

رویکردی نو در بررسی پیش‌بینی پذیری ترافیک شهری مبتنی بر تئوری آشوب و

پیش‌بینی جریان ترافیک شهر مشهد مبتنی بر سیستم فازی - عصبی تطبیقی چندگانه

سید حمید عباسی (مستول مکاتبات)، مربی، گروه مهندسی کامپیوتر، دانشگاه آزاد اسلامی، واحد دامغان، دامغان، ایران.

مهدی یعقوبی، استادیار، دانشکده مهندسی کامپیوتر، دانشگاه آزاد اسلامی واحد مشهد، مشهد، ایران

E-mail: h.abbasi@damghaniau.ac.ir

پذیرش: ۹۱/۰۲/۲۴

دریافت: ۹۱/۰۸/۱۷

چکیده

پیش‌بینی کوتاه مدت پارامترهای ترافیکی مانند جریان ترافیک، سرعت و ازدحام، دارای اهمیت بسیاری در پژوهش‌های حوزه سیستم‌های حمل و نقل هوشمند مدرن است. در این مقاله، ابتدا با بکارگیری تئوری آشوب به بررسی پیش‌بینی پذیری جریان ترافیک شهری پرداخته شده و غیرتصادفی بودن سری زمانی حجم ترافیک مورد بررسی قرار گرفته است. سپس، در حوزه پیش‌بینی، با توجه به این نکته که یکی از مهم‌ترین مشکلات در هنگام پیش‌بینی وضعیت آینده ترافیک، ناقص بودن داده‌ها به علل مختلف است، الگوریتم ارایه شده در این مقاله با بکارگیری روش‌های پیش‌پردازش، سعی بر کاهش تأثیر داده‌های معیوب دارد. همچنین در فاز پیش‌پردازش، دسته‌بندی‌های مناسب با در نظر گرفتن تأثیرات پارامترهای اجتماعی بر جریان ترافیک، صورت گرفته است. در بخش بعد و به منظور پیش‌بینی جریان ترافیک، با توجه به ویژگی‌های تطبیق‌پذیری، الگوریتم‌های خودیادگیر شبکه‌های عصبی و نیز یادگیری قوانین فازی که در ساختار ANFIS ترکیب شده است، از این مدل برای پیش‌بینی کوتاه‌مدت حجم ترافیک استفاده شده است. مدل مطرح شده در این مقاله، برای پیش‌بینی جریان ترافیک موجود در بلوار فرامرزعباسی در شهر مشهد در کشور ایران مورد استفاده قرار گرفته است. مقایسه نتایج مقادیر پیش‌بینی شده جریان ترافیک با مقادیر اندازه‌گیری شده در واقعیت، نشان می‌دهد که مدل مطرح شده به طور رضایت بخشی جریان ترافیک را پیش‌بینی می‌کند.

واژه‌های کلیدی: پیش‌بینی کوتاه مدت، سری زمانی، نمای لیاپانوف، سیستم استنتاج فازی

۱. مقدمه

نویسندگان نشان دادند که این رفتار تصادفی بسیار نامنظم بوده و حتی نمی‌توان آن را با آزمایش در یک دوره ۲ ساعته مترکم کرده و نشان داد [Stathopoulos and Karlaftis, 2003]. برای مدلسازی و پیش‌بینی کوتاه مدت جریان ترافیک آنالیزهای آماری سری زمانی، در فرم مدل‌های خانواده ARIMA به سرعت رشد و توسعه یافتند. اما با این حال و با توجه به این که تغییرات زمانی جریان ترافیک یک خصوصیت ویرانگر در پیش‌بینی کوتاه مدت است، متدهای سری زمانی سنتی نیز معمولاً اداره کردن تغییرات سریع جریان در فضای شهری ناتوان هستند. استفاده از سایر تکنیکها از قبیل رگرسیون غیرپارامتریک، رگرسیون خطی محلی و مدل‌های فیلترینگ کالمن پیشرفتهایی را در مدلسازی کوتاه مدت جریان ترافیک نشان دادند، اما در راه‌های شریانی دارای چراغ راهنمایی، مورد آزمایش قرار نگرفتند. وابستگی مکانی جریان باعث می‌شود انتشار آن در مکان تأثیراتی در بهبود کارایی مدل برای پیش‌بینی جریان داشته باشد. مقالات نشان می‌دهند که پیچیدگی در مدلسازی این رفتارها به علت افزایش پیچیدگی مدلها است. برای رویارویی با این مشکل، برخی از نویسندگان به سمت مدلسازی چند متغیره گرایش پیدا کرده اند که در این حالت مدلها از داده‌هایی از موقعیتهای مورد نظر از قبیل مکانهایی در خلاف جهت استفاده می‌کنند و این مدلها که دارای امکانات بیشتری برای مدیریت داده‌های متوالی مرتبط هستند، برای پیش‌بینی کوتاه مدت جریان استفاده می‌شوند. [Williams, 2001] برای پیش‌بینی جریان ترافیک در تقاطعها، این مقاله یک روش پیش‌بینی جدید را براساس تکنیک ترکیب اطلاعات توسط ANFIS ارائه کرده است. ANFIS یک ابزار استخراج فازی است که در چارچوب شبکه‌های تطبیقی پیاده‌سازی شده است. این روش قابلیت یادگیری قوانین فازی را با تطبیق پذیری و الگوریتمهای خودیادگیر شبکه‌های عصبی ترکیب میکند. از ساختار ANFIS در کاربردهای مختلفی همچون پیش‌بینی، شناسایی و دسته بندی استفاده شده است [Aliyari, Teshnehlab and Khaki, 2009; Vosoulipour, Teshnehlab and Moghadam, 2008][Wei and Cheng,

با گسترش کاربرد سیستمهای حمل و نقل هوشمند (ITS^۱)، تحقیقات بسیاری در مورد جریان ترافیک و پردازش آن متمرکز شده اند. جریان ترافیک برای تمام زیر سیستمهای ITS نظیر سیستم مدیریت ترافیک پیشرفته (ATMS^۲)، سیستم اطلاعات مسافرتی پیشرفته (ATIS^۳) و سیستم حمل و نقل عمومی پیشرفته (APTS^۴)، بسیار بنیادی و پراهمیت است. پیش‌بینی جریان ترافیک به صورت دقیق و زنده، پایه و اساس مطالعات کنترل ترافیک و جریان آن است. به تازگی، با توسعه سیستمهای ترافیک هوشمند، پیش‌بینی ترافیک نقش مهمی در مدیریت ترافیک و سیستمهای اطلاعاتی پیشرفته ایفا می‌کند. روشهایی از قبیل شبکه‌های عصبی مصنوعی، الگوریتم‌های ژنتیک و فیلترینگ کالمن، به وسیله بسیاری از محققین، برای پیش‌بینی ترافیک مورد استفاده قرار گرفته است [Shi and Zheng, 2004; Liu et al. 2005]. این روشهای کلاسیک آنالیز، جریان ترافیک را به عنوان یک پدیده تصادفی در نظر گرفته و بنابراین، این نظریه‌ها مبتنی بر فرآیندهای تصادفی هستند. کشف پدیده آشوب نشان داد که ذات سیستمهای پیچیده تصادفی نیست، بلکه می‌توان این سیستمهای پیچیده را توسط مدل آشوبناک در یک سیستم دینامیکی غیرخطی توصیف کرد [Tsonis, 1993]. جریان ترافیک می‌تواند هم به عنوان یک پدیده زمانی و هم به عنوان یک پدیده مکانی در نظر گرفته شود، زیرا که مفهوم آن هم وابسته به زمان و هم وابسته به مکان (فاصله از نقطه پیش‌بینی) است. همان گونه که HEAD در سال ۱۹۹۵ پیشنهاد کرد در محیط شهری که حضور زمان بندی به ترافیک یک رفتار زمانی- مکانی بسیار تصادفی تر می‌دهد، مطالعه آن نسبت به آزادراهها بسیار دشوارتر است [Head, 1995]. پس از آن، همان گونه که Stathopoulos و Carlaftis نشان دادند، جریان ترافیک در راه‌های شریانی شهری دارای یک رفتار زمانی - مکانی خاص بوده که حالت تصادفی را نمایش می‌دهد که درک و دریافت نظم تناوبی سنتی (ماهانه، هفتگی، روزانه و یا حتی ساعتی) را از بین برده است [Stathopoulos and Karlaftis, 2001]. در مطالعه بعدی همین

اندازه‌ای برای میزان آشوبی بودن سیستم در اختیار قرار دهد. توصیف مقداری حساسیت رفتار سیستم به مقادیر اولیه در شرایط آشوبی با معرفی نماهای لیاپانوف امکان‌پذیر می‌شود. اگر دو مسیر نزدیک به هم در شرایط آشوبی ابتدا به اندازه d از یکدیگر فاصله داشته باشند، فاصله آنها در لحظه t به صورت رابطه ۱ خواهد بود:

$$d(t) = d_0 e^{\lambda t} \quad (1)$$

پارامتر λ نمای لیاپانوف نام دارد. برای آشوبناک بودن یک سیستم، بزرگ‌ترین نمای لیاپانوف به دست آمده بایستی از صفر بزرگ‌تر باشد و اگر این عدد از یک هم بزرگ‌تر باشد، بیشینه طول پیش‌بینی دقیق کوتاه‌تر از فرکانس نمونه‌برداری داده‌های موجود در سری زمانی است. بنابراین تنها سیستم‌های با نماهای لیاپانوف بین صفر تا یک، از قابلیت پیش‌بینی آشوبناک برخوردارند. در صورتی که این نما بسیار کوچک‌تر از یک باشد، پیش‌بینی بلندمدت به‌طور دقیق امکان‌پذیر است [Pengjian, Xuwei and Santi, 2005]. اکنون روش محاسبه نمای لیاپانوف برای سیستمی که در آن سری زمانی در اختیار است، بررسی می‌شود.

۲-۱ شناسایی رفتار آشوبناک سری زمانی با استفاده از نماهای لیاپانوف


استفاده از نماهای لیاپانوف متداول‌ترین راه برای شناسایی قابلیت پیش‌بینی پذیری سری‌های زمانی از جمله سری زمانی حجم ترافیک است. نمای مثبت نشانه واگرایی و نمای منفی نشانه همگرایی است و بزرگی قدرمطلق نما، سرعت همگرایی یا واگرایی را نشان می‌دهد [Law, Yousefpoor, Esfahani and Nojumi, 2008; rence and Feng, 2005]. فرض کنید سری x_0, x_1, x_2, \dots در دسترس و فاصله زمانی بین آنها از $t_n - t_{n-1} = \tau$ به دست آید که τ فاصله زمانی بین دو اندازه‌گیری متوالی است. اگر سیستم رفتار آشوبی داشته باشد، واگرایی مسیرهای مجاور بر اساس رشته اختلاف‌های بین آنها به صورت رابطه ۲ قابل بیان است:

2010: این مقاله با بکارگیری داده‌های ترافیکی در چندین بازه زمانی قبل سعی در پیش‌بینی بازه زمانی بعدی دارد. با مقایسه روش پیشنهاد شده در این مقاله با روش‌های سنتی موجود برای پیش‌بینی حجم ترافیک، روش پیشنهاد شده دارای هوشمندی، قابلیت اطمینان و دقت بیشتری است. در این مقاله در بخش ۲ به معرفی بزرگ‌ترین نمای لیاپانوف به عنوان معیاری جهت بررسی قابل پیش‌بینی بودن سیستم پرداخته شده است، سپس در بخش ۳، مدل عصبی فازی بکار گرفته شده در مقاله برای پیش‌بینی تشریح شده است، در بخش ۴ به معرفی داده‌های بکار گرفته شده و با انجام عملیات پیش‌پردازش بر روی آنها، داده‌ها آماده شده و سپس با محاسبه نمای لیاپانوف برای داده‌ها، قابلیت پیش‌بینی جریان ترافیک مورد ارزیابی قرار گرفته است. سپس در بخش ۵ با استفاده از مدل پیشنهادی، به پیش‌بینی جریان ترافیک در یکی از تقاطع‌های شهر مشهد پرداخته شده و نتایج بیان شده است. در نهایت در بخش ۶ نتیجه‌گیری بیان شده و راهکارهایی برای تحقیقات بعدی ارائه شده است.

۲. بررسی غیرتصادفی و پیش‌بینی پذیر بودن سیستم با استفاده از نماهای لیاپانوف

نماهای لیاپانوف یک سیستم، مجموعه‌ای از اندازه‌های هندسی نامتغیرند که به‌طور مستقیم، دینامیک درون سیستم را بیان می‌کنند. یکی از کاربردهای آنها در تشخیص پدیده آشوب در یک سیستم و همچنین معیاری برای میزان آشوبناک بودن یک رفتار است [Yang and Wu, 2011]. مبحث رفتار آشوبی، تا آنجا که به حساسیت در برابر شرایط اولیه و ناپایداری ساختاری مربوط می‌شود، کیفی است، در حالی که ما در مطالعه سیستم، اطلاعات مربوط به رفتار آن را به صورت یک معادله دیفرانسیل، یک نگاشت بازگشتی یا یک سری زمانی در اختیار داریم و بر همین اساس لازم است که روش‌های تحلیلی یا کمی برای تشخیص آشوب در هر سیستم، در اختیار باشد که با استفاده از آن بتوان رفتار آشوبی را از رفتار تصادفی نویزگونه تشخیص داد. از طرفی این روش باید بتواند

مناسب کار نظام‌مندی نیست و عمدتاً نیاز به سعی و خطای بسیار برای رسیدن به بهترین کارایی ممکن دارد. به همین دلیل ایده استفاده از الگوریتم‌های یادگیری برای سیستم‌های فازی مطرح شد. در این بین توانایی‌های یادگیری شبکه‌های عصبی آنها را، به عنوان اولین اهداف مورد نظر برای ادغام در روش‌های فازی به منظور خودکارسازی رویه توسعه و استفاده از سیستم‌های فازی برای کاربردهای مختلف مطرح کرد. تخمین تابع با استفاده از روش‌های یادگیری بسیار در شبکه‌های عصبی و شبکه‌های عصبی فازی مطرح شده است. یکی از سیستم‌های عصبی فازی معروف برای تخمین توابع مدل ANFIS است. ANFIS توسط Jang پیشنهاد شد [Jang, 1993], [Jang, Sun and Mizutani, 1997]. ساختار ANFIS شامل قابلیت‌های استنتاج سیستم فازی و انطباق‌پذیری شبکه عصبی است. ANFIS، روشی است برای بهبود بخشیدن به قوانین سیستم فازی با کمک الگوریتم‌های آموزشی در شبکه‌های عصبی مصنوعی. در مقایسه با شبکه عصبی مصنوعی، ANFIS به علت تنظیم‌پذیری پارامترهای سیستم فازی، سریع‌تر آموزش می‌بیند و همچنین دقت بیشتری دارد. در شکل ۱، یک ANFIS را مشاهده می‌کنید که از نوع Sugeno است و دارای دو ورودی و یک خروجی است.



شکل ۱. شمایی از معماری ANFIS

قوانین سیستم فازی Sugeno مرتبه یک، به صورت زیر است:

$$\text{Rule } i: \text{ If } x \text{ is } A_i \text{ and } y \text{ is } B_i \text{ then } f_i = p_i x + q_i y + r_i$$

شبکه‌های عصبی مصنوعی، شبکه‌های پیش‌خوردی شامل پنج لایه هستند. هر نود i در اولین لایه، یک نود وفقی است که مطابق

$$d_0 = |x_j - x_i| \quad (2)$$

$$d_1 = |x_{j+1} - x_{i+1}|$$

$$d_2 = |x_{j+2} - x_{i+2}|$$

⋮

$$d_n = |x_{j+n} - x_{i+n}|$$

فرض می‌شود با افزایش n مقادیر d_n به طور نمایی افزایش می‌یابند (حداقل به صورت میانگین)، بنابراین:

$$d_n = d_0 e^{\lambda n} \quad (3)$$

و با محاسبه لگاریتم آن :

$$\lambda = \frac{1}{n} \ln \frac{d_n}{d_0} \quad (4)$$

رابطه فوق، نمای لیاپانوف را برای یک سری زمانی در اختیار ما قرار می‌دهد. در صورتی که مقدار حاصل شده به عنوان نمای لیاپانوف یک سری زمانی مقداری بزرگ‌تر از صفر باشد، سری زمانی مذکور تصادفی نیست و می‌توان آن را تحت مدل آشوبناک توصیف کرد و بنابراین قابل پیش‌بینی است.

۳. سیستم فازی - عصبی

پس از معرفی نمای لیاپانوف به عنوان معیاری برای بررسی قابل پیش‌بینی بودن سیستم، در این بخش به بررسی سیستم فازی-عصبی که از آن برای پیش‌بینی حجم ترافیک استفاده شده، پرداخته می‌شود. این معماری به نام ANFIS نامیده می‌شود که مخفف شبکه وفقی بر اساس سیستم استنتاج فازی است. در ادامه شرح مختصری در مورد معماری ANFIS ارائه می‌شود. از هنگامی که روشها و سیستم‌های فازی به منظور استفاده در کاربردهای متفاوت معرفی شده‌اند، پژوهشگران متوجه شده‌اند که ایجاد یک سیستم فازی قدرتمند، کار چندان ساده‌ای نیست. دلیل این مساله این است که یافتن توابع عضویت و قوانین فازی

رابطه ۵ است:

$$O_i^1 = \mu_{A_i}(x) \quad (5)$$

که در آن x ورودی به گره i و A_i برچسب زبانی (کوچک، بزرگ و...) است که با این تابع گره در ارتباط است. به عبارت دیگر O_i^1 تابع عضویت مجموعه فازی A است که ورودی x ، در آن شرایط خاصی دارد. تابع عضویت A می‌تواند تابع گوسین باشد یا تابع عضویت مثلثی و یا غیره. پارامترهای تابع عضویت که در این لایه بکار می‌روند به عنوان پارامترهای مقدم هستند. لایه دوم، خروجی‌های لایه اول را ترکیب می‌کند. در نتیجه خروجی مطابق رابطه ۶ خواهد شد.

$$O_i^2 = w_i = \mu_{A_i}(x) \mu_{B_i}(y) \quad (6)$$

در اینجا هر گره خروجی قدرت آتش زدن یک قانون را بازنمایی می‌کند. لایه بعدی که لایه سوم است، خروجی لایه‌های قبل را نرمال کرده و قدرت آتش زدن قانون f را نسبت به جمع کلی قدرت‌های آتش زدن همه قوانین بر اساس رابطه ۷ محاسبه می‌کند.

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad (7)$$

در لایه چهارم، خروجی بر اساس لایه سوم به دست می‌آید که در رابطه ۸ نشان داده شده است:

$$O_i^4 = w f_i = w_i(p_i x + q_i y + r_i) \quad (8)$$

که در آن f یک تابع است و در سیستم فازی Sugeno نوع اول بکار می‌رود. پارامترهای این نود (p_i, q_i, r_i) به عنوان پارامترهای تالی نامیده می‌شوند. در نهایت، خروجی نهایی AN-FIS، خروجی آخرین لایه است که از رابطه ۹ به دست می‌آید.

$$O_i^5 = z = \sum_i \bar{w}_i f_i \quad (9)$$

هدف اصلی از طراحی ANFIS، بهبود دادن پارامترهای آن است. دو مرحله برای طراحی ANFIS وجود دارد. مرحله اول، طراحی پارامترهای مقدم و مرحله دوم، آموزش پارامترهای تالی است. روشهای مختلفی نیز برای طراحی پارامترهای مقدم پیشنهاد شده است که از میان آنها می‌توان به خوشه‌بندی C-

means، خوشه‌بندی fuzzy c-means و خوشه‌بندی تفریقی اشاره کرد. زمانی که پارامترهای مقدم به دست آیند، پارامترهای تالی بر اساس داده‌های ورودی - خروجی حاصل می‌شوند.

۴. پیاده سازی

در این قسمت پس از معرفی داده‌ها و انجام عملیات پیش پردازش بر روی داده‌ها، ابتدا با محاسبه بزرگ ترین نمای لیاپانوف برای سری زمانی حاصل از جریان ترافیک به بررسی غیرتصادفی بودن و قابل پیش‌بینی بودن سیستم پرداخته شده است. در بخش بعدی پس از به قطعیت رسیدن در وجود پدیده آشوب در سری زمانی حاصل از جریان ترافیک، با بکارگیری سیستم ANFIS به پیش‌بینی جریان ترافیک موجود در بلوار فرامرزی عباسی شهر مشهد پرداخته شده و نتایج آن و نیز دقت پیش‌بینی با استفاده از پارامترهای ارزیابی ارائه شده است.

۴-۱ معرفی داده‌های مورد مطالعه و انجام پیش‌پردازش بر روی داده‌ها

با توجه به اینکه شهر مشهد از سیستم نرم‌افزاری SCATS برای کنترل ترافیک در اکثر تقاطع‌های خود استفاده می‌کند، نویسندگان مقاله نیز از داده‌های این سیستم برای پیش‌بینی استفاده کرده‌اند. ابتدا به بررسی ساختار داده‌ای ارائه شده توسط نرم افزار و اصطلاحات مورد استفاده پرداخته شده است. داده‌های مورد بررسی در این مقاله مربوط به تقاطع خیام - فردوسی از سمت میدان جانباز در بازه زمانی دو سال شامل سالهای ۱۳۸۶ و ۱۳۸۷ است. موقعیت تقاطع مورد نظر در نرم‌افزار SCATS در شکل ۲ نشان داده شده است. در تقاطع فوق مسیر شمال دارای ۳ خط است که حلقه‌های القایی^۹ شماره ۱۲، ۱۳ و ۱۴ حجم خودروهای این مسیر را ثبت می‌کنند، مسیر جنوب دارای ۲ خط است که حلقه‌های القایی ۶ و ۷ حجم خودروهای این مسیر را ثبت می‌کنند، مسیر غرب دارای ۴ خط است که حلقه‌های القایی شماره ۸، ۹، ۱۰ و ۱۱ حجم خودروهای این مسیر را ثبت می‌کنند و در نهایت، مسیر شرق که دارای ۴ خط بوده و حلقه‌های القایی شماره ۲، ۳، ۴ و ۵ حجم خودروهای این

از جمله روزهای جمعه و نیز روزهای مناسبتی در مجموعه داده دیگری گردآوری می‌شود. همچنین با مدنظر قرار دادن این نکته که انجام پیش‌بینی برای ساعت‌های ۲۴ نیمه شب تا ۵ صبح با توجه به حجم کم ترافیک ضروری نیست، داده‌های مربوط به این ساعات از شبانه‌روز از مجموعه داده حذف شده‌اند. به این ترتیب ۵ مجموعه داده (۵ سری زمانی) آماده می‌شوند.

۴-۲ بررسی پیش‌بینی پذیری جریان ترافیک با استفاده از نماهای لیپانوف


در این قسمت با استفاده از روش معرفی شده در قسمت ۲-۱ به محاسبه بزرگ‌ترین نماهای لیپانوف برای هر مجموعه داده پرداخته شده است. برای فصل بهار $\lambda_{Spring} = 0/275$ تابستان $\lambda_{Summer} = 0/411$ پاییز $\lambda_{Fall} = 0/308$ زمستان $\lambda_{Winter} = 0/312$ و ایام تعطیل $\lambda_{Holidays} = 0/092$ به دست آمدند. با توجه به آن که برای داشتن رفتار آشوبناک باید حداقل یک نمای لیپانوف بزرگ‌تر از صفر وجود داشته باشد، وجود این مقادیر برای λ به مفهوم رفتار آشوبی سیستم است. در نهایت از محاسبات انجام شده می‌توان چنین نتیجه گرفت که گرچه سیستم تصادفی نیست و از قابلیت پیش‌بینی برخوردار است، اما به علت آشوبناک بودن سیستم، پیش‌بینی باید در کوتاه مدت صورت گیرد و در بلندمدت پیش‌بینی با دقت قابل قبول ممکن نیست.

۵. شبیه‌سازی و ارزیابی نتایج

۱-۵ تنظیم داده‌های آموزش و آزمایش

پس از انجام پیش‌پردازش بیان شده در قسمت ۴-۱، برای آماده‌سازی داده‌ها جهت انجام پیش‌بینی با استفاده از سیستم AN-FIS به صورت زیر عمل می‌شود. ابتدا لازم به ذکر است که در هنگام دسته‌بندی داده‌ها به پنج مجموعه داده براساس روش ذکر شده در قسمت ۴-۱ و به منظور درک بهتر هر FIS در الگوریتم پیشنهادی که در ادامه به آنها پرداخته می‌شود، در هنگام آموزش سیستم‌های استنتاج فازی چندگانه (موازی)، همپوشانی داده‌ها مدنظر قرار گرفته است، زیرا داده‌های هر فصل از سال، کاملاً

مسیر را ثبت می‌کنند. از جمله داده‌های ثبت شده توسط سیستم SCATS، حجم خودروها در بازه‌های زمانی ۱۵ دقیقه‌ای بوده و بنابراین در هرروز ۹۶ عدد و در یک سال ۳۵۰۴۰ عدد برای هر حلقه ثبت می‌شود. لازم به ذکر است که در میان حجم انبوه داده‌ها رکوردهایی یافت می‌شوند که به دلیل نقص فنی حسگرها تعداد خودروها را صفر گزارش کرده‌اند. برای رفع این مشکل در این گونه موارد میانگین تعداد خودروهای بازه قبل و بعد در نظر گرفته شده است و اگر در کل روز این مشکل وجود داشته باشد،



شکل ۲. موقعیت تقاطع خیام-فرامرزی عباسی در نرم‌افزار SCATS برای هر ساعت، از داده‌های همان بازه در هفته قبل استفاده شده است. همچنین در صورتی که یکی از حلقه‌های القایی خاموش بوده و تعداد خودرو را گزارش نکرده باشد، از داده به دست آمده توسط حلقه القایی مجاور به دلیل شباهت مقادیر حاصل شده استفاده می‌شود. پیش‌بینی صورت گرفته در این پروژه برای مسیر شرق به غرب تقاطع بوده و برای کاهش نویزهای ممکن از داده‌های حلقه‌های شماره ۳ و ۴ که دربردارنده حجم خودروهایی است که در مسیر مستقیم حرکت می‌کنند، استفاده شده است. ابتدا با توجه به موقعیت سیاحتی-زیارتی شهر مشهد و تفاوت میزان جمعیت و به تبع آن حجم خودروها در فصول مختلف و نیز ایام مختلف سال، داده‌های هر فصل مشخص شده است. در مرحله بعد برای افزایش دقت پیش‌بینی و با در نظر گرفتن این نکته که الگوی ترافیکی تقاطع‌ها در روزهای تعطیل مانند جمعه‌ها با سایر روزهای کاری هفته متفاوت است، داده‌های روزهای تعطیل سال

ورودی و یک خروجی و بالاخره پنج ورودی و یک خروجی تنظیم می‌شوند.

۲-۵ پیش‌بینی حجم ترافیک با استفاده از سیستم فازی - عصبی تطبیقی (ANFIS)

شکل ۳ بلوک دیاگرام سیستم پیاده سازی شده با ANFIS در حالتی که سیستم دارای سه ورودی و یک خروجی است را نشان می‌دهد.

جدول ۱. نمونه داده ها جهت آموزش سیستم سه ورودی-یک خروجی

ورودی سیستم فازی			خروجی
t-۲	t-۱	t	t+۱
216	214	199	234
214	199	234	162
199	234	162	205
234	162	205	77
162	205	77	169

پنج بلاک نمایش داده شده در شکل برای انجام پیش‌بینی برای ۵ مجموعه داده است. لازم به ذکر است که در آزمایشهای انجام شده پس از آموزش سیستم، برای هر ANFIS در مرحله آزمایش هم از داده‌هایی درون بازه زمانی مشابه و هم از داده‌هایی خارج از بازه زمانی داده‌های آموزش استفاده شده است تا اعتبارسنجی مناسبی بر روی مدل صورت گیرد. در این قسمت با استفاده از توضیحات ارائه شده در قسمت‌های ۴-۱ و ۵-۱ به آموزش و سپس آزمایش سیستم پرداخته شده است. همان گونه که قبلاً نیز اشاره شد، سیستم‌های سه ورودی-یک خروجی، چهار ورودی-یک خروجی و بالاخره پنج ورودی-یک خروجی برای پیش‌بینی حجم ترافیک مورد استفاده قرار گرفته‌اند و نتایج هر یک بیان شده است.

مستقل نبوده و شباهت‌هایی بین فصول قبلی یک فصل از نظر حجم ترافیک وجود دارد. این داده‌ها می‌توانند دقت پیش‌بینی را افزایش دهند. به‌طور مثال در هنگام آماده‌سازی داده‌های فصل پائیز داده‌ها از ۲۰ شهریور تا ۱۰ دی به عنوان مجموعه داده انتخاب می‌شوند و برای آماده‌سازی داده‌های فصل تابستان، داده‌ها از تاریخ ۲۰ خرداد تا ۱۰ مهر انتخاب می‌شوند. در این حالت علاوه بر ساده سازی کل سیستم استنتاج فازی در محاسبه نتیجه پیش‌بینی، قانونی که مورد استفاده قرار می‌گیرد متناسب با بازه‌ای که داده‌های ورودی به آن تعلق دارند بوده و دقت پیش‌بینی افزایش خواهد یافت. پس از آن که داده‌هایی که قرار است به عنوان داده‌های آموزش به سیستم اعمال شود مشخص شدند، قوانین فازی بر اساس این داده‌ها ساخته می‌شوند. در این مرحله و به منظور ساخت قوانین فازی و به جهت آموزش این سیستم فازی پنج حالت مختلف سه ورودی-یک خروجی، چهار ورودی-یک خروجی، پنج ورودی-یک خروجی آزمایش شده اند (این سه حالت با توجه به تاثیر مقادیر قبلی حجم ترافیک بر روی مقدار بازه بعدی ترافیک و به صورت آماری در نظر گرفته شده اند). برای آموزش سیستم در ساختار سه ورودی-یک خروجی سه نمونه متوالی داده‌های حجم ترافیک به عنوان ورودی و نمونه چهارم به عنوان خروجی در نظر گرفته می‌شود. برای آموزش سیستم در ساختار چهار ورودی-یک خروجی، چهار نمونه متوالی داده‌های حجم ترافیک به عنوان ورودی و نمونه پنجم به عنوان خروجی در نظر گرفته می‌شود. در نهایت برای آموزش سیستم در ساختار پنج ورودی-یک خروجی پنج نمونه متوالی داده‌های حجم ترافیک به عنوان ورودی و نمونه ششم به عنوان خروجی در نظر گرفته می‌شود. جدول ۱ نمونه داده‌ها برای آموزش سیستم سه ورودی-یک خروجی را نشان می‌دهد. برای ایجاد مجموعه داده آزمایش سیستم نیز مطابق روش تهیه داده‌های آموزش عمل می‌شود. به این ترتیب که ابتدا داده‌هایی که به عنوان داده‌های آموزش در نظر گرفته شده اند جدا شده (داده‌های ماه‌های ۱۲ ماه سال ۱۳۸۶ و شش ماه اول سال ۱۳۸۷) و داده‌های باقیمانده (داده‌های شش ماه دوم سال ۱۳۸۷) به صورت سه ورودی و یک خروجی، چهار

$$F_k(u_1, u_2, u_3) = q_k + q_{k1}u_1 + q_{k2}u_2 + q_{k3}u_3 \quad (11)$$

خروجی هر زیر سیستم، میانگین وزنی خروجی قوانین است. هر قانون به وسیله نتایج تابع عضویت محاسبه می شود. برای این کار، ابتدا مقادیر ورودی به فرم فازی تبدیل می شوند و سپس مقادیر توابع با هم and شده و فاکتور وزنی محاسبه می شود. در رابطه ۱۲ برای نمونه W_1 نشان داده شده است:

$$w_1 = M_{11}(X_1) \cdot M_{21}(X_2) \cdot M_{31}(X_3) \quad (12)$$


زمانی که فاکتور وزنی محاسبه شد، خروجی هر زیرسیستم، با محاسبه میانگین وزنی، حاصل می شود که در رابطه ۱۳ نشان داده شده است:

$$Y = \frac{\sum_{k=1}^{729} W_k R_k}{\sum_{k=1}^{729} W_k} \quad (13)$$

پس از طی مراحل آموزش سیستم، ANFIS طراحی شده برای پیش بینی حجم ترافیک دارای ۷۸ گره، ۱۰۸ پارامتر خطی و ۱۸ پارامتر غیرخطی و در مجموع ۱۲۶ پارامتر است و تعداد قوانین تولید شده ۲۷ است.

۳-۵ نتایج پیش بینی

در این قسمت به ارایه نتایج پیش بینی حجم ترافیک با استفاده از سیستم عصبی فازی تطبیقی پرداخته شده است. لازم به ذکر است که این نتایج در یک دوره دو ساله شامل سالهای ۱۳۸۶ و ۱۳۸۷ به دست آمده است. دیاگرام شکل ۴ حالات مختلف پیش بینی را برای سیستم سه ورودی- یک خروجی نشان می دهد. لازم به ذکر است که در دیاگرام نشان داده شده در شکل ۴، منظور از پیش بینی کامل^۱، پیش بینی به صورت کامل و بدون جداسازی داده های روزهای تعطیل و نیز حذف ساعات اولیه صبح (ساعات ۲۴ تا ۵ صبح) است. در واقع در پیش بینی کامل به جای استفاده از پنج ANFIS (چهار ANFIS برای چهار فصل سال و یک ANFIS برای ایام تعطیل)، از چهار ANFIS استفاده شده و برای ایام تعطیل ساختار جداگانه ای در نظر گرفته نشده است. همچنین منظور از پیش بینی درونی^۲، انجام پیش بینی به صورتی



شکل ۳. بلوک دیاگرام سیستم چندگانه پیاده سازی شده با ANFIS برای هر ورودی سه تابع عضویت گوسین (لازم به ذکر است که تابع عضویت گوسین بهترین نتیجه را برای پیش بینی در پی داشته و بنابراین از این تابع عضویت برای ورودیها استفاده شده است) در نظر گرفته شده است. به طور نمونه، برای سیستم سه ورودی- یک خروجی اگر X_1, X_2, X_3 ورودی و Y خروجی سیستم باشد، هر ترکیب ممکن بین ورودیها و تابع عضویت، یک قانون در مجموعه قوانین محسوب می شود. به این ترتیب تعداد قوانین برای این سیستم ۲۷ عدد خواهد بود که در زیر یک نمونه آن نشان داده شده است:

1. If (x_1 is M_{11}) and (x_2 is M_{21})
and (x_3 is M_{31}) then $R_1 = F_1(X_1, X_2, X_3)$

در قوانین فوق، M_{ij} معرف زامین تابع عضویت مربوط به i امین ورودی، R_k معرف خروجی k امین قانون و F_k معرف k امین خروجی تابع عضویت است. با توجه به این که تابع عضویت از نوع گوسین است، M_{ij} از رابطه ۱۰ محاسبه می شود:

$$M_{ij}(u) = e^{-\frac{(u-p)^2}{2\delta^2}} \quad (10)$$

در روابط فوق، مقدار p ثابتی است که محدوده توابع عضویت را تعیین می کند و مقدار بهینه آن با آموزش مشخص می شود. خروجی توابع عضویت نیز به صورت خطی بوده و به صورت رابطه ۱۰ محاسبه می شود:

با استفاده از پیش‌بینی بیرونی با ساختار سه ورودی- یک خروجی در حالتی که داده‌های ایام تعطیل و نیز ساعات ۲۴ تا ۵ صبح حذف گردیده‌اند، نشان داده شده‌اند. نتایج به دست آمده برای ساختارهای پنج ورودی- یک خروجی و شش ورودی- یک خروجی در تمامی حالات پیش‌بینی در شکل‌های ۹ تا ۱۴ نشان داده شده‌اند.

در قسمت بعدی به بررسی نتایج با استفاده از پارامترهای ارزیابی پرداخته شده است. پارامترهای ارزیابی بکار گرفته شده برای بررسی کارایی روش فوق عبارتند از:

$$MRE^a \text{ یا خطای نسبی میانگین که با رابطه ۱۴ نشان داده شده است:} \quad (14)$$

$$MRE = \frac{1}{N} \left(\sum_{t=1}^N \frac{|x_t - \hat{x}_t|}{x_t} \right)$$

پارامتر بعدی $MSRE^a$ یا خطای نسبی مربع میانگین است که با رابطه ۱۵ نشان داده شده است:

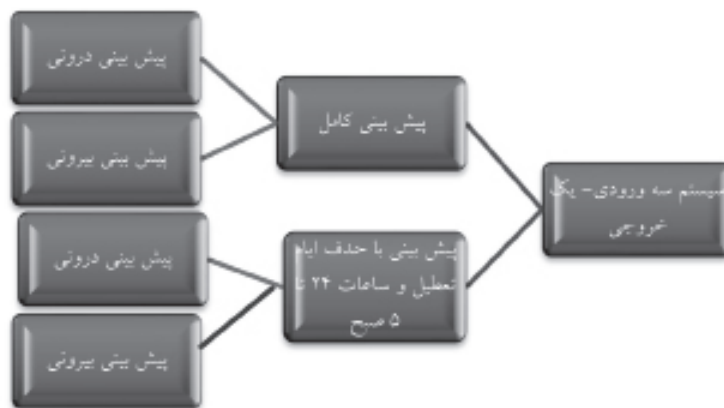
$$MSRE = \frac{1}{N} \left(\sum_{t=1}^N \left(\frac{x_t - \hat{x}_t}{x_t} \right)^2 \right) \quad (15)$$

و در نهایت پارامتر سوم EC^a یا ضریب همبستگی است که نشان دهنده درجه تطبیق داده پیش‌بینی شده با داده ترافیکی واقعی است که با رابطه ۱۶ نشان داده شده است:

$$EC = 1 - \frac{\sqrt{\sum_{t=1}^N (x_t - \hat{x}_t)^2}}{\sqrt{\sum_{t=1}^N x_t^2} + \sqrt{\sum_{t=1}^N \hat{x}_t^2}} \quad (16)$$

لازم به ذکر است که روابط ۱۴-۱۶ x_t و \hat{x}_t به ترتیب مقدار پیش‌بینی شده و مقدار اندازه‌گیری شده در واقعیت را نشان

است که داده‌های آموزش و آزمایش متعلق به یک بازه زمانی باشند که در این صورت از ساختار کامل با بکارگیری پنج AN-FIS برای انجام پیش‌بینی استفاده می‌شود. برای مثال در صورتی که یک ANFIS که برای پیش‌بینی فصل پائیز در نظر گرفته شده مدنظر قرار گیرد، در صورتی که از داده‌هایی از فصل پائیز یک سال برای آزمایش سیستم استفاده شود، پیش‌بینی درونی و در غیراین صورت پیش‌بینی بیرونی صورت گرفته است (بنابراین در پیش‌بینی بیرونی از دو ANFIS یکی برای ایام عادی سال و دیگری برای روزهای تعطیل سال استفاده می‌شود). شکل ۵ میزان حجم واقعی ترافیک و حجم ترافیک پیش‌بینی شده با استفاده از ANFIS سه ورودی- یک خروجی در حالتی که از تمامی داده‌های روز استفاده شده و داده‌های ایام تعطیل نیز حذف نشده‌اند و داده‌های آزمون نیز در بازه‌ای مشابه با داده‌های آموزش قرار دارند (پیش‌بینی درونی) را نشان می‌دهد. شکل ۶ میزان حجم واقعی ترافیک و حجم ترافیک پیش‌بینی شده با استفاده از پیش‌بینی درونی با ساختار سه ورودی- یک خروجی در حالتی که داده‌های روزهای تعطیل و نیز ساعات ۲۴ تا ۵ صبح حذف گردیده‌اند، نشان داده شده‌اند. شکل ۷ میزان حجم واقعی ترافیک و حجم ترافیک پیش‌بینی شده با استفاده از پیش‌بینی بیرونی با ساختار سه ورودی- یک خروجی در حالتی که از تمامی داده‌های روز استفاده شده و ایام تعطیل نیز حذف نشده‌اند را نشان می‌دهد. در شکل ۸ میزان حجم واقعی ترافیک و حجم ترافیک پیش‌بینی شده



شکل ۴. حالات مختلف پیش‌بینی برای ساختار ANFIS سه ورودی- یک خروجی که برای هر ورودی سه تابع عضویت در نظر گرفته شده و دارای ۲۷ قانون است.

جدول ۲. نتایج پیش‌بینی با استفاده از ANFIS سه ورودی -

یک خروجی

EC	MSRE	MRE	انواع روشهای پیش‌بینی برای ساختار سه ورودی - یک خروجی
۰/۸۸	۰/۱۰	۰/۱۵	پیش‌بینی درونی با داده‌های کامل روز
۰/۹۶	۰/۰۲	۰/۰۹	پیش‌بینی درونی با حذف ایام تعطیل و ساعات اولیه صبح
۰/۸۴	۰/۰۸	۰/۱۹	پیش‌بینی بیرونی با داده‌های کامل روز
۰/۹۰	۰/۰۵	۰/۱۴	پیش‌بینی بیرونی با حذف ایام تعطیل و ساعات اولیه صبح

جدول ۳. نتایج پیش‌بینی با استفاده از ANFIS چهار ورودی -

یک خروجی

EC	MSRE	MRE	انواع روشهای پیش‌بینی برای ساختار چهار ورودی - یک خروجی
۰/۸۳	۰/۱۳	۰/۱۶	پیش‌بینی درونی با داده‌های کامل روز
۰/۸۸	۰/۰۷	۰/۱۰	پیش‌بینی درونی با حذف ایام تعطیل و ساعات اولیه صبح
۰/۸۳	۰/۱۴	۰/۲۰	پیش‌بینی بیرونی با حذف ایام تعطیل و ساعات اولیه صبح



جدول ۴. نتایج پیش‌بینی با استفاده از ANFIS پنج ورودی -

یک خروجی



EC	MSRE	MRE	انواع روشهای پیش‌بینی برای ساختار پنج ورودی - یک خروجی
۰/۸۲	۰/۱۳	۰/۱۵	پیش‌بینی درونی با داده‌های کامل روز
۰/۸۵	۰/۱۰	۰/۱۲	پیش‌بینی درونی با حذف ایام تعطیل و ساعات اولیه صبح
۰/۸۲	۰/۱۶	۰/۲۲	پیش‌بینی بیرونی با حذف ایام تعطیل و ساعات اولیه صبح

می‌دهند. جدولهای ۲ تا ۴ پارامترهای MRE، MSRE و EC را برای انواع مختلف پیش‌بینی نشان می‌دهند. جدولهای ۲ تا ۴ میزان خطای پیش‌بینی و ضریب EC را برای ساختارهای سه ورودی - یک خروجی، چهار ورودی - یک خروجی و پنج ورودی - یک خروجی در حالات مختلف نشان می‌دهند. حالتی که نتایج مرتبط با آنها رضایت‌بخش نیستند (مانند پیش‌بینی بیرونی برای داده‌های کامل روز در ساختار چهار ورودی - یک خروجی) در جدولهای زیر نشان داده نشده‌اند. همان‌گونه که قبلاً نیز بیان شد پارامترهای MRE و MSRE نشان‌دهنده میزان خطا و EC پارامتری است که نشان‌دهنده میزان مشابهت روند داده‌های پیش‌بینی شده با داده‌های واقعی است که مسلماً هرچه این مقدار بزرگ‌تر باشد، پیش‌بینی با دقت بیشتری صورت گرفته است.



با مشاهده جدولهای ۲ تا ۴ مشاهده می‌شود که در صورتی که پیش‌بینی درونی با ANFIS سه ورودی - یک خروجی و با حذف ایام تعطیل و ساعات اولیه صبح انجام شود (استفاده از ساختار شکل ۳ با پنج ANFIS)، کمترین مقدار برای پارامترهای MRE و MSRE و بیشترین مقدار برای پارامتر EC به دست خواهد آمد که این مقادیر نشان می‌دهند که کمترین میزان خطا و بیشترین میزان مشابهت بین روند حجم ترافیک پیش‌بینی شده و حجم ترافیک واقعی در این حالت وجود خواهد داشت که نتایج حاصل شده از این روش در شکل ۶ نشان داده شده‌است. این نتایج دلالت بر این موضوع دارد که سه بازه زمانی قبل بیشترین تأثیر را بر روی حجم ترافیک بازه بعدی داشته و با در نظر گرفتن این سه بازه بیشترین دقت پیش‌بینی صورت می‌گیرد. همچنین نتایج حاصل شده نشان می‌دهند که جداسازی فصلی داده‌ها و در نظر گرفتن یک ANFIS برای هر یک از فصلها و نیز جداسازی ایام تعطیل و در نظر گرفتن یک ANFIS برای این ایام مناسب‌ترین سیستم پیش‌بینی ترافیک است.





شکل ۵. میزان حجم ترافیک پیش‌بینی شده و واقعی با استفاده از پیش‌بینی درونی و ساختار سه ورودی- یک خروجی با استفاده از تمام داده‌های روز. شکل ۶. میزان حجم ترافیک پیش‌بینی شده و واقعی با استفاده از پیش‌بینی درونی و ساختار سه ورودی- یک خروجی با حذف ایام تعطیل و ساعات ۲۴ تا ۵ صبح (بهترین نتیجه).



شکل ۷. میزان حجم ترافیک پیش‌بینی شده و واقعی با استفاده از پیش‌بینی بیرونی و ساختار سه ورودی- یک خروجی با حذف ایام تعطیل و ساعات ۲۴ تا ۵ صبح. شکل ۸. میزان حجم ترافیک پیش‌بینی شده و واقعی با استفاده از پیش‌بینی بیرونی و ساختار سه ورودی- یک خروجی با حذف ایام تعطیل و ساعات ۲۴ تا ۵ صبح.

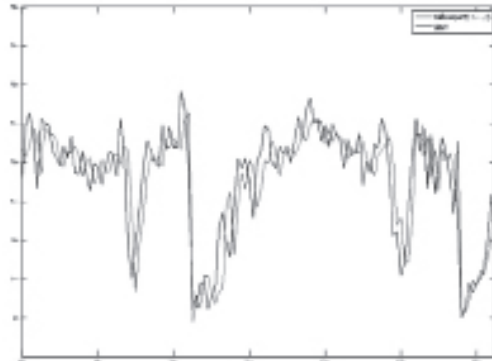



شکل ۹. میزان حجم ترافیک پیش‌بینی شده و واقعی با استفاده از پیش‌بینی درونی و ساختار چهار ورودی- یک خروجی با استفاده از تمام داده‌های روز. شکل ۱۰. میزان حجم ترافیک پیش‌بینی شده و واقعی با استفاده از حذف ایام تعطیل و ساعات ۲۴ تا ۵ صبح یک استفاده از پیش‌بینی درونی و ساختار چهار ورودی- یک خروجی.



شکل ۱۱. میزان حجم ترافیک پیش‌بینی شده و واقعی با استفاده از پیش‌بینی بیرونی و ساختار چهار ورودی - یک خروجی با حذف ایام تعطیل و ساعات ۲۴ تا ۵ صبح.

شکل ۱۲. میزان حجم ترافیک پیش‌بینی شده و واقعی با استفاده از پیش‌بینی درونی و ساختار پنج ورودی - یک خروجی با استفاده از تمام داده‌های روز.



شکل ۱۳. میزان حجم ترافیک پیش‌بینی شده و واقعی با استفاده از پیش‌بینی درونی و ساختار پنج ورودی - یک خروجی با حذف ایام تعطیل و ساعات ۲۴ تا ۵ صبح.

شکل ۱۴. میزان حجم ترافیک پیش‌بینی شده و واقعی با استفاده از پیش‌بینی بیرونی و ساختار پنج ورودی - یک خروجی با حذف ایام تعطیل و ساعات ۲۴ تا ۵ صبح.

۶. جمع‌بندی و نتیجه‌گیری

در این مقاله ابتدا با استفاده از پارامتر بزرگ‌ترین نمای لیاپانوف به شناسایی رفتار آشوبناک ترافیک مبتنی بر سری زمانی پرداخته شده و قابل پیش‌بینی بودن سری زمانی جریان ترافیک مورد بررسی قرار گرفته است. پس از به قطعیت رسیدن در وجود پدیده آشوب در یک سری زمانی حاصل از جریان ترافیک، پیش‌بینی کوتاه مدت جریان ترافیک با استفاده از سریهای زمانی فازی و مدل عصبی-فازی چندگانه ANFIS صورت گرفته است. نکته دیگری که در پژوهشهای صورت گرفته در زمینه پیش‌بینی ترافیک کمتر به آن پرداخته شده و در این مقاله مورد توجه قرار

گرفته است، انجام پیش‌بینی به صورت فصلی یا دوره‌ای است که این امر موجب افزایش دقت سیستم پیش‌بینی می‌شود و با انجام این امر، عوامل اجتماعی تاثیرگذار در شرایط ترافیکی نیز به طور خودکار وارد مدل شده و در افزایش دقت مدل تاثیرگذار خواهند بود. روش معرفی شده، برای پیش‌بینی حجم ترافیک بلوار فرامرز عباسی شهر مشهد بکار گرفته شده و نتایج آن و نیز دقت پیش‌بینی با استفاده از پارامترهای ارزیابی ارائه شده است. نتایج نشان می‌دهند که روش پیشنهادی در صورتی که برای هر فصل سال، ANFIS جداگانه‌ای در نظر گرفته شود و روزهای تعطیل نیز به صورت جداگانه مورد بررسی قرار گیرند، می‌تواند

با دقت مطلوبی حجم ترافیک را پیش‌بینی کند.

- Jang, J. S. R., Sun, C. T. and Mizutani, E. (1997) "Neuro-fuzzy and soft computing", Prentice Hall, Upper Saddle River, NJ, USA.

- Lawrence, W. L. and Feng, Y. (2005) "Identification for chaotic phenomena in short-term traffic flows", Journal of the Eastern Asia Society for Transportation Studies, Vol. 6, PP.1518–1533.

- Liu, J., Li, L., Guan, W. and Cai, X. (2005) "Short-term prediction of traffic flow in Beijing ring road based on neural network", Journal of Transportation Systems Engineering and Information Technology, Vol. 5(6), pp. 110–115.

- Pengjian, S. A., Xuwei, L. and Santi, K. (2005) "Chaotic analysis of traffic time series", Chaos, Solutions and Fractals, Vol. 25, pp.121–128.

- Shi, Q. X. and Zheng, W. Z. (2004) "Short-term traffic flow prediction methods comparison of road networks", Journal of Traffic and Transportation Engineering, Vol 4, No. 4, pp. 68–71.

- Stathopoulos, A. and Karlaftis, M. G. (2003) "A multivariate state-space approach for urban traffic flow modeling and prediction", Transportation Research Part C: Emerging Technologies 11 (2), pp. 121–135.

- Stathopoulos, A. and Karlaftis, M. G. (2001) "A temporal and spatial variations of real-time traffic data in urban areas", Transportation Research Re-

۷. پی‌نوشت‌ها

- 1 - Intelligence Transportation Systems
- 2 - Advanced Traffic Management System
- 3 - Advanced Travel Information System
- 4 - Advanced Public Transportation System
- 5 - Inductive Loop
- 6 - Full Prediction
- 7 - Inside Prediction
- 8 - Mean Relative Error
- 9 - Mean Square Relative Error
- 10 - Equalization Coefficient

۸. مراجع

-Aliyari, M., Teshnehlab, M. and Khaki, A. (2009) "Identification using ANFIS with intelligent hybrid stable learning algorithm approaches", Neural Computation & Applications, Vol. 18, PP. 157–174

- Cheng, C. and Wei, L. (2010) "One step-ahead ANFIS time series model for forecasting electricity loads", Optimization and Engineering, Vol. 11, No. 2, pp. 303-317

- Head, L. K. (1995) "Event-based short-term traffic flow prediction model", Transportation Research Record 1510, pp. 45–52.

- Jang, J. S. R. (1993) "ANFIS: Adaptive-network-based fuzzy inference systems", IEEE Trans. On Systems, Management and Cybernetics, Vol. 23, No.3, pp. 665-685.

cord, Journal of the Transportation Research Board ,
No.1768, pp. 135–140.

- Tsonis, A. A. (1992) “Chaos: from theory to applications”, Plenum Press, New York.

- Vosoulipour, A., Teshnehlab, M. and Moghadam, H. A. (2008) “Classification on diabetes mellitus dataset based-on artificial neural networks and ANFIS”, 4th Kuala Lumpur International Conference on Biomedical Engineering, IFMBE Proceedings, Vol. 21, PP. 27-30

- Williams, B. M. (2001) “Multivariate vehicular traffic flow prediction: An evaluation of ARIMAX modeling”, Transportation Research Record, 1776, pp. 194–200.

- Yang, C. and Wu, C. (2011) “A robust method on estimation of Lyapunov exponents from a noisy time series”, Nonlinear Dynamics, Vol. 64, No. 3, pp. 279-292.

- Yousefpoor, P., Esfahani, M.S. and Nojumi, H. (2008) “Looking for systematic approach to select chaos tests”, Applied Mathematics and Computation, 198, PP. 73–91.