

پیش‌بینی رفتار رانندگان وسایل نقلیه سواری در هنگام مواجهه با راه‌بندان با استفاده از مدل شبکه عصبی

مقاله علمی - پژوهشی

سید حامد سید متین، دانشجوی دکتری، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران
علی عبدی کردانی*، استاد، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران

*پست الکترونیکی نویسنده مسئول: aliabdi@eng.ikiu.ac.ir

دریافت: ۱۴۰۲/۱۰/۲۴ - پذیرش: ۱۴۰۳/۰۳/۲۷

صفحه ۱۴۸-۱۳۱

چکیده

عدم توازن عرضه و تقاضا در ساعات شلوغی تردد باعث ازدحام ترافیک در معابر می‌شود که تأثیر بسزایی بر ایمنی، زمان سفر و مصرف سوخت دارد. بررسی رفتار رانندگان قبل از ازدحام و راه‌بندان می‌تواند ضمن ارائه راهکارهای مناسب به کاهش اثرات آن کمک کند. اگرچه پیش‌بینی رفتار رانندگان با استفاده از مدل‌های مختلف توسط محققین ارائه شده است، اما به پیش‌بینی رفتار رانندگان قبل از راه‌بندان توجه چندانی نشده است. هدف اصلی این مطالعه تعیین مدلی برای پیش‌بینی رفتار رانندگان در مواجهه با راه‌بندان با استفاده از مدل شبکه عصبی است. در این تحقیق رفتار ۱۲۴ راننده هنگام مواجهه شدن با راه‌بندان از طریق فیلم‌برداری ویدئویی بدون جلب‌توجه رانندگان ضبط و پردازش شد و مشخصات فردی و رفتاری رانندگان نیز با تجزیه و تحلیل پرسش‌نامه‌های تکمیل شده توسط رانندگان استخراج شد. پس از تحلیل توصیفی، داده‌های جمع‌آوری شده با استفاده از تحلیل عاملی تأییدی روابط بین متغیرهای مشاهده شده و نهفته (نگرشی یا رفتاری) در نرم‌افزار Amos v.24 مورد ارزیابی قرار گرفتند و دو متغیر پنهان قانون‌گیری و رانندگی پرخاشگرانه تعیین شدند. باتوجه به خروجی مدل شبکه عصبی که در نرم‌افزار SPSS ایجاد گردید، مهم‌ترین عامل در پیش‌بینی رفتار تغییر خطوط رانندگان در هنگام مواجهه با ترافیک، متغیر نگرشی قانون‌گیری و سپس فاصله عرضی تا موانع یا خودروهای واقع در سمت چپ و راست ماشین موردنظر تعیین شدند. دقت مدل برای داده‌های آزمون برابر با ۹۳/۹ درصد است.

واژه‌های کلیدی: رفتار راننده، ازدحام، راه‌بندان، شبکه عصبی مصنوعی

۱- مقدمه

تصمیم رانندگان هنگام قرارگرفتن در انتهای صف وسایل نقلیه، مانند تقاطعات کنترل شده با چراغ‌راهنمایی و عوارضی اشاره دارد. تراکم ترافیک می‌تواند منجر به افزایش استرس و پرخاشگری راننده شود و این امر اهمیت مدیریت ترافیک مؤثر استراتژی‌های مقابله با استرس را برای رانندگان برجسته می‌کند. (Hennessy & Wiesenthal, 1999). تراکم ترافیک می‌تواند بر رفتار راننده و پیامدهای بالقوه ایمنی تأثیرگذار باشد

ازدحام ترافیک یک موضوع رایج در مناطق شهری است و می‌تواند باعث تأخیر و واردآمدن استرس قابل‌توجهی به رانندگان شود و به دلیل تأثیرات منفی آن بر رفتار رانندگان و ایمنی جاده، به نگرانی فزاینده‌ای در بین محققان و سیاست‌گذاران تبدیل شده و یکی از مهم‌ترین عواملی است که در رانندگی پرخاشگرانه مدنظر قرار گرفته است. رفتار رانندگان در مواجهه با راه‌بندان موضوع بسیار با اهمیتی است که به

ترافیک، پیاده‌سازی سیستم‌های حمل‌ونقل هوشمند، طراحی سیستم‌های همیار راننده پیشرفته و سیستم‌های کمک ناوبری و ارائه اطلاعات ترافیکی در زمان واقعی به رانندگان باشد که نهایتاً منتج به افزایش ایمنی می‌گردند. در این مطالعه رفتار ۱۲۴ راننده قبل و هنگام مواجه شدن با صف راه‌بندان از طریق فیلمبرداری ثبت گردید و زمانیکه رانندگان پشت صف راه‌بندان متوقف شدند فرم پرسشنامه دموگرافیک و رفتار رانندگی به آنها تحویل داده و خواسته شد تا در زمان مناسب تکمیل و به پایگاه داده مشخص شده ارسال نمایند. فرآیند ثبت تصاویر به گونه ای عملیاتی گردید که رانندگان متوجه ضبط ویدئویی نشوند تا بر روی تصمیم و عملکرد آنها تأثیرگذار نباشد. پس از گردآوری داده‌ها، مراحل انجام پردازش، تحلیل و مدلسازی داده‌ها صورت پذیرفت که شامل ۳ گام اساسی است. در گام اول به پردازش داده‌ها و تحلیل توصیفی متغیرها پرداخته شده است. سپس در گام دوم با کمک مدل اندازه‌گیری ضمن تعیین روابط متغیرهای پنهان و شاخص‌ها، روابط متغیرها مورد ارزیابی قرار گرفته است. در گام سوم رفتار رانندگان در هنگام مواجهه با راه‌بندان مورد ارزیابی قرار گرفته و با استفاده از شبکه عصبی مدلسازی گردید. پژوهش حاضر تلاش می‌کند تا یک مدل پیش‌بینی رفتار و تصمیم رانندگان را در هنگام مواجه شدن با صف راه‌بندان ارائه نماید. نتیجه چنین رویکردی می‌تواند به درک بهتر الگوهای رفتاری رانندگان در شرایط مختلف تشکیل ازدحام، تراکم و صف راه‌بندان از جمله در صف عوارضی‌ها منجر شود؛ بنابراین، هدف پژوهش حاضر براین اساس است که رویکرد مطالعه منجر به شناسایی مدل رفتار رانندگان می‌شود.

فرضیه‌های پژوهش حاضر به شرح زیر است:

۱. ویژگی‌های اجتماعی-اقتصادی رانندگان بر رفتار آنها در هنگام مواجه شدن با راه‌بندان اثرگذار هستند.
۲. ویژگی‌های حرکتی و موقعیت وسیله نقلیه بر رفتار رانندگان در هنگام مواجه شدن با راه‌بندان اثرگذار هستند.

۲- پیشینه تحقیق

استفاده از شبکه‌های عصبی مصنوعی برای پیش‌بینی رفتار رانندگان در مواجهه با ترافیک، یک موضوع پژوهشی در حال گسترش در زمینه مهندسی حمل‌ونقل و سیستم‌های حمل‌ونقل هوشمند است. با تجزیه و تحلیل انواع داده‌های ورودی از جمله

و ازدحام ترافیک بیشتر به رفتار رانندگی تهاجمی منجر می‌شود که با افزایش خطرات تصادف همراه است. تراکم ترافیک بر رفتار راننده در ادامه مسیر پس از ازدحام تأثیر منفی می‌گذارد؛ لذا این امر اهمیت درک و پرداختن به اثرات تراکم ترافیک بر رفتار رانندگان برای بهبود ایمنی جاده را برجسته می‌کند. (Li et al., 2020)

عوامل متعددی از قبیل شخصیت راننده، سطح تجربه رانندگی، شرایط ترافیکی و فیزیکی جاده و رفتار سایر رانندگان، می‌تواند بر رفتار راننده در پشت صف راه‌بندان تأثیر گذار باشند. به‌عنوان مثال، راننده ای که عموماً بی‌حوصله است ممکن است رفتار تهاجمی داشته باشد بیشتر تلاش کند جلوی وسایل نقلیه دیگر برود، در حالی که راننده‌ای که تجربه بیشتری دارد بهتر می‌تواند جریان ترافیک را پیش‌بینی و رفتار خود را بر اساس آن تنظیم کند. برخی از رانندگان ممکن است بی‌حوصله شوند و سعی کنند خط خود را تغییر دهند یا راه وسایل نقلیه دیگر را قطع کنند، در حالی که برخی دیگر ممکن است صبورانه در مسیر حرکتی خود منتظر بمانند. این رفتارها می‌تواند بر جریان ترافیک و ایمنی تأثیر بگذارد. قبل از مواجهه با راه‌بندان، رانندگان ممکن است رفتارهای خاصی از خود نشان دهند و مانورهای خاصی را برای جلوگیری از آن انجام دهند. به‌عنوان مثال، برخی از رانندگان ممکن است به طور مکرر خط را تغییر دهند تا بتوانند سریع‌ترین خط را پیدا کنند. برخی دیگر ممکن است سرعت خود را تنظیم کنند یا مسیرهای دیگری را برای جلوگیری از مناطق شلوغ انتخاب کنند. ویژگی‌های فردی مانند ویژگی‌های شخصیتی، نگرش و درک خطر، عوامل کلیدی مؤثر بر رفتارهای رانندگی هستند که در مطالعات انجام شده توسط کوابنان در سال ۲۰۰۲ (Kouabenan, 2002)، ما و همکاران در سال ۲۰۱۰ (Ma, Yan, 2010)، هری و بالدوین در سال ۲۰۰۰ (Huang, & Abdel-Aty, 2010)، پونالوری در سال ۲۰۱۲ (Perry, Baldwin, & skills, 2000)، سان و الفتیادو در سال ۲۰۱۰ (Ponnaluri, 2012)، اولبرگ و راندمو در سال ۲۰۰۲ (Elefteriadou, 2010)، اولبرگ و راندمو در سال ۲۰۰۲ (Ulleberg & Rundmo, 2002) به آنها اشاره کرده اند.

با درک رفتار رانندگان قبل از ازدحام و مانورهای مربوط به آن، برنامه‌ریزان و مهندسان حمل‌ونقل می‌توانند راهبردهایی را برای کاهش ازدحام و بهبود جریان ترافیک ایجاد کنند که می‌تواند شامل اقداماتی مانند کالیبراسیون نرم‌افزارهای شبیه‌سازی ترافیک، بهینه‌سازی زمان‌بندی چراغ‌راهنمایی

نتایج آزمایش نشان می‌دهد که شبکه عصبی پس انتشار پیش‌بینی دقیقی از رفتار تغییر خط راننده در جریان ترافیک شهری دارد. این مطالعه بر اهمیت پیش‌بینی دقیق رفتار تغییر خط راننده برای بهبود ایمنی رانندگی و کاهش خطر تصادفات تاکید می‌کند. (Ding, Wang, Wang, & Baumann, 2013)

مقاله "پیش‌بینی چند پارامتری رفتار تغییر مسیر رانندگان با مدل شبکه عصبی" در سال ۲۰۱۵ توسط پنگ و همکاران منتشر گردید. این مقاله یک مدل شبکه عصبی را برای پیش‌بینی دقیق رفتار تغییر مسیر رانندگان بر اساس رفتارهای جستجوی بصری، رفتارهای عملکرد خودرو، حالت‌های حرکت خودرو و شرایط رانندگی پیشنهاد می‌کند. مدل شبکه عصبی پس انتشار ارائه شده می‌تواند رفتار تغییر خط رانندگان را برای حداقل ۱/۵ ثانیه پیش‌بینی کند، که برتر از استفاده از چراغ راهنما (راه‌نما زدن) در پیش‌بینی رفتار تغییر مسیر است. (Peng, Guo, Fu, Yuan, & Wang, 2015)

مقاله "مدل‌سازی پیش‌بینی مسیر تغییر مسیر با استفاده از شبکه‌های عصبی" نوشته حمیدرضا حامدی و روزبه شاد، استفاده از شبکه عصبی پس انتشار پیش‌خور دو لایه برای ارزیابی پیچیدگی تغییر خط ذاتی را مورد بحث قرار می‌دهد. مدل با استفاده از داده‌های مسیر در مقیاس بزرگ برآورد و اعتبارسنجی شد. داده‌های تجربی تغییر خط از پروژه NGSIM برای آموزش و آزمایش مدل تغییر خط مبتنی بر شبکه عصبی به‌دست آمد. یافته‌ها نشان داد که مدل معرفی شده می‌تواند پیش‌بینی دقیق تغییر خط خودروها را در خط سیر کوچک با دقت رضایت‌بخش انجام دهد. مدل شبکه عصبی تقریباً همان پیش‌بینی‌های مسیرهای تغییر مسیر مشاهده‌ای و همچنین دنبال کردن مسیرهای وسیله نقلیه در خطوط اصلی و هدف را ارائه داد. علاوه بر این، مدل تغییر خط مبتنی بر شبکه عصبی معرفی شده با مدل تغییر خط بر اساس رگرسیون برداری مقایسه شد. مشخص شد که پیش‌بینی‌های مسیر هر دو مدل به اندازه کافی با داده‌های رصد شده سازگار است و می‌تواند حرکت‌های جانبی و طولی خودرو را ثبت کند. یافته‌های تحلیل نشان داد که عملکرد شبکه عصبی پیشنهادی و مدل‌های رگرسیون برداری بالاتر از مدل با ورودی‌های جدید است. این مطالعه نشان داد که مدل معرفی شده می‌تواند پیش‌بینی دقیق تغییر مسیر خودروها را تحت خطاهای مسیر کوچک و دقت رضایت‌بخش انجام دهد. این تحقیق پتانسیل شبکه‌های عصبی را در پیش‌بینی تصمیمات تغییر خط راننده که می‌تواند برای بهبود ایمنی

جریان ترافیک، مشخصات فیزیکی جاده و رفتار رانندگان، شبکه‌های عصبی را می‌توان آموزش داد تا واکنش احتمالی رانندگان به وضعیت‌های مختلف ترافیکی را پیش‌بینی کنند. یکی از کاربردهای احتمالی این مدل، بهبود مدیریت ترافیک و کاهش شلوغی با فراهم کردن اطلاعات و راهنمایی به رانندگان در زمان واقعی است. پیش‌بینی تصمیمات تغییر خط راننده با استفاده از مدل شبکه عصبی موضوعی است که در زمینه تحقیقات فعال در زمینه رانندگی خودران و سیستم‌های حمل‌ونقل هوشمند انجام می‌شود. در این بخش مروری بر ادبیات پیشین از مطالعات مختلف آورده شده است.

چنگ و همکارانش در مقاله‌ای با عنوان "پیش‌بینی تصمیم‌های تغییر خط راننده با استفاده از مدل شبکه عصبی" که سال ۲۰۱۴ منتشر گردید با استفاده از مدل شبکه عصبی و مدل لوجیت، عوامل مؤثر بر تصمیم‌گیری رانندگان در ارتباط با تغییر خط را بررسی و در نهایت، مدل پیش‌بینی تصمیم‌گیری رانندگان در ارتباط با تغییر خط را ارائه کردند. این مطالعه از داده‌های مسیر در مقیاس بزرگ برای تخمین و اعتبارسنجی مدل استفاده می‌کند. مدل پیشنهادی توانست ۹۴/۵۸ درصد از نمونه‌های تغییر خط چپ و ۷۳/۳۳ درصد از نمونه‌های تغییر خط راست را در فرآیند تخمین مدل به درستی پیش‌بینی کند. در مقابل، مقادیری که توسط مدل لوجیت چندجمله‌ای پیش‌بینی شده بود - که اغلب به‌عنوان چارچوبی برای تغییر خط در مطالعات قبلی پذیرفته شده بود - به ترتیب تنها ۱۳/۲۵ و ۳/۳۳ درصد بود. در حالی که دقت هر دو مدل به طور محسوسی در فرآیند اعتبارسنجی مدل کاهش می‌یابد، نتایج پیش‌بینی تصمیمات تغییر خط در مدل شبکه عصبی از مدل لوجیت چندجمله‌ای بهتر عمل می‌کند. (Zheng, Suzuki, & Fujita, 2014). مطالعه‌ای با عنوان "مدل شبکه عصبی برای پیش‌بینی مسیر تغییر مسیر راننده در جریان ترافیک شهری" توسط چنشی دینگ، ووهونگ وانگ، شیائو وانگ و مارتین باومن، اثربخشی شبکه عصبی پس انتشار را برای پیش‌بینی تغییر مسیر بر اساس داده‌های خودروی عبوری مورد بحث قرار می‌دهد. هدف این مقاله نشان دادن سودمندی شبکه عصبی پس انتشار در پیش‌بینی فرآیند تغییر خط است. نویسندگان همچنین نتایج را بین مدل شبکه عصبی پس انتشار و مدل شبکه عصبی برگشتی المان مقایسه کردند. داده‌های شبیه‌ساز رانندگی پردازش شدند و سپس برای اعتبارسنجی مدل استفاده شدند.

رانندگی و کاهش خطر تصادفات حیاتی باشد، برجسته می‌کند. (Hamedi & Shad, 2022)

مقاله «پیش‌بینی رفتار تغییر مسیر هوشمند و استراتژی تصمیم‌گیری برای یک خودروی خودران» توسط ویدا ونگ و همکاران یک روش پیش‌بینی مبتنی بر یک سیستم استنتاج فازی و یک شبکه عصبی حافظه طولانی کوتاه مدت پیشنهاد می‌کند. نویسندگان فرآیندهای شناختی رانندگان را با استفاده از سیستم استنتاج فازی شبیه‌سازی کردند. قوانین فازی بر اساس شناخت رانندگان فرمول نویسی و سپس اطلاعات محیط رانندگی به امکان‌سنجی تغییر خط تبدیل شده است. امکان سنجی تغییر خط به دست آمده و مسیر وسیله نقلیه مربوطه به‌عنوان متغیرهای ورودی شبکه عصبی LSTM برای پیش‌بینی رفتار تغییر خط طراحی شده است. بر اساس نتایج پیش‌بینی، یک استراتژی تصمیم‌گیری هوشمند برای برنامه‌ریزی مسیر وسیله نقلیه خودران برای اطمینان از ایمنی رانندگی طراحی شده است. روش پیش‌بینی که از خط سیر واقعی وسایل نقلیه درست شده است توسط مجموعه داده‌های NGSIM آموزش و آزمایش گردید. نرخ دقیق روش ۹۲/۴٪ است. نتایج نشان می‌دهد که این استراتژی می‌تواند به طور قابل توجهی عملکرد رانندگی در برخورد با رفتارهای تغییر مسیر را بهبود بخشد. این تحقیق پتانسیل شبکه‌های عصبی را در پیش‌بینی تصمیمات تغییر خط راننده که می‌تواند برای بهبود ایمنی رانندگی و کاهش خطر تصادفات حیاتی باشد، برجسته می‌کند. (Wang et al., 2021)

مقاله «یک مدل شخصی‌شده برای پیش‌بینی رفتار تغییر مسیر راننده با استفاده از شبکه عصبی عمیق» توسط جون گائو و همکاران یک مدل شبکه عصبی عمیق برای پیش‌بینی رفتار تغییر مسیر پیشنهاد می‌کند. نویسندگان از سه نوع سیگنال فیزیولوژیکی راننده برای پیش‌بینی تغییرات خط قبل از وقوع واقعی رویداد استفاده می‌کنند. این سیگنال‌ها شامل الکتروکاردیوگرام، پاسخ پوستی گالوانیکی و نرخ تنفس هستند و در مطالعات قبلی تعیین شده‌اند تا به بهترین نحو پاسخ راننده به محیط رانندگی را منعکس کنند. یک شبکه عصبی کانولوشنال گروهی جدید، مدل MTS-GCNN برای طبقه‌بندی الگوی سری زمانی چند متغیره پیشنهاد شده است. این مدل از ساختار کوواریانس در چندین سری زمانی برای تقسیم حجم ورودی به گروه‌ها استفاده می‌کند، سپس ساختار MTS-GCNN را با خوشه‌بندی توالی‌های ورودی با خوشه‌بندی طیفی یاد می‌گیرد. نتایج تجربی نشان داد که در مقایسه با سایر مدل‌های

پیشرفته، MTS-GCNN از نظر دقت پیش‌بینی به طور قابل توجهی بهتر عمل می‌کند. این مطالعه بر اهمیت پیش‌بینی دقیق رفتار تغییر خط راننده برای بهبود ایمنی رانندگی و کاهش خطر تصادفات تاکید می‌کند (Gao, Zhu, & Murphey, 2019).

مقاله «پیش‌بینی تصمیمات تغییر خط راننده با استفاده از یادگیری عمیق» توسط چنگ وی و همکاران در مورد استفاده از یک مدل پیش‌بینی شبکه عصبی ترکیبی برای پیش‌بینی رفتار تغییر مسیر به طور دقیق و بهبود زمان آینده‌نگر پیش‌بینی بحث می‌کند. این مدل بر اساس یک شبکه عصبی بازگشتی و یک شبکه عصبی کاملاً متصل است. این مدل از طریق آزمایش در سناریوهای ترافیک واقعی اعتبارسنجی شد و با پنج مدل پیش‌بینی دیگر مقایسه شد. نتایج نشان داد که مدل پیش‌بینی پیشنهادی می‌تواند رفتار تغییر مسیر را به طور مؤثرتر و زودتر از مدل‌های دیگر پیش‌بینی کند. مدل پیشنهادی به‌دقت پیش‌بینی ۹۳/۵ درصد دست یافت و زمان آینده‌نگر پیش‌بینی را به طور متوسط حدود ۲/۱ ثانیه بهبود بخشید. این مطالعه بر اهمیت پیش‌بینی دقیق رفتار تغییر خط راننده برای بهبود ایمنی رانندگی و کاهش خطر تصادفات تاکید می‌کند. (Wei, Hui, & Khattak, 2021). این مطالعات پتانسیل شبکه‌های عصبی را در پیش‌بینی تصمیم‌های تغییر خط راننده نشان می‌دهد که می‌تواند برای توسعه و پیشرفت سیستم‌های رانندگی و بهبود ایمنی جاده‌ها حیاتی باشد. با این حال، توجه به این نکته حائز اهمیت است که رفتار رانندگی پیچیده است و می‌تواند تحت تأثیر عوامل زیادی قرار گیرد، بنابراین این مدل‌ها ممکن است همیشه دقیق نباشند.

۳- روش تحقیق

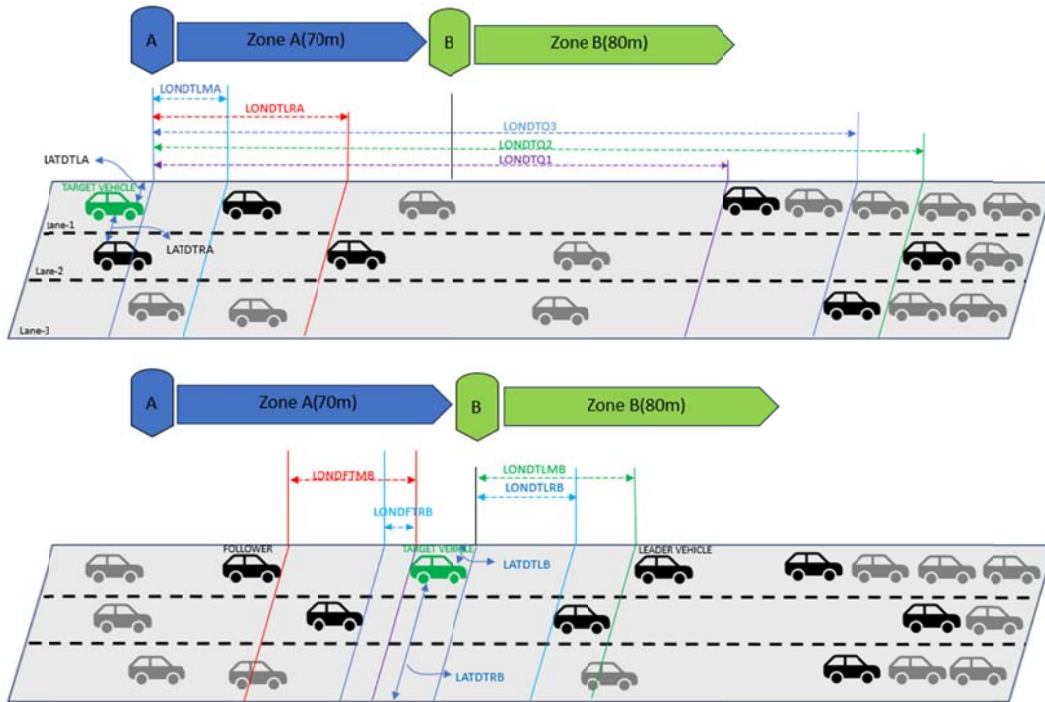
به منظور بررسی واکنش رانندگان در مواجهه با صف راه‌بندان، گردآوری اطلاعات میدانی در معبر با درجه عملکردی بزرگراهی (بزرگراه شهید آشناسان) در شهر تهران صورت پذیرفت. اطلاعات مرتبط با رفتار رانندگان در مواجهه با ازدحام و صف راه‌بندان به کمک ضبط تصاویر ویدئویی و بدون جلب توجه رانندگان برداشت و سپس پردازش گردید. همچنین به منظور اخذ اطلاعات اقتصادی-اجتماعی رانندگان پرسشنامه رفتاری پس از توقف آنها در صف راه‌بندان در اختیار آنها قرار گرفت و از آنها درخواست شد تا در زمان مناسب نسبت به تکمیل و ارسال فرم پرسشنامه به بانک داده مشخص شده اقدام نمایند. متغیرهای موردنیاز برای بررسی رفتار رانندگان در مواجهه با صف راه‌بندان، بر اساس نتایج مرور ادبیات موضوع

در تصویر ۱ موقعیت ضبط ویدئویی در برداشت میدانی نشان داده شده است.
در شکل ۱ شماتیک متغیرهای مربوط به مشخصات حرکتی و موقعیت وسیله نقلیه ارائه شده است.

جمع آوری شد. در این مطالعه، رفتار رانندگان در ۲ گروه دسته‌بندی شده است.
۱-رانندگانی که بدون انحراف از مسیر در خط حرکتی خود ادامه مسیر می‌دهند.
۲-رانندگانی که در مواجهه با صف راه‌بندان با انحراف از مسیر خود تغییر خط می‌دهند.



تصویر ۱. ضبط تصاویر ویدئویی رفتار رانندگان در هنگام مواجهه با راه‌بندان



شکل ۱. شماتیک متغیرهای مربوط به مشخصات حرکتی و موقعیت وسیله نقلیه (موقعیت قرارگیری خودروی هدف نسبت به خودروهای پیشرو، پیرو، انتهای صف و موانع کناری)

۳-۱- تحلیل توصیفی داده‌ها

پس از تهیه بانک اطلاعاتی موردنیاز، متغیرهای مستقل به شکل‌های گوناگون از جمله ترکیبی و مجازی^۱ با استفاده از متغیرهای اولیه ساخته شد. پس از آماده‌سازی پایگاه‌داده، تعداد ۱۲۴ نمونه معتبر جهت تحلیل مورد استفاده قرار گرفته است. از منظر مشخصات اقتصادی اجتماعی، ۲۵/۸ درصد نمونه

همان‌گونه که در شکل ۱ ملاحظه می‌گردد محدوده‌ای به طول ۱۵۰ متر به منظور بررسی رفتار رانندگان مورد بررسی قرار گرفته و پارامترهایی از قبیل فاصله طولی خودروی هدف تا خودروی پیرو و پیشرو و فاصله عرضی خودروی هدف تا مانع یا وسیله نقلیه در سمت چپ یا راست و نیز سرعت خودروهای هدف و پیرو و پیشرو برداشت شده است.

موردنظر را زنان و مابقی (۷۴/۲ درصد) را مردان تشکیل دادند. از نظر سن افراد شرکت‌کننده در این آزمایش، گروه سنی ۳۱-۴۰ سال با فراوانی نسبی ۳۶/۲ درصد بیشترین سهم و گروه سنی ۷۱-۸۰ با حدود ۱ درصد کمترین سهم را به خود اختصاص دادند. در رابطه با تجربه رانندگی نیز مقدار میانگین نشانگر آن است که به طور متوسط افراد دارای تجربه رانندگی بیش از ۱۰-۵ سال هستند. در جدول ۱ متغیرهای وابسته و مستقل معرفی شده‌اند.

جدول ۱. معرفی متغیرهای مستقل و وابسته

تعریف	علامت اختصاری	نوع متغیر	مستقل/وابسته
سرعت خودروی پیرو	VF	مشخصات حرکتی وسایل نقلیه	مستقل
سرعت خودروی هدف	VT		
سرعت خودروی پیشرو	VL		
زمان سفر خودروی هدف بعد از تغییر خط تا رسیدن به پشت صف	TTTLCBQ		
سرعت خودروی هدف بعد از تغییر خط تا رسیدن به پشت صف	VTLCBQ		
معکوس زمان سفر خودروی هدف تا خودروی جلویی	TTTLM		
اگر سرعت خودروی تعقیب‌کننده کمتر از ۲۵ باشد؛ ۱؛ در غیر این صورت = ۰	VF25L		
اگر سرعت خودروی تعقیب‌کننده بین ۲۵ تا ۳۰ باشد؛ ۱؛ در غیر این صورت = ۰	VF2530		
اگر سرعت خودروی تعقیب‌کننده بین ۳۰ تا ۳۵ باشد؛ ۱؛ در غیر این صورت = ۰	VF3035		
اگر سرعت خودروی تعقیب‌کننده بین ۳۵ تا ۴۰ باشد؛ ۱؛ در غیر این صورت = ۰	VF3540		
اگر سرعت خودروی تعقیب‌کننده بیش از ۴۰ باشد؛ ۱؛ در غیر این صورت = ۰	VF40H		
اگر سرعت خودروی جلویی کمتر از ۲۵ باشد؛ ۱؛ در غیر این صورت = ۰	VL25L		
اگر سرعت خودروی جلویی بین ۲۵ تا ۳۰ باشد؛ ۱؛ در غیر این صورت = ۰	VL2530		
اگر سرعت خودروی جلویی بین ۳۰ تا ۳۵ باشد؛ ۱؛ در غیر این صورت = ۰	VL3035		
اگر سرعت خودروی جلویی بین ۳۵ تا ۴۰ باشد؛ ۱؛ در غیر این صورت = ۰	VL3540		
اگر سرعت خودروی جلویی بیش از ۴۰ باشد؛ ۱؛ در غیر این صورت = ۰	VL40H		
فاصله طولی خودرو هدف تا پشت صف خط ۱	LONDTQ1	مشخصات موقعیت وسيله نقلیه در مسیر	مستقل
فاصله طولی خودرو هدف تا پشت صف خط ۲	LONDTQ2		
فاصله طولی خودرو هدف تا پشت صف خط ۳	LONDTQ3		
فاصله طولی خودرو هدف تا پشت صف خط ۴	LONDTQ4		
فاصله طولی خودروی هدف تا خودروی پیشرو در خط اصلی در زون A	LONDTLMA		
فاصله جانبی خودروی هدف از مانع یا خودروی سمت چپ در زون A	LATDTLA		
فاصله جانبی خودروی هدف از مانع یا خودروی سمت راست در زون A	LATDTRA		
فاصله طولی خودروی هدف تا خودروی پیشرو در خط اصلی در زون B	LONDTLMB		
فاصله طولی خودروی هدف تا خودروی پیرو در خط اصلی در زون B	LONDTMB		
فاصله جانبی خودروی هدف از مانع یا خودروی سمت چپ در زون B	LATDTLB		
فاصله جانبی خودروی هدف از مانع یا خودروی سمت راست در زون B	LATDTRB		
فاصله طولی خودروی هدف تا پشت صف خط بعد از تغییر خط	LDTLCBQ		

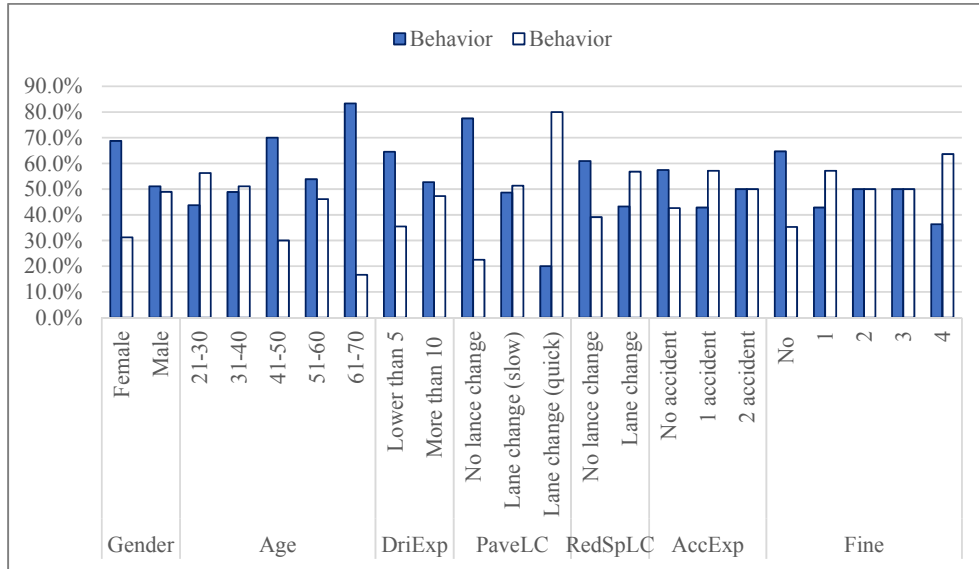
ادامه جدول ۱. تحلیل توصیفی داده‌ها

تعریف	علامت اختصاری	نوع متغیر	مستقل/وابسته
رفتار تغییر خط در مواجهه با خرابی روسازی ۱- بدون هیچ مانور حرکتی و تغییر خطی و صرفاً با کاهش سرعت از خرابی روسازی عبور کرده و به مسیر خود ادامه می‌دهم ۲- با کاهش سرعت و انجام مانور حرکتی به طوری که از خط عبوری خود خارج نشوم از مجاورت خرابی روسازی عبور می‌نمایم ۳- با انجام مانور حرکتی زیاد به طوری که از خط عبوری خود خارج شوم از مجاورت خرابی روسازی عبور می‌نمایم	PAVELC	رفتار رانندگی	مستقل
رفتار تغییر خط در مواجهه با وجود سرعت‌گیر ۱- بدون توجه به وضعیت سرعتکاه در خط عبوری خود ادامه مسیر داده و به آرامی از سرعتکاه عبور می‌نمایم ۲- ترجیح می‌دهم توقف و یا کاهش سرعت نداشته باشم و با تغییر خط عبوری سعی می‌کنم از آن بخشی از سرعتکاه که برآمدگی ندارد عبور کنم	REDSPLC		
تجربه تصادف هنگام رانندگی در یکسال گذشته ۱- صفر ۲- یک ۳- دو ۴- سه ۵- چهار و بیشتر	ACCEXP		
تجربه جریمه در یکسال گذشته ۱- صفر ۲- یک ۳- دو ۴- سه ۵- چهار و بیشتر	FINE		
فراموش کردن نگاه کردن به آینه در هنگام تغییر خط ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	MIROR		
نشان دادن عصبانیت با زدن بوق ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	BOOQ		
نشان دادن عصبانیت با تعقیب رانندگان ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	FLWANG		
جر و بحث یا درگیری فیزیکی با رانندگان دیگر ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	BAHS		
سبقت از راست رانندگان ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	RSEBQAT		
تغییر مسیر ناگهانی به محض دیدن بسته بودن مسیر ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	SUDLC		
سبقت از رانندگانی که با سرعت کم حرکت می‌کنند ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	LSPSEB		
چراغ زدن به راننده جلویی برای کنار رفتن ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	NEARLIG		
حرکت در شانه راست جاده برای فرار از ترافیک ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	RGAV		

ادامه جدول ۱. تحلیل توصیفی داده‌ها

تعریف	علامت اختصاری	نوع متغیر	مستقل / وابسته
کورس گذاشتن با سایر افراد ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	COURSE	رفتار رانندگی	مستقل
ویراژ دادن در مسیر ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	VIRAZH		
استفاده از خط ویژه به هنگام ترافیک ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	LVIZHE		
عبور از چراغ زرد در صورت عدم وجود دوربین ۱- هرگز ۲- خیلی کم ۳- کم ۴- برخی اوقات ۵- زیاد ۶- تقریباً همیشه	YELLOW		
قانون‌گریز بودن (نگرشی)	BGHANON	مشخصات راننده	مستقل
رفتار پرخاشگرانه (نگرشی)	AGRESIVE		
زن بودن = ۱؛ در غیر این صورت = ۰	FEMALE		
مرد بودن = ۱؛ در غیر این صورت = ۰	MALE		
سن بین ۲۱-۳۰ سال = ۱؛ در غیر این صورت = ۰	AGE2130		
سن بین ۳۱-۴۰ سال = ۱؛ در غیر این صورت = ۰	AGE3140		
سن بین ۴۱-۵۰ سال = ۱؛ در غیر این صورت = ۰	AGE4150		
سن بین ۵۱-۶۰ سال = ۱؛ در غیر این صورت = ۰	AGE5160		
سن بین ۶۱-۷۰ سال = ۱؛ در غیر این صورت = ۰	AGE6170		
سن بین ۷۱-۸۰ سال = ۱؛ در غیر این صورت = ۰	AGE7180		
تجربه رانندگی کمتر از ۵ سال = ۱؛ در غیر این صورت = ۰	DRIEXP5		
تجربه رانندگی بیش از ۱۰ سال = ۱؛ در غیر این صورت = ۰	DRIEXP10		
تغییر خط (اگر تغییر خط بدهد = ۱، در غیر این صورت = ۰)	Behavior		وابسته

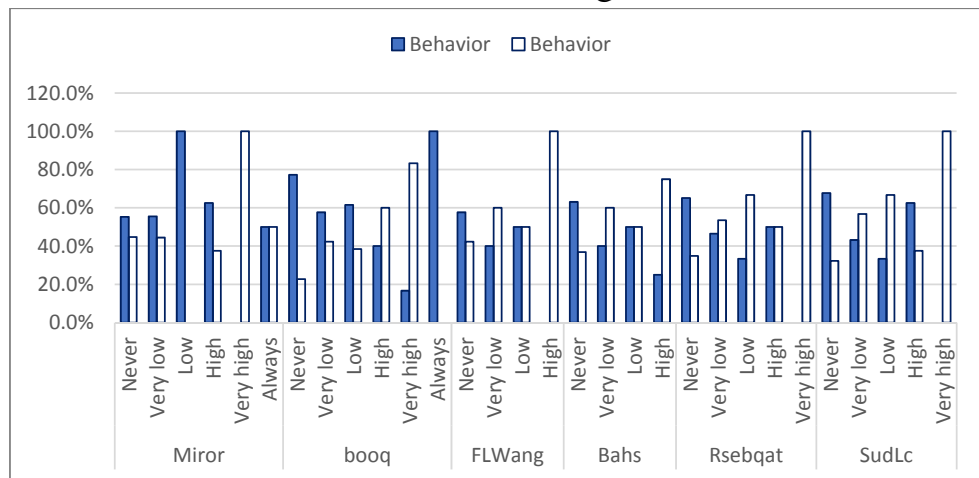
در نمودارهای زیر رفتار تغییر خط افراد شرکت‌کننده در آزمایش به تفکیک متغیرهای مستقل ارائه شده است.



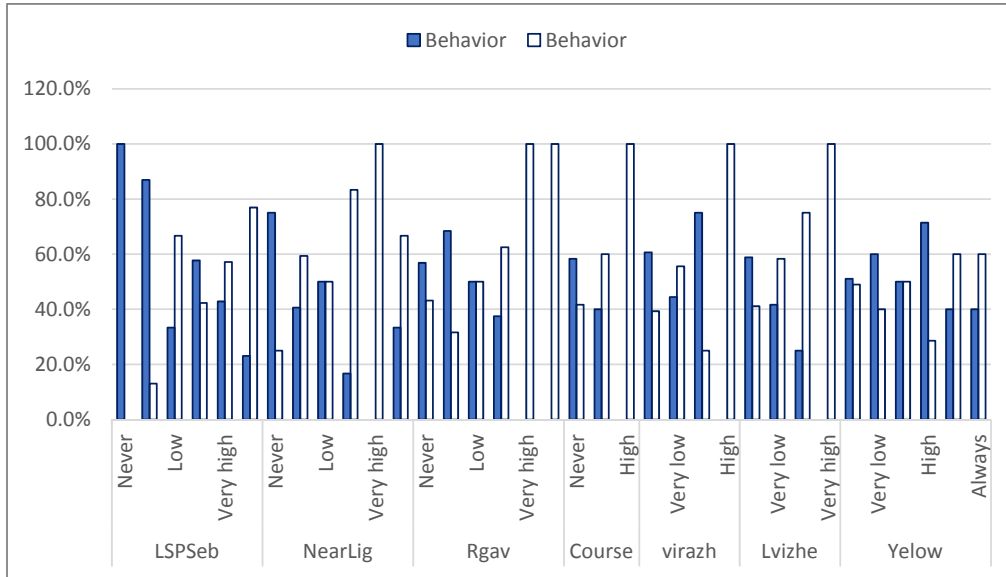
نمودار ۱. رفتار تغییر خط رانندگان به تفکیک متغیرهای مستقل

افرادی که در مواجهه با سرعت‌کاه نیز مانور تغییر خط انجام می‌دهند نیز صادق است. در رابطه با تجربه تصادف نیز، الگوی مشخصی وجود ندارد اما افرادی که تجربه تصادف در یک سال گذشته ندارند بیشترین تمایل را برای تغییر خط در مواجهه با صف دارند.

همان‌گونه که در نمودار ۱ مشاهده می‌گردد، از نظر جنسیت، زنان به دلیل قدرت ریسک کمتر نسبت به مردان، تمایل کمتری به تغییر خط در مواجهه با صف دارند. همچنین از نظر سنی، افراد جوانتر (بازه سنی ۲۱-۳۰) بیشترین تمایل برای تغییر خط را در مواجهه با صف دارند. تفاوت محسوسی در رفتار تغییرخط افراد با تجربه رانندگی متفاوت مشاهده نگردید اما رانندگان با تجربه بیشتر رانندگی، تمایل نسبتاً بیشتری به تغییرخط در مقایسه با افراد کم تجربه‌تر دارند. افرادی که در مواجهه با خرابی روسازی به سرعت تغییر خط می‌دهند، همین رفتار را در مواجهه با صف نیز از خود نشان می‌دهند. این موضوع برای



نمودار ۲. رفتار تغییر خط رانندگان به تفکیک متغیرهای مستقل



نمودار ۳. رفتار تغییر خط رانندگان به تفکیک متغیرهای مستقل

رانندگانی که با سرعت کم حرکت می‌کنند (سطح همیشه)، چراغ زدن مکرر به خودروهایی جلویی (سطح خیلی زیاد)، حرکت از سمت راست جاده (سطح همیشه و خیلی زیاد)، کورس گذاشتن با سایر راننده‌ها (سطح زیاد)، ویراژ دادن با سرعت بالا (سطح زیاد)، استفاده از خط ویژه به هنگام ترافیک (سطح خیلی زیاد)، عبور از چراغ زرد در صورت عدم وجود دوربین ثبت تخلفات (سطح همیشه و خیلی زیاد)، صادق است. در جدول ۲ تحلیل توصیفی و آماری داده‌های برداشت شده ارائه شده است.

افرادی که به صورت مکرر (۴ مرتبه) جریمه شدند، کمترین تمایل را برای عدم تغییر خط از خود نشان می‌دهند. این موضوع همان‌گونه که در نمودار ۲ و نمودار ۳ مشاهده می‌شود، برای افرادی که به صورت همیشگی رفتارهای پرخطرانه و قانون‌گریزانه همچون عدم توجه به آینه به هنگام تغییر مسیر (سطح خیلی زیاد)، بوق زدن ممتد به نشانه اعتراض به رانندگان (سطح خیلی زیاد)، تعقیب رانندگان به هنگام عصبانیت (سطح زیاد)، جر و بحث یا درگیری لفظی با دیگران (سطح زیاد)، سبقت از سمت راست رانندگان (سطح خیلی زیاد)، تغییر مسیر ناگهانی (سطح خیلی زیاد)، سبقت از

جدول ۲. تحلیل توصیفی داده‌ها

مستقل/وابسته	نوع متغیر	علامت اختصاری	میانگین	انحراف معیار	حداقل	حداکثر
مستقل	مشخصات وسیله نقلیه	VF	۳۸/۶۴	۷/۰۴	۲۳/۸	۵۱/۴
		VT	۳۸/۹۳	۶/۸۵	۲۳/۸	۵۱/۴
		VL	۳۹/۱۰	۶/۸۷	۲۳/۸	۵۱/۴
		TTTLCBQ	۸/۰۱	۳/۳۶	۱	۱۶/۷
		VTLCBQ	۶/۵۰	۱/۸۰	۳	۱۲/۳
		TTTLM	۰/۱۶	۰/۱۲	۰/۰۶	۱
		VF25L	۰/۰۲	۰/۱۵	۰	۱
		VF2530	۰/۱۲	۰/۳۳	۰	۱
		VF3035	۰/۲۵	۰/۴۳	۰	۱
		VF3540	۰/۲۳	۰/۴۲	۰	۱
		VF40H	۰/۴۵	۰/۵۰	۰	۱
		VL25L	۰/۰۲	۰/۱۵	۰	۱
		VL2530	۰/۱۱	۰/۳۱	۰	۱
		VL3035	۰/۲۳	۰/۴۲	۰	۱
		VL3540	۰/۲۳	۰/۴۲	۰	۱
VL40H	۰/۴۹	۰/۵۰	۰	۱		
مستقل	مشخصات جاده	LONDTQ1	۸۸/۴۶	۹/۴۱	۶۷	۱۰۸
		LONDTQ2	۱۰۳/۹۹	۱۳/۴۱	۷۷	۱۴۵
		LONDTQ3	۱۱۲/۲۰	۱۰/۳۲	۸۵	۱۴۵
		LONDTQ4	۱۲۱/۱۱	۱۳/۰۱	۱۰۰	۱۵۰
		LONDTLMA	۲۰/۸۴	۱۵/۵۸	۱	۶۵
		LATDTLA	۴/۱۴	۲/۵۴	۰/۵	۹/۵
		LATDTRA	۵/۳۴	۲/۹۸	۱	۱۲
		LONDTLMB	۱۴/۱۲	۱۱/۱۴	۰/۵	۵۰
		LONDFTM	۱۵/۶۲	۱۴/۴۴	۱	۷۰
		LATDTLB	۳/۴۳	۲/۲۲	۰/۵	۸/۹
		LATDTRB	۶/۱۵	۳/۲۴	۰/۷	۱۵
		LDTLCBQ	۵۲/۲۸	۲۶/۲۳	۳	۱۳۰

ادامه جدول ۲. تحلیل توصیفی داده‌ها

مستقل/وابسته	نوع متغیر	علامت اختصاری	میانگین	انحراف معیار	حداقل	حداکثر
مستقل	رفتار رانندگی	PAVELC	۱/۷۶	۰/۵۹	۱	۳
		REDSPLC	۱/۳۰	۰/۴۶	۱	۲
		ACCEXP	۱/۱۵	۰/۴۰	۱	۳
		FINE	۱/۹۹	۱/۳۴	۱	۵
		MIROR	۱/۸۸	۱/۵۰	۱	۶
		BOOQ	۲/۵۹	۱/۲۱	۱	۶
		FLWANG	۱/۱۴	۰/۴۵	۱	۴
		BAHS	۱/۴۴	۰/۷۳	۱	۴
		RSEBQAT	۱/۶۷	۰/۹۰	۱	۵
		SUDLC	۱/۷۳	۰/۹۱	۱	۵
		LSPSEB	۳/۹۷	۱/۲۶	۱	۶
		NEARLIG	۱/۹۳	۱/۲۶	۱	۶
		RGAV	۱/۵۵	۱/۰۴	۱	۶
		COURSE	۱/۱۵	۰/۴۲	۱	۴
		VIRAZH	۱/۳۸	۰/۷۰	۱	۴
		LVIZHE	۱/۲۳	۰/۶۸	۱	۴
YELLOW	۲/۱۶	۱/۳۷	۱	۶		
وابسته	تغییر یا عدم تغییر خط	Behavior	۰/۴۴	۰/۵۰	۰	۱

تابع ساختاری با پارامترهای ψ ، φ ، γ ، β سؤال‌های مربوط به قوت یا شدت روابط (مستقیم، غیرمستقیم و کل) بین متغیرهای نهفته و مقدار واریانس تبیین‌شده در کل مدل را پاسخ می‌دهد.

۳-۳- مدل شبکه عصبی

شبکه‌های عصبی مصنوعی در واقع روشی است که هوش مصنوعی را بیشتر و بهتر به انسان شبیه می‌کند و توانایی‌های تحلیل داده‌های پیچیده را به هوش مصنوعی می‌دهد. شبکه عصبی یک سیستم کامپیوتری است که از مغز و سیستم عصبی انسان الگوبرداری شده است. شبکه عصبی مصنوعی یک الگوی پردازش اطلاعات است که براساس عملکرد سیستم‌های عصبی زیستی برای پردازش اطلاعات است. مطابق شکل ۲ هر شبکه عصبی از اجزای عمودی انباشته به نام لایه‌ها تشکیل شده است. هر خط نقطه چین نشان دهنده یک لایه است. به‌طور کلی سه دسته لایه وجود دارد.

مقادیر میانگین و انحراف استاندارد سرعت خودرو هدف، پیرو و پیشرو نشانگر آن است که سرعت وسایل در مسیر دارای روندی همسو است. از نظر رفتار رانندگی افراد نیز، سبقت‌گرفتن از رانندگانی که دارای سرعت کم هستند شایع‌ترین رفتار میان افراد شرکت‌کننده در آزمایش با میانگین ۳/۹۷ است.

۳-۲- مدل اندازه‌گیری

مدل اندازه‌گیری یا قسمت تحلیل عاملی تأییدی، مشخص می‌کند که چگونه متغیرهای نهفته یا فرضی در قالب تعداد بیشتری متغیرهای قابل مشاهده، اندازه‌گیری شده‌اند. قسمت تابع ساختاری یا تحلیل مسیر از طرف دیگر روابط علی بین متغیرهای نهفته را بررسی می‌کند. به عبارت دیگر مدل اندازه‌گیری با پارامترهای $\theta\delta$ ، $\theta\delta$ ، λy ، λx سؤال‌های مربوط به روایی و اعتبار متغیرهای مشاهده شده را پاسخ می‌دهد و مدل

۲. تابع سیگموئید

این تابع یک منحنی S شکل است و زمانی که خروجی مدل احتمال باشد، از تابع سیگموئید استفاده می‌شود؛ چون تابع سیگموئید مقادیر را به بازه صفر تا ۱ می‌برد و احتمالات هم میان همین بازه قرار دارند. ماهیت این تابع غیرخطی بوده و مقادیر x در بازه ۲ الی -۲ است.

$$F(x) = \frac{1}{1 + e^{-x}} \quad (2)$$


این تابع معمولاً در لایه خروجی یک طبقه‌بندی باینری استفاده می‌شود و نتیجه منحصراً ۰ یا ۱ است؛ بنابراین اگر مقدار بزرگتر از ۰/۵ باشد، نتیجه را می‌توان به راحتی پیش‌بینی کرد که ۱ باشد.

۳. تابع تانژانت هایپربولیک

تابع تانژانت هایپربولیک همواره بهتر از تابع سیگموئید عمل می‌کند. در واقع این تابع نسخه تغییر یافته ریاضی تابع سیگموئید است. هر دوی این تابع‌ها مشابه بوده و می‌توانند از یکدیگر مشتق شوند.

$$F(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (3)$$

شبکه‌های عصبی مصنوعی بر پایه نورون‌های زیستی بنا شده‌اند که دارای خواص منحصربه‌فردی هستند. آن‌ها تقریب‌گرهای عمومی، تطبیق‌پذیر و مقاوم بوده و به همین دلیل در حل مسائل پیچیده و غیرخطی بسیار کارآمد هستند به طوری که در سال‌های اخیر مورد توجه قرار گرفته‌اند. پرسپترون چندلایه یک کلاس از شبکه عصبی مصنوعی پیش‌خور است. اصطلاح پرسپترون چندلایه به طور مبهم استفاده می‌شود، گاهی اوقات به طور آزاد به معنای هر شبکه عصبی مصنوعی پیش‌خور، گاهی اوقات به طور دقیق به شبکه‌های متشکل از چندین لایه پرسپترون (با فعال‌سازی آستانه) اشاره می‌کند. پرسپترون‌های چندلایه گاهی اوقات به صورت محاوره‌ای به عنوان شبکه‌های عصبی "وانیلی" شناخته می‌شوند، به ویژه زمانی که دارای یک لایه پنهان هستند. یک پرسپترون چندلایه حداقل از سه لایه گره تشکیل شده است: یک لایه ورودی، یک لایه پنهان و یک لایه خروجی. به جز گره‌های ورودی، هر گره یک نورون است که از یک تابع فعال‌ساز غیرخطی استفاده می‌کند. پرسپترون چندلایه از یک روش یادگیری نظارت شده به نام پس انتشار برای آموزش استفاده می‌کند. لایه‌های متعدد و فعال‌سازی غیرخطی آن پرسپترون



شکل ۲. ساختار لایه‌ها در شبکه عصبی

در یک شبکه عصبی به منظور کسب بیشینه قدرت پیش‌بینی، نیاز به اعمال یک تابع فعال‌سازی برای لایه‌های پنهان است. هدف از تابع فعال‌سازی، وارد کردن غیرخطی بودن به خروجی یک نورون است. توابع فعال‌ساز در واقع مانند دروازه‌ای هستند که در هر نورون وجود دارد. ورودی این دروازه‌ها همان ورودی‌های هر نورون در هر لایه است (در وزن‌های متناظر خود ضرب شده‌اند و با مقدار ثابت اریب جمع شده‌اند) و خروجی آن به لایه بعدی منتقل می‌شود. در اکثر مواقع توابع فعال‌ساز غیرخطی در شبکه‌های عصبی استفاده می‌شوند. توابع فعال‌ساز غیرخطی انواع مختلفی دارند.

۱. تابع واحد یکسو شده خطی

تابع واحد یکسو شده خطی در زمینه یادگیری عمیق بسیار مشهور است و در بیشتر مواقع استفاده می‌شود این تابع به این صورت عمل می‌کند که مقادیر منفی (زیر صفر) را صفر و مقادیر مثبت (بیشتر از صفر) و مقادیر برابر با صفر را همان مقدار خودش در نظر می‌گیرد.

$$F(x) = \begin{cases} x & x > 0 \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

این تابع به نوعی پرکاربردترین تابع فعال‌سازی است و به طور عمده در لایه‌های پنهان شبکه عصبی پیاده‌سازی می‌شود.

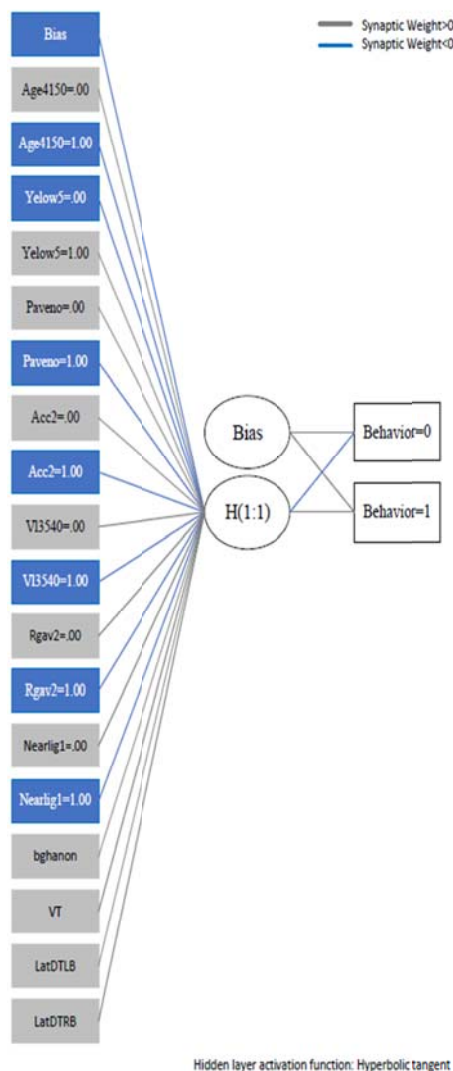
۴-تحلیل و بررسی نتایج

۴-۱- نتایج مدل اندازه گیری

در این بخش، نتایج مدل اندازه‌گیری انجام شده با استفاده از نرم‌افزار Amos v.24 برای تعیین روابط بین شاخص‌ها و سازه‌های نهان ارائه شده است. به‌منظور ارزیابی پایایی، بارهای عاملی مرتبط با سازه‌های نهان بررسی شده که تمامی بارهای عاملی بیشتر از ۰/۵ است. همچنین آلفای کرونباخ نیز برای هر دو سازه نهان محاسبه گردید و مقدار آن‌ها بیش از ۰/۶ است. به‌منظور بررسی نکویی برازش مدل به داده‌ها نیز از آماره‌های CFI، NFI، CMIN/df و RMSEA استفاده شده است. بر اساس مراجع، مقادیر CFI، NFI، TLI و IFI باید بیش از ۰/۹ بوده و مقادیر ۰/۰۱، ۰/۰۵ و ۰/۰۸ برای شاخص RMSEA، به ترتیب نشانگر برازش عالی، خوب و قابل قبول است. در نهایت نیز مقدار CMIN/df کمتر از ۳ بیانگر برازش بسیار خوب است. در جدول ۳ خروجی مدل اندازه‌گیری ارائه شده است.

به‌منظور ارزیابی پایایی، بارهای عاملی مرتبط با سازه‌های نهان بررسی شده است. تمامی بارهای عاملی بیشتر از ۰/۵ است. همچنین آلفای کرونباخ نیز برای هر دو سازه نهان محاسبه گردید و مقدار هر دوی آن‌ها بیش از ۰/۶ است. به‌منظور بررسی نکویی برازش مدل به داده‌ها نیز از آماره‌های CFI، NFI، CMIN/df و RMSEA استفاده شده است. بر اساس مراجع، مقادیر CFI، NFI، TLI و IFI باید بیش از ۰/۹ بوده و مقادیر ۰/۰۱، ۰/۰۵ و ۰/۰۸ برای شاخص RMSEA، به ترتیب نشانگر برازش عالی، خوب و قابل قبول است. در نهایت نیز مقدار cmin/df کمتر از ۳ بیانگر برازش بسیار خوب است. بر اساس تایید فوق، داده‌ها برازش خوبی داشتند و روایی و پایایی سازه‌های نهان موردتأیید است.

چندلایه را از یک پرسپترون خطی متمایز می‌کند و می‌تواند داده‌هایی را که به‌صورت خطی قابل‌تفکیک نیستند متمایز کند. با استفاده از نرم‌افزار SPSS یک مدل شبکه عصبی چندلایه تخمین زده شده است. به‌منظور دسته‌بندی داده‌های بخش آموزش و آزمایش، از نسبت ۷۰ به ۳۰ برای داده‌های آموزش و آزمایش به ترتیب استفاده گردید. پس از سعی و خطاهای متعدد در زمینه تعداد لایه و انواع توابع فعال‌ساز، مدل بهینه با بهترین عملکرد پیش‌بینی ارائه گردید که تابع فعال‌ساز تانژانت هایپربولیک بهترین عملکرد را در مقایسه با سایر توابع داشت. ساختار مدل شبکه عصبی در نمودار ۴ نشان داده شده است. همانطور که مشخص است، مدل دارای سه لایه ورودی، خروجی و میانی است.



نمودار ۴. ساختار مدل شبکه عصبی

جدول ۳. نتایج مدل اندازه گیری (تحلیل عاملی تائیدی)

Standardized Regression Weights: (Group number 1 - Default model)		
شخص	سازه نهان	برآورد
LSPSeb	agre	۰/۷۵۲
NearLig		۰/۶۵۸
Rsebqat	bghanon	۰/۷۱۱
Rgav		۰/۷۰۱
Course		۰/۷۴۳
virazh		۰/۶۸۷

۴-۲- نتایج مدل شبکه عصبی

همانطور که در نمودار ۴ مشخص گردید، مدل شبکه عصبی پیشنهادی دارای سه لایه ورودی، خروجی و میانی است. عملکرد پیش‌بینی مدل در جدول زیر ارائه شده است. همانطور که ملاحظه می‌گردد، دقت پیش‌بینی صحیح مدل برای داده‌های آزمایش برابر با ۹۳/۹٪ است.

Classification

Sample	Observed	Predicted		
		۰	۱	Percent Correct
Training	۰	۴۴	۶	٪۸۸/۰
	۱	۸	۳۳	٪۸۰/۵
	Overall Percent	٪۵۷/۱	٪۴۲/۹	٪۸۴/۶
Testing	۰	۱۸	۱	٪۹۴/۷
	۱	۱	۱۳	٪۹۲/۹
	Overall Percent	٪۵۷/۶	٪۴۲/۴	٪۹۳/۹

Dependent Variable: Behavior

جدول ۴. عملکرد پیش‌بینی مدل شبکه عصبی

در ادامه نمودار ROC نیز ارائه شده است. یکی دیگر از روش‌های بررسی و ارزیابی عملکرد دسته‌بندی دودویی، نمودار مشخصه عملکرد یا به اختصار منحنی ROC است. کارایی الگوریتم‌های دسته‌بندی دودویی معمولاً به وسیله شاخص‌هایی مثل حساسیت و صراحت سنجیده می‌شوند. اما در نمودار ROC هر دوی این شاخص‌ها ترکیب شده و به صورت یک منحنی نمایش داده می‌شوند. هرچه این نمودار به سمت مختصات (0,1) نزدیک‌تر باشد نشانگر عملکرد بهتر مدل است. همچنین از مساحت زیر نمودار نیز به عنوان یک شاخص کمی بدین منظور استفاده شده است. مقادیر بیش از ۰/۹ نشانگر قدرت عالی مدل در دسته‌بندی و پیش‌بینی متغیر وابسته است.

Model Fit Summary- RMSEA				
Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	۰/۰۵۷	۰/۰۰	۰/۱۲۹	۰/۳۷۹
Independence model	۰/۲۷۴	۰/۲۳۶	۰/۳۱۵	۰/۰۰


Model Fit Summary- CMIN			
Model	Default model	Saturated model	Independence model
NPAR	۱۳	۲۱	۶
CMIN	۱۱/۲۵	۰/۰۰	۱۵۳/۹
DF	۸	۰	۱۵
P	۰/۱۹		۰/۰۰
CMIN/DF	۱/۴۱		۱۰/۲۶

Model Fit Summary- Baseline Comparisons			
Model	Default model	Saturated model	Independence model
NFI Delta1	۰/۹۲۷	۱/۰۰	۰/۰۰
RFI rho1	۰/۸۶		۰/۰
IFI Delta2	۰/۹۸	۱/۰۰	۰/۰۰
TLI rho2	۰/۹۶		۰/۰۰
CFI	۰/۹۸	۱/۰۰	۰/۰۰

Model Fit Summary- RMR, GFI			
Model	Default model	Saturated model	Independence model
RMR	۰/۰۲۹	۰/۰۰۰	۰/۲۷۷
GFI	۰/۹۶۹	۱/۰۰۰	۰/۶۲۵
AGFI	۰/۹۱۸		۰/۴۷۵
PGFI	۰/۳۶۹		۰/۴۴۶

جدول ۵. اهمیت متغیرهای مستقل در پیش‌بینی رفتار تغییر خط رانندگان در هنگام مواجهه با صف راه‌بندان


ناحیه B است. در نهایت سرعت خودروی هدف نیز از عواملی است که اهمیتی بیش از ۵۰ درصد دارد.



نمودار ۶. اهمیت متغیرهای مستقل در پیش‌بینی رفتار تغییر خط رانندگان در هنگام مواجهه با صف راه‌بندان

Independent Variable Importance

	Importance	Normalized Importance
age4150	۰/۰۵۴	٪۲۹/۵
yellow5	۰/۰۵۶	٪۳۰/۵
paveno	۰/۰۷۰	٪۳۸/۴
acc2	۰/۰۱۴	٪۷/۶
vl3540	۰/۰۶۸	٪۳۷/۲
rgav2	۰/۰۲۲	٪۱۲/۰
nearlig1	۰/۰۷۱	٪۳۹/۲
bghanon	۰/۱۸۲	٪۱۰۰/۰
VT	۰/۱۳۶	٪۷۴/۴
LatDTLB	۰/۱۸۲	٪۹۹/۸
LatDTRB	۰/۱۴۶	٪۸۰/۰



نمودار ۵. نمودار ROC

۵- نتیجه‌گیری

این مطالعه با هدف ارائه مدل پیش‌بینی رفتار رانندگان در مواجهه با ازدحام پیش رو و صف راه‌بندان به استفاده از مدل شبکه عصبی صورت پذیرفت. نتایج و یافته‌های این پژوهش به توسعه استراتژی‌های مدیریت ترافیک مؤثرتر کمک می‌کنند و در نهایت تجربه رانندگی را برای همه کاربران جاده بهبود می‌بخشند. در واقع درک تأثیر ازدحام ترافیک بر رفتار راننده می‌تواند به افزایش ایمنی ترافیک در موقعیت‌های مربوط به راه‌بندان کمک کند.

در این مطالعه رفتار ۱۲۴ راننده در هنگام مواجهه با صف راه‌بندان تحلیل و پردازش گردید و سپس با استفاده از مدل اندازه‌گیری (تحلیل عاملی تأییدی) ۲ متغیر نهان قانون‌گریزی و رفتار پرخاشگرانه رانندگان تعیین گردید. روایی و پایایی و نکویی برازش مدل مورد ارزیابی و تأیید قرار گرفت. مطابق نتایج مدل شبکه عصبی، دقت پیش‌بینی صحیح مدل برای

در نهایت اهمیت هر یک از متغیرهای مستقل بررسی گردید. مطابق جدول ۵ و نمودار ۶ بیشترین اهمیت در پیش‌بینی رفتار تغییر خط رانندگان در مواجهه با صف را متغیر نگرشی قانون‌گریز بودن دارد و سپس فاصله عرضی با موانع یا خودروهای موجود در سمت چپ و راست خودروی هدف در

Journal of the International Society for Research on Aggression, 25(6), 409-423 .

-Kouabenan, D. R. J. J. o. R. R., (2002). Occupation, driving experience, and risk and accident perception. 5(1), 49-68.

-Li, G., Lai, W., Sui, X., Li, X., Qu, X., Zhang, T., & Li, Y., (2020). Influence of traffic congestion on driver behavior in post-congestion driving. *Accident Analysis & Prevention*. 141, 105508 .

-Ma, M., Yan, X., Huang, H., & Abdel-Aty, M., (2010). Occupational driver safety of public transportation: Risk perception, attitudes, and driving behavior. *Paper presented at the Proceedings of the Transportation Research Board 89th Annual Meeting*.

-Peng, J., Guo, Y., Fu, R., Yuan, W., & Wang, C., (2015). Multi-parameter prediction of drivers' lane-changing behaviour with neural network model. *Applied Ergonomics*, 50, 207-217.

-Perry, A. R., Baldwin, D. A. J. P., & skills, M., (2000). Further evidence of associations of type A personality scores and driving-related attitudes and behaviors. 91(1), 147-154 .

-Ponnaluri, R. V. J. I. R., (2012). Road traffic crashes and risk groups in India. *Analysis, Interpretations, and Prevention Strategies*. 35(2), 104-110.

-Sun, D., & Elefteriadou, L. J. T. R. R., (2010). Research and implementation of lane-changing model based on driver behavior. 2161(1), 1-10 .

-Ulleberg, P., & Rundmo, T. J. S. J. o. P., (2002). Risk-taking attitudes among young drivers: The psychometric qualities and dimensionality of an instrument to measure young drivers' risk-taking attitudes. 43(3), 227-237.

-Wang, W., Qie, T., Yang, C., Liu, W., Xiang, C., & Huang, K., (2021). An intelligent lane-changing behavior prediction and decision-making strategy for an autonomous vehicle. *IEEE Transactions on Industrial Electronics*, 69(3), 2927-2937.

-Wei, C., Hui, F., & Khattak, A. J., (2021). Driver lane-changing behavior prediction based on deep learning. *Journal of Advanced Transportation*, 2021, 1-15.

-Zheng, J., Suzuki, K., & Fujita, M., (2014). Predicting driver's lane-changing decisions using a neural network model. *Simulation Modelling Practice and Theory*, 42, 73-83.

داده‌های آزمایش برابر با ۹۳/۹٪ است و بیشترین اهمیت در پیش‌بینی رفتار تغییرخط رانندگان در مواجهه با صف را متغیر نگرشی قانون‌گریز بودن دارد و سپس فاصله عرضی با موانع یا خودروهای موجود در سمت چپ و راست خودروی هدف در ناحیه B است. در نهایت سرعت خودروی هدف نیز از عواملی است که اهمیتی بیش از ۵۰ درصد دارد.

نتایج این مدل‌ها برای ارزیابی مدل‌های رفتاری رانندگان، کالیبراسیون نرم‌افزارهای شبیه‌سازی ترافیک و نیز توسعه سیستم‌های کمکی خودرو و خودروهای خودران، برای بهبود ایمنی تردد مفید خواهند بود. با توجه به آنکه در این مطالعه، بررسی واکنش رانندگان در معبر با درجه عملکردی بزرگراهی مورد بررسی قرار گرفت، برای مطالعات بعدی پیشنهاد می‌شود که پیش‌بینی رفتار رانندگان در هنگام مواجهه با راه‌بندان در معابر شهری با درجه عملکردی دیگر مورد بررسی قرار گیرد. همچنین پیشنهاد می‌گردد هدف سفر رانندگان نیز به‌عنوان یکی از عوامل تأثیرگذار بر رفتار رانندگان در هنگام مواجهه با صف در مدل پیش‌بینی لحاظ گردد. با توجه به اینکه واکنش ناگهانی رفتار رانندگان (انحراف از مسیر حرکت) احتمال وقوع تصادف را افزایش می‌دهد؛ ولی الزاماً ممکن است به یک تصادف منجر نشود؛ بنابراین پیشنهاد می‌شود که ارتباط بین شدت و نوع تصادفات در معابر شهری که با صف راه‌بندان مواجه می‌شوند مورد بررسی قرار گیرد.

۶- مراجع

-Ding, C., Wang, W., Wang, X., & Baumann, M., (2013). A neural network model for driver's lane-changing trajectory prediction in urban traffic flow. *Mathematical Problems in Engineering*.

-Gao, J., Zhu, H., & Murphey, Y. L., (2019). A personalized model for driver lane-changing behavior prediction using deep neural network. *Paper presented at the 2019 2nd International Conference on Artificial Intelligence and Big Data (ICAIBD)*.

-Hamedi, H., & Shad, R., (2022). Lane-changing trajectory prediction modeling using neural networks. *Advances in Civil Engineering*.

-Hennessy, D. A., & Wiesenthal, D. L., (1999). Traffic congestion, driver stress, and driver aggression. *Aggressive Behavior. Official*

Predicting Passenger Car Drivers' Behavior when Encountering Traffic Jams Using a Neural Network Model

Seyed Hamed Seyed Matin, Ph.D., Candidate, Department of Civil Engineering, Faculty of Technical and Engineering, Imam Khomeini International University, Qazvin, Iran.

Ali Abdi Kordani, Professor, Department of Civil Engineering, Faculty of Technical and Engineering, Imam Khomeini International University, Qazvin, Iran.

E-mail: aliabdi@eng.ikiu.ac.ir

Received: Jan 2024- Accepted: Jun 2024

ABSTRACT

The imbalance of supply and demand during rush hours causes traffic congestion on roads, which has a significant impact on safety, travel time, and fuel consumption. Investigating the behavior of drivers before congestion and traffic jams can help to reduce its effects while providing suitable solutions. Although the prediction of drivers' behavior using different models has been presented by researchers, the prediction of drivers' behavior before traffic jams has not been paid much attention. The main purpose of this study is to determine the model for predicting the behavior of drivers when they encounter traffic jams using a neural network model. In this research, the behavior of 124 drivers was processed by recording video films without attracting drivers' attention, and the demographic and behavioral characteristics of the drivers were extracted from the analysis of the questionnaires completed by the drivers. After descriptive analysis, the collected data were evaluated using confirmatory factor analysis of the relationships between the observed and latent (attitudinal or behavioral) variables in Amos v.24 software, and two latent variables of law evasion and aggressive driving were determined. According to the output of the neural network model that was formed in SPSS software, the most important in predicting the behavior of drivers to lane changes when encountering traffic jams is the attitudinal variable of law evasion and then the transverse distance to obstacles or cars on the left and right side of the target car. The accuracy of the model for the test data is equal to 93.9%.

Keywords: Driver Behavior, Congestion, Traffic Jams, Artificial Neural Network