

## پیش‌بینی کوتاه‌مدت حجم تردد بزرگراه‌های شهری با استفاده از تبدیلات حوزه فرکانس

سید امید موسوی زاده کاشی<sup>۱</sup>، میثم اکبرزاده<sup>۲</sup>

۱- دانشجوی کارشناسی ارشد، دانشکده مهندسی حمل‌ونقل، دانشگاه صنعتی اصفهان، اصفهان

۲- استادیار، دانشکده مهندسی حمل‌ونقل، دانشگاه صنعتی اصفهان، اصفهان

### چکیده

مدیریت مناسب ترافیک شهری مستلزم پیش‌بینی کوتاه‌مدت وضعیت تردد بزرگراه‌های شهری است. در صورت پیش‌بینی جریان آینده نزدیک (چند دقیقه بعد) هدایت جریان از طریق تابلوهای پیام متغیر نصب‌شده در بزرگراه‌ها امکان‌پذیر می‌شود. وضعیت جریان ترافیک در بزرگراه‌های شهری از عوامل مختلفی تأثیر می‌گیرد و پیوسته در حال تغییر است، در نتیجه معمولاً پیش‌بینی شهودی آن امکان‌پذیر نیست. مقاله‌ی حاضر به توسعه روشی برای پیش‌بینی کوتاه‌مدت جریان ترافیک می‌پردازد. مقاله حاضر با استفاده از تبدیل موجک، فرکانس‌های اصلی سیگنال تردد را استخراج نموده و سپس وضعیت تردد پنج دقیقه آینده را با استفاده از شبکه عصبی پیش‌بینی نموده است. نتایج پیش‌بینی جریان با استفاده از مدل ترکیبی تبدیل موجک - شبکه مصنوعی عصبی نسبت به مدل‌های آماری و مدل ساده شبکه مصنوعی عصبی از دقت بیشتری برخوردار است. بهترین نتیجه با استفاده از موجک‌ها با یک فرکانس اصلی و سه فرکانس فرعی بدست آمد. ساختار نهایی قادر است حجم تردد در ۵ دقیقه آینده را با میانگین خطای مطلق ۷/۴۳ پیش‌بینی نماید.

واژگان کلیدی: پیش‌بینی جریان ترافیک، پردازش سیگنال، تبدیل موجک، شبکه مصنوعی عصبی

### ۱- مقدمه

از اطلاعات ترافیکی زمان حال و گذشته به‌منظور تخمین جریان ترافیک در بازه زمانی بین چند ثانیه تا چند ساعت آینده. اطلاعات مورد استفاده جریان عبارت‌اند از حجم، چگالی، سرعت، زمان سفر و حالت. از اطلاعات پیش‌بینی‌شده جریان ترافیک می‌توان به‌منظور ارائه اطلاعات ترافیکی به‌موقع به رانندگان جهت تصمیم‌گیری مناسب، برنامه‌ریزی مناسب‌تر چراغ‌های راهنمایی مرتبط با مسیر موردنظر و برنامه‌ریزی زمانی مناسب‌تر سامانه حمل‌ونقل همگانی استفاده کرد. در صورت قابل‌قبول بودن دقت پیش‌بینی، مجموع این عوامل موجب بهبود جریان ترافیک در مسیر موردنظر می‌گردد.

در عالم تحلیل داده دو رویکرد فکری عمده عبارت‌اند از آمار و هوش محاسباتی. آمار، عبارت است از جمع‌آوری، سامان‌دهی و تفسیر داده‌های عددی به‌صورت ریاضی‌وار. هوشمندی به این معنی است که در ابتدا ساختاری وجود ندارد و ساختار تحلیلی به‌تدریج با استفاده از داده‌های موجود ساخته می‌شود. رویکرد هوش محاسباتی برای ایجاد مدل‌های هوشمند عناصر

رشد جمعیت و تعداد خودروها در شهرها و تنوع رفتارهای ترافیکی افراد باعث نوسان بالای جریان ترافیک در راه‌های درون‌شهری شده است. تغییرات این جریان در بزرگراه‌های شهری که کریدورهای اصلی حمل‌ونقل درون‌شهری محسوب می‌شوند از اهمیت زیادی برخوردار است و بر سایر معابر اطراف آن تأثیرگذار است. آگاهی از وضعیت آینده جریان ترافیک می‌تواند اطلاعات ارزشمندی را در اختیار مسافران و سیستم مدیریت حمل‌ونقل قرار دهد. اطلاعات پیش‌بینی‌شده جریان می‌تواند به روش‌های مختلفی از قبیل پیام‌های رادیویی، تابلوهای پیام متغیر و ... در اختیار مسافران قرار بگیرد. پیش‌بینی جریان ترافیک با دقت کافی، سبب تبدیل سیستم حمل‌ونقل هوشمند از حالت انفعالی<sup>۱</sup> به حالت پیش‌دستانه<sup>۲</sup> می‌شود [۱].

- 1 Passive Response
- 2 Proactive Action

سال گذشته بوده است. اجرای مدل‌های سری زمانی چند متغیره و استفاده از مدل‌های کلاسیک آماری و شبکه‌های عصبی از دیگر روش‌های رایج هستند. امروزه مسائل پیش‌بینی کوتاه‌مدت ترافیک به سمت ساختارهایی ترکیبی از شبکه‌های عصبی جهت یافته‌اند. این ساختارها اغلب عملکرد بهتری نسبت به مدل‌های ساده‌ی خود بازگشت، به‌خصوص جهت مدل‌سازی مدل‌های چندبعدی و مدل‌هایی با پارامترهای مختلف بیرونی دارند. ساختارهای ترکیبی شامل مدل‌های پایه‌ی آماری و یا هوش محاسباتی هستند. جهت بهینه‌سازی ساختارهای ترکیبی پیش‌بینی، طیف گسترده‌ای از روش‌های پیش‌بینی شامل روش‌های  $PPCA^1$ ،  $LASSO^2$ ، منطق فازی<sup>۳</sup>، موجک‌ها<sup>۴</sup>، الگوریتم ژنتیک<sup>۵</sup>، روش تبرید شبیه‌سازی شده<sup>۶</sup>، بیزین<sup>۷</sup> و الگوریتم‌های الهام گرفته از طبیعت به کار گرفته شده است.

وانگ دانپینگ و همکاران از تحلیل پویای وضعیت جریان و پیش‌بینی کوتاه‌مدت تراکم ترافیک در سیستم پیشرفته اطلاعات مسافر<sup>۸</sup> و سیستم پیشرفته مدیریت ترافیک<sup>۹</sup> سخن گفتند. روش‌های پیش‌بینی جریان ترافیک در دو بخش روش‌های آماری ریاضی و روش‌های تحلیل طیفی مبتنی بر نظریه موجک‌ها و شبکه مصنوعی عصبی تقسیم‌بندی می‌شوند. این پژوهش از عدم پذیرش یک روش خاص جهت پیش‌بینی جریان ترافیک سخن می‌گوید و اشاره می‌کند که مدل‌های ترکیبی از دقت -بیشتری در پیش‌بینی برخوردارند [۱].

### ۳- ادبیات موضوع

#### ۳-۱- مروری بر روش‌های آماری

یکی از راهکارهای پیش‌بینی کوتاه‌مدت جریان ترافیک استفاده از مسئله سری زمانی است. یک سری زمانی شامل الگوهای مختلفی است که عبارت‌اند از روند، سطح، تغییرات فصلی و اختلالات. تحلیل یک سری زمانی مبتنی بر این فرض است که الگوهای رفتاری گذشته، در آینده نیز ادامه پیدا خواهند کرد. روش‌های آماری مختلفی برای تجزیه و تحلیل سری زمانی

یادگیری، انطباق، تکامل و منطق فازی را ترکیب می‌کند. هر دو این رویکردها هدف یکسانی را دنبال می‌کنند اما همواره در فاصله‌ای نسبت به یکدیگر قرار دارند. محققان هر یک از این رویکردها اغلب در فهم و ارتباط با یکدیگر موفق نبوده‌اند. اگرچه استنتاج‌های آماری قوی می‌توانند فهم پژوهشگر را از موضوع موردبررسی افزایش دهند، ولی در تحلیل پدیده‌های پیچیده و غیرخطی با مرتبه‌ی بالا موفق نیستند [۲].

پیش‌بینی کوتاه‌مدت ترافیک دارای دو جنبه اساسی است. جنبه‌ی فنی مبتنی بر فناوری حمل‌ونقل هوشمند (ITS) و جنبه تحلیلی مبتنی بر روش‌ها، الگوریتم‌ها و پردازشگرهای تحلیل داده می‌باشد. اگرچه در ابتدا روش‌های کلاسیک آماری به‌عنوان روش غالب مورد استفاده در پیش‌بینی نقطه‌ای ترافیک مورد توجه بودند، اما اکنون تمرکز رویکرد بسیاری از پژوهش‌های حوزه‌ی تحلیل، در حال انتقال از تحلیل‌های کلاسیک آماری (مدل‌های خانواده‌ی آریما) به سمت مدل‌های هوشمند (مستخرج از داده) است [۲][۳]. مدل‌های هوشمند شامل روش‌هایی مانند شبکه‌های عصبی، شبکه‌های بیزی، روش‌های فازی و تکاملی می‌باشد. برخی منابع مدل‌های آماری را در پیش‌بینی تحت شرایط ترافیکی ناپایدار، یا راه‌ها با ترکیب پیچیده ضعیف دانسته‌اند [۲].

#### ۲- مروری بر منابع

پژوهش‌های انجام‌شده در زمینه‌ی پیش‌بینی جریان ترافیک از جنبه‌های نوع و تعداد متغیر مورد پیش‌بینی، بازه پیش‌بینی، سطح پوشش، روش گردآوری داده، مدل پیش‌بینی و روش بهینه‌سازی قابل دسته‌بندی هستند [۲]. در کلیه موارد بررسی شده، متغیر مورد پیش‌بینی شامل سرعت، حجم تردد، زمان سفر، چگالی، حالت و یا ترکیبی از این عوامل بوده است. بازه‌های پیش‌بینی از چند دقیقه تا چند روز متغیر بوده‌اند. پژوهش‌های انجام‌شده از لحاظ سطح پوشش در چهار دسته‌ی بزرگراه بین‌شهری، بزرگراه درون‌شهری، راه‌های شریانی و کل شبکه شهری قابل دسته‌بندی هستند. در پژوهش‌های انجام‌شده از روش‌های مختلفی برای گردآوری داده شامل GPS، شناساگر، شبیه‌ساز، فناوری شناسایی خودکار خودرو، بلوتوث و سایر استفاده شده است.

پیش‌بینی کوتاه‌مدت ترافیک از زاویه‌های مختلف از قبیل یک مسئله‌ی سری زمانی، مسئله‌ی رگرسیون و تابع تقریب، خوشه‌بندی، مسئله‌ی تشخیص الگو یا ترکیبی از موارد قبلی دیده شده است. استفاده از استنباط بیزین به‌عنوان روش جایگزین استنباط آماری کلاسیک یکی از پیشرفت‌های ۱۰

1 Probabilistic Principal Component Analysis

2 Adaptive Absolute Shrinkage and Selection Operator

3 Fuzzy Logic

4 Wavelet


5 Genetic Algorithm

6 Simulated Annealing

7 Bayesian

8 Advanced Traveler Information Systems

9 Advanced Traffic Management System



شکل ۳: ساختار عملکرد شبکه مصنوعی عصبی

مقادیر تصادفی تولیدشده به‌وسیله‌ی یک تابع خطا یا تابع تحریک‌پذیری با مقادیر واقعی مقایسه می‌شوند. مقایسه‌ی خروجی شبکه با مقدار واقعی باعث تغییر ضرایب وزنی شبکه و نزدیک‌تر شدن خروجی شبکه به مقدار واقعی در دفعات بعدی می‌شود. پس به‌طور ساده می‌توان فرآیند آموزش را، روش میزان کردن ضرایب وزنی تعریف کرد.

### ۳-۲-۳- پردازش سیگنال

سیگنال اغلب اطلاعات یک متغیر را به‌صورت دامنه‌ای از زمان ارائه می‌کند. از آنجایی که بسیاری از جزئیات در دامنه‌ی فرکانسی سیگنال نهفته است، به تبدیلات ریاضی جهت دستیابی به دامنه‌ی فرکانسی سیگنال نیاز داریم. بسیاری از تغییرات ناگهانی در جریان ترافیک از قبیل زمان و مکان تشکیل گلوگاه‌ها و صف را می‌توان از تجزیه سیگنال دریافت [۵]. در بین تبدیلات ریاضی مختلف در بحث پیش‌بینی جریان ترافیک آن تبدیلاتی ارزشمند هستند که بتوانند اطلاعات زمانی و فرکانسی را به ما ارائه کنند. روش تبدیل فوریه به خاطر عدم دسترسی همزمان به اطلاعات فرکانسی و اطلاعات زمانی نمی‌تواند روش مناسبی در مبحث پیش‌بینی جریان باشد. همچنین روش تبدیل فوریه زمان کوتاه به خاطر عدم وضوح اطلاعات زمانی و اطلاعات فرکانسی روش مناسبی به شمار نمی‌رود. بنابراین به سمت روش تبدیل موجک پیش می‌رویم.

### ۳-۲-۱- روش تبدیل موجک

تبدیل موجک یکی از تبدیلات در حوزه‌ی زمان - فرکانس محسوب می‌شود که می‌تواند اطلاعات زمانی و فرکانسی را به‌صورت همزمان ارائه کند. تبدیل موجک به‌عنوان روشی

وجود دارند که این روش‌ها پس از تشخیص الگوهای موجود در سری زمانی، یک مدل منحصربه‌فرد از سری زمانی جهت بسط به آینده و پیش‌بینی آن تنظیم می‌کنند. تعدادی از این روش‌ها عبارت‌اند از میانگین‌گیری ساده، میانگین‌گیری متحرک، هموارسازی نمایی، هموارسازی تطبیقی و روش هموارسازی نمایی تطبیقی قابل‌تعمیم<sup>۱</sup> (AEES) [۴].

### ۳-۲-۲- شبکه‌ی مصنوعی عصبی

شبکه‌های مصنوعی عصبی در سالیان اخیر در حوزه‌ی مدل‌سازی و پیش‌بینی اطلاعات ترافیکی در رشته‌ی حمل‌ونقل موردتوجه قرار گرفته‌اند. چهارچوب شبکه عصبی بدین‌صورت است که اولین یا پایین‌ترین لایه، لایه‌ی ورودی است که اطلاعات خارجی را دریافت می‌کند. آخرین یا بالاترین لایه، لایه‌ی خروجی است که راه‌حل مسئله را ارائه می‌کند. لایه‌ی ورودی و خروجی با یک یا چند لایه‌ی میانی که لایه‌های پنهان نامیده می‌شوند، از هم جدا می‌شوند. به ورودی‌های هر سلول بنا بر میزان تأثیرشان در مدل وزن‌های مختلفی تخصیص داده می‌شود.

شبکه‌ی عصبی با سه پارامتر مختلف الگوی اتصال بین سلول‌های لایه‌های مختلف، فرآیند آموزش شبکه‌ی عصبی و تابع تحریک‌پذیری تعریف می‌شود. معمولاً شبکه‌های عصبی به‌گونه‌ای شکل می‌گیرند که به ازای ورودی خاص، خروجی خاصی را تولید کنند، این فرآیند را آموزش یا یادگیری شبکه‌ی مصنوعی عصبی می‌نامند. نحوه‌ی کارکرد فرآیند آموزش به این صورت است که الگویی به شبکه وارد می‌شود و شبکه به ازای آن الگوی ورودی، خروجی تصادفی تولید می‌کند.

1 Adaptive Extended Exponential Smoothing

تعریف مختلفی را شامل می‌شوند. هر یک از این توابع عملکرد منحصر به فردی دارد و بسته به نوع موضوع مورد بحث می‌توان از توابع موجک مادر مختلفی استفاده کرد.

#### ۴- مطالعه موردی

جهت انجام پژوهش از اطلاعات بزرگراه US-۱۰۱ شهر لس‌آنجلس در کالیفرنیا آمریکا استفاده شده است. بدین منظور از اطلاعات شناساگر اطلاعات حجمی سه روز غیر تعطیل برداشت شده است. این اطلاعات حجم ترافیک را در بازه‌هایی با دقت ۵ دقیقه نمایش می‌دهد. پس مجموع ۸۶۴ داده در طول سه روز در اختیار داریم که عملیات تحلیل و پیش‌بینی را بر روی آن انجام می‌دهیم.

جهت تحلیل سیگنال ترافیکی به دست آمده روش‌های مختلف آماری و روش‌های هوشمند از قبیل شبکه عصبی و روش ترکیبی تبدیل موجک - شبکه عصبی استفاده شده است و نتایج به دست آمده با شاخص‌های ارزیابی مدل پیش‌بینی با یکدیگر مقایسه شده‌اند.

#### ۴-۱- شاخص‌های ارزیابی مدل پیش‌بینی

جهت ارزیابی مدل‌های پیش‌بینی سه شاخص میانگین خطای مطلق (MAE)، میانگین درصدی خطای مطلق (MAPE) و ریشه میانگین مربعات خطا (RMSE) در نظر گرفته شده‌اند. این شاخص‌ها توانایی تشخیص تفاوت‌های مقادیر پیش‌بینی شده با مقادیر واقعی را دارا هستند و می‌توانند مدل را از جنبه‌های مختلفی مورد ارزیابی قرار دهند.

$$MAE = \frac{\sum |v_o - v_p|}{N} \quad (2)$$


جایگزین برای تبدیل فوریه‌ی زمان کوتاه توسعه داده شده است که از وضوح زمانی و فرکانسی قابل قبولی برخوردار نبود.

ساختار روش تبدیل موجک بدین گونه است که سیگنال در یک تابع شبه پنجره‌ای ضرب می‌گردد و تبدیل برای سیگنال در کل قسمت‌های زمانی سیگنال محاسبه می‌گردد. رابطه‌ی محاسبه تبدیل موجک بدین صورت است.

$$CWT_X^\Psi(\tau, s) = \Psi_X^\Psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int x(t) \Psi^* \left( \frac{t-\tau}{s} \right) dt \quad (1)$$

در این رابطه  $s$  پارامتر مقیاس،  $\tau$  پارامتر انتقال و  $\Psi$  تابع موجک مادر را نشان می‌دهد. عبارت "مادر" به این ویژگی اشاره می‌کند که تمامی توابع ساخته شده به وسیله‌ی این تابع پنجره‌ای، از یکجا مشتق یافته‌اند که آن همان موجک مادر است. "موج" بیان‌کننده‌ی رفتار نوسانی این تابع و "ک" بیانگر کوچکی دامنه‌ی تعریف آن است. پارامتر مقیاس در تبدیل موجک در حقیقت عکس فرکانس است. با تغییرات این پارامتر می‌توان به فرکانس‌های مختلف سیگنال مورد نظر دست یافت. در حقیقت با تغییر پارامتر مقیاس دهانه‌ی تابع موجک مادر باز و بسته می‌شود و توسط این پارامتر می‌توان به فرکانس‌های مختلف سیگنال دست یافت. پارامتر انتقال وظیفه‌ی جابه‌جایی تابع موجک مادر با مقیاس‌های مختلف در طول سیگنال را بر عهده دارد تا میزان حضور آن جزء فرکانسی در زمان‌های مختلف سیگنال مشخص شود.

تابع موجک مادر می‌تواند شامل توابع مختلفی از قبیل هار، خانواده‌ی دوبیشز، کلاه مکزیکی، خانواده‌ی کوفلتز، خانواده‌ی سیملت، میر، مرلت و خانواده‌ی گوسی باشد که دامنه‌های



شکل ۴: سیگنال حجم ترافیک ۳ روزه با دقت ۵ دقیقه

بر وضعیت ترافیک یک گام جلوتر انتخاب شده‌اند. تأخیرهای (۲۸۷، ۲۸۸، ۲۸۹) به خاطر در نظر گرفتن وضعیت ترافیک روز قبل در حدود همین زمان انتخاب گشته‌اند. در گام نخست عملکرد چند مدل آماری ساده با یک مدل هوشمند شبکه مصنوعی عصبی با ورودی سیگنال خام مقایسه گشته است.

در مقایسه انجام‌گرفته بین مدل‌های ساده آماری مثل هموارسازی نمایی با ضریب  $\alpha=0.6$  و مدل شبکه مصنوعی عصبی با ورودی سیگنال ساده کاهش محسوس در میزان خطاها مشاهده نمی‌گردد. با توجه به شکل ۴ این مدل در بسیاری از نقاط مقدار پیش‌بینی را بالاتر از مقدار واقعی برآورد و همچنین در پیش‌بینی با کمی تأخیر عمل می‌کند.

بدین منظور با استفاده از روش تبدیل موجک که فرکانس‌های مختلف سیگنال در طول زمان را برآورد می‌کند، سیگنال


$$MAPE = \frac{1}{N} \sum \frac{|v_o - v_p|}{v_o} \times 100\% \quad (3)$$

$$RMSE = \sqrt{\frac{\sum (v_o - v_p)^2}{N-1}} \quad (4)$$

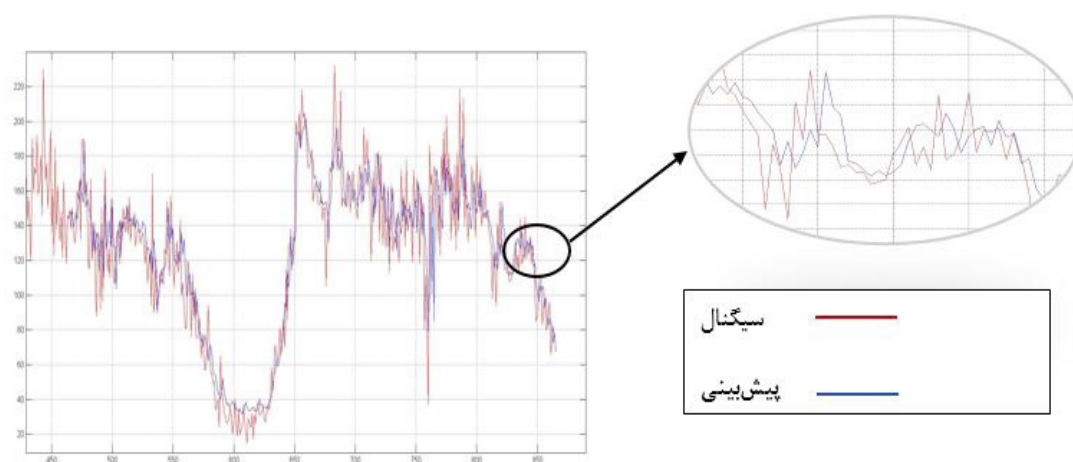
در روابط بالا  $v_o$  بیانگر حجم واقعی یا موجود جریان ترافیک،  $v_p$  بیانگر حجم پیش‌بینی‌شده جریان ترافیک و  $N$  مجموع تعداد  $v_o$  یا  $v_p$  انتخاب‌شده در رابطه را نشان می‌دهد.

#### ۴-۲- انتخاب مدل بینه

بازه زمانی جهت پیش‌بینی کوتاه‌مدت آینده یک گام جلوتر یا ۵ دقیقه مفروض گشته است. جهت آموزش شبکه‌ی مصنوعی عصبی برای پیش‌بینی یک گام جلوتر از تأخیرهای زمانی (۰، ۱، ۲، ۳، ۴، ۲۸۷، ۲۸۸، ۲۸۹) استفاده گشته است. تأخیرهای (۱، ۲، ۳، ۴) بر اساس تأثیر وضعیت ترافیک حال تا ۴ گام قبل تر




شکل ۵: مقایسه میانگین درصدی خطای مطلق میان مدل‌های آماری ساده و شبکه مصنوعی عصبی



شکل ۶: مدل پیش‌بینی شبکه مصنوعی عصبی با ورودی سیگنال ساده

جدول ۱: خطاهای مدل‌های شبکه مصنوعی عصبی با ورودی‌های مختلف جزئیات و تقریب‌ها

مدل	ورودی مدل	MAE	MAPE	RMSE	زمان (ثانیه)
ANN(signal)	سیگنال خام	۱۴.۱۹	۱۴.۵۷	۱۹.۴۳	۱۰
WT-ANN(۱d۱a)	$d_1 + a_1$	۱۰.۶۵	۱۱.۶۶	۱۴.۹۸	۱۲
WT-ANN(۲d۲a)	$d_1 + d_2 + a_1 + a_2$	۸.۹۲	۱۰.۲۰	۱۲.۸۴	۲۰
WT-ANN(۳d۳a)	$d_1 + d_2 + d_3 + a_1 + a_2 + a_3$	۷.۳۴	۷.۴۱	۱۲.۵۴	۳۶
WT-ANN(۴d۴a)	$d_1 + \dots + d_4 + a_1 + \dots + a_4$	۹.۵۸	۱۰.۴۰	۱۳.۰۵	۵۴
WT-ANN(۵d۵a)	$d_1 + \dots + d_5 + a_1 + \dots + a_5$	۶.۹۲	۷.۰۸	۹.۶۰	۷۷
WT-ANN(۶d۶a)	$d_1 + \dots + d_6 + a_1 + \dots + a_6$	۸.۶۲	۹.۴۴	۱۳.۴۶	۱۰۲
WT-ANN(۳d۱a)	$d_1 + d_2 + d_3 + a_3$	۷.۳۴	۷.۴۱	۱۲.۵۴	۱۹
WT-ANN(۵d۱a)	$d_1 + d_2 + d_3 + d_4 + d_5 + a_5$	۸.۷۳	۸.۸۵	۱۲.۳۱	۲۹



شکل ۷: مقایسه مدل‌های شبکه مصنوعی عصبی با ورودی‌های مختلف جزئیات و تقریب‌ها

ترافیکی را به بخش‌های مختلف جزئیات<sup>۱</sup> و تقریب‌ها<sup>۲</sup> تقسیم‌بندی می‌کنیم. انتخاب گشته‌اند و عملکرد آن‌ها با استفاده از شاخص‌های ارزیابی و در نظر گرفتن فاکتور زمان فراگیری شبکه مصنوعی عصبی مقایسه گشته است.

طبق مقایسه انجام گرفته بین مدل‌های مختلف تا مدل WT-ANN(۳d۳a) که سیگنال را به ۳ بخش جزئیات و ۳ بخش تقریب‌ها تقسیم می‌کند از مقدار خطاها کاسته می‌شود. از این مدل به بعد اضافه کردن بیشتر جزئیات و تقریب‌ها با توجه به اینکه تغییر چندانی در دقت پیش‌بینی صورت نمی‌گیرد و زمان تحلیل افزایش می‌یابد منطقی به نظر نمی‌رسد. در نظر گرفتن مدل WT-ANN(۳d۱a)، که دارای یک بخش تقریب و سه بخش جزئیات است نتایجی در حدود مدل WT-ANN(۳d۳a) ارائه می‌دهد که با توجه به زمان تحلیل کمتر مناسب‌تر است. علت این امر را می‌توان تأثیر کم‌تر فرکانس‌های پایین که همان تقریب‌ها هستند بر وقایع نزدیک در آینده دانست.

ترافیکی را به بخش‌های مختلف جزئیات<sup>۱</sup> و تقریب‌ها<sup>۲</sup> تقسیم‌بندی می‌کنیم.

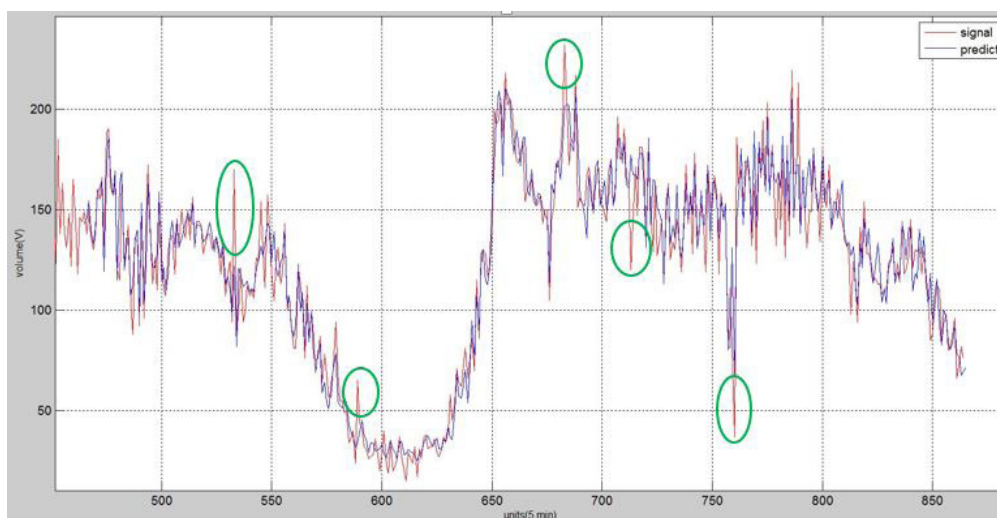
$$S = d_1 + \dots + d_n + a_1 + \dots + a_n \quad (5)$$

در رابطه بالا S سیگنال، d جزئیات و a تقریب‌ها را نمایش می‌دهد. بنابراین ما سیگنال را می‌توانیم برحسب نیاز به تعداد مختلفی از جزئیات و تقریب‌ها تبدیل کنیم. جزئیات فرکانس‌های بالاتر و تقریب‌ها فرکانس‌های پایین‌تر را نمایندگی می‌کنند. اکنون می‌توانیم به جای در نظر گرفتن سیگنال ساده به عنوان ورودی شبکه مصنوعی عصبی از تقریب‌ها و جزئیات به عنوان ورودی آن استفاده کنیم. شبکه عصبی با تنظیم ضرایب در طی فرآیند یادگیری برحسب نیاز جزئیات و تقریب‌های بااهمیت‌تر را برمی‌گزیند.

در این مرحله چندین مدل با جزئیات و تقریب‌های مختلف

1 Detail

2 Approximation



شکل ۸: سیگنال حجم و پیش‌بینی با مدل WT-ANN(۳d۱a)

پیش‌بینی نوسانات از خود نشان می‌دهد (شبکه نهایی قادر است حجم تردد در ۵ دقیقه آینده را با میانگین خطای مطلق ۷/۴۳ پیش‌بینی نماید). ولی در تشخیص برخی از تغییرات ناگهانی عملکرد ضعیفی دارد.

طبق نتایج به‌دست‌آمده از مدل WT-ANN(۳d۱a) این مدل توانایی خوبی در پیش‌بینی نوسانات جریان ترافیکی دارد. این مدل تنها در برخی از نقاط که تغییرات ناگهانی در جریان ترافیک رخ می‌دهد عملکرد مناسبی ندارد.

## ۶- مراجع

- 1- W. Danping, H. Kunyuan, H. Xiaowei, 2015, Research on the Application of Intelligent Algorithm in Short-Term Traffic Flow Forecast.
- 2- Vlahogianni, E. I., Karlaftis, M. G., & Golias, J. C. (2014). Short-term traffic forecasting: Where we are and where we're going. Transportation Research Part C: Emerging Technologies, 43, 3-19.
- 2- E. I. Vlahogianni, M. G. Karlaftis, J. C. Golias, 2014, Short-term traffic forecasting: Where we are and where we're going, Transportation Research Part C: Emerging Technologies, 43, 3-19.
- 3- M. G. Karlaftis, E. I. Vlahogianni, 2011, Statistical methods versus neural networks in transportation research: Differences, similarities and some insights, Transportation Research Part C: Emerging Technologies, 19(3), 387-399.
- 4- J. T. Mentzer, M.A. Moon, 2004, Sales forecasting management: a demand management approach, Sage Publications.
- 5- Z. Zheng, S. Ahn, D. Chen, J. Laval, 2011, Applications of wavelet transform for analysis of freeway traffic: Bottlenecks, transient traffic, and traffic oscillations, ansportation Research Part B: Methodological, 45(2), 372-384.

## ۵- نتیجه‌گیری

در این مقاله ابتدا عملکرد تعدادی از مدل‌های ساده آماری با یک شبکه مصنوعی عصبی با ورودی سیگنال خام مقایسه شده است. در این مقایسه، مدل شبکه عصبی با ورودی سیگنال خام نسبت به مدل‌های آماری ساده عملکرد بهتری دارد ولی چندان تفاوت محسوسی در نتایج به‌دست‌آمده مشاهده نمی‌شود. مشکل بسیار مهم این مدل وجود یک تأخیر زمانی در نتایج پیش‌بینی نسبت به داده‌های واقعی است. به همین جهت از آنجایی که سیگنال ترافیک یک سیگنال پرنوسان است روش تبدیل موجک برای دریافت ویژگی‌های جزئی سیگنال برگزیده شده است. در این روش ابتدا سیگنال خام به چندین زیرشاخه با فرکانس‌های مختلف که همان جزئیات و تقریب‌ها هستند تقسیم شده و سپس از این قسمت‌ها به‌عنوان ورودی مدل شبکه مصنوعی عصبی استفاده گشته است. مسئله اصلی در این روش انتخاب تعداد تقریب‌ها و جزئیات بر اساس دو فاکتور دقت پیش‌بینی و مدت‌زمان تحلیل است. به این دلیل که پیش‌بینی کوتاه‌مدت مدنظر است پس فاکتور زمان از اهمیت زیادی برخوردار است. نتایج به‌دست‌آمده نشان داد که قسمت جزئیات به خاطر کوتاه‌مدت بودن بازه پیش‌بینی اهمیت بیشتری نسبت به قسمت تقریب‌ها دارند. پس در نهایت با توجه به این موارد مدل WT-ANN(۳d۱a) با سه قسمت جزئیات و یک قسمت تقریب‌ها انتخاب گشته است. مدل به‌دست‌آمده با استفاده از این روش عملکرد مناسبی را در

## Short-Term Traffic Volume Forecasting in Urban Highways Using Frequency Domain Transformations

Seyed Omid Mousavizadeh Kashi, Meisam Akbarzadeh

1-Graduate Student, Department of Transportation Eng., Isfahan Univ. of Technology

2-Assistant Professor, Department of Transportation Eng., Isfahan Univ. of Technology

### Abstract

Traffic flow on urban highways influenced by various factors and constantly changing from one state to another. Therefore, knowledge of the future traffic flow condition is remarkably important. This paper analyzing volume data to predict future traffic flow. To predict traffic flow we can use different statistical or computational intelligence methods, such as artificial neural networks. Using of artificial neural network model with crude signal input is not better than simple statistical models. As the traffic signal has high noise, in order to access the details of signal we use wavelet transform to turned it into several Frequency sections. These sections are considered as an input to the artificial neural network model. Flow forecasting with wavelet transform-artificial neural network model is more accurate than simple artificial neural network model.

**key words:** forecasting traffic flow, signal processing, wave transform artificial neural network.