

پیش‌بینی تغییر خط راننده در آزادراه‌ها با استفاده از شبکه عصبی بازگشتی با

حافظه بلندمدت و ماشین بردار پشتیبان بر اساس داده‌های میکروسکوپی

محمد منیعات، گروه مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

محمود صفارزاده (مسئول مکاتبات)، استاد، گروه مهندسی عمران و محیط زیست، دانشگاه تربیت مدرس، تهران، ایران

E-mail: saffar_m@modares.ac.ir

حسن ذوقی، استادیار، گروه مهندسی عمران، واحد کرج، دانشگاه آزاد اسلامی، تهران، ایران

علیرضا سرکار، استادیار، گروه مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

پذیرش: ۱۴۰۴/۰۸/۱۲

دریافت: ۱۴۰۴/۰۴/۲۲

چکیده

تغییر خط یکی از مانورهای حیاتی در رانندگی است که نقش مهمی در ایمنی و روانی جریان ترافیک دارد. هدف این پژوهش، توسعه و مقایسه مدل‌های یادگیری ماشین برای پیش‌بینی کوتاه‌مدت تغییر خط رانندگان در آزادراه است. بدین منظور، از داده‌های میکروسکوپی مجموعه داده شبیه‌سازی نسل آینده (NGSIM) استفاده شد و دو مدل شامل شبکه عصبی بازگشتی با حافظه بلندمدت (LSTM) و ماشین بردار پشتیبان (SVM) طراحی و ارزیابی گردیدند. پیش‌بینی‌ها در بازه‌های زمانی ۱ تا ۵ ثانیه پیش از وقوع مانور انجام شد تا اثر افق زمانی بر عملکرد مدل‌ها بررسی شود. برای ارزیابی، معیارهایی نظیر میانگین مربع خطا (MSE)، بازخوانی (Recall) و امتیاز F1 مورد استفاده قرار گرفتند. نتایج نشان داد مدل LSTM در تمامی شاخص‌ها نسبت به SVM برتری معناداری دارد و در بازه‌های کوتاه‌مدت (۱ تا ۵ ثانیه) به بالاترین دقت و کمترین خطا دست یافت. همچنین تحلیل آماری نشان داد که در خطوط راست آزادراه تمایل به تغییر خط بیشتر است. یافته‌های این پژوهش می‌تواند در طراحی سیستم‌های کمک‌راننده پیشرفته و توسعه الگوریتم‌های پیش‌بینی دقیق در خودروهای نیمه‌خودران و خودران مورد استفاده قرار گیرد.

واژگان کلیدی: پیش‌بینی تغییر خط، شبکه عصبی بازگشتی با حافظه بلندمدت، ماشین بردار پشتیبان، داده‌های میکروسکوپی، سیستم

کمک‌راننده

۱. مقدمه

رانندگی یک فعالیت پیچیده است که نیازمند هماهنگی مستمر میان ادراک، آگاهی محیطی و کنترل وسیله نقلیه است. در میان انواع رفتارهای رانندگی، تغییر خط به عنوان یکی از مهم ترین مانورها شناخته می شود؛ زیرا نه تنها بر ایمنی ترافیک اثرگذار است، بلکه در افزایش ظرفیت و روانی جریان عبور و مرور نیز نقش کلیدی دارد (Han et al., 2025). این فرآیند شامل چندین لایه رفتاری است، اول کنترل سطح پایین (مانند فرمان و شتاب)، دوم، نظارت بر وضعیت پیرامونی و تصمیم گیری درباره زمان و مکان مناسب برای تغییر خط است (Xiao et al., 2025). با ظهور خودروهای خودران و نیمه خودران، درک و دقت مدل های رفتار تغییر خط و تعقیب خودرو شامل واکنش تصمیمات راننده جهت عملکرد ایمن این خودروها و ترافیک اطراف حیاتی است (Kim et al., 2024; Maniat, 2024; Parisa Raufi & Mohammad Maniat, 2024). در سال های اخیر، مطالعات متعددی در زمینه مدل های تغییر خط با هدف افزایش ظرفیت و بهبود ایمنی جاده ها انجام شده است (Ma & Li, 2023). به طور کلی، دو نوع داده برای مدل سازی مورد استفاده قرار می گیرد. نوع اول داده هایی هستند که از طریق شبیه سازی به دست می آیند؛ به این صورت که با استفاده از دوربین های نصب شده داخل خودرو، رفتار راننده از جمله عملکرد وسیله نقلیه در شرایط شبیه سازی شده یا حرکات چشم مورد بررسی قرار می گیرد (Huo et al., 2020; Madigan et al., 2018; Salvucci & Liu, 2002). نوع دوم داده ها معمولاً از تردد شمارها، دوربین های نظارتی یا اطلاعات سامانه موقعیت یاب جهانی (GPS) که در آزادراه ها نصب شده اند، به دست می آید (Ali et al., 2019; He et al., 2024). با وجود این پیشرفت ها، همچنان شکاف های مهمی در ادبیات وجود دارد. نخست آن که در بسیاری از مطالعات، افق زمانی پیش بینی تغییر خط به طور شفاف بیان نشده است؛ در نتیجه، گزارش صرف معیارهایی مانند امتیاز F1 یا بازخوانی

(Recall) نمی تواند ارزیابی دقیقی از کارایی مدل ارائه دهد، زیرا عملکرد مدل در افق های زمانی مختلف (مثلاً یک ثانیه در مقایسه با پنج ثانیه قبل از مانور) تفاوت چشمگیری دارد. خوشبختانه در پژوهش های جدیدتر این موضوع مورد توجه قرار گرفته است. برای مثال، زو و همکاران افق زمانی ۴ ثانیه ای را برای پیش بینی تغییر خط و مسیر حرکت در نظر گرفته اند (Zhou et al., 2025). همچنین در مطالعه لیو و همکاران، بر اهمیت انتخاب بازه زمانی مناسب تأکید شده و نویسندگان اشاره کرده اند که افق های زمانی ۲ تا ۳ ثانیه در اغلب پژوهش ها رایج است (Lyu et al., 2025). در مقابل، فو و همکاران افق زمانی بسیار کوتاه تر، یعنی ۰/۴ ثانیه، را برای پیش بینی لحاظ کرده اند (Fu et al., 2023). چالش دیگر در پیش بینی تغییر خط آن است که شاخص های کمی متداول مانند ضریب تعیین (R^2) یا میانگین خطای مربعی ریشه ای (Root Mean Squared Error – RMSE) به تنهایی کافی نیستند (Maniat & Ebrahimzadeh, 2024; Parisa Raufi & Mohammad Maniat, 2024). برای ارزیابی جامع عملکرد مدل لازم است از معیارهای طبقه بندی همچون امتیاز F1 یا بازخوانی (Recall) نیز استفاده شود. این رویکرد نشان می دهد که صرفاً کالیبره بودن مدل تضمین کننده دقت آن نیست؛ بلکه باید میزان دقت واقعی مدل در قالب معیارهای کمی و در بازه های زمانی مختلف به طور شفاف سنجیده شود. به عنوان نمونه، ویرتمولر و همکاران با مقایسه چهار مدل هوش مصنوعی در افق زمانی ۳/۵ ثانیه، به دقت ۹۶٪ دست یافته اند (Wirthmüller et al., 2021).

با این حال، در بسیاری از کاربردهای ایمنی مرتبط با سامانه های کمک راننده، پیش بینی تغییر خط در بازه های زمانی طولانی (بیش از ۵ ثانیه) ضرورتی ندارد؛ زیرا بیشتر سامانه های هشداردهنده و کنترل ایمنی در خودروهای هوشمند و نیمه خودران، برای ارائه واکنش مؤثر و به موقع، تنها به پیش بینی های کوتاه مدت، حداکثر تا ۵ ثانیه پیش از وقوع تغییر خط نیاز دارند (Jin et al., 2024). بر این اساس، پژوهش حاضر با هدف پیش بینی کوتاه مدت تغییر

داده‌های میکروسکوپی

مارکوف پنهان نیز در اوایل این دوره مطرح بودند؛ برای مثال، لی و همکاران با الگوبرداری از روش‌های بازشناسی گفتار یک مدل ترکیبی مبتنی بر مدل‌های مارکوف پنهان ارائه دادند که به دقت حدود ۹۰٪ در تشخیص قصد تغییر خط راست و چپ دست یافت با این حال، پیچیدگی ذاتی رفتار تغییر خط و ضرورت یادگیری الگوهای زمانی پیشرفته موجب شده است که پژوهشگران به تدریج به سمت استفاده از مدل‌های قدرتمند مبتنی بر شبکه‌های عصبی حرکت کنند. در این راستا، یکی از نخستین تلاش‌ها در این حوزه به کارگیری شبکه‌های عصبی پرسپترون چندلایه (Multilayer Perceptron – MLP) بود. این مدل‌های پیش‌خور با بهره‌گیری از ویژگی‌های آنی یا تجمیعی وسیله نقلیه (مانند سرعت، فاصله و شتاب) به تشخیص یا برآورد احتمال تغییر خط پرداخته‌اند.

با وجود نتایج اولیه قابل قبول، مطالعات اخیر نشان داده‌اند که مدل‌های بازگشتی، به‌ویژه شبکه‌های عصبی بازگشتی دوطرفه و تجمیعی (Ensemble Bidirectional Recurrent Neural Networks – EBiRNN)، در پیش‌بینی رفتارهای پویای رانندگان مانند تغییر خط عملکرد به‌مراتب بهتری دارند. برای مثال، یانگ و همکاران گزارش کرده‌اند که مدل EBiRNN در مقایسه با روش‌های کلاسیک نظیر ماشین بردار پشتیبان (SVM) و مدل زنجیره مارکوف پنهان (HMM)، دقت بالاتری در پیش‌بینی تغییر خط ارائه می‌دهد. این برتری عمدتاً ناشی از توانایی EBiRNN در بهره‌گیری از توالی داده‌های زمانی از هر دو جهت گذشته و آینده است؛ ویژگی‌ای که آن را برای مدل‌سازی رفتارهای وابسته به زمان در مانورهای رانندگی به گزینه‌ای بسیار مناسب تبدیل می‌کند (Xing et al., 2020). با این حال، هرچند یانگ و همکاران به دقت بالای ۹۶٫۱٪ در پیش‌بینی تغییر خط دست یافته‌اند، اما این پیش‌بینی تنها در افق زمانی ۰٫۵ ثانیه پیش از مانور صورت گرفته است؛ بازه‌ای که برای سامانه‌های هشداردهنده و واکنش انسانی، به دلیل نیاز به زمان پاسخگویی بیشتر، کارایی کافی ندارد. ازاین‌رو، برای درک

خط رانندگان در آزادراه با استفاده از داده‌های میکروسکوپی مجموعه‌داده شبیه‌سازی نسل آینده (Next Generation Simulation – NGSIM) انجام شده است. اگرچه پژوهش‌های اخیر به بررسی افق‌های زمانی مختلف در پیش‌بینی تغییر خط پرداخته‌اند، اغلب آن‌ها تنها یک بازه‌ی زمانی خاص (برای مثال ۰٫۴ یا ۴ ثانیه قبل از مانور) را مدنظر قرار داده‌اند و به مقایسه‌ی جامع عملکرد مدل‌ها در بازه‌های زمانی متوالی ۱ تا ۵ ثانیه پیش از تغییر خط پرداخته‌اند. علاوه‌براین، بیشتر تحقیقات موجود یا صرفاً از روش‌های یادگیری عمیق مانند LSTM و GRU استفاده کرده‌اند یا بر مدل‌های ترکیبی متمرکز بوده‌اند، در حالی که مقایسه‌ی مستقیم میان روش‌های کلاسیک (SVM) و روش‌های عمیق (LSTM) بر مبنای داده‌های میکروسکوپی NGSIM کمتر مورد توجه قرار گرفته است. نوآوری این پژوهش در آن است که ضمن بررسی تأثیر افق‌های زمانی مختلف بر دقت پیش‌بینی تغییر خط، کارایی دو رویکرد متفاوت SVM و LSTM را در یک چارچوب مشترک مقایسه کرده و از ترکیب معیارهای کمی و معیارهای طبقه‌بندی F1 و Recall برای ارزیابی جامع عملکرد مدل‌ها بهره می‌برد. به‌طور خلاصه، این پژوهش بر آن است که نشان دهد اتکا به «دقیق بودن مدل» بدون توجه به افق زمانی پیش‌بینی، برای کاربردهای ایمنی و سامانه‌های کمک‌راننده کافی نیست؛ نکته‌ای که در بخش قابل‌توجهی از پژوهش‌های پیشین نادیده گرفته شده است.

۲. ادبیات پژوهش

پیش‌بینی به‌موقع تغییر خط رانندگان نقشی کلیدی در افزایش ایمنی و کارایی سیستم‌های کمک‌راننده و خودروهای خودران دارد. از سال ۲۰۱۵ به بعد، با در دسترس بودن داده‌های میکروسکوپی (مسیر و وضعیت خودروهای منفرد در ترافیک) و پیشرفت یادگیری عمیق، مدل‌های شبکه عصبی به‌طور گسترده برای این منظور به‌کار گرفته شده‌اند (Althé & de La Fortelle, 2017). روش‌های سنتی‌تر مانند مدل‌های لاجیت یا

بهتر روند زمانی در تصمیم‌گیری رانندگان، استفاده از شبکه‌های عصبی بازگشتی (Recurrent Neural Networks - RNN) و به‌ویژه نسخه‌های پیشرفته‌ی آن همچون شبکه‌های حافظه بلندمدت (LSTM) و واحد بازگشتی دروازه‌دار (Gated Recurrent Unit - GRU) مورد توجه قرار گرفته است (Altché & de La Fortelle, 2017). مدل‌های حافظه‌دار با تحلیل توالی مشاهدات گذشته (مانند موقعیت و سرعت خودرو در چند ثانیه اخیر)، قادرند احتمال تغییر خط در آینده نزدیک را پیش‌بینی کنند. شواهد تجربی نیز کارایی بالای شبکه‌های عصبی بازگشتی (RNN) را تأیید می‌کنند. به‌عنوان نمونه، آلتشه و دلافورتل با آموزش یک شبکه عصبی بازگشتی با حافظه بلندمدت (LSTM) بر روی مجموعه داده شبیه‌سازی (NGSIM) که شامل هزاران ساعت داده مسیر وسایل نقلیه در بزرگراه است — نشان دادند که این مدل توانست مسیر آینده خودرو، از جمله حرکت عرضی برای تغییر خط، را با خطای متوسط کمتر از ۰/۷ متر در بعد عرضی و ۲/۵ متر بر ثانیه در بعد طولی برای افق زمانی ۱۰ ثانیه‌ای پیش‌بینی کند (Altché & de La Fortelle, 2017).

هرچند بسیاری از تحقیقات اولیه بر داده‌های حرکتی عددی (مانند مختصات و سرعت) متمرکز بودند، پژوهشگران دریافته‌اند که استفاده از داده‌های دیداری و حسگرهای محیطی می‌تواند سیگنال‌های غنی‌تری برای پیش‌بینی تغییر خط فراهم کند. شبکه‌های عصبی پیچشی (CNN) ابزار اصلی در استخراج ویژگی از تصاویر و داده‌های فضایی هستند و در سال‌های اخیر وارد عرصه پیش‌بینی مانورهای رانندگی شده‌اند. برای نمونه، دیه‌زالوارز و همکاران یک رویکرد مبتنی بر CNN را توسعه دادند که با تحلیل داده‌های حسگر لیدار پیرامون خودرو (به شکل نقشه عمق یا تصاویر دوبعدی از محیط) و ترکیب آن با متغیرهای غیرمکانی (مثل سرعت نسبی خودروی جلویی)، قصد راننده برای تغییر خط را پیش‌بینی می‌کند (Díaz-Álvarez et al., 2021). آنان معماری شبکه‌ی پیچشی خود

را به‌گونه‌ای بازطراحی کردند که بتواند به‌طور همزمان ورودی‌های فضایی (اطلاعات محیطی پیرامون خودرو) و غیرفضایی (مانند متغیرهای حرکتی) را دریافت و پردازش کند. نتایج این پژوهش نشان داد که مدل شبکه عصبی کانولوشنی (CNN) پیشنهادی قادر است تفاوت‌های رفتاری ظریف میان رانندگان مختلف را شناسایی کرده و عملکردی به‌مراتب فراتر از سطح شانس ارائه دهد. هرچند بدیهی است که مقایسه‌ی نهایی باید با روش‌های پیشرفته‌تر صورت گیرد، اما همین یافته‌ها بیانگر پیچیدگی ذاتی مسئله تغییر خط و نیاز به داده‌های غنی و دقیق برای توسعه مدل‌های قابل اعتماد است (Díaz-Álvarez et al., 2021). از سوی دیگر، برخی مطالعات به سراغ داده‌های دوربین رفته‌اند تا از روی ویدئوهای رانندگی، تغییر خط را تشخیص یا پیش‌بینی کنند. برای مثال، لیانگ و همکاران با بهره‌گیری از شبکه‌های پیچشی سه‌بعدی (قابلیت تحلیل ویدئو به عنوان دنباله‌ای از فریم‌ها)، یک چارچوب بازشناسی اقدام راننده طراحی کردند که صرفاً با تکیه بر ویدئوی مقابل خودرو می‌تواند، تغییر خط خودروی جلویی را تشخیص دهد. روش آنها روی مجموعه داده‌ی ویدئویی آزمایش شد و توانست به بهترین نتایج طبقه‌بندی تغییر خط با استفاده از داده‌ی خام تصویری دست یابد. این دستاورد اهمیت اطلاعات بصری (مانند حرکات بدنه‌ی خودرو، راهنما زدن یا تغییرات کوچک مسیر) را در کنار داده‌های سینماتیکی نشان می‌دهد. به‌طور کلی، ترکیب شبکه‌های پیچشی برای استخراج ویژگی‌های محیطی/دیداری با مدل‌های زمانی، رویکردی قدرتمند برای فهم زمینه و قصد تغییر خط ارائه می‌دهد (Liang et al., 2022). پژوهش‌های جدید نشان می‌دهند که گرایش عمده در حوزه پیش‌بینی تغییر خط، استفاده از مدل‌های ترکیبی است؛ به‌گونه‌ای که این رویکردها یا قابلیت‌های متنوع شبکه‌های عصبی را با یکدیگر تلفیق می‌کنند، یا یادگیری عمیق را با سایر الگوریتم‌های داده‌کاوی و تصمیم‌گیری در هم می‌آمیزند تا دقت و پایداری مدل‌ها افزایش یابد (Li et al., 2024). از دیگر رویکردهای نوین، می‌توان به

داده‌های میکروسکوپی

در این تحقیق، هدف اصلی پیش‌بینی رفتار تغییر خط راننده در آزادراه بر اساس داده‌های میکروسکوپی است. برای این منظور، دو رویکرد یادگیری ماشین و یادگیری عمیق شامل ماشین بردار پشتیبان (SVM) و شبکه عصبی بازگشتی با حافظه بلندمدت (LSTM) مورد استفاده قرار گرفته‌اند. مقایسه این دو مدل امکان ارزیابی عملکرد روش‌های سنتی و مدرن در سناریوهای زمانی مختلف را فراهم می‌سازد. داده‌های مورد استفاده از مجموعه داده I-80 استخراج شده‌اند که شامل اطلاعات دقیق موقعیت، سرعت، فاصله نسبی و وضعیت مانور خودروها با وضوح زمانی ۱۰ هرتز (هر ۰.۱ ثانیه) است. بردار ویژگی‌ها شامل متغیرهایی نظیر سرعت لحظه‌ای، فاصله مکانی با خودروهای جلویی، سرعت نسبی، شماره خط، و نیز متغیر فاصله جانبی لحاظ شده است. تحلیل‌ها در چهار بازه‌ی زمانی مختلف پیش از وقوع تغییر خط انجام می‌شود: ۱، ۲، ۳، ۴ و ۵ ثانیه. هدف از این طراحی، بررسی تأثیر افق زمانی بر عملکرد پیش‌بینی است؛ به‌طوری‌که مشخص شود دقت مدل‌ها در پیش‌بینی مانور راننده با نزدیک شدن به لحظه تغییر خط چگونه تغییر می‌کند. مدل SVM به‌عنوان یک روش کلاسیک با قابلیت تعمیم بالا و دقت خوب برای مسائل با ویژگی‌های محدود، و مدل LSTM به‌عنوان رویکردی توانمند برای تحلیل وابستگی‌های زمانی در داده‌های سریالی، پیاده‌سازی و آموزش داده شده‌اند. عملکرد این مدل‌ها با استفاده از معیارهایی نظیر دقت (Accuracy)، امتیاز F1 و میانگین مربع خطا (MSE) مورد ارزیابی و مقایسه قرار گرفته است.

۳-۱ مطالعه موردی


به‌منظور ارزیابی مدل پیش‌بینی تغییر خط در آزادراه، از مجموعه داده برنامه شبیه‌سازی نسل آینده (NGSIM) متعلق به سازمان فدرال بزرگراه‌های ایالات متحده استفاده شده است (FHWA, 2016). در این تحقیق به‌طور خاص از داده‌های مربوط به آزادراه بین‌ایالتی ۸۰ (Interstate 80) استفاده شده است که در تاریخ ۱۳ آوریل ۲۰۰۵، در مسیر شرقی این آزادراه

ترکیب یادگیری عمیق با الگوریتم‌های یادگیری کلاسیک اشاره کرد (Zhang et al., 2024). به عنوان نمونه، گنگ و همکاران یک مدل دو مرحله‌ای پیشنهاد داده‌اند که ابتدا با الگوریتم XGBoost وضعیت ایمنی و امکان تغییر خط در محیط جاری ارزیابی می‌شود و سپس یک شبکه بازگشتی دوطرفه احتمال تغییر خط را در بازه‌ی زمانی آینده پیش‌بینی می‌کند. این مدل ترکیبی بر روی داده‌های ریزدانه‌ی مجموعه داده‌ی آزمایش شده و به دقت کلی حدود ۹۸/۸٪ دست یافته است؛ ضمن آنکه توانسته با بیش از ۸۷٪ صحت، وقوع تغییر خط را تا ۲ ثانیه قبل پیش‌بینی کند (Geng et al., 2023). دستیابی به چنین دقت بالایی نسبت به روش‌های مقایسه‌شده، حاکی از اثربخشی بهره‌گیری توأمان دانش محیطی توسط XGBoost و قدرت یادگیری ترتیب‌های زمانی توسط شبکه GRU است. با وجود دستاوردهای اخیر در به‌کارگیری مدل‌های پیشرفته و ترکیبی برای پیش‌بینی تغییر خط، هنوز چند چالش اساسی وجود دارد. نخست آن‌که در بسیاری از تحقیقات، افق زمانی پیش‌بینی به‌طور شفاف مشخص نشده و این امر باعث شده ارزیابی عملکرد مدل‌ها تنها به معیارهایی مانند دقت کلی یا F1 محدود شود، در حالی‌که دقت واقعی در بازه‌های زمانی متفاوت (مثلاً یک ثانیه در مقایسه با پنج ثانیه قبل از مانور) می‌تواند به‌طور چشمگیری تغییر کند. دوم آن‌که، اگرچه مدل‌های ترکیبی توانایی بالاتری در استخراج ویژگی‌های فضایی و زمانی نشان داده‌اند، اما مقایسه‌ی مستقیم روش‌های کلاسیک مانند SVM با شبکه‌های عمیق‌تر نظیر LSTM در افق‌های زمانی کوتاه‌مدت هنوز به‌طور جامع بررسی نشده است. بنابراین، پژوهش حاضر با هدف پر کردن این شکاف، بر پیش‌بینی کوتاه‌مدت تغییر خط (۱ تا ۵ ثانیه پیش از مانور) مبتنی بر داده‌های میکروسکوپی مجموعه داده NGSIM و مقایسه‌ی عملکرد SVM و LSTM متمرکز شده است.

۳. روش پژوهش


قرار دارد. شماره گذاری خطوط از ۱ تا ۶ بوده و از سمت چپ ترین خط، خط ویژه خودروهای با سرنشین بالا HOV به سمت راست افزایش می یابد. مجموعه داده آزادراه I-80 شامل شش خط حرکت در بزرگراه است. این داده ها مسیر دقیق هر وسیله نقلیه را در خطوط مختلف محدوده مورد مطالعه، در بازه های زمانی یک دهم ثانیه، ثبت می کنند. گردآوری داده ها در ساعات اوج ترافیک انجام شده است تا بازه های مختلف تراکم ترافیکی شامل آغاز تراکم، گذار از حالت غیرمتراکم به متراکم، و تراکم کامل در زمان اوج به درستی بازنمایی شوند. این مجموعه داده در مجموع شامل ۴۵ دقیقه داده است که به سه بازه ۱۵ دقیقه ای تقسیم شده اند: از ساعت ۴:۰۰ تا ۴:۱۵ بعد از ظهر، از ۵:۰۰ تا ۵:۱۵، و از ۵:۱۵ تا ۵:۳۰ در تاریخ ۱۳ آوریل ۲۰۰۵ است.

واقع در منطقه خلیج سان فرانسیسکو و در شهر امری ویل، ایالت کالیفرنیا، جمع آوری شده اند. این مجموعه داده ها به صورت آزاد و رایگان از طریق وبسایت رسمی NGSIM در دسترس هستند (FHWA, 2016). داده ها مربوط به تردد وسایل نقلیه در مسیر شمالی آزادراه I-80 در منطقه امری ویل هستند. برای گردآوری داده ها، از دوربین های ویدیویی نصب شده در بالای ساختمانی ۳۰ طبقه به نام Pacific Park Plaza استفاده شده است. این ساختمان در نشانی ۶۳۶۳ Christie Avenue قرار دارد و در مجاورت مستقیم این آزادراه واقع شده است. محدوده مورد مطالعه حدوداً ۵۰۰ متر (۱۶۴۰ فوت) طول دارد و شامل یک رمپ ورودی در خیابان پاول است که در شکل ۲، ۱ با خط لوزی شکل مشخص شده است. رمپ ورودی خیابان اشبی (Ashby Avenue) نیز درست در پایین دست این محدوده



شکل ۱. طرح شماتیک منطقه مورد مطالعه و پوشش دوربین NGSIM I-80 (FHWA, 2016)

پیش‌بینی تغییر خط راننده در آزادراه‌ها با استفاده از شبکه عصبی بازگشتی با حافظه بلندمدت و ماشین بردار پشتیبان بر اساس داده‌های میکروسکوپی



شکل ۲. شناسه خط NGSIM I-80 (FHWA, 2016)

L_{id} شناسه خط فعلی که خودرو در آن قرار دارد.

V سرعت آنی خودرو.

ΔV سرعت نسبی بین نزدیک‌ترین خودروی جلویی و خودروی موردنظر.

SH فاصله مکانی (فضای خالی) بین نزدیک‌ترین خودروی جلویی و خودروی موردنظر.

SG_{lead} فاصله مکانی میان دو خودروی جلویی که یکی از دیگری نزدیک‌تر است.

Δx_{ego} فاصله جانبی خودرو نسبت به خط مرکزی خط‌فعلی.


۲-۳ متغیرهای تابع اصلی

بردار ویژگی (Feature Vector - FV) را می‌توان با استفاده از متغیرهای مشخصی در معادله تعریف کرد. در مجموع، ۶ متغیر برای توصیف محیط رانندگی در این بردار به‌کار رفته‌اند. لازم به ذکر است که در فرآیند طراحی مدل برای رانندگان مختلف، اندازه و ترکیب بردار ویژگی ممکن است بسته به نوع مسئله و هدف خاصی که مدل در پی حل آن است، تغییر کند.

دو نوع بردار ویژگی در این تحقیق معرفی شده‌اند:

$$FV = (L_{id}, V, \Delta V, SH, Acc, \Delta x_{ego})$$

توضیح متغیرهای استفاده‌شده در بردار ویژگی به شرح زیر است:



شکل ۳. تصویرسازی از وسیله نقلیه مورد نظر و وسایل نقلیه اطراف آن

به‌طور غیرمنطقی از خط ششم به خط هفتم (رمپ ورود) جابه‌جا شده‌اند؛ حال آنکه چنین مانوری در شبکه مورد مطالعه امکان‌پذیر نیست. این خطاها عمدتاً ناشی از ناپایداری حرکات لحظه‌ای خودروها هنگام ورود از رمپ به خط اصلی و بازگشت موقتی به خط ورودی بوده است که در داده‌ها به‌صورت تغییر خط ۶ به ۷ ثبت شده است. برای رفع این مشکل، با استفاده از کدنویسی در محیط Python و

۳-۳ پیش‌پردازش داده‌ها

استفاده مستقیم از داده‌های خام مجموعه‌داده NGSIM به دلیل وجود برخی ناهنجاری‌ها و کاستی‌ها امکان‌پذیر نیست. به همین دلیل، فرایند پیش‌پردازش داده‌ها در دو مرحله اصلی انجام شد:

۱. شناسایی و حذف خطاهای ثبت موقعیت و خط حرکتی: در بررسی داده‌های خام مشاهده گردید که در موارد محدودی (۴۳ رکورد از مجموع حدود ۴,۵ میلیون رکورد) خودروها

به‌کارگیری توابع پردازش داده در کتابخانه‌ی Pandas، داده‌های اصلی بازیابی و موارد نویزی حذف شدند تا کیفیت و اعتبار داده‌ها افزایش یابد. در خطوط دیگر نیز این موارد مشاهده شد و آنها نیز حذف گردید.

۲. استخراج سرعت خودروهای پیشرو: در داده‌های NGSIM تنها سرعت خودروها به‌صورت مستقیم ثبت شده بود، در حالی که برای تحلیل رفتار تغییر خط، اطلاع از سرعت خودروهای پیشرو (Preceding Vehicle) نیز ضروری بود. از آنجا که شناسه (ID) خودروهای پیشرو در داده‌های اصلی موجود بود، با بهره‌گیری از کدنویسی در Python 3.11 و ابزار Pandas 2.0، TensorFlow 2.x سرعت این خودروها استخراج و به داده‌ها اضافه گردید. لازم به ذکر است که به‌دلیل حجم بالای داده‌ها، استفاده از نرم‌افزارهای متداولی مانند Microsoft Excel یا Access امکان‌پذیر نبود؛ زیرا این نرم‌افزارها حداکثر توانایی پردازش حدود یک میلیون رکورد را دارند. در حالی که در این پژوهش، حجم داده‌ها حدود ۴٫۵ میلیون رکورد بوده و پردازش آن با استفاده از رایانه‌ای با پردازنده Intel Core i5 و حافظه RAM برابر با ۴۸ گیگابایت، حدود ۱۵ دقیقه به طول انجامید.

۳-۴ تنظیم پارامترهای مدل‌ها

در مدل ماشین بردار پشتیبان (SVM)، سه نوع هسته Linear، Polynomial و RBF بررسی گردید. نتایج نشان داد که هسته

RBF به دلیل توانایی بالاتر در مدل‌سازی روابط غیرخطی انتخاب مناسب‌تری است. همچنین پارامترهای کلیدی C و γ در بازه‌های وسیع مورد آزمون قرار گرفتند و مقادیر بهینه با استفاده از Grid Search همراه با اعتبارسنجی متقاطع پنج‌تایی (5-Fold Cross Validation) تعیین شدند. مقادیر نهایی $C=10$ و $\gamma=0.01$ بهترین تعادل میان بایاس و واریانس را فراهم کردند (جدول ۱).

در مدل شبکه عصبی بازگشتی LSTM، چندین معماری مختلف شامل تعداد لایه‌ها، تعداد واحدهای حافظه، طول توالی ورودی (Time Steps) و میزان Dropout بررسی شد. نتایج نشان داد که معماری دو لایه LSTM با ۱۲۸ واحد حافظه در هر لایه و نرخ Dropout برابر با ۰٫۲۵، بهترین عملکرد را در پیش‌بینی تغییر خط ارائه می‌دهد. الگوریتم بهینه‌سازی Adam با نرخ یادگیری ۰٫۰۰۱ انتخاب شد که نسبت به سایر بهینه‌سازها همگرایی سریع‌تر و پایدارتر داشت. همچنین از Early Stopping بر اساس شاخص F1 برای جلوگیری از بیش‌برازش استفاده شد. اندازه Batch برابر با ۱۲۸ و تعداد Epoch معادل ۵۰ تعیین شد (جدول ۲).

به‌طور کلی، در هر دو مدل برای انتخاب مقادیر بهینه ابتدا از جستجوی تصادفی برای محدود کردن دامنه مقادیر استفاده گردید و سپس Grid Search برای شناسایی ترکیب نهایی پارامترها به کار گرفته شد. معیار اصلی انتخاب پارامترها امتیاز F1 بود تا تعادل میان دقت (Precision) و بازخوانی (Recall) در شرایط داده‌های نامتوازن حفظ شود.

جدول ۱. تنظیم پارامترهای مدل ماشین بردار پشتیبان (SVM)

مدل	پارامتر	محدوده/گزینه‌های بررسی شده	مقدار انتخاب شده	توضیحات
SVM	Kernel	Linear, Polynomial, RBF	RBF	برای داده‌های غیرخطی مناسب‌تر است
	C	۰٫۰۱-۱۰۰	۱۰	کنترل جریمه خطای دسته‌بندی
	γ (Gamma)	۰٫۰۰۱-۱	۰٫۰۱	تعیین تأثیر نمونه‌ها در فضای ویژگی
	روش انتخاب	Grid Search + 5-Fold CV	—	ترکیب C و γ بهینه انتخاب شد

پیش‌بینی تغییر خط راننده در آزادراه‌ها با استفاده از شبکه عصبی بازگشتی با حافظه بلندمدت و ماشین بردار پشتیبان بر اساس داده‌های میکروسکوپی

جدول ۲. تنظیم پارامترهای مدل شبکه عصبی بازگشتی با حافظه بلندمدت (LSTM)

مدل	پارامتر	محدوده/گزینه‌های بررسی شده	مقدار انتخاب شده	توضیحات
LSTM	تعداد لایه‌ها	۱ تا ۳	۲	دو لایه LSTM بهینه‌تر بود
	تعداد واحدها (Units)	۶۴، ۱۲۸، ۲۵۶	۱۲۸	تعادل بین دقت و هزینه محاسباتی
	طول توالی (Time Steps)	۱۰-۵۰ فریم	۲۰ فریم (۲ ثانیه)	ورودی از داده‌های گذشته
	Dropout	۰/۵-۰/۱	۰/۲۵	جلوگیری از بیش‌برازش
	Optimizer	Adam ، RMSprop, SGD	Adam	نرخ یادگیری ۰,۰۰۱
	Batch Size	۳۲، ۶۴، ۱۲۸، ۲۵۶	۱۲۸	انتخاب براساس سرعت و دقت
	Epochs	۱۰۰-۳۰۰	۵۰	Early Stopping بر اساس F1
	روش انتخاب	Random Search + Grid Search	—	انتخاب بهترین ترکیب پارامترها

پیش‌بینی کرده است، در حالی که خودرو در خط خود باقی مانده است.

پیش‌بینی‌های نادرست منفی (False Negatives - fn) مواردی هستند که مدل نتوانسته تغییر خط واقعی (چه به چپ و چه به راست) را شناسایی کند. فرمول‌های ارزیابی به شرح زیر هستند:

$$Precision = PR = \frac{tp}{tp + fp} \quad (2)$$

$$Recall = RE = \frac{tp}{tp + fn} \quad (3)$$

$$F1-score = \frac{2PR.RE}{PR + RE} \quad (4)$$

این معیارها برای ارزیابی عملکرد مدل پیش‌بینی تغییر خط مورد استفاده قرار گرفته‌اند تا تعادل میان دقت و بازخوانی حفظ شود، به‌ویژه در سناریوهایی که توزیع کلاس‌ها نامتوازن است (مانند تعداد کمتر نمونه‌های تغییر خط نسبت به ماندن در خط). برای هر دو مدل شبکه عصبی، داده‌ها به نسبت ۷۰٪ آموزش و ۳۰٪ آزمون تقسیم شدند.

۴. تحلیل داده‌ها

جدول ۳ حاضر ویژگی‌های کلیدی استخراج شده از مجموعه داده NGSIM را نشان می‌دهد. در داده‌های خام آمریکا داده‌ها به واحد

۳-۵ ارزیابی و صحت سنجی پیش‌بینی

میانگین مربع خطا (Mean Square Error - MSE) به عنوان یکی از معیارهای ارزیابی عملکرد مدل شبکه عصبی مورد استفاده قرار گرفته است. این معیار با استفاده از رابطه زیر محاسبه می‌شود:

$$MSE = \frac{1}{N} \sum_{i=1}^N (OB_i - OP_i)^2 \quad (1)$$

که در آن:

OB نمایانگر تصمیم واقعی (مشاهده شده) برای تغییر خط است، OP احتمال پیش‌بینی شده توسط مدل برای تغییر خط است، N تعداد کل نمونه‌ها در مجموعه داده است.

این معیار میزان انحراف پیش‌بینی مدل از مقادیر واقعی را به صورت میانگین مربع خطا اندازه‌گیری می‌کند؛ هر چه مقدار MSE کمتر باشد، عملکرد مدل بهتر تلقی می‌شود. امتیاز F1 شامل دو کلاس مثبت (تغییر خط به چپ و تغییر خط به راست) و یک کلاس منفی (ثبات در خط فعلی) شود.

پیش‌بینی‌های درست مثبت (True Positives - tp) شامل پیش‌بینی‌های صحیح از تغییر خط به چپ یا راست هستند.

پیش‌بینی‌های نادرست مثبت (False Positives - fp)

پیش‌بینی‌های نادرستی هستند که مدل به اشتباه تغییر خط را

نوسان دارد و نشان‌دهنده آن است که به‌طور میانگین خودروها با سرعتی نزدیک به سرعت خودروی جلویی حرکت می‌کنند. شتاب خودروها عمدتاً در بازه $-۳,۴$ تا $۳,۴$ متر بر مجذور ثانیه قرار دارد. همچنین، سرفاصله مکانی (SH) میانگین حدود $۱۶,۵$ متر و سرفاصله زمانی میانگین $۲,۹۸$ ثانیه (براساس میانه) را نشان می‌دهد.

فوت است که با تبدیل واحد به متر به شکل استاندارد درآمد است. با تبدیل واحد به همان‌گونه که مشاهده می‌شود، میانگین طول خودروها حدود $۴,۹$ متر و میانگین عرض آن‌ها $۲,۰۸$ متر است که با واقعیت ناوگان خودرویی مطابقت دارد. سرعت آنی وسایل نقلیه در بازه ۰ تا حدود ۲۹ متر بر ثانیه (معادل تقریباً ۱۰۴ کیلومتر بر ساعت) متغیر است. سرعت نسبی (ΔV) حول صفر

جدول ۳. آمار توصیفی متغیرهای کلیدی

متغیر	نماد	count	mean	std	min	max	median
طول خودرو به متر	v_length	۴۵۶۶۳۸۷	۴/۹۱۲	۲/۲۲۹	۱/۴۹۴	۲۳/۶۸۳	۴/۵۱۱
عرض خودرو به متر	v_Width	۴۵۶۶۳۸۷	۲/۰۸۹	۰/۲۶۶	۰/۸۲۳	۲/۵۹۱	۲/۱۰۳
سرعت آنی متر بر ثانیه	v	۴۵۶۶۳۸۷	۴/۸۹۷	۴/۰۱۵	۰/۰۰۰	۲۹/۰۴۷	۵/۴۶۲
سرعت خودرو جلویی متر بر ثانیه	v_Lead	۴۵۶۶۳۸۷	۵/۸۴۳	۳/۹۷۴	۰/۰۰۰	۲۹/۰۴۷	۵/۴۱۰
سرعت نسبی متر بر ثانیه	ΔV	۴۵۶۶۳۸۷	-۰/۰۱۰	۱/۵۷۶	-۲۷/۵۶۰	۲۹/۰۴۷	۰/۰۰۰
شتاب خودرو متر بر مجذور ثانیه	Acc	۴۵۶۶۳۸۷	۰/۰۰۲	۱/۴۴۹	-۳/۴۱۴	-۳/۴۱۴	۰/۰۰۰
شتاب خودرو جلوی متر بر مجذور ثانیه	Acc_Lead	۴۵۶۶۳۸۷	۰/۰۰۲	۱/۴۴۱	-۳/۴۱۴	-۳/۴۱۴	۰/۰۰۰
شماره خط	L_id	۴۵۶۶۳۸۷	۳/۸۳۳	۱/۶۸۱	۱/۰۰۰	۷/۰۰۰	۴/۰۰۰
سرفاصله مکانی به متر	Space_Headway(SH)	۴۵۶۶۳۸۷	۱۶/۵۶۷	۱۱/۳۵۵	۰/۵۴۰	۴۰۲/۸۰۸	۱۴/۱۳۷
سرفاصله زمانی به ثانیه	Time_Headway	۴۵۶۶۳۸۷	۳/۱۵۵	۱۹۹/۹	۰/۵۷۸	۱۱۷۳/۹۰	۲/۹۸۰
فاصله جانبی به متر	Δx_{ego}	۴۵۶۶۳۸۷	۳/۵۶۰	۰/۵۴۱	۰/۰۱۲	۷/۲۳۵	۳/۶۷۸

وضعیت معکوس است؛ یعنی خودروها فقط می‌توانند به سمت چپ تغییر خط دهند و نه راست، بنابراین تغییر خط به سمت چپ در این خط نیز ۱۰۰% به راست است. در مورد on-ramp (رمپ ورودی آزادراه)، تمامی تغییر خطوط به صورت اجباری و به سمت چپ هستند؛ زیرا خودروها برای ورود به آزادراه باید از رمپ به مسیر اصلی وارد شوند. به همین دلیل، هر دو مقدار راست و چپ در این ناحیه ۱۰۰% گزارش شده‌اند، یعنی خودرو در این خط حتماً تغییر خط می‌دهد که ناشی از الزامی بودن تغییر مسیر در این موقعیت است. برای خطوط میانی (از خط ۲ تا ۵)، الگوی کلی تمایل به تغییر خط به سمت چپ


شکل ۴ درصد تغییر خط وسایل نقلیه به سمت راست و سمت چپ را در خطوط مختلف آزادراه نمایش می‌دهد. محور افقی نشان‌دهنده شماره خط (از ۱ تا ۶) و نیز رمپ ورود (on-ramp) است، و محور عمودی، درصد تغییر خط را برای هر جهت (چپ و راست) نشان می‌دهد. در خط 1 که در لبه چپ آزادراه قرار دارد، هیچ خط‌دیگری در سمت چپ وجود ندارد؛ بنابراین تمام تغییر خطوط ممکن فقط به سمت راست صورت می‌گیرند. همان‌طور که نمودار نشان می‌دهد، در این خط، درصد تغییر خط به سمت راست ۱۰۰% و به سمت چپ صفر است. در مقابل، در خط ۶ که در لبه راست آزادراه واقع شده است،

پیش‌بینی تغییر خط راننده در آزادراه‌ها با استفاده از شبکه عصبی بازگشتی با حافظه بلندمدت و ماشین بردار پشتیبان بر اساس

داده‌های میکروسکوپی

می‌دهد. در این زمان‌ها، رانندگان برای افزایش سرعت و کاهش زمان سفر، سعی می‌کنند به خطوط چپ‌تر منتقل شوند.


معمولاً بیشتر از سمت راست قابل مشاهده است. این رفتار احتمالاً به دلیل ترجیح رانندگان برای حرکت به خطوط سریع‌تر در سمت چپ آزادراه، به‌ویژه در ساعات اوج ترافیک، رخ



شکل ۴. درصد تغییر خط به چپ و راست در هر لاین

می‌رود. در خطوط سمت چپ، به‌ویژه خط ۱، درصد تغییر خط نسبتاً پایین است. دلیل این موضوع می‌تواند این باشد که این خطوط معمولاً برای رانندگی با سرعت بالا استفاده می‌شوند و خودروهایی که وارد این خطوط می‌شوند، تمایلی به تغییر مجدد خط ندارند. نزدیکی خطوط ۵ و ۶ به رمپ‌های ورود و خروج نیز می‌تواند عاملی برای افزایش تغییر خط در این خط‌ها باشد؛ زیرا رانندگان در این موقعیت‌ها بیشتر درگیر مانورهای لازم برای ورود یا خروج از آزادراه هستند. شکل ۵ به‌خوبی نشان می‌دهد که تمایل به تغییر خط در خط‌های راست آزادراه بیشتر است. این یافته برای طراحی سیستم‌های هشدار تغییر خط و بهینه‌سازی الگوریتم‌های پیش‌بینی بسیار مهم است؛ زیرا نشان می‌دهد مدل‌ها باید حساسیت بیشتری به موقعیت‌های سمت راست آزادراه داشته باشند که در آن‌ها تغییر خط محتمل‌تر است.

شکل ۵ درصد کل تغییرات خط را در هر یک از شش خط (خطوط) آزادراه نشان می‌دهد. محور افقی، شماره خط را از ۱ (چپ‌ترین خط) تا ۶ (راست‌ترین خط) نمایش می‌دهد و محور عمودی، درصد تغییر خط را برای هر خط مشخص کرده است. با افزایش شماره خط (از خط ۱ به سمت خط ۶)، درصد تغییر خط افزایش می‌یابد. این روند نشان می‌دهد که هرچه خودرو به سمت راست آزادراه نزدیک‌تر باشد (خط‌های شماره ۵ و ۶)، احتمال تغییر خط بیشتر است. این مسئله می‌تواند به دلایلی باشد. رانندگانی که از رمپ‌های ورودی وارد آزادراه می‌شوند، تمایل دارند برای افزایش سرعت و پیوستن به جریان اصلی ترافیک، به خطوط میانی یا چپ منتقل شوند. در خطوط راست، به‌ویژه خط ۶، بیشتر خودروها قصد دارند به خطوط سریع‌تر در سمت چپ حرکت کنند؛ در نتیجه نرخ تغییر خط بالا



شکل ۵. درصد تغییر خط در خط

بازخوانی (Recall): نسبت صحیح پیش‌بینی شده از بین مواردی که واقعاً تغییر خط رخ داده است. امتیاز F1: میانگینی موزون از دقت (Precision) و بازخوانی (Recall) که نشان‌دهنده تعادل بین این دو معیار است. پیش‌بینی‌ها در بازه‌های زمانی ۱ تا ۵ ثانیه پیش از وقوع تغییر خط انجام شده‌اند تا تأثیر افق زمانی بر عملکرد مدل‌ها سنجیده شود.

جدول ۴ زیر عملکرد دو مدل هوش مصنوعی، یعنی ماشین بردار پشتیبان (SVM) و شبکه عصبی بازگشتی با حافظه بلندمدت (LSTM) را در پیش‌بینی تغییر خط راننده در بازه‌های زمانی مختلف قبل از وقوع مانور بررسی می‌کند. برای ارزیابی مدل‌ها، از سه شاخص کلیدی استفاده شده است: میانگین مربع خطا (MSE) که نشان‌دهنده میزان انحراف پیش‌بینی مدل نسبت به مقدار واقعی است. هر چه MSE کمتر باشد، دقت پیش‌بینی بیشتر است.

جدول ۴. ارزیابی کارایی و دقت مدل‌ها پیش‌بینی تغییر خط

مدل هوش مصنوعی	زمان قبل از تغییر خط (ثانیه)	MSE	Recall	F1
SVM	۱	۰/۰۸	۰/۸۱	۰/۸۳
	۲	۰/۱	۰/۷۸	۰/۸
	۳	۰/۱۴	۰/۷۱	۰/۷۴
	۴	۰/۱۸	۰/۶۳	۰/۶۷
	۵	۰/۲۳	۰/۵۵	۰/۵۹
LSTM	۱	۰/۰۴	۰/۹۱	۰/۹۲
	۲	۰/۰۶	۰/۸۹	۰/۹
	۳	۰/۰۹	۰/۸۵	۰/۸۷
	۴	۰/۱۳	۰/۷۹	۰/۸۱
	۵	۰/۱۷	۰/۷۴	۰/۷۷

پیش‌بینی تغییر خط راننده در آزادراه‌ها با استفاده از شبکه عصبی بازگشتی با حافظه بلندمدت و ماشین بردار پشتیبان بر اساس

داده‌های میکروسکوپی

منظور، مدل ماشین بردار پشتیبان (SVM) به‌عنوان یک روش کلاسیک و شبکه عصبی بازگشتی با حافظه بلندمدت (LSTM) به‌عنوان یک روش مبتنی بر یادگیری عمیق طراحی و ارزیابی گردیدند. نتایج نشان داد که LSTM به دلیل توانایی درک وابستگی‌های زمانی در داده‌های رفتاری، عملکرد دقیق‌تر و پایاتری نسبت به SVM ارائه می‌دهد و به‌ویژه در بازه‌های کوتاه‌مدت یک تا سه ثانیه پیش از تغییر خط، با دقت و امتیاز F1 بالاتر، رفتار رانندگان را به‌درستی پیش‌بینی می‌کند. در مقابل، گسترش افق زمانی پیش‌بینی تا پنج ثانیه باعث کاهش دقت و افزایش خطا شد؛ موضوعی که نشان‌دهنده محدودیت‌های اساسی در مدل‌سازی رفتارهای آینده‌نگر است. آنچه این پژوهش را متمایز می‌سازد، ترکیب دو جنبه مهم است: از یک‌سو مقایسه هم‌زمان روش‌های کلاسیک و یادگیری عمیق در یک چارچوب واحد و مبتنی بر داده‌های واقعی میکروسکوپی، و از سوی دیگر توجه به افق‌های زمانی متوالی به‌جای یک بازه ثابت. افزون بر این، تحلیل آماری رفتار رانندگان در خطوط مختلف آزادراه نشان داد که تمایل به تغییر خط در خطوط راست بیشتر و در رمپ‌های ورودی به‌صورت اجباری رخ می‌دهد، در حالی که در خطوط چپ احتمال تغییر خط کمتر است. ارائه جزئیات کامل در زمینه پیش‌پردازش داده‌ها، مدیریت داده‌های پرت و تنظیم پارامترهای مدل‌ها نیز شفافیت و بازتولیدپذیری یافته‌ها را افزایش داده است. به‌طور کلی، نتایج این تحقیق بیانگر آن است که بهره‌گیری از داده‌های میکروسکوپی در کنار رویکردهای یادگیری عمیق می‌تواند به پیش‌بینی دقیق‌تر رفتارهای پیچیده رانندگان کمک کند و زمینه‌ساز بهبود سامانه‌های کمک‌راننده پیشرفته و توسعه فناوری‌های خودروهای نیمه‌خودران و خودران باشد.

۶. پی‌نوشت‌ها

1. NGSIM – Next Generation Simulation Dataset
2. SVM – Support Vector Machine
3. LSTM – Long Short-Term Memory
4. ANN – Artificial Neural Network

مدل LSTM در تمامی شاخص‌های MSE، Recall و F1 عملکرد بهتری نسبت به مدل SVM دارد. این برتری به‌ویژه در بازه‌های زمانی کوتاه‌تر (۱ تا ۳ ثانیه) بسیار چشم‌گیرتر است. دلیل این عملکرد بهتر، توانایی LSTM در مدل‌سازی وابستگی‌های زمانی و به‌خاطر سپردن اطلاعات گذشته در توالی‌های زمانی است. با افزایش فاصله زمانی تا وقوع تغییر خط (از ۱ به ۵ ثانیه)، عملکرد هر دو مدل به‌تدریج کاهش می‌یابد. این روند در MSE به‌صورت افزایش خطا و در Recall و F1 به‌صورت کاهش مقادیر دیده می‌شود. این کاهش طبیعی است، زیرا با دور شدن از لحظه وقوع مانور، نشانه‌های رفتاری راننده کمتر قابل تشخیص هستند. مدل SVM نسبت به افزایش بازه زمانی حساس‌تر است و کاهش عملکرد آن شیب تندتری دارد؛ در حالی که LSTM توانایی خود را در بازه‌های بلندتر تا حدودی حفظ می‌کند. این نشان می‌دهد که مدل‌های مبتنی بر حافظه زمانی برای پیش‌بینی‌های زود هنگام مؤثرتر هستند. هر دو مدل در زمان‌های نزدیک به تغییر خط (۱ تا ۲ ثانیه) بهترین عملکرد را دارند. در این بازه‌ها، LSTM به دقت F1 بیش از ۹۰٪ و MSE کمتر از ۰,۰۶ دست می‌یابد که نشان‌دهنده قابلیت عملیاتی برای سیستم‌های هشدار زود هنگام است. مدل LSTM به‌طور قابل توجهی نسبت به SVM در پیش‌بینی رفتار تغییر خط دقیق‌تر عمل می‌کند، به‌ویژه در بازه‌های زمانی کوتاه که برای کاربردهای ایمنی در خودروهای نیمه‌خودران حیاتی است. همچنین مشخص شد که هرچه پیش‌بینی زودتر انجام شود (مثلاً ۴ یا ۵ ثانیه قبل)، چالش مدل‌سازی بیشتر شده و خطا افزایش می‌یابد. بنابراین، انتخاب مدل و تعیین بازه زمانی مناسب، دو عامل کلیدی در طراحی سیستم‌های پیش‌بینی مانورهای رانندگی هستند.

۵. نتیجه‌گیری

در این پژوهش، مسئله پیش‌بینی تغییر خط رانندگان در آزادراه با استفاده از داده‌های میکروسکوپی دقیق مجموعه داده NGSIM و دو رویکرد یادگیری ماشین بررسی شد. برای این

<https://doi.org/https://doi.org/10.48130/DTS-2023-0009>

– Geng, B., Ma, J., & Zhang, S. (2023). Ensemble deep learning-based lane-changing behavior prediction of manually driven vehicles in mixed traffic environments. *Electronic Research Archive*, 31(10).

– Han, L., Ma, X., Wang, Y., He, L., Li, Y., Zhang, L., & Yi, Q. (2025). Safe and Efficient DRL Driving Policies Using Fuzzy Logic for Urban Lane Changing Scenarios. *Journal of Intelligent and Connected Vehicles*, 8(1), 1–13. <https://doi.org/https://doi.org/10.1109/DDCLS66240.2025.11065182>

– He, C., Jiang, W., Li, J., Wei, J., Guo, J., & Zhang, Q. (2024). Fuzzy Logic-Based Autonomous Lane Changing Strategy for Intelligent Internet of Vehicles: A Trajectory Planning Approach. *World Electric Vehicle Journal*, 15(9), 403.

– Huo, D., Ma, J., & Chang, R. (2020). Lane-changing-decision characteristics and the allocation of visual attention of drivers with an angry driving style. *Transportation research part F: traffic psychology and behaviour*, 71, 62–75.

<https://doi.org/https://doi.org/10.1016/j.trf.2020.03.008>

– Jin, L., Liu, X., Wang, Y., Han, Z., Guo, B., Luo, G., & Xu, X. (2024). Multi-modality trajectory prediction with the dynamic spatial interaction among vehicles under connected vehicle environment. *Scientific Reports*, 14(1), 2873.

<https://doi.org/https://doi.org/10.1038/s41598-024-53315-6>

– Kim, H., Hong, J., & Lee, S. (2024). Investigating impact of situation awareness-based displays of semi-autonomous driving in

5. MSE – Mean Squared Error

6. RMSE – Root Mean Squared Error

7. F1-score – F1 Score (Harmonic Mean of Precision and Recall)

8. Precision – Positive Predictive Value

9. Recall – Sensitivity or True Positive Rate

10. RBF – Radial Basis Function

11. CV – Cross Validation

12. ID – Identifier

13. ΔV – Relative Speed (Difference between ego and preceding vehicle speed)

14. SH – Space Headway

15. Time Headway – Time Headway

۷. مراجع

– Ali, Y., Zheng, Z., Haque, M. M., & Wang, M. (2019). A game theory-based approach for modelling mandatory lane-changing behaviour in a connected environment. *Transportation Research Part C: Emerging Technologies*, 106, 220–242.

<https://doi.org/https://doi.org/10.1016/j.trc.2019.07.011>

– Altché, F., & de La Fortelle, A. (2017). An LSTM network for highway trajectory prediction. 2017 IEEE 20th international conference on intelligent transportation systems (ITSC).

– Díaz-Álvarez, A., Clavijo, M., Jiménez, F., & Serradilla, F. (2021). Inferring the driver's lane change intention through lidar-based environment analysis using convolutional neural networks. *Sensors*, 21(2), 475.

– FHWA. (2016). Next Generation Simulation (NGSIM) Program I-80 Videos. Provided by ITS DataHub through Data.transportation.gov. <https://doi.org/http://doi.org/10.21949/1504477>

– Fu, X., Liu, J., Huang, Z., Hainen, A., & Khattak, A. J. (2023). LSTM-based lane change prediction using Waymo open motion dataset: The role of vehicle operating space. *Digital Transportation and Safety*, 2(2), 112–123.

- Raufi, P., & Maniat, M. (2024). Novel Calibration Approach for Freeway Traffic Models in Single and Multi-Regimes Fundamental Diagram.
- Raufi, P., & Maniat, M. (2024). Transport Policy's Impact on Auto Emissions: A Critical Review. Available at SSRN 4719317.
- Salvucci, D. D., & Liu, A. (2002). The time course of a lane change: Driver control and eye-movement behavior. *Transportation research part F: traffic psychology and behaviour*, 5(2), 123–132.
- Wirthmüller, F., Klimke, M., Schlechtriemen, J., Hipp, J., & Reichert, M. (2021). Predicting the time until a vehicle changes the lane using LSTM-based recurrent neural networks. *IEEE Robotics and Automation Letters*, 6(2), 2357–2364.
<https://doi.org/https://doi.org/10.1109/LRA.2021.3058930>
- Xiao, Y., Wu, W., Zhai, C., Zhai, M., & Zhang, J. (2025). Analysis of empirical lane-changing rate effect on multi-lane traffic on curved roads. *Chinese Journal of Physics*, 95, 260–274.
<https://doi.org/https://doi.org/10.1016/j.cjph.2025.01.041>
- Xing, Y., Lv, C., Wang, H., Cao, D., & Velenis, E. (2020). An ensemble deep learning approach for driver lane change intention inference. *Transportation Research Part C: Emerging Technologies*, 115, 102615.
<https://doi.org/https://doi.org/10.1016/j.trc.2020.102615>
- Zhang, K., Pu, T., Zhang, Q., & Nie, Z. (2024). Coordinated Decision Control of Lane-Change and Car-Following for Intelligent Vehicle Based on Time Series Prediction and urgent situations. *Transportation research part F: traffic psychology and behaviour*, 105, 454–472.
<https://doi.org/https://doi.org/10.1016/j.trf.2024.07.018>
- Li, Z., Zhao, X., Zhao, C., Liu, Y., & Wang, C. (2024). A Self-Selection Personalized Lane-Changing Trajectory Prediction Approach Through a Hybrid Deep Learning Model. *IEEE Transactions on Vehicular Technology*.
<https://doi.org/https://doi.org/10.1109/TVT.2024.3457917>
- Liang, K., Wang, J., & Bhalerao, A. (2022). Lane change classification and prediction with action recognition networks. *European Conference on Computer Vision*.
- Lyu, Y., Wang, Y., Liu, H., Dong, X., He, Y., & Ren, Y. (2025). A Driving-Preference-Aware Framework for Vehicle Lane Change Prediction. *Sensors*, 25(17), 5342.
- Ma, C., & Li, D. (2023). A review of vehicle lane change research. *Physica A: Statistical Mechanics and its Applications*, 626, 129060.
<https://doi.org/https://doi.org/10.1016/j.physa.2023.129060>
- Madigan, R., Louw, T., & Merat, N. (2018). The effect of varying levels of vehicle automation on drivers' lane changing behaviour. *PloS one*, 13(2), e0192190.
- Maniat, M. (2024). Introduction of Discourse Analysis in Transportation: A Framework for Understanding Policy and Practice in Urban Mobility.
- Maniat, M., & Eebrahimzadeh, A. (2024). Enhancing Traffic Prediction Accuracy: A Comparative Analysis of Data Quality and Model Evaluation Using Artificial Intelligence.

Deep Reinforcement Learning. Sensors, 24(2), 403.

– Zhou, D., Chen, Y., Fan, K., Bai, Q., Luo, Y., & Xie, G. (2025). Research on Vehicle Lane Change Intent Recognition Based on Transformers and Bidirectional Gated Recurrent Units. World Electric Vehicle Journal, 16(3), 155.

پیش‌بینی تغییر خط راننده در آزادراه‌ها با استفاده از شبکه عصبی بازگشتی با حافظه بلندمدت و ماشین بردار پشتیبان بر اساس

داده‌های میکروسکوپی

محمد منیعات، دانش‌آموخته‌ی کارشناسی ارشد گروه مهندسی عمران گرایش حمل و نقل، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی است. در حال حاضر در حال تحصیل در مقطع دکترای در همین رشته در این دانشگاه است. زمینه‌های پژوهشی مورد علاقه ایشان شامل ایمنی ترافیک، تحلیل رفتار رانندگان، اقتصاد حمل و نقل و مدل‌سازی داده‌محور، روش‌های تصمیم‌گیری، هوش مصنوعی، تحلیل گفتمان، طراحی شهری در حمل و نقل می‌باشد و همچنین عضو هیئت داور ۲۰۲۵ ژورنال لهستانی Transport Problems و داور چندین ژورنال ISI و اسکوپس دیگر هستند.



دکتر محمود صفارزاده تحصیلات کارشناسی خود را در رشته مهندسی عمران از دانشگاه شهید باهنر کرمان و در مقطع کارشناسی ارشد گرایش حمل و نقل، دانشگاه کارلتون کانادا و در مقطع دکترای گرایش راه و ترابری با گرایش برنامه ریزی و طراحی فرودگاه از دانشگاه کارلتون کانادا و هم اکنون استاد دانشگاه تربیت مدرس است. سوابق آموزشی وی تدریس دروس برنامه ریزی و طراحی فرودگاه، مهندسی پایانه‌های حمل و نقل، مهندسی ترافیک، مهندسی ترابری، کاربرد کامپیوتر در برنامه ریزی و مدیریت فرودگاه، مهندسی سیستم‌های حمل و نقل، طرح هندسی پیشرفته راه در دانشگاه‌های تربیت مدرس، صنعتی شریف، صنعتی امیرکبیر است.



دکتر حسن ذوقی، استادیار، گروه مهندسی عمران، واحد کرج، دانشگاه آزاد اسلامی است. زمینه‌های پژوهشی ایشان شامل مهندسی ترافیک، زیرساخت‌های حمل و نقل و تحلیل سیستم‌های جاده‌ای می‌باشد.



دکتر علیرضا سرکار هم‌اکنون استادیار گروه مهندسی عمران راه و ترابری در دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران هستند. زمینه‌های آموزشی و پژوهشی دکتر سرکار شامل تحلیل و طراحی روسازی راه‌ها، فناوری و مواد روسازی، و مهندسی ترافیک می‌باشد. حوزه‌های تحقیقاتی مورد علاقه‌ی ایشان نیز شامل بهبود عملکرد مخلوط‌های آسفالتی با افزودنی‌های پلیمری و الیافی، ارزیابی رفتار دمایی و رطوبتی روسازی، مدل‌سازی جریان ترافیکی، و توسعه روش‌های نوین نگهداری راه در شرایط اقلیمی ایران است. همچنین دکتر سرکار به‌عنوان داور علمی چندین نشریه تخصصی داخلی و بین‌المللی فعالیت دارند.

