

مدل تعقیب خودروی مبتنی بر شبکه‌های عصبی مصنوعی با در نظر گیری قابلیت پیش‌بینی مکانی رانندگان

مهدی رفعتی فرد، افشین شریعت مهیمنی

۱- دانشجوی دکتری، آزمایشگاه تحقیقاتی ترافیک، دانشگاه علم و صنعت ایران، تهران

۲- دانشیار، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران، تهران

چکیده

مدل‌های تعقیب خودرو از جمله مهم‌ترین مدل‌های رفتاری رانندگی بوده و در زمینه‌های مختلف مهندسی حمل‌ونقل نظیر شبیه‌سازی‌های ریزنگر ترافیک و ایمنی مورد استفاده قرار می‌گیرد. رفتار تعقیب خودرو تحت تأثیر عوامل مختلفی قرار دارد. باین وجود به دلیل نبود اطلاعات کافی و ماهیت پنهان بسیاری از آن‌ها تنها تعداد محدودی از این عوامل در نظر گرفته می‌شود. قابلیت پیش‌بینی مکانی راننده یکی از عواملی است که در مدل‌های تعقیب خودرو به‌ویژه مدل‌های مبتنی بر هوش مصنوعی کمتر مورد توجه قرار گرفته است. در این مقاله به منظور در نظر گیری قابلیت پیش‌بینی مکانی رانندگان یک مدل تعقیب خودروی مبتنی بر شبکه عصبی توسعه داده شده است. متغیرهای سرعت خودروی موضوع، سرعت اولین و دومین خودروی پیشرو، سرعت خودروی پیرو، اولین و دومین فرصت پیشین و فرصت پسین به‌عنوان متغیرهای ورودی و شتاب خودروی موضوع به‌عنوان خروجی مدل در نظر گرفته شده است. نتایج کالیبراسیون مدل ارائه شده نشان می‌دهد که در بیشتر موارد مدل توسعه داده شده عملکرد بهتری نسبت به مدل پایه داشته و بر داده‌های واقعی انطباق بیشتری دارد. علاوه بر این در برخی از موارد مدل‌ها تا حدودی عملکرد مشابهی با یکدیگر دارند. بررسی‌های صورت گرفته نشان می‌دهد عملکرد مشابه دو مدل در برخی از مواقع به دلیل همبستگی زیاد فرصت‌های پیشین است.

واژگان کلیدی: مدل تعقیب خودرو، پیش‌بینی مکانی، شبکه عصبی، زمان پاسخ

۱- مقدمه

در سال‌های اخیر استفاده از ابزارهای شبیه‌ساز ریزنگر ترافیک جهت ارزیابی گزینه‌های مدیریت پویای ترافیک، کاربردهای مختلف سیستم‌های هوشمند حمل‌ونقل، گزینه‌های مختلف طرح هندسی و غیره افزایش یافته است. توانایی این نرم‌افزارها جهت مدل‌سازی فرآیندها و اندرکنش‌های پیچیده موجود در سیستم‌های حمل‌ونقل از یک‌طرف و ناتوانی ابزارهای تحلیلی در مدل‌سازی و تجزیه و تحلیل این نوع از سیستم‌ها از طرف دیگر، منجر به محبوبیت روزافزون و توسعه دامنه وسیعی از نرم‌افزارهای شبیه‌ساز ریزنگر ترافیک شده است [۱]. صحت و میزان دقت نتایج حاصل از به‌کارگیری نرم‌افزارهای شبیه‌ساز ریزنگر

ترافیک به میزان زیادی وابسته به عملکرد مدل‌های رفتار رانندگی بکار رفته در آن‌ها است. مهم‌ترین این مدل‌ها، مدل تعقیب خودرو و تغییر خط عبوری است. از این‌رو مدل‌های مذکور از سوی محققین ترافیک مورد توجه زیادی قرار گرفته است [۲، ۳]. مدل تعقیب خودرو نخستین بار توسط پایپس [۴] معرفی گردید. مدل تعقیب خودرو در واقع توصیف‌کننده حرکت طولی خودروها در یک خط عبوری بوده و چگونگی اندرکنش خودروی پیرو با خودروی پیشرو را بیان می‌کند. در یک نگاه کلی مدل‌های تعقیب خودرو را می‌توان به دو گروه مدل‌های مبتنی بر معادله و مدل‌های مبتنی بر الگوریتم‌های یادگیری ماشین تقسیم‌بندی نمود.

در مدل‌های مبتنی بر معادله، فرآیند تعقیب خودرو با استفاده از معادلات جبری دیفرانسیلی توصیف شده و بین متغیرهای ورودی و خروجی یک رابطه صریح ریاضی در نظر گرفته می‌شود. پارامترهای مدل با استفاده از داده‌های میدانی و به‌صورت میانگین برآورد شده و به فرم ثابت‌هایی در معادله وارد می‌شوند. مدل‌های تعقیب خودروی مبتنی بر معادله را بر اساس منطق پایه بکار رفته در آن‌ها می‌توان به مدل‌های تحریک پاسخ [۵] مدل‌های فاصله دلخواه [۶] مدل‌های اجتناب از برخورد یا فاصله ایمن [۷، ۸]، مدل‌های سرعت بهینه [۹]، مدل‌های اتوماتای سلولی [۱۰]، مدل‌های روانی-جسمانی [۱۱] و مدل‌های مبتنی بر انتخاب گسسته [۱۲] طبقه‌بندی نمود. در این مدل‌ها متغیرهایی نظیر سرعت نسبی، شتاب، سرعت دلخواه و سرفاصله خالص به‌عنوان متغیرهای مستقل و شتاب یا سرعت خودروی پیرو به‌عنوان متغیر وابسته در نظر گرفته می‌شود. در گروه دوم از مدل‌های تعقیب خودرو، از ابزارهای هوش مصنوعی و یادگیری ماشین نظیر شبکه‌های عصبی مصنوعی جهت مدل‌سازی استفاده شده است. توانایی این الگوریتم‌ها در بیان ارتباطات غیرخطی و پیچیده، عدم نیاز به دانش قبلی و در نظرگیری فرض صریح در ارتباط با چگونگی رابطه بین متغیرهای ورودی و خروجی آن‌ها را به ابزارهای قدرتمندی جهت مدل‌سازی تبدیل کرده است [۱۳]. در سال‌های اخیر استفاده از شبکه‌های عصبی در زمینه‌های مختلف حمل‌ونقلی نظیر؛ پیش‌بینی کوتاه‌مدت شاخص‌های عملکردی ترافیک [۱۴، ۱۵] پیش‌بینی زمان سفر [۱۶]، پیش‌بینی تصادفات [۱۷]، هماهنگ‌سازی چراغ‌های راهنمایی و مدیریت ترافیک [۱۸] و پیش‌بینی رفتار تغییر خط عبوری رانندگان [۱۹] مورد توجه زیادی قرار گرفته است. طبیعت غیرخطی بالای رفتارهای تعقیب خودروی رانندگان و عدم قطعیت‌های پارامتریک و ساختاری این نوع رفتارها نیز منجر به استفاده از الگوریتم‌های هوشمند برای توصیف و پیش‌بینی این نوع از رفتارهای رانندگی شده است [۲۰-۲۲].

از جمله موارد حائز اهمیت در ساخت مدل‌های تعقیب خودرو، انتخاب مناسب متغیرهای تأثیرگذار بر رفتار رانندگی است. رفتار تعقیب خودرو رانندگان تحت تأثیر عوامل مختلفی قرار دارد. صیف الزمان و همکارانش [۳] با بررسی تحقیقات انجام شده در ارتباط با رفتار رانندگی پانزده متغیر؛ خصوصیات اقتصادی اجتماعی، زمان عکس‌العمل، خطای برآورد، آستانه‌های ادراک، پیش‌بینی مکانی، پیش‌بینی زمانی، موقعیت رانندگی، عدم کنترل کامل راننده، پرخاشگری یا ریسک‌پذیری، ضرورت رانندگی، حواس‌پرتی، مهارت در رانندگی، سرعت، فاصله مکانی و زمانی دلخواه را به‌عنوان متغیرهای اصلی تأثیرگذار ارائه کردند. علیرغم

بیان طیف وسیعی از متغیرهای تأثیرگذار در رفتار تعقیب خودروی رانندگان، به دلیل ماهیت پنهان بسیاری از این عوامل و یا عدم دسترسی به داده‌های مناسب جهت در نظرگیری تأثیرات آن‌ها، در عمل تنها متغیرهای محدودی به‌عنوان متغیرهای ورودی در مدل‌های تعقیب خودرو استفاده شده است. از جمله مهم‌ترین این متغیرها، توانایی پیش‌بینی مکانی یا پیش‌بینی چندانگانه رانندگان است.

در جریان رانندگی، رانندگان نه‌تنها خودروی جلوی خویش بلکه چندین خودروی پایین‌دست و حتی خودروهای پیرامونی خویش را در نظر گرفته و بر اساس آن، شرایط ترافیکی آینده را پیش‌بینی و با یک تأخیر زمانی به آن پاسخ می‌دهند. این پیش‌بینی منجر به جلوگیری از تغییرات ناگهانی و نرم‌تر شدن پروفیل شتاب خودروها و در نتیجه راحتی سرنشینان می‌شود. راننده در صورتی که افزایش و یا کاهش سرعت در جریان پایین‌دست را پیش‌بینی نماید، می‌تواند پیش از رسیدن موج مذکور به خود نسبت به آن عکس‌العمل نشان داده و شتاب افزایشی یا کاهش‌ی مناسب را بکار برده و یا به‌کارگیری آن‌ها را به تأخیر بیندازد. تأثیر این پیش‌بینی بسته به شرایط ترافیکی، می‌تواند باعث کاهش و یا افزایش زمان عکس‌العمل راننده شود. در واقع بخشی از پدیده‌های مشاهده‌شده در بررسی خط سیر خودروی پیرو و پیشرو، نظیر پاسخ راننده به یک تحریک پیش از رخداد آن (زمان عکس‌العمل منفی) و یا متفاوت بودن علامت ترم‌های تحریک و پاسخ [۲۳] می‌تواند ناشی از توانایی پیش‌بینی مکانی راننده باشد. به‌عبارت‌دیگر راننده ممکن است با خودرو پیشروی خود اختلاف سرعت منفی داشته و در حال نزدیک شدن به او باشد. ولی چون پیش‌بینی او از جریان پایین‌دست افزایش سرعت است، در پاسخ به‌کارگیری شتاب کاهش‌ی را به تعویق انداخته و یا حتی شتاب افزایشی متناسب با پیش‌بینی خویش استفاده نماید. از طرف دیگر این پیش‌بینی می‌تواند منجر به رعایت سرفاصله کوچک‌تری توسط رانندگان شود به‌طوری‌که رانندگان در شرایط ترافیکی پیچیده و حتی با سرفاصله‌های زمانی کوچک‌تر از زمان عکس‌العمل مورد انتظار، یک رانندگی راحت و عاری از تصادف را تجربه نماید. به‌عبارت‌دیگر این امر منجر به همبستگی بین بیش از دو وسیله نقلیه و تأثیر بر روی رفتار جمعی آن‌ها و در نهایت افزایش پایداری مجانبی جریان ترافیک می‌شود [۲۴].

لازم به ذکر است، برداشت داده‌های موقعیت مکانی با نویزهایی همراه است که این خطاها در فرآیند استخراج داده‌های سرعت و شتاب تشدید می‌شوند. به‌منظور کاهش اثرات این نویزها از روش ارائه‌شده توسط رفعتی فرد و همکاران [۳۰] جهت اصلاح داده‌های خط سیر خودرو استفاده شده است.

۳- متدولوژی


۳-۱- چارچوب مدل‌سازی

به منظور در نظرگیری قابلیت پیش‌بینی مکانی رانندگان و بررسی اثرات آن در نتایج مدل‌سازی و پایداری جریان ترافیک، دو مدل تعقیب خودروی مبتنی بر شبکه عصبی با متغیرهای ورودی متفاوت ساخته شده است. در نوع اول همان‌گونه که در شکل ۱- الف نشان داده شده است، متغیرهای سرعت خودروی موضوع، سرعت‌های اولین و دومین خودروی پیش رو، سرفاصله خالص با اولین و دومین خودروی پیش رو و ورودی و شتاب خودروی موضوع به عنوان متغیر خروجی در نظر گرفته شده است. بر این اساس فرم عمومی مدل تعقیب خودروی اول به‌صورت زیر است.

(رابطه ۱)

$$a_n(t) = f(V_{n-2}(t-\tau'), g'_2(t-\tau), V_{n-1}(t-\tau), g'_1(t-\tau), V_n(t-\tau), g^f(t-\tau))$$

مدل دوم نیز مشابه مدل اول بوده و تنها متغیرهای سرعت خودروی موضوع و اولین خودروی پیش رو و سرفاصله خالص با اولین خودروی پیش رو در هر گام زمانی به عنوان متغیرهای ورودی و سرعت خودروی موضوع در گام زمانی که در آن تأخیر زمانی راننده است، به عنوان متغیر خروجی در نظر گرفته شده است (شکل ۱-ب). برای ساخت مدل‌های مذکور از یک شبکه عصبی سه لایه شامل یک لایه ورودی، یک لایه خروجی و یک لایه پنهان استفاده شده است. چگونگی برآورد پارامترها، کالیبراسیون و اعتبارسنجی مدل در ادامه بیان شده است.



شکل ۱: متغیرهای در نظر گرفته شده به عنوان ورودی (الف) مدل اول (با پیش‌بینی مکانی) (ب) مدل دوم (مدل پایه)

۳-۲- شبکه عصبی مصنوعی

بر اساس تعریف کوهونن شبکه‌های عصبی مصنوعی، شبکه‌های به هم پیوسته موازی از عناصر ساده (معمولاً انطباقی) است که ساختار سلسله مراتبی آن‌ها به منظور اندرکنش با اشیا جهان واقعی، عملکرد مشابهی با سیستم عصبی زیستی دارد [۳۱]. اساس عملکرد شبکه عصبی را نورون‌ها تشکیل می‌دهند. نورون‌ها در واقع کوچک‌ترین واحد پردازش اطلاعات هستند. شکل ۲-الف یک نورون رایج با n ورودی را نشان می‌دهد.

پیش‌بینی چندگانه در مدل‌های جنرال موتور [۲۵]، سرعت بهینه [۲۶]، راننده هوشمند [۲۷] و اتوماتای سلولی [۲۸] مورد بررسی قرار گرفته است. نتایج این پژوهش‌ها افزایش پایداری بیشتر این مدل‌ها نسبت به مدل‌های پایه آن‌ها را نشان می‌دهد. علیرغم در نظرگیری توانایی پیش‌بینی چندگانه رانندگان و بررسی تأثیر آن بر روی رفتار تعقیب خودروی آن‌ها در مدل‌های مبتنی بر معادله، در بیشتر مدل‌های مبتنی بر هوش مصنوعی، اندرکنش‌های بین چندین وسیله نقلیه در یک خط عبوری نادیده گرفته شده و تنها متغیرهایی نظیر سرعت خودروی پیرو و پیشرو، سرفاصله خالص، شتاب خودروی پیرو و نوع خودروی پیرو و پیشرو به عنوان متغیرهای ورودی در نظر گرفته شده است. از این‌رو در مقاله حاضر بر روی طراحی شبکه عصبی برای پیش‌بینی رفتار تعقیب خودرو در جریان ترافیک با در نظرگیری قابلیت پیش‌بینی مکانی رانندگان تمرکز شده است. به این منظور یک مدل تعقیب خودروی مبتنی بر شبکه عصبی با در نظرگیری پیش‌بینی مکانی آموزش داده شده و نتایج با یک مدل تعقیب خودروی مبتنی بر شبکه عصبی رایج (بدون در نظرگیری پیش‌بینی مکانی) مقایسه شده است.

ساختار مقاله به این صورت است که در بخش دوم داده‌های استفاده شده معرفی شده است. در بخش سوم متدولوژی در نظر گرفته شده جهت مدل‌سازی رفتار تعقیب خودرو با استفاده از شبکه‌های عصبی بیان شده و نتایج مدل‌سازی در بخش چهارم ارائه و مورد تجزیه و تحلیل قرار گرفته است. در نهایت در بخش پایانی نیز ضمن جمع‌بندی مطالب ارائه‌شده، پیشنهادهایی جهت مطالعات آتی ارائه گردیده است.

۲- مجموعه داده‌ها

داده‌های خط سیر استفاده شده در این پژوهش از رویکرد جنوبی مقطعی از بزرگراه US ۱۰۱ در لس‌آنجلس جمع‌آوری شده است. مقطع مورد نظر شامل ۵ خط عبوری اصلی، یک رمپ ورود و یک رمپ خروج به همراه خط عبوری کمکی بین آن‌ها است. این مجموعه داده‌ها توسط اداره راه‌های امریکا به عنوان بخشی از پروژه شبیه‌سازی نسل بعدی فراهم شده و به‌طور گسترده‌ای برای توسعه مدل‌های ریزنگر ترافیک و کالیبراسیون آن‌ها مورد استفاده قرار گرفته است [۲۹]. داده‌های استخراج‌شده از طریق پردازش تصویر شامل موقعیت مکانی خودروها، نوع خودروها، سرعت و شتاب آن‌ها در بازه زمانی ۷:۵۰ تا ۸:۳۵ و با دقت زمانی ۰٫۱ ثانیه است. جریان ترافیک ۸۰۷۷ وسیله نقلیه بر ساعت با ترکیب ۹۷٫۰٪ خودروی سواری، ۲٫۲٪ خودروی سنگین و ۰٫۷٪ موتورسیکلت است. متوسط سرعت در مقطع مذکور ۳۵٫۰ کیلومتر بر ساعت و چگالی ۲۳۱ خودرو در هر کیلومتر است.

نورون‌های لایه بعد متصل هستند. این چیدمان اصطلاحاً یک شبکه با اتصالات کامل را تشکیل می‌دهد. شکل ۲- ب یک شبکه عصبی پرسپترون سه لایه (یک لایه ورودی، یک لایه پنهان و یک لایه خروجی) را نشان می‌دهد. در این ساختار همان‌گونه که مشخص است، هر نورون در هر لایه به وسیله لینک‌های وزن‌دار به نورون‌های لایه بعدی خود متصل بوده و خروجی‌های هر لایه به صورت ورودی برای لایه‌های بعدی در نظر گرفته می‌شود. فرم ریاضی شبکه عصبی نشان داده شده به صورت زیر است.



$$y_k = f_k^{(3)} \left(\sum_{j=1}^{L^2} w_{kj}^{(3)} \times f_j^{(2)} \left(b_j^{(2)} + \sum_{i=1}^n w_{ji}^{(2)} x_i \right) + b_k^{(3)} \right)$$

$$k, k = \{1, 2, \dots, L^2\} \quad \text{رابطه (۳)}$$

که در آن؛ x_i متغیر ورودی i ام؛ $w_{ji}^{(2)}$ وزن متغیر i برای نورون j در لایه دوم؛ $b_j^{(2)}$ بایاس نورون j در لایه دوم؛ $f_j^{(2)}$ تابع فعال‌سازی نورون j در لایه دوم؛ وزن $w_{kj}^{(3)}$ سیگنال ورودی به نورون k در لایه سوم از نورون j در لایه دوم $f_k^{(3)}$ تابع فعال‌سازی نورون k در لایه سوم (خروجی k ام)؛ y_k خروجی k ام شبکه عصبی، n تعداد متغیرهای ورودی؛ L (۲) تعداد نورون‌ها در لایه دوم؛ و L (۳) تعداد نورون‌ها در لایه سوم (خروجی‌های شبکه عصبی) است.

۳-۳- چگونگی در نظرگیری تأخیر زمانی در شبکه‌های عصبی پرسپترون چندلایه

سؤال اصلی هنگام استفاده از شبکه‌های عصبی پرسپترون چندلایه در پیش‌بینی رفتار تعقیب خودروی رانندگان، به‌کارگیری شیوه‌ای برای در نظرگیری تأخیر زمانی رانندگان در پاسخ به تحریکات مشاهده شده است. شبکه‌های پرسپترون چندلایه فاقد حافظه داخلی جهت در نظرگیری چنین رفتار زمانی هستند. از این رو چنین خصوصیتی بایستی به صورت خارجی برای شبکه پرسپترون عصبی چندلایه (MLPs) در نظر گرفته شود. به عنوان مثال، شتاب خودروی پیرو ($a_n(t)$) را به عنوان خروجی شبکه عصبی در نظر بگیرید. به منظور پیش‌بینی مقدار a در هر گام زمانی t ، شبکه بایستی برای زوج مقادیر ورودی -خروجی که ممکن است تعدادی از ورودی‌ها دارای تاخیرات زمانی باشند، آموزش ببیند. بعد از آموزش، شبکه عصبی قادر است تا مقدار مشاهده شده $V_n(t)$ را با استفاده از ورودی‌های همراه با تأخیر برآورد نماید. در این چارچوب شبکه عصبی پرسپترون چندلایه عملکردی شبیه تقریب زننده تابع داشته و شبکه عصبی حاصل را می‌توان یک مدل غیرخطی چند متغیره در نظر گرفت [۳۱].



شکل ۲. شبکه عصبی مصنوعی الف) مدل ریاضی نورون مصنوعی ب) شبکه عصبی چند لایه

عناصر تشکیل دهنده یک نورون، لینک‌های ارتباطی وزن‌دار، جمع کننده، بایاس و تابع فعال‌سازی است. در یک نورون مصنوعی هر یک از داده‌های ورودی i ، با وزن در محاسبات وارد می‌شود. این وزن‌های در واقع میزان اهمیت و تأثیر هر یک از ورودی‌ها در خروجی‌ها را نشان می‌دهند. به عنوان مثال وزن صفر () برای متغیر ، عدم تأثیر متغیر مذکور در خروجی را نشان می‌دهد. تابع جمع شونده، مجموع متغیرهای ورودی وزن‌دار و یک عدد ثابت به نام بایاس را محاسبه می‌کند. این عدد ثابت منجر می‌شود که نورون به زیر فضایی از فضای ورودی بایاس گردد. در نهایت حاصل جمع حاصل تحت عنوان ورودی خالص با استفاده از تابع فعال‌سازی که جهت محدود کردن خروجی نورون با توجه به نیازهای خاص حل مسئله انتخاب و مورد استفاده قرار می‌گیرد، به خروجی y تبدیل می‌شود. در حالت کلی از دیدگاه ریاضی یک نورون چیزی جز تابعی به فرم زیر نیست.

$$y = f(\text{net}) \quad \text{رابطه (۲)}$$

$$\text{net} = b + w_1 x_1 + w_2 x_2 + \dots + w_n x_n = b + \sum_{i=1}^n w_i x_i$$

که در آن؛ x_i متغیرهای ورودی i ام؛ w_i وزن متغیر i ام؛ b بایاس؛ تابع فعال‌سازی؛ و n تعداد متغیرهای ورودی به نورون است. در بسیاری از موارد با یک نورون ساده نمی‌توان کار خاصی انجام داد. برای رفع این مشکل از موازی و همچنین لایه‌ای کردن ساختار فوق استفاده می‌شود. یکی از ساده‌ترین و در عین حال کارآمدترین چیدمان‌های پیشنهادی برای استفاده در مدل‌سازی، پرسپترون چندلایه است. که از یک لایه ورودی، چند لایه پنهان و یک لایه خروجی تشکیل شده است. در این ساختار، تمام نورون‌های یک لایه به تمام

محلی پارامترها به جای مقادیر عمومی است. برای غلبه بر این مشکل در این پژوهش از الگوریتم ژنتیک جهت برآورد مقادیر وزن‌ها و بایاس‌ها استفاده شده است.

۴- نتایج

جدول ۱ مقادیر تابع هدف و زمان عکس‌العمل‌های برآورد شده هر یک از مدل‌ها را نشان می‌دهد. همان‌گونه که مشخص است مقادیر میانگین تابع هدف برای شتاب و سرعت در مدل با در نظرگیری قابلیت پیش‌بینی مکانی نسبت به مدل پایه (بدون در نظرگیری پیش‌بینی مکانی راننده) تا حدودی کمتر است. اما در ارتباط با فرصت خالص به‌طور معکوس مقدار میانگین برآورد شده برای مدل پایه به مقدار جزئی از مدل با قابلیت پیش‌بینی مکانی کمتر است. این امر به این دلیل است که همان‌گونه که پونزو و همکارانش [۳۲] به آن اشاره کرده‌اند، در صورتی که یک مدل بتواند رفتار مشاهده شده را به‌صورت کامل توصیف نماید، در این صورت نوع معیار کارایی در نظر گرفته شده جهت کالیبراسیون مدل در تعیین پارامترهای مدل (در اینجا وزن‌ها) بی‌تأثیر بوده و به عنوان مثال کاهش مقدار خطا در مقادیر برآورد شده شتاب به‌صورت خودکار منجر به کاهش خطا در مقادیر برآورد شده سرعت و فرصت خالص می‌شود. اما در واقعیت مدل‌ها کم‌وبیش با خطاهایی همراه بوده و انتخاب معیار کارایی‌های متفاوت می‌تواند منجر به برآورد مقادیر متفاوتی از پارامترها شده و لذا کاهش مقدار تابع هدف برای شتاب ممکن است منجر به افزایش مقدار خطا برای سرعت و فرصت خالص شود. شکل ۳ شتاب و سرعت مشاهده و برآورد شده را برای یک خودرو نشان می‌دهد. همان‌گونه که مشخص است مدل شبکه عصبی با در نظرگیری قابلیت پیش‌بینی مکانی تغییرات شتاب و سرعت را نسبت به مدل پایه بهتر نشان می‌دهد.

جدول ۱: نتایج مدل‌سازی رفتار تعقیب خودرو

مدل	معیار کارایی (MOP)	مقدور میانگین مربع خطا (RMSE)			انحراف معیار
		میانگین	حداقل	حداکثر	
مدل پایه	شتاب	۰.۸۳	۰.۵۳	۱.۳۷	۰.۱۸
	سرعت	۰.۷۶	۰.۳۹	۱.۸۶	۰.۲۶
	فرصت	۲.۳۱	۰.۴۵	۸.۱۵	۱.۶
مدل با قابلیت پیش‌بینی مکانی	شتاب	۰.۷۹	۰.۴۹	۱.۳۷	۰.۱۹
	سرعت	۰.۶۷	۰.۳۵	۱.۳۷	۰.۲۳
	فرصت	۲.۴۰	۰.۴۶	۹.۷۲	۱.۹۳

برای درک بهتر این موضوع مقادیر شتاب واقعی و پیش‌بینی‌شده توسط مدل‌ها به‌صورت تابعی از سرعت نسبی خودروی پیرو و اولین خودروی پیشرو با در نظرگیری تأخیر زمانی ۰.۸ ثانیه در شکل ۴ نشان داده شده است. مدل تعقیب خودروی مبتنی بر شبکه عصبی با در نظرگیری قابلیت پیش‌بینی مکانی راننده نسبت به مدل پایه محدوده بیشتری از داده‌ها را تحت

۳-۴- معیار کارایی و تابع هدف

انتخاب معیار کارایی مناسب که نشان‌دهنده رفتار واقعی سیستم و مدل باشد از جمله موارد حائز اهمیت در مدل‌سازی است. در صورتی که مدل به‌صورت دقیق سیستم واقعی را بازتولید نماید و به‌عبارت‌دیگر هیچ اختلافی بین خروجی‌های مدل و مقادیر مشاهده شده وجود نداشته باشد. نوع معیار کارایی و تابع هدف انتخاب‌شده تأثیری بر روی مقادیر برآورد شده پارامترها ندارد. اما از آنجاکه مدل تلخیصی از واقعیت است، کم‌وبیش با خطاهایی همراه است. از این‌رو انتخاب معیار کارایی متفاوت ولی با تابع هدف یکسان و حتی مقادیر بهینه مشابه از تابع هدف، می‌تواند منجر به تخمین‌های متفاوتی از پارامترهای مدل شود. در حالت کلی هر کمیت متغیر با زمان نظیر سرعت، سرفاصله، شتاب می‌تواند به عنوان معیار کارایی مورد استفاده قرار گیرد. در ادامه شتاب به عنوان معیار کارایی مناسب استفاده شده است.

قلب فرآیند بهینه‌سازی، تابع هدف استفاده شده در آن است. تابع هدف انتخاب‌شده تأثیر مستقیمی بر مقادیر برآورد شده پارامترهای مدل دارد. در این پژوهش تابع هدف مجذور میانگین مربع خطا به فرم رابطه (۴) به عنوان تابع هدف انتخاب شده است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i^{meas} - Y_{i|\hat{\theta}}^{sim})^2} \quad \text{رابطه (۴)}$$

که در آن؛ Y_i^{meas} و Y_i^{sim} مقادیر اندازه‌گیری شده و شبیه‌سازی‌شده معیار کارایی در لحظه λ است.

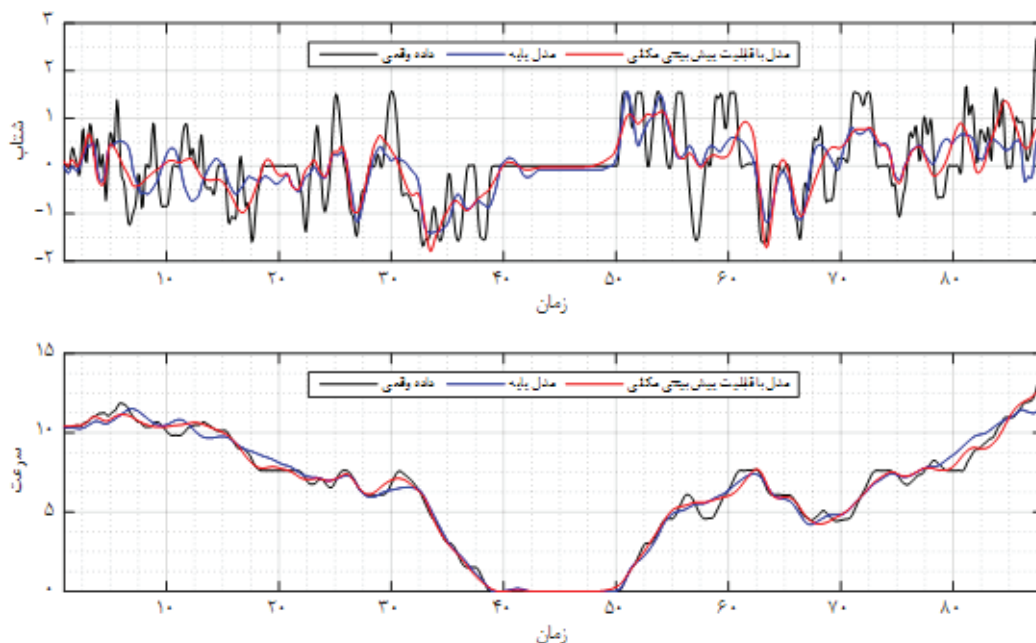
۳-۵- آموزش شبکه عصبی و تنظیم پارامترهای مدل

عملکرد یک شبکه عصبی وابسته به پارامترهای آن (وزن‌های و بایاس‌ها) است. فرآیند تعیین پارامترهای شبکه عصبی را آموزش شبکه عصبی می‌نامند. فرآیند آموزش را می‌توان به‌صورت یک مسئله بهینه‌سازی جهت حداقل کردن خطای بین خروجی‌های مدل و مقادیر مشاهده شده بیان نمود. الگوریتم‌های یادگیری شبکه عصبی تلاش می‌کنند تا وزن‌ها و بایاس‌ها در شبکه را به گونه‌ای تا زمان رسیدن به معیارهای توقف از پیش تعیین شده، بهینه نمایند. معیار توقف می‌تواند به‌صورت رسیدن به یک مقدار قابل قبول خطا در فرآیند آموزش و یا رسیدن به یک هزینه محاسباتی از پیش تعیین‌شده در نظر گرفته شود. الگوریتم‌های زیادی نظیر حداقل گرادینان و پس انتشار برای این منظور ارائه شده است. عیب اصلی این روش‌ها احتمال قرار گرفتن تابع هدف در مینیمم محلی و برآورد مقادیر

پوشش قرار می‌دهد. در این شکل درصد نقاطی که در هریک از نواحی دستگاه مختصات قرار دارد محاسبه شده است.

همان‌گونه که مشاهده می‌شود در حدود ۸۰ درصد داده‌ها در ربع اول و سوم دستگاه مختصات که در آن‌ها تحریک و پاسخ هم علامت هستند و حدود ۲۰ درصد از داده‌ها در ربع دوم و چهارم که ترم تحریک و پاسخ علامت مخالف هم دارند، قرار دارد.

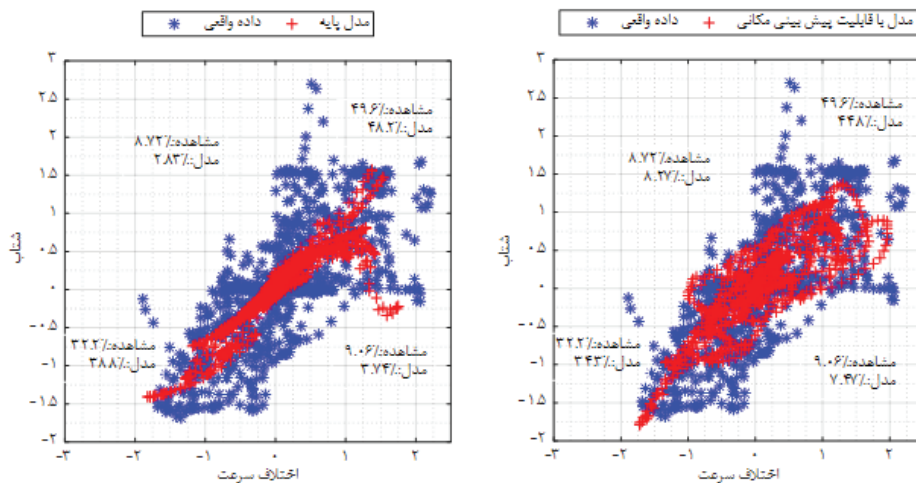
قرارگیری بخشی از مشاهدات در ربع دوم و چهارم می‌تواند به دلایل تأخیر زمانی راننده در پاسخ به تحریکات مشاهده شده باشد. به منظور حذف تأثیر زمان عکس‌العمل راننده، همان‌گونه که قبلاً به آن اشاره شد، اختلاف سرعت و مقادیر شتاب با تأخیر زمانی نسبت به یکدیگر رسم شده‌اند. دلیل دیگر قرارگیری بخشی از مشاهدات در این نواحی محدودیت قدرت ادراکی راننده است. به عبارت دیگر در محدوده اختلاف سرعت‌های کوچک با توجه به محدودیت‌های ادراکی، راننده به درستی قادر به تشخیص این اختلاف سرعت‌ها نبوده و به کارگیری شتاب در این وضعیت تا حدود زیادی تصادفی است. لذا این نقاط به طول معمول در اختلاف سرعت‌ها و شتاب‌های کم و در نزدیکی مبدأ مختصات قرار می‌گیرند. دلیل دیگر قرارگیری مشاهدات در این نواحی، قابلیت پیش‌بینی مکانی راننده است. به عنوان مثال ممکن است سرفاصله خالص بین خودروی پیرو و پیشرو در حال کاهش باشد ولی از آنجاکه سرفاصله خالص بین اولین و دومین خودروی پیرو در حال افزایش است لذا راننده استفاده از شتاب کاهشی را به تعویق انداخته و یا با توجه به پیش‌بینی افزایش سرعت خودروی اولین خودروی پیرو، شتاب افزایشی بکار می‌برد. به تعویق انداختن به کارگیری شتاب کاهشی و یا افزایشی همان‌گونه که در داده‌های واقعی نیز به وضوح مشخص است، منجر به قرارگیری مشاهدات به موازات و نزدیکی محور افقی (اختلاف سرعت) می‌شود. همچنین پیش‌بینی افزایش و یا کاهش سرفاصله برخلاف تغییرات فعلی سرفاصله منجر به قرارگیری مشاهدات در نواحی دوم و چهارم مختصات می‌شود. همان‌گونه که در شکل ۶ مشاهده می‌شود مدل شبکه عصبی با قابلیت پیش‌بینی مکانی نسبت به مدل پایه نقاط بیشتری را در نواحی دوم و چهارم دستگاه مختصات برآورد می‌کند.




شکل ۳: پروفیل شتاب مشاهده شده و تخمین زده شده توسط مدل‌های تعقیب خودرو

لازم به ذکر است، اگرچه مدل شبکه عصبی با در نظرگیری قابلیت پیش‌بینی مکانی در بخشی از داده‌های منجر به بهبود عملکرد مدل تعقیب خودرو می‌شود. با این وجود بررسی مدل‌های ساخته شده نشان می‌دهد در برخی از موارد عملکرد مدل شبکه عصبی با قابلیت پیش‌بینی مکانی مشابه با مدل پایه دارد. شکل ۵ توزیع شتاب‌های برآورد شده توسط مدل شبکه عصبی با قابلیت پیش‌بینی مکانی و مدل پایه را نشان می‌دهد. همچنان که نشان داده شده است، توزیع شتاب‌های برآورد شده در هر دو مدل کاملاً به هم شبیه است. اگرچه یکی از دلایل عملکرد نسبتاً مشابه مدل پایه و مدل با قابلیت پیش‌بینی مکانی

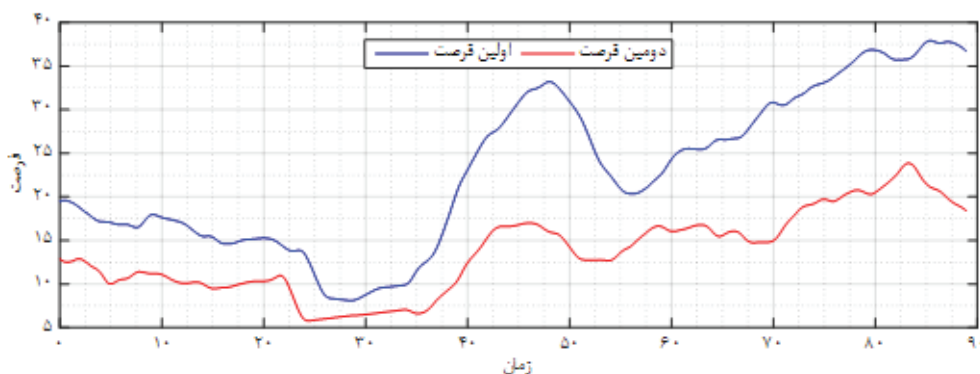
راننده همچنان که ژنگ و همکارانش [۲۰] به آن اشاره نمودند می‌تواند نبودن نمونه‌های مناسب (معرف) در مجموعه داده‌های آموزش باشد، بررسی عمیق‌تر داده‌های استفاده شده جهت ساخت مدل‌ها مشخص نمود که اولین و دومین فرصت خالص الگوی مشابهی با یکدیگر دارند (به عنوان نمونه شکل ۶). در صورتی که ضریب همبستگی خطی و یا همبستگی تقاطعی را به عنوان معیارهای شباهت سری زمانی فرصت‌ها در نظر گرفته شود، مقادیر حاصل به ترتیب ۰,۹۵ و ۰,۹۹ است. مقادیر بالای به دست آمده نشان می‌دهد که بخش عمده‌ای از کارکرد دومین فرصت در مدل با قابلیت پیش‌بینی مکانی به وسیله اولین فرصت قابل بیان است. به عبارت دیگر در نظریه قابلیت پیش‌بینی مکانی راننده با استفاده از داده‌های فرصت خالص دوم اگرچه باعث استخراج اطلاعات بیشتری از داده‌های می‌شود اما بخش عمده‌ای از این اطلاعات با استفاده از اولین فرصت نیز قابل استخراج است. جدول ۲ نتایج به‌کارگیری مدل‌های ارائه‌شده برای داده‌های بزرگراه I۸۰ را به منظور بررسی انتقال‌پذیری مدل‌ها نشان می‌دهد. عملکرد مدل‌ها در حدود ۱۵ تا ۲۰ درصد بدتر است. با این وجود عملکرد مدل‌ها شبیه به کارگیری مدل‌ها برای داده‌های US۱۰۱ است. در بخشی از داده‌های استفاده شده مدل با در نظرگیری قابلیت پیش‌بینی مکانی منجر به بهبود معیارهای عملکردی شده و در بخش دیگری از داده‌ها میزان بهبود معیارهای کارایی اندکی بوده و دو مدل عملکرد تقریباً مشابهی دارند. نکته دیگری که لازم است به آن اشاره شود این است که به‌کارگیری مدل پایه برای داده‌های بزرگراه I۸۰ برای تعداد معدودی از خودروها منجر به نتایج نادرستی نظیر وقوع تصادف می‌شود.



شکل ۴: شتاب تخمین زده شده خودروی موضوع به صورت تابعی از اختلاف سرعت خودروی موضوع و اولین خودروی پیشرو (الف) مدل پایه (ب) مدل با در نظرگیری قابلیت پیش‌بینی مکانی



شکل ۵: توزیع شتاب (الف) مدل با در نظرگیری یک خودروی پیشرو (ب) مدل با در نظرگیری دو خودروی پیشرو



شکل ۶: سری زمانی اولین و دومین فرصت خالص

جدول ۲: نتایج به‌کارگیری مدل شبکه عصبی با/بدون قابلیت پیش‌بینی مکانی برای داده‌های بزرگراه 180

مدل	معیار کارایی (MOP)	مجدور میانگین مربع خطا (RMSE)		
		میانگین	حداقل	حداکثر
مدل پایه	شتاب	۰,۹۲	۰,۵۷	۳,۶
	سرعت	۰,۸۲	۰,۴۹	۲,۸۶
	فرصت	۳,۱۲	۱,۲۶	۷,۸۲
مدل با قابلیت پیش‌بینی مکانی	شتاب	۰,۸۹	۰,۵۸	۲,۵۹
	سرعت	۰,۸۱	۰,۴۹	۲,۸۲
	فرصت	۳,۱۹	۱,۳۴	۸,۲۷

ورودی به منظور در نظرگیری قابلیت پیش‌بینی مکانی راننده است. به منظور کالیبراسیون مدل‌ها و جلوگیری از قرار گرفتن در بهینه محلی، ابتدا وزن‌ها با استفاده از الگوریتم ژنتیک محاسبه شده و سپس از الگوریتم پس انتشار جهت تنظیم نهایی وزن‌های سیناپسی استفاده شده است. نتایج مدل‌سازی نشان می‌دهد در نظرگیری قابلیت پیش‌بینی مکانی راننده در بخشی از داده‌ها به‌طور قابل‌ملاحظه‌ای منجر به بهبود معیارهای کارایی شده و در بخش دیگری از داده‌ها میزان بهبود معیارهای کارایی اندک بوده و دو مدل عملکرد تقریباً مشابهی دارند. یکی از دلایل نزدیکی عملکرد عمومی دو مدل به یکدیگر می‌تواند همبستگی بالای اولین و دومین فرصت خالص به عنوان ورودی مدل جهت در نظرگیری قابلیت پیش‌بینی باشد. تحلیل‌های انجام‌شده نشان می‌دهد که متوسط ضریب همبستگی خطی و همبستگی تقاطعی به عنوان معیارهایی جهت شباهت بین اولین و دومین فرصت خالص به ترتیب برابر ۰,۹۵ و ۰,۹۹ است. این همبستگی بالا سبب می‌شود که بخش عمده‌ای از اطلاعات قابل استخراج از دومین فرصت خالص توسط شبکه عصبی از طریق اولین فرصت خالص نیز قابل استخراج باشد. در نهایت لازم است به این نکته اشاره شود در مدل‌های فعلی

۵- نتیجه‌گیری

یکی از متغیرهای تأثیرگذار در فرآیند تعقیب خودروی رانندگان، توانایی پیش‌بینی مکانی یا پیش‌بینی چندگانه راننده است. در جریان رانندگی، راننده ممکن است علاوه بر خودروی جلوی خویش چندین خودروی پایین‌دست و حتی خودروهای پیرامونی خویش را در نظر گرفته و بر اساس آن، شرایط ترافیکی آینده را پیش‌بینی و با یک تأخیر زمانی به آن پاسخ می‌دهند. توانایی پیش‌بینی مکانی راننده و تأثیر آن بر روی رفتار تعقیب خودروی آن‌ها در مدل‌های مبتنی بر معادله نظیر مدل‌های جنرال موتور، سرعت بهینه، گپی‌س و راننده هوشمند مورد بررسی قرار گرفته است. با این وجود در بیشتر مدل‌های مبتنی بر هوش مصنوعی، اندرکنش‌های بین چندین وسیله نقلیه در یک خط عبوری نادیده گرفته شده است. در این مقاله دو نوع مدل تعقیب خودروی مبتنی بر شبکه عصبی مورد تجزیه و تحلیل قرار گرفته است. مدل پایه یک شبکه عصبی پرسپترون سه لایه با یک لایه ورودی، یک لایه پنهان و یک لایه خروجی به همراه پنج نورون در لایه پنهان بدون در نظرگیری قابلیت پیش‌بینی مکانی راننده و مدل دوم مدل شبکه عصبی مشابه با مدل پایه با در نظرگیری دومین فرصت خالص به عنوان

1. Springer :2011 .Barceló, J., Fundamentals of Traffic Simulation
2. Zheng, Z., Recent developments and research needs in modeling lane changing. ,Transportation Research Part B: Methodological .32-16 .p :60 .2014
3. Saifuzzaman, M. and Z. Zheng, Incorporating human-factors in car-following models: A review of recent developments and research needs. Transportation Research Part C: Emerging Technologies .403-379 .p :48 .2014
4. Pipes, L.A., An Operational Analysis of Traffic Dynamics. Journal of Applied Physics .274 .p :(3)24 .1953
5. Chandler, R.E., R. Herman, and E.W. Montroll, Traffic Dynamics: Studies in Car Following. Operations Research .184-165 .p :(2)6 .1958
6. Treiber, M., A. Hennecke, and D. Helbing, Congested traffic states in empirical observations and microscopic simulations. Phys Rev E Stat Phys Plasmas Fluids Relat Interdiscip Topics .24-1805 .Pt A): p 2)62 .2000
7. Kometani, E. and T. Sasaki, A Safety Index for Traffic with Linear Spacing. Operations Research .720-704 .p :(6)7 .1959
8. Gipps, P.G., A behavioural car-following model for computer simulation. Transportation Research Part B: Methodological .111-105 .p :(2)15 .1981
9. Helbing, D. and P. Molnár, Social force model for pedestrian dynamics. Physical Review E .4286-4282 .p :(5)51 .1995
10. Nagel, K. and M. Schreckenberg, A cellular automaton model for freeway traffic. Journal de Physique I .2229-2221 .p :(12)2 .1992
11. Wiedemann, R., Simulation des Straßenverkehrsflusses, in Proceedings of the Karlsruhe, :1974 .Schriftenreihe des Instituts für Verkehrswesen der Universität Karlsruhe .Germany
12. Toledo, T., H.N. Koutsopoulos, and M. Ben-Akiva, Integrated driving behavior modeling. ,Transportation Research Part C: Emerging Technologies .112-96 .p :(2)15 .2007
13. Anderson, J.A., Neurocomputing .MIT press :1993
14. Ma, X., et al., Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. Transportation Research Part C: Emerging Technologies .197-187 .p :54 .2015
15. Zhu, J.Z., 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: Emerging Technologies .154-139 .p :47 .2014
16. van Lint, J.W.C., S.P. Hoogendoorn, and H.J. van Zuylen, Accurate freeway travel time prediction with state-space neural networks under missing data. Transportation Research Part C: Emerging Technologies .369-347 .p :(6-5)13 .2005
17. Lu, J., et al., A hybrid model of partial least squares and neural network for traffic incident detection. Expert Systems with Applications .4784-4775 .p :(5)39 .2012
18. Ozan, C., et al., A modified reinforcement learning algorithm for solving coordinated signalized networks. Transportation Research Part C: Emerging Technologies .55-40 .p :54 .2015
19. Zheng, J., K. Suzuki, and M. Fujita, Predicting driver's lane-changing decisions using a neural network model. Simulation Modelling Practice and Theory .83-73 .p :42 .2014
20. Zheng, J., K. Suzuki, and M. Fujita, Car-following behavior with instantaneous driver-vehicle reaction delay: A neural-network-based methodology. Transportation research part C: emerging technologies .351-339 .p :36 .2013

- Khodayari, A., et al., A modified car-following model based on a neural network model of the human driver effects. *Systems, Man and Cybernetics, Part A: Systems and Humans*, IEEE Transactions on, 2012, (6)42. p :1449-1440.
- Chong, L., et al., A rule-based neural network approach to model driver naturalistic behavior in traffic. *Transportation Research Part C: Emerging Technologies* .22 .2013 ,p :32 .-207 .223
- Koutsopoulos, H.N. and H. Farah, Latent class model for car following behavior. *Transportation research part B: methodological* .23 .2012 ,p :(5)46 .578-563
- Wagner, C., Asymptotic solutions for a multi-anticipative car-following model. *Physica A: Statistical Mechanics and its Applications* .24 .1998 ,p :(1)260 .224-218
- Bexelius, S., An extended model for car-following. *Transportation Research* .25 .1968 ,p :(1)2 .21-13
- Lenz, H., C. Wagner, and R. Sollacher, Multi-anticipative car-following model. *The European Physical Journal B-Condensed Matter and Complex Systems* .26 .1999 ,p :(2)7 .-331 .335
- Treiber, M., A. Kesting, and D. Helbing, Influence of Reaction Times and Anticipation on Stability of Vehicular Traffic Flow. *Transportation Research Record: Journal of the Transportation Research Board* .27 .2007 ,p :1999 .29-23
- Knospe, W., et al., Human behavior as origin of traffic phases. *Physical Review E* .28 .2001 ,p :(1)65 .015101
- FHWA, NGSIM—Next Generation SIMulation .29 .2004
- Rafati Fard, M., A. Shariat Mohaymany, and M. Shahri, A new methodology for vehicle trajectory reconstruction based on wavelet analysis. *Transportation Research Part C: Emerging Technologies* .30 .2017 ,p :74 .167-150
- Kohonen, T., An introduction to neural computing. *Neural Networks* .31 .1988 ,p :(1)1 .16-3
- Punzo, V. and F. Simonelli, Analysis and Comparison of Microscopic Traffic Flow Models with Real Traffic Microscopic Data. *Transportation Research Record: Journal of the Transportation Research Board* .32 .2005 ,p :1934 .63-53

Neural network-based car following model
with considering the drivers' spatial anticipation capability

Mehdi Rafati Fard , Afshin Shariat Mohaymany

PhD candidate, Traffic Research Laboratory, Iran University of Science and-1
Technology, Tehran

PhD, Civil engineering department, Iran University of Science and Technology,-2
Tehran

Abstract

Car following models are considered as one of the most important driving behavior models, which have widely been applied in various fields of transportation engineering such as microscopic traffic simulation and safety. Large number of factors affect drivers' car following behavior. In practice, due to the lack of appropriate data and latent nature of some factors, only few numbers of them have been considered in model development. Drivers' ability to spatial anticipation of traffic flow is one of the important factors of car following behavior, which has been neglected in construction of car following models, particularly in neural network-based car following models. In order to consider this capability, a car following model based on neural network has been developed. Speed of the subject vehicle, speed of first and second leader and speed of follower as well as first and second lead gap and first lag gap were considered as input variables while the model's output is acceleration of the subject vehicle. Calibration results indicate the better performance of the proposed model in comparison to the base model (without spatial anticipation). Additionally, in some situations both models have similar performance. Further investigations show that this is due to the large correlation between first and second lead gap

Keywords: Car following, spatial anticipation, neural network, Response time