TDNN از داده‌های اخیر در امر پیش‌بینی، این شبکه عصبی نسبت به دو شبکه عصبی دیگر دارای کیفیت پیش‌بینی بالاتری (و یا انحراف معیار خطای پیش‌بینی کمتری) است. در این شبیه‌سازی عملکرد مدل عصبی-فازی تقریباً شبیه به مدل‌های عصبی است. در میان الگوریتم‌های ترکیب، الگوریتم FWA به‌دلیل استفاده از منطق فازی و تأثیر میزان خطای همه مدل‌های پیش‌بین در تعیین ضریب وزنی یک مدل، توانسته است پاسخ بهتری را نسبت به بقیه الگوریتم‌ها داشته باشد که حاکی از قدرت بالای این الگوریتم در پیش‌بینی جریان ترافیک با شرایط عادی است.

$$VAPE = \text{variance} \left(\frac{\sum |Y(t) - \hat{Y}(t)|}{Y(t)} \right) \times 100\% \quad (13)$$

۴-۱- داده‌های مورد استفاده

داده‌های مورد استفاده جهت شبیه‌سازی‌ها، متعلق به حسگرهای نصب‌شده در شبکه بزرگراهی ناحیه Metro در ایالت مینه‌سوتا آمریکا است که در اینترنت قابل دسترسی می‌باشند [۳۷]. در این مقاله مطابق شکل ۹، از اطلاعات مربوط به سه حسگر d783، d784، d785 نصب‌شده در ایستگاه شماره ۲۸۶ (بعد از گذرگاه فرعی خروجی) بزرگراه EB، I-394 (مسیر غرب به شرق) استفاده شده است. داده‌ها مربوط به شش ماه اول سال ۲۰۱۲ میلادی بوده و جریان ترافیک موجود در بازه زمانی پانزده دقیقه‌ای و با استفاده از نرم‌افزار مخصوص [۳۸] استخراج شده است. در این مقاله پیش‌بینی‌های ما بر اساس داده‌های مربوط به روزهای غیر تعطیل است و قصد داریم پیش‌بینی یک گام به جلو را انجام داده و جریان ترافیک پانزده دقیقه بعد را پیش‌بینی نماییم.

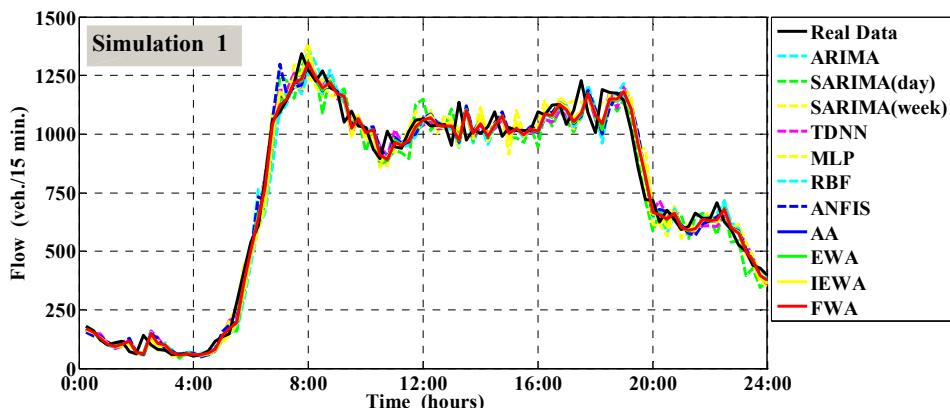


شکل ۹: دریافت‌کننده‌های حلقه‌های d783، d784، d785 نصب‌شده در ایستگاه شماره ۲۸۶ بزرگراه I-394 (مسیر غرب به شرق) [۳۷]

۴-۲- شبیه‌سازی ۱: پیش‌بینی با استفاده از داده‌های عادی

در این شبیه‌سازی به پیش‌بینی جریان ترافیک با استفاده از یکسری داده مربوط به روزهای عادی و بدون اثر هرگونه اغتشاشی پرداخته و عملکرد الگوریتم‌های ترکیب ارائه‌شده در قسمت قبل را بررسی می‌کنیم. داده‌های استفاده‌شده مربوط به ماه ژوئن سال ۲۰۱۲ میلادی بوده و هدف ما پیش‌بینی جریان ترافیک روز جمعه (آخرین روز کاری ماه ژوئن) و با استفاده از داده‌های بیست روز غیر تعطیل گذشته این ماه است.

داده‌های استفاده‌شده برای مدل ARIMA شامل داده‌های مربوط به یک ساعت اخیر می‌باشند. همچنین برای مدل SARIMA_(day) از داده‌های مربوط به یک هفته اخیر (پنج روز کاری) و برای مدل SARIMA_(week) از داده‌های مربوط به کل یک ماه (بیست روز غیر تعطیل) استفاده می‌نماییم. برای مدل TDNN نیز از داده‌های مربوط به کل یک ماه استفاده می‌نماییم به‌طوری‌که در هر لحظه با استفاده از داده‌های چهار گام قبل (یک ساعت اخیر) گام بعدی را پیش‌بینی می‌نماییم. برای مدل‌های MLP، RBF و ANFIS نیز از داده‌های مربوط



شکل ۱۰: نمودار جریان ترافیک واقعی و پیش‌بینی شده توسط مدل‌های پیش‌بین و الگوریتم‌های ترکیب در شبیه‌سازی ۱

جدول ۲: خطای پیش‌بینی جریان ترافیک توسط مدل‌های پیش‌بین و الگوریتم‌های ترکیب در شبیه‌سازی ۱

الگوریتم‌های ترکیب				مدل‌های پیش‌بین							شبیه‌سازی ۱
FWA	IEWA	EWA	AA	ANFIS	RBF	MLP	TDNN	SARIMA (week)	SARIMA (day)	ARIMA	معیار خطا
۸/۶۰۰۸	۸/۶۹۲۰	۸/۸۸۷۳	۹/۱۳۱۸	۱۰/۳۱۹۰	۱۰/۷۷۷۳	۱۰/۵۰۰۰	۹/۶۸۱۳	۸/۷۲۱۸	۹/۴۷۶۷	۹/۶۲۵۷	MAPE (%)
۰/۸۵۹۲	۰/۸۸۱۳	۱/۰۰۸۲	۱/۱۱۴۲	۱/۷۶۷۶	۱/۷۵۵۷	۲/۱۶۰۹	۱/۵۸۵۶	۰/۸۹۶۳	۱/۲۱۳۸	۱/۲۴۶۷	VAPE (%)

نحوه انجام شبیه‌سازی ۲ مشابه شبیه‌سازی قبلی بوده و نتایج به‌دست‌آمده در شکل ۱۲ و جدول ۳ آمده است.

در شبیه‌سازی ۲ به پیش‌بینی جریان ترافیک با استفاده از داده‌های عادی و غیرعادی پرداخته و عملکرد الگوریتم‌های ترکیب را به‌همراه مدل‌های پیش‌بین پارامتری و غیر پارامتری مورد بررسی قرار دادیم. داده‌های غیرعادی استفاده‌شده در این شبیه‌سازی که به‌صورت داده‌های اغتشاشی مطرح می‌باشند یا به‌دلیل تغییرات شرایط آب و هوایی (و به‌صورت بارش سنگین باران یا برف) و یا به‌دلیل تغییرات شرایط ترافیکی (و به‌صورت وقوع تصادف در جاده) می‌باشند که در هر دو صورت منجر به ترافیک سنگین و ازدحام شدید در جاده شده‌اند.

آن طوری که انتظار می‌رفت و از نتایج عددی جدول ۳ نیز قابل مشاهده است، الگوریتم ترکیب FWA بهترین ردیابی را با کاهش خطای پیش‌بینی انجام داده است که حاکی از قدرت بالای این الگوریتم در پیش‌بینی جریان ترافیک و مقاومت بالای آن در حضور داده‌های غیرعادی و اغتشاشی است. همان طوری که ملاحظه می‌گردد الگوریتم جدید ارائه‌شده در این مقاله وابستگی کمتری به نوع داده‌ها داشته و به‌خوبی داده‌های معیوب را شناسایی نموده و تأثیر آن‌ها را در پیش‌بینی کاهش می‌دهد. مجدداً در این شبیه‌سازی نیز بهترین جواب متعلق به الگوریتم ترکیب FWA است.


۳-۴- شبیه‌سازی ۲: پیش‌بینی با استفاده از داده‌های اغتشاشی

در این شبیه‌سازی قصد داریم جریان ترافیک را با استفاده از داده‌های عادی و یکسری داده‌های غیرعادی و اغتشاشی (بارش باران، برف و یا وقوع تصادف) پیش‌بینی نموده و عملکرد الگوریتم ترکیب FWA را با سایر الگوریتم‌های ترکیب و مدل‌های پیش‌بین مقایسه نماییم. در این شبیه‌سازی نیز بازه زمانی داده‌ها به‌مدت یک ماه بوده و از روز پنجشنبه اول ماه مارس تا روز پنجشنبه بیست و نهم ماه مارس سال ۲۰۱۲ میلادی است و هدف ما پیش‌بینی جریان ترافیک مربوط به روز جمعه سی‌ام ماه مارس با استفاده از داده‌های بیست‌ویک روز کاری گذشته این ماه است.

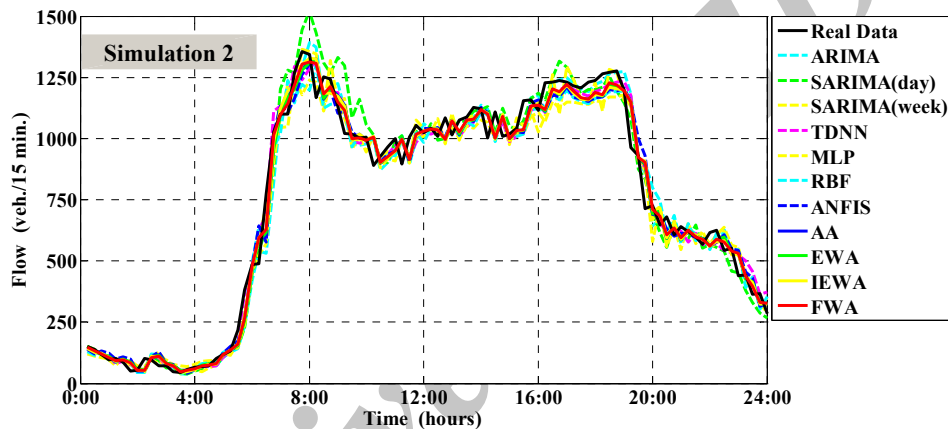
با بررسی و تحلیل کل داده‌ها و مطابق شکل ۱۱ مشاهده می‌کنیم که در روز چهارشنبه هفتم ماه مارس احتمالاً به‌علت بارش سنگین برف و باران، ترافیک خیلی سنگینی به‌وجود آمده است و داده‌های ترافیکی آن روز مشابه داده‌های یک روز کاملاً تعطیل، است. همچنین در روز جمعه شانزدهم ماه مارس شاهد ازدحام شدیدی در جاده هستیم که احتمالاً ناشی از وقوع تصادف است [۳۷]. ما قصد داریم تأثیر این روزها و وجود داده‌های اغتشاشی شامل تغییرات شرایط آب و هوایی و ترافیکی را بر روند پیش‌بینی جریان ترافیک مشاهده نماییم.

جدول ۳: خطای پیش‌بینی جریان ترافیک توسط مدل‌های پیش‌بین و الگوریتم‌های ترکیب در شبیه‌سازی ۲

الگوریتم‌های ترکیب				مدل‌های پیش‌بین							شبیه‌سازی ۲
FWA	IEWA	EWA	AA	ANFIS	RBF	MLP	TDNN	SARIMA (week)	SARIMA (day)	ARIMA	معیار خطا
۸/۸۰۵۶	۹/۳۸۸۶	۹/۵۳۹۰	۹/۱۰۰۳	۱۱/۱۶۵۸	۱۲/۴۵۰۴	۱۲/۲۳۹۹	۱۵/۶۰۴۳	۱۰/۸۱۴۷	۱۰/۰۶۳۲	۱۰/۲۰۶۱	MAPE (%)
۱/۰۳۸۵	۱/۱۵۹۰	۱/۲۰۰۶	۱/۱۳۳۴	۲/۴۴۶۱	۱/۶۷۹۵	۲/۳۴۵۵	۵/۶۸۲۳	۱/۲۶۲۶	۱/۲۳۰۰	۱/۵۲۳۰	VAPE (%)



شکل ۱۱: نمودار جریان ترافیک مربوط به روزهای اغتشاشی ۷ و ۱۶ مارس به همراه روز پیش‌بینی ۳۰ مارس سال ۲۰۱۲



شکل ۱۲: نمودار جریان ترافیک واقعی و پیش‌بینی شده توسط مدل‌های پیش‌بین و الگوریتم‌های ترکیب در شبیه‌سازی ۲

۵- نتیجه‌گیری

در سیستم‌های ترافیکی، برخی از مدل‌های پیش‌بین قادر هستند که تغییرات لحظه‌ای را به خوبی پیش‌بینی نمایند. این مدل‌ها برای پیش‌بینی وقایع ناگهانی ترافیکی مانند وقوع تصادف در جاده بسیار مناسب می‌باشند. همچنین برخی دیگر از مدل‌های پیش‌بین برای پیش‌بینی رخدادهای افزایشی آرام، مانند بارش باران و یا برف شدید در جاده مناسب می‌باشند. بنابراین مدل‌های ترکیبی باید قادر به پیش‌بینی دقیق‌تری باشند و تقریباً بتوانند هر دو حالت فوق را هم‌زمان در نظر بگیرند. به طور کلی می‌توان همه الگوریتم‌های ترکیب بیان شده در این مقاله را به نوعی از خانواده مدل‌های ترکیبی WA در نظر گرفت که در هرکدام از این الگوریتم‌ها، ضرایب وزنی موجود به طور جداگانه‌ای محاسبه می‌شوند. این ضرایب وزنی، بیانگر ارزش هرکدام از مدل‌های پیش‌بین در عملیات ترکیب می‌باشند. با توجه به مطالعات انجام‌یافته در این زمینه، استفاده از این الگوریتم‌های ترکیب در حوزه حمل‌ونقل زمینی و برای پیش‌بینی جریان ترافیک، یک نوآوری محسوب می‌گردد.

در این مقاله با استفاده از ساختار کنترل‌کننده فازی، یک الگوریتم ترکیب جدید بنام FWA جهت پیش‌بینی کوتاه‌مدت جریان ترافیک برای یک گام بعد (که پانزده دقیقه در نظر گرفته شده است) ابداع نموده‌ایم. با توجه به ساختار محاسباتی الگوریتم FWA، در مقایسه با انواع مختلف مدل‌های پیش‌بینی سابق (روش‌های پارامتری، روش‌های غیر پارامتری و ترکیبی) و الگوریتم‌های ترکیب متفاوت AA، EWA و IEWA، الگوریتم FWA به‌عنوان یک مدل پیش‌بین ترکیبی جدید، دارای دقت بالایی است.

تمامی عملیات پیش‌بینی جریان ترافیک با استفاده از داده‌های حسگری واقعی و مربوط به بزرگراهی در ایالت مینه‌سوتا آمریکا اجرا و شبیه‌سازی شده است. داده‌های واقعی مورد استفاده در این مقاله شامل داده‌های عادی و اغتشاشی (بارش باران، برف و یا وقوع تصادف) می‌باشند که ما عملکرد همه آن‌ها را با انجام دو شبیه‌سازی در پیش‌بینی جریان ترافیک در نظر گرفته‌ایم. آن طوری که در شبیه‌سازی‌ها دیده می‌شود الگوریتم FWA نسبت به داده‌های مزاحم کاملاً حساس بوده و با شناسایی آن‌ها و ایجاد عدم وابستگی به این داده‌ها توانسته است پیش‌بینی دقیق‌تری را نسبت به سایر مدل‌ها، ارائه

- based on past experiences," *IET Intelligent Transportation Systems*, vol. 6, no. 3, pp. 292-305, 2012.
- [14] T. Peng, and Z. Tang, "A small scale forecasting algorithm for network traffic based on relevant local least squares support vector machine regression model," *Applied Mathematics and Information Sciences*, vol. 9, no. 2, pp. 653-659, 2015.
- [15] A. Stathopoulos, L. Dimitriou, and T. Tsekeris, "Fuzzy modeling approach for combined forecasting of urban traffic flow," *Computer Aided Civil and Infrastructure Engineering*, vol. 23, pp. 521-535, 2008.
- [16] J.K. Kumar, and A. Kailas, "Prediction of future stock close price using proposed hybrid ANN model of functional link fuzzy logic neural model," *IAES International Journal of Artificial Intelligence*, vol. 1, no. 1, pp. 25-30, 2012.
- [۱۷] فرشته صادقی، ابوالفضل جلیلود، سیدهادی حسینی و منیژه صفاری، "ارائه یک روش ترکیبی مبتنی بر تبدیل موجک گسسته برای پیش‌بینی بار الکتریکی با استفاده از یک مدل دوبعدی"، *مجله مهندسی برق دانشگاه تبریز*، جلد ۵۴، شماره ۳، صفحات ۶۷-۷۸، پاییز ۹۴.
- [18] D. Zeng, J. Xu, J. Gu, L. Liu, and G. Xu, "Short term traffic flow prediction using hybrid ARIMA and ANN models," *Workshop on Power Electronics and Intelligent Transportation System*, Guangzhou, China, pp. 621-625, 2008.
- [19] Y. Zhang, Y. Zhang, and A. Haghani, "A hybrid short-term traffic flow forecasting method based on spectral analysis and statistical volatility model," *Transportation Research part C*, vol. 43, no. 1, pp. 65-78, 2014.
- [20] S.H. Hosseini, B. Moshiri, A. Rahimi-Kian, and B.N. Araabi, "Short-term traffic flow forecasting by mutual information and artificial neural networks," *IEEE International Conference on Industrial Technology*, Athens, Greece, pp. 1136-1141, 2012.
- [21] C.Y. Chong, "Hierarchical estimation", *Proceedings of the MIT/ONR C3 Workshop*, Monterey, CA, 1979.
- [22] L. Spyer, "Computation and transmission requirements for a decentralized linear-quadratic-Gaussian control problem," *IEEE Transactions on Automatic Control*, vol. 24, pp. 266-269, 1979.
- [23] X.R. Li, Y.M. Zhu, J. Wang, and C.Z. Han, "Optimal linear estimation fusion Part I: unified fusion rules," *IEEE Transactions on Information Theory*, vol. 49, no. 9, pp. 2192-2208, 2003.
- [24] A.T. Alouani, "Distributed estimators for nonlinear systems," *IEEE Transactions on Automatic Control*, vol. 35, no. 9, pp. 1078-1081, 1990.
- [25] A.T. Alouani, and J.D. Birdwell, "Distributed estimation: constraints on the choice of the local models," *IEEE Transactions on Automatic Control*, vol. 33, no. 5, pp. 503-506, 1988.
- [26] Z. Xu, and Q.L. Da, "An overview of operators for aggregating information", *International Journal of Intelligent Systems*, vol. 18, pp. 953-969, 2003.
- [27] V. Torra, and Y. Narukawa, *Modeling Decisions Information Fusion and Aggregation Operators*, Springer, 2007.
- [28] G. Yu, J. Hu, C. Zhang, L. Zhuangand, and J. Song, "Short-term traffic flow forecasting based on Markov chain model," *Intelligent Vehicles Symposium*, pp. 208-212, 2003.
- نماید. در ساختار ترکیب الگوریتم FWA، سعی شده است هم از قابلیت‌های سری‌های زمانی و هم از قدرت تطبیق‌پذیری انواع مختلف شبکه‌های عصبی و عصبی-فازی استفاده بشود که منجر به کاهش خطای پیش‌بینی جریان ترافیک شده است.

مراجع

- [1] K.Y. Chan, et al., "Neural-network-based models for short-term traffic flow forecasting using a hybrid exponential smoothing and Levenberg-Marquardt algorithm," *IEEE Transaction Intelligent Transportation System*, vol. 13, no. 2, pp. 644-654, 2012.
- [2] L. Yang, J. Hu, and L. Kong, "Two dimensional mixed traffic flow considering the transit traffic," *TELKOMNIKA, Indonesian Journal of Electrical Engineering*, vol. 10, no. 8, pp. 1969-1974, 2012.
- [3] S.H. Hosseini, B. Moshiri, A. Rahimi-kian, and B.N. Araabi, "Traffic flow prediction using MI algorithm and considering noisy and data loss conditions: An application to Minnesota traffic flow prediction," *PROMET-Traffic and Transportation*, vol. 26, no. 5, pp. 393-403, 2014.
- [4] A. Nagare, and S. Bhatia, "Traffic flow control using neural network," *International Journal of Applied Information Systems*, vol. 1, no. 2, pp. 50-52, 2012.
- [5] Y. Zhang, *How to Provide Accurate and Robust Traffic Forecasts Practically*, Abdel-Rahim, A. (Ed.): 'Intelligent Transportation System' (INTECH, eBook), pp. 189-206, 2012.
- [6] J. Zhong, and S. Ling, "Key factors of K-nearest neighbors nonparametric regression in short-time traffic flow forecasting," *21st International Conference on Industrial Engineering and Engineering Management*, pp. 9-12, 2014.
- [7] A. Ramezani, B. Moshiri, A. Rahimi-Kian, B. Aarabi, and B. Abdulhai, "Distributed maximum likelihood estimation for flow and speed density prediction in distributed traffic detectors with Gaussian mixture model assumption," *IET Intelligent Transportation Systems*, vol. 6, no. 2, pp. 215-222, 2012.
- [8] M.C. Tan, S.C. Wong, J.M. Xu, Z.R. Guan, and P. Zhang, "An aggregation approach to short-term traffic flow prediction," *IEEE Transaction on Intelligent Transportation Systems*, vol. 10, no. 1, pp. 60-69, 2009.
- [9] L. Lv, M. Chen, Y. Liu, and X. Yu, "A plane moving average algorithm for short-term traffic flow prediction," *Advances in Knowledge Discovery and Data Mining*, vol. 9078, pp. 357-369, 2015.
- [10] S.V. Kumar, and L. Vanajakshi, "Short-term traffic flow prediction using seasonal ARIMA model with limited input data," *European Transport Research Review*, vol. 7, no. 21, pp. 1-9, 2015.
- [11] J.Z. Zhu, J.X. Cao, and Y. Zhu, "Traffic volume forecasting based on radial basis function neural network with the consideration of traffic flows at the adjacent intersections," *Transportation Research Part C*, vol. 10, no. 47, pp. 139-154, 2014.
- [12] Y. Hou, and Y. Mai, "Chaotic prediction for traffic flow of improved BP neural network," *TELKOMNIKA, Indonesian Journal of Electrical Engineering*, vol. 11, no. 3, pp. 1683-1690, 2013.
- [13] H. Chang, Y. Lee, B. Yoon, and S. Baek, "Dynamic near-term traffic flow prediction: system-oriented approach

- [۳۴] فرناز صباحی و محمدرضا اکبرزاده توتونچی، "شناسایی سیستم‌های غیر خطی بر اساس منطق فازی توسعه‌یافته"، مجله مهندسی برق دانشگاه تبریز، جلد ۴۴، شماره ۱، صفحات ۳۲-۲۳، بهار ۹۳.
- [35] A.P. Engelbrecht, *Computational Intelligence*, John Wiley & Sons Ltd, 2007.
- [36] O. Nelles, *Nonlinear System Identification*, Springer, 2000.
- [37] www.d.umn.edu/tdrl/traffic/, Retrieved June 30, 2013.
- [38] www.d.umn.edu/~tkwon/TDRLSoftware/TravelTimeMetroTC.msi/, Retrieved August 08, 2015.
- [29] S.H. Hosseini, M. Shabaniyan, and B.N. Araabi, "A neuro-fuzzy control for TCP network congestion," *Applications of Soft Computing: Springer*, vol. 58, pp. 93-101, 2009.
- [30] Y. WANG, and X.R. LI, "Distributed estimation fusion with unavailable cross-correlation," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 48, no. 1, pp. 259-278, 2012.
- [31] C. Thomas, and B. Narayanaswamy, "Mathematical basis of sensor fusion in intrusion detection systems," *Chapter 10 of Sensor Fusion and Its Applications*, Edited by C. Thomas, Published by Sciyo, pp. 225-250, 2010.
- [32] J. Triesch, and C. von-der-Malsburg, "Democratic integration: Self-organized integration of adaptive cues," *Neural Computation*, vol. 13, pp. 2049-2074, 2001.
- [33] G. Brown, *Ensemble Learning, Encyclopedia of Machine Learning*, Springer Press, 2010.

زیر نویس‌ها

- ¹¹ Arithmetic Averaging
- ¹² Weighted Arithmetic Averaging
- ¹³ Ordered Weighted Averaging
- ¹⁴ Error-based Weighted Averaging
- ¹⁵ Fuzzy Weighted Averaging
- ¹⁶ Improved EWA
- ¹⁷ Soft Switching
- ¹⁸ Fuzzification Membership Functions
- ¹⁹ De-Fuzzification
- ²⁰ Center of Gravity

- ¹ Intelligent Transportation System
- ² Maximum Likelihood
- ³ Auto-Regressive Integrated Moving Average
- ⁴ Seasonal ARIMA
- ⁵ Multi-Layer Perceptron
- ⁶ Radial Basis Function
- ⁷ Time Delay Neural Network
- ⁸ K Nearest Neighbor
- ⁹ Support Vector Machine
- ¹⁰ Chong and Spyer

Archive