

ارائه روشی مبتنی بر الگوریتم‌های یادگیری ماشین برای پیش‌بینی تراکم ترافیک در شبکه‌های خودرویی هوشمند (VANET)

محمد حسین شفیق آبادی^{۱*}، فاطمه حسین زاده^۲

۱- گروه مهندسی کامپیوتر، واحد اسلامشهر، دانشگاه آزاد اسلامی، اسلامشهر، ایران

۲- گروه مهندسی کامپیوتر، واحد اسلامشهر، دانشگاه آزاد اسلامی، اسلامشهر، ایران

چکیده

با گسترش شهرنشینی، پیش‌بینی تراکم ترافیک در شبکه‌های موردی خودرویی به چالشی بنیادین در سامانه‌های حمل‌ونقل هوشمند تبدیل شد. این پژوهش با هدف پر کردن شکاف‌های موجود، روشی نوین و ترکیبی مبتنی بر الگوریتم‌های یادگیری عمیق را برای پیش‌بینی بلادرنگ تراکم ترافیک ارائه داد. مدل پیشنهادی با تلفیق هوشمندانه شبکه‌های عصبی پیچشی و حافظه کوتاه‌مدت طولانی، وابستگی‌های پیچیده مکانی و توالی‌های زمانی را به‌صورت هم‌زمان مدل‌سازی کرد. داده‌های پژوهش از طریق شبیه‌سازی محیط واقعی شبکه‌های خودرویی جمع‌آوری و با روش‌های پیش‌پردازش و مهندسی ویژگی آماده‌سازی شدند. یافته‌های آماری نشان دادند که روش ترکیبی با دستیابی به ریشه میانگین مربعات خطای ۳/۸۴ و ضریب تعیین ۰/۹۶، دقت بالاتری نسبت به مدل‌های کلاسیک داشت. در افق کوتاه‌مدت پنج دقیقه‌ای، دقت پیش‌بینی ۹۶٪ رسید و با افزایش افق زمانی، خطا به تدریج افزایش یافت. مدل در شرایط ترافیکی عادی پایداری بالایی نشان داد، اما در تراکم بحرانی نیازمند بهینه‌سازی تکمیلی بود. همچنین، زمان پیش‌بینی هر نمونه ۵۲ میلی‌ثانیه به دست آمد که در محدوده استاندارد تأخیر مجاز قرار گرفت. این چارچوب مقیاس‌پذیر به‌عنوان هسته پردازشی برای تصمیمات پیش‌دستانه در مدیریت ترافیک شهری مورد بهره‌برداری قرار گرفت.

واژگان کلیدی:

شبکه‌های موردی خودرویی، پیش‌بینی تراکم ترافیک، یادگیری عمیق، شبکه‌های عصبی پیچشی، حافظه کوتاه‌مدت طولانی، سامانه‌های حمل‌ونقل هوشمند.

مقدمه :

امروزه با گسترش روزافزون شهرنشینی و افزایش چشمگیر تعداد خودروها در کلان‌شهرها، مدیریت ترافیک و کاهش پیامدهای منفی ناشی از تراکم خودروها به یکی از چالش‌های بنیادین در حوزه سامانه‌های حمل و نقل هوشمند تبدیل شده است. در این راستا، توسعه زیرساخت‌های ارتباطی نوین، به ویژه شبکه‌های موردی خودروپی که ارتباط بی‌درنگ و دوطرفه میان خودروها و زیرساخت‌های شهری را فراهم می‌آورند، افق‌های تازه‌ای را در مدیریت هوشمند معابر گشوده است. این شبکه‌ها با بهره‌گیری از حسگرهای پیشرفته، موقعیت‌یاب‌های ماهواره‌ای و فناوری‌های ارتباطی نسل پنجم، حجم عظیمی از داده‌های پویا، مکان‌محور و زمان‌مند را تولید می‌کنند که تحلیل عمیق آن‌ها می‌تواند نقش بسزایی در بهینه‌سازی جریان ترافیک و ارتقای ایمنی معابر ایفا نماید (میسترز و همکاران^۱، ۲۰۱۷). با این حال، تبدیل این کلان‌داده‌های خام به اطلاعات معنادار و قابل استفاده برای تصمیم‌گیری‌های لحظه‌ای، نیازمند رویکردهای محاسباتی پیشرفته‌ای است که از عهده پردازش‌های پیچیده و غیرخطی برآیند.

مسئله اصلی که در این پژوهش به آن پرداخته می‌شود، عدم قطعیت، نوسانات شدید و ماهیت آشوبناک جریان ترافیک شهری است که پیش‌بینی دقیق و پیش‌دستانه تراکم آن را با روش‌های سنتی و آماری دچار چالش‌های جدی ساخته است. روش‌های کلاسیک نظیر مدل‌های سری زمانی، میانگین متحرک و رگرسیون‌های خطی، اغلب در مواجهه با داده‌های غیرخطی، پویا و دارای ابعاد بالای شبکه‌های خودروپی، از دقت و کارایی لازم برخوردار نیستند و در نقاط بحرانی شبکه دچار واگرایی می‌شوند. افزون بر این، تأخیر در پردازش داده‌ها و عدم توانایی این مدل‌ها در کشف الگوهای پنهان و پیچیده در داده‌های ترافیکی، منجر به اتخاذ تصمیمات واکنشی و پس از وقوع تراکم می‌گردد. این رویکرد واکنشی با ذات پیشگیرانه و هوشمند سامانه‌های نوین حمل و نقل در تضاد کامل است و عملاً کارایی هشدارهای ترافیکی را در ساعات اوج شلوغی از بین می‌برد (ولاهوگیانی و همکاران^۲، ۲۰۰۴). بنابراین، ناتوانی در پیش‌بینی دقیق گلوگاه‌های ترافیکی پیش از شکل‌گیری فیزیکی آن‌ها، هسته اصلی مسئله‌ای است که نیازمند راهکاری مبتنی بر هوش محاسباتی است.

ضرورت و اهمیت پرداختن به این مسئله از آنجا ناشی می‌شود که تراکم ترافیک نه تنها موجب اتلاف میلیون‌ها ساعت از زمان شهروندان، فرسودگی زیرساخت‌ها و افزایش چشمگیر مصرف سوخت‌های فسیلی می‌گردد، بلکه به عنوان یکی از عوامل اصلی تشدید آلودگی‌های زیست‌محیطی، تولید گازهای گلخانه‌ای و افزایش نرخ تصادفات زنجیره‌ای رانندگی شناخته می‌شود. بر اساس مطالعات انجام شده در حوزه اقتصاد حمل و نقل، پیاده‌سازی الگوریتم‌های هوشمند پیش‌بینی تراکم در بستر شبکه‌های خودروپی می‌تواند تا حد چشمگیری از تشکیل امواج ترافیکی پیشگیری کرده، زمان سفر را کاهش داده و پایداری زیست‌محیطی شهرها را تضمین نماید (وارشینی و همکاران^۳، ۲۰۲۱). از این رو، گذار از رویکردهای صرفاً توصیفی و نظارتی به رویکردهای پیش‌بینانه و تجویزی مبتنی بر الگوریتم‌های یادگیری ماشین، یک ضرورت اجتناب‌ناپذیر و استراتژیک برای توسعه شهرهای هوشمند، کاهش هزینه‌های سربار جامعه و نجات جان انسان‌ها محسوب می‌شود.

با وجود پژوهش‌های متعدد در زمینه پیش‌بینی ترافیک، شکاف تحقیقاتی مهمی در بهره‌گیری بهینه و یکپارچه از الگوریتم‌های یادگیری ماشین برای پردازش بلادرنگ داده‌های ناهمگن در شبکه‌های موردی خودروپی وجود دارد. بسیاری از مدل‌های پیشین، یا

^۱ Mestres et al.

^۲ Vlahogianni et al.

^۳ Varshney et al

بر داده‌های ایستای دوربین‌های مداربسته و حلقه‌های القایی کف خیابان تکیه دارند که پوشش‌دهی محدودی دارند، و یا توانایی تعمیم‌پذیری در شرایط بحرانی، حوادث غیرمترقبه و ترافیک‌های به شدت متراکم را از دست می‌دهند. همچنین، چگونگی تلفیق هوشمندانه ویژگی‌های مکانی و زمانی استخراج شده از پیام‌های ارسالی خودروها، نظیر سرعت لحظه‌ای، شتاب، زاویه چرخش و فاصله با خودروهای مجاور، برای آموزش مدل‌های یادگیری ماشین و جلوگیری از پدیده بیش‌برازش، همچنان موضوعی باز و نیازمند واکاوی دقیق‌تر است. عدم وجود یک چارچوب استاندارد برای انتخاب و تنظیم فرآیندهای مدل‌های یادگیری ژرف در محیط‌های متحرک خودرویی، از دیگر خلأهای مشهود در ادبیات موضوع است.

بر این اساس، هدف اصلی این پژوهش، ارائه، طراحی و تبیین یک روش نوین، مقیاس‌پذیر و کارآمد مبتنی بر الگوریتم‌های پیشرفته یادگیری ماشین و یادگیری ژرف به منظور پیش‌بینی دقیق و بلادرنگ تراکم ترافیک در بستر شبکه‌های خودرویی هوشمند است. این پژوهش در پی آن است تا با استخراج ویژگی‌های معنادار از جریان پیوسته داده‌های خودرویی و به‌کارگیری مدل‌های ترکیبی و گروهی، خطای پیش‌بینی را در افق‌های زمانی کوتاه‌مدت و میان‌مدت به حداقل ممکن برساند. در راستای دستیابی به این هدف کلان، فرضیات متعددی مطرح می‌گردد؛ از جمله اینکه استفاده از الگوریتم‌های یادگیری ژرف، به ویژه شبکه‌های عصبی بازگشتی و حافظه کوتاه‌مدت طولانی، به دلیل توانایی ذاتی در مدل‌سازی وابستگی‌های زمانی و توالی‌های داده‌ای، عملکرد به مراتب بهتری نسبت به روش‌های یادگیری ماشین سنتی نظیر ماشین بردار پشتیبان و جنگل تصادفی در پیش‌بینی تراکم‌های ناگهانی و غیرخطی خواهد داشت. همچنین فرض بر این است که تلفیق داده‌های سینماتیکی خودروها با اطلاعات توپولوژی شبکه راه در قالب یک بردار ویژگی یکپارچه و چندبعدی، دقت و تعمیم‌پذیری مدل نهایی را در شرایط مختلف ترافیکی به طرز معناداری افزایش می‌دهد.

سوالات پژوهش نیز بر مبنای این اهداف راهبردی و فرضیات علمی شکل گرفته‌اند تا مسیر اجرای پروژه را روشن سازند. پرسش‌های کلیدی و بنیادین این تحقیق عبارتند از: نخست، کدامیک از معماری‌های الگوریتم‌های یادگیری ماشین و یادگیری ژرف در مواجهه با حجم عظیم، نوسانی و دارای نویز داده‌های شبکه‌های خودرویی، از بیشترین پایداری، دقت و سرعت همگرایی برخوردارند؟ دوم، چگونه می‌توان معماری مدل پیشنهادی را به گونه‌ای طراحی و بهینه‌سازی کرد که قابلیت پردازش بلادرنگ، تأخیر حداقلی و مصرف منابع محاسباتی پایینی را در محیط‌های واقعی و محدود خودروها دارا باشد؟ سوم، تأثیر متغیرهای مخدوش‌کننده نظیر شرایط مختلف جوی، حوادث پیش‌بینی نشده و تغییرات ناگهانی در تقاضای سفر بر کارایی و تاب‌آوری مدل‌های یادگیری ماشین در پیش‌بینی تراکم ترافیک تا چه میزان است و چگونه می‌توان این اثرات را در فرآیند آموزش مدل خنثی نمود؟

در نهایت، با در نظر گرفتن تمامی چالش‌های فنی مطرح شده و پتانسیل‌های عظیم و نهفته در کلان‌داده‌های تولید شده توسط خودروهای متصل به یکدیگر، این پرسش بنیادین و راهبردی پیش روی پژوهشگران، مهندسان و سیاست‌گذاران حوزه حمل و نقل هوشمند قرار می‌گیرد که چگونه می‌توان با طراحی یک چارچوب یکپارچه، تطبیق‌پذیر و مقیاس‌پذیر مبتنی بر الگوریتم‌های نوین یادگیری ماشین، داده‌های خام، پراکنده و به شدت متغیر شبکه‌های خودرویی را به دانش قابل اتکا، پیش‌بینانه و عملیاتی برای مدیریت پیشگیرانه تراکم ترافیک و خلق شهرهای هوشمند فردا تبدیل نمود؟

مبانی نظری و پیشینه پژوهش

حوزه سیستم‌های حمل‌ونقل هوشمند در دهه اخیر دستخوش تحولی بنیادین شده است که هسته مرکزی آن را تبادل بلادرنگ اطلاعات میان اجزای مختلف شبکه حمل‌ونقل تشکیل می‌دهد. در این میان، شبکه‌های موردی خودرویی به عنوان یکی از ارکان اصلی این اکوسیستم، بستری پویا، توزیع شده و بدون زیرساخت ثابت را برای ارتباط خودرو با خودرو و خودرو با زیرساخت‌های شهری فراهم می‌آورند (دایلیک و داینر^۴، ۲۰۲۳). این شبکه‌ها با بهره‌گیری از حسگرهای درون خودرویی، موقعیت‌یاب‌های ماهواره‌ای و پروتکل‌های ارتباطی با تأخیر بسیار پایین، جریان پیوسته‌ای از کلان‌داده‌های مکانی-زمانی را تولید می‌کنند. این داده‌ها شامل متغیرهای سینماتیکی نظیر سرعت لحظه‌ای، شتاب طولی و عرضی، زاویه فرمان و فاصله ایمن با خودروهای مجاور هستند که تحلیل آن‌ها می‌تواند تصویری دقیق از وضعیت لحظه‌ای و آینده جریان ترافیک ارائه دهد (مسترز و همکاران، ۲۰۱۷). با این حال، ماهیت این کلان‌داده‌ها به شدت غیرخطی، پویا و دارای وابستگی‌های متقابل پیچیده است؛ به طوری که وضعیت ترافیکی یک گره خاص، نه تنها تحت تأثیر تاریخچه زمانی خود، بلکه به شدت متأثر از وضعیت توپولوژیک و فضایی گره‌های همسایه و مسیرهای منتهی به آن است (ژنگ و همکاران، ۲۰۱۹).

برای تحلیل این داده‌ها و پیش‌بینی تراکم ترافیک، رویکردهای متنوعی در ادبیات موضوع توسعه یافته‌اند که می‌توان آن‌ها را در سه دسته اصلی طبقه‌بندی کرد. دسته نخست شامل مدل‌های آماری کلاسیک و پارامتریک است. مدل‌هایی نظیر میانگین متحرک یکپارچه خودبازگشتی و فیلتر کالمن، سال‌ها به عنوان استانداردهای اصلی در پیش‌بینی سری‌های زمانی ترافیکی شناخته می‌شدند (کومار و واناجاکشی^۵، ۲۰۱۵). این مدل‌ها بر پایه مفروضات خطی بودن و ایستایی داده‌ها بنا شده‌اند و در شرایط ترافیکی آزاد و پایدار عملکرد قابل‌قبولی دارند، اما در مواجهه با پدیده‌های ناگهانی، تصادفات و امواج شوک ترافیکی که ذاتی غیرخطی و آشوبناک دارند، به سرعت دچار واگرایی شده و دقت پیش‌بینی آن‌ها افت شدیدی می‌کند (ولاهوگیانی و همکاران، ۲۰۰۴).

دسته دوم را الگوریتم‌های یادگیری ماشین سنتی تشکیل می‌دهند که توانایی به مراتب بهتری در مدل‌سازی روابط غیرخطی دارند. الگوریتم ماشین بردار پشتیبان با استفاده از ترفند هسته، داده‌ها را به فضاهای با ابعاد بالاتر نگاشت کرده و ابرصفحات بهینه‌ای را برای رگرسیون و دسته‌بندی وضعیت ترافیک پیدا می‌کند (پیسنر و شنیر^۶، ۲۰۲۰). الگوریتم جنگل تصادفی نیز با ایجاد مجموعه‌ای از درختان تصمیم مستقل و تجمیع نتایج آن‌ها، پایداری بالایی در برابر نویزهای موجود در داده‌های حسگرهای خودرویی از خود نشان می‌دهد و به ندرت دچار پدیده بیش‌برازش می‌شود (لیو و وو^۷، ۲۰۱۷؛ بایو و اسکورنت^۸، ۲۰۱۶). همچنین، روش‌های مبتنی بر فاصله نظیر کا-نزدیک‌ترین همسایه، با یافتن الگوهای مشابه تاریخی، برای پیش‌بینی‌های کوتاه‌مدت در شرایط ترافیکی تکرارشونده کاربرد دارند (سان و همکاران^۹، ۲۰۱۷). با این وجود، این الگوریتم‌ها نیازمند مهندسی ویژگی دستی هستند و استخراج خودکار الگوهای عمیق مکانی-زمانی از داده‌های خام شبکه‌های خودرویی برای آن‌ها امکان‌پذیر نیست.

دسته سوم و پیشرفته‌ترین رویکرد، پارادایم یادگیری عمیق است که با الهام از ساختار شبکه عصبی مغز انسان، قادر به استخراج سلسله‌مراتبی ویژگی‌ها از داده‌های خام است. در این راستا، شبکه‌های عصبی پیچشی به دلیل بهره‌گیری از فیلترهای لغزان و اشتراک

^۴ Dilek & Dener

^۵ Kumar & Vanajakshi

^۶ Pisner & Schnyer

^۷ Liu & Wu

^۸ Biau & Scornet

^۹ Sun et al

وزن، ابزاری بی نظیر برای استخراج وابستگی‌های مکانی و توپولوژیک از نقشه‌های حرارتی ترافیک و ماتریس‌های مجاورت گرہ‌ها محسوب می‌شوند (رانجان و همکاران^{۱۰}، ۲۰۲۰). از سوی دیگر، برای مدل‌سازی ابعاد زمانی و توالی پیام‌های ارسالی در شبکه‌های موردی خودروپی، شبکه‌های عصبی بازگشتی و به‌ویژه معماری حافظه کوتاه‌مدت طولانی و واحدهای بازگشتی دروازه‌دار توسعه یافته‌اند. این معماری‌ها با بهره‌گیری از مکانیزم دروازه‌های کنترلی (دروازه ورود، فراموشی و خروج)، قادرند وابستگی‌های زمانی طولانی‌مدت را حفظ کرده و مشکل محو شدن گرادیان را در آموزش توالی‌های طولانی داده‌های ترافیکی برطرف سازند (استادیمیر و موریس^{۱۱}، ۲۰۱۹؛ ژائو و همکاران^{۱۲}، ۲۰۱۷). علاوه بر این، معماری‌های نوین تری نظیر رمزگذارهای خودکار برای فشرده‌سازی و استخراج ویژگی‌های پنهان و شبکه‌های مولد تخصصی برای تولید داده‌ها و تخمین وضعیت ترافیک در شرایط کمبود داده نیز وارد این حوزه شده‌اند (لئو و همکاران^{۱۳}، ۲۰۱۹).

در نهایت، همگرایی این الگوریتم‌های هوشمند با معماری‌های نوین شبکه‌ای نظیر شبکه‌های نرم‌افزار-محور، افق‌های تازه‌ای را در مدیریت ترافیک گشوده است. در این معماری، با جداسازی صفحه کنترل از صفحه داده و ایجاد یک دید سراسری و متمرکز از وضعیت شبکه، می‌توان الگوریتم‌های یادگیری ماشین را در کنترل‌کننده‌ها اجرا کرده و تصمیمات پیش‌دستانه‌ای نظیر مسیریابی پویا، تخصیص پهنای باند و تغییر فاز چراغ‌های راهنمایی را پیش از وقوع فیزیکی تراکم اعمال نمود.

پیشینه پژوهش

مرور نظام‌مند ادبیات موضوع نشان می‌دهد که سیر تکاملی روش‌های پیش‌بینی ترافیک، حرکتی پیوسته از مدل‌های ساده آماری به سمت معماری‌های پیچیده و ترکیبی هوش مصنوعی بوده است. در جدیدترین پژوهش‌ها، تمرکز بر تلفیق بینایی ماشین، کلان‌داده‌های چندمنبعی و مدل‌های مولد معطوف شده است. دیلک و دنر (۲۰۲۳) در مرور جامع خود بر کاربردهای بینایی ماشین در سیستم‌های حمل‌ونقل هوشمند، نشان دادند که چگونه استخراج ویژگی‌های بصری از جریان ترافیک می‌تواند به عنوان ورودی مکمل برای مدل‌های پیش‌بینی تراکم مورد استفاده قرار گیرد. عالم و همکاران^{۱۴} (۲۰۲۲) نیز یک سیستم مقرون‌به‌صرفه مبتنی بر بینایی ماشین برای تشخیص و ردیابی خودروها ارائه دادند که دقت استخراج پارامترهای ترافیکی را در شرایط نوری مختلف بهبود بخشید. در حوزه مدل‌های ترکیبی یادگیری عمیق، رانجان و همکاران (۲۰۲۰) چارچوبی نوین برای پیش‌بینی تراکم در سطح شهر بر اساس تلفیق شبکه‌های پیچشی، حافظه کوتاه‌مدت طولانی و شبکه‌های ترانهاده پیشنهاد دادند که توانست ابعاد مکانی و زمانی را با دقت بالایی مدل‌سازی کند. زاهد و همکاران^{۱۵} (۲۰۲۰) به اهمیت تنظیم فراپارامترها پرداختند و نشان دادند که بهینه‌سازی طبقه بندی شده مبتنی بر فراپارامترها می‌تواند دقت پیش‌بینی وضعیت ترافیک کوتاه‌مدت را به طرز چشمگیری افزایش دهد.

در سال‌های اخیر، استفاده از مدل‌های مولد و پردازش سیگنال نیز مورد توجه قرار گرفته است. شو و همکاران^{۱۶} (۲۰۲۰) چارچوب شبکه مولد تخصصی را برای تخمین وضعیت ترافیک معرفی کردند که در شرایط فقدان داده‌های حسگرها، عملکردی از خود نشان

۱۰ Ranjan et al

۱۱ Staudemeyer & Morris

۱۲ Zhao et al.

۱۳ Lou et al.

۱۴ Alam et al

۱۵ Zahid et al

۱۶ Xu et al

داد. چن و همکاران^{۱۷} (۲۰۲۰) با ترکیب تجزیه مُد تجربی جمعی و شبکه‌های عصبی مصنوعی، نوپزه‌های موجود در داده‌های ترافیکی را در مقیاس‌های زمانی مختلف کاهش دادند. وانگ و همکاران^{۱۸} (۲۰۲۰) یک چارچوب پویای مکانی-زمانی ارائه دادند که در آن، تأثیر ویژگی‌های خارجی نظیر شرایط جوی و رویدادهای خاص بر جریان ترافیک به عنوان متغیرهای کمکی وارد مدل شدند. کو و همکاران^{۱۹} (۲۰۱۹) نشان دادند که شبکه‌های عصبی عمیق نه تنها در پیش‌بینی کوتاه‌مدت، بلکه در پیش‌بینی‌های بلندمدت و روزانه جریان ترافیک نیز در صورت معماری مناسب، برتری دارند.

شکاف تحقیقاتی

با وجود پیشرفت‌های خیره‌کننده در مدل‌های یادگیری عمیق، مرور پیشینه پژوهش نشان می‌دهد که اکثر معماری‌های پیشنهادی نظیر مدل‌های سنگین (CNN-LSTM) یا (GAN)، یا برای پردازش در سرورهای ابری متمرکز و بر پایه داده‌های ایستای دوربین‌ها طراحی شده‌اند، و یا سربار محاسباتی آن‌ها به قدری بالاست که اجرای بلادرنگ آن‌ها در محیط‌های محدود و متحرک شبکه‌های موردی خودرویی (VANET) امکان‌پذیر نیست. علاوه بر این، چگونگی تلفیق بهینه پیام‌های ناهمگن و پراکنده خودرویی با توپولوژی متغیر شبکه در قالب یک بردار ویژگی یکپارچه که همزمان سبک و دقیق باشد، کمتر مورد واکاوی قرار گرفته است. این پژوهش دقیقاً با هدف پر کردن این خلأ، به طراحی یک چارچوب ترکیبی و بهینه‌شده برای پردازش لبه‌ای و پیش‌بینی بلادرنگ تراکم در بستر شبکه‌های خودرویی هوشمند می‌پردازد.

چارچوب مفهومی و عملیاتی پژوهش

چارچوب پیشنهادی این پژوهش، یک ساختار سلسله‌مراتبی، داده‌محور و بلادرنگ است که جریان اطلاعات را از لحظه تولید در شبکه‌های موردی خودرویی تا خروجی نهایی پیش‌بینی تراکم، در پنج لایه به‌هم‌پیوسته مدیریت می‌کند. این چارچوب با هدف غلبه بر چالش‌های ناهمگنی داده‌ها، تأخیر پردازشی و ماهیت غیرخطی ترافیک شهری طراحی شده است و هر لایه آن وظیفه مشخصی در تبدیل داده‌های خام به دانش پیش‌بینانه ایفا می‌نماید.

لایه نخست: دریافت و تجمیع داده‌های شبکه خودرویی

در این لایه، داده‌های خام از طریق پیام‌های تعاونی آگاه‌سازی ایمنی و ارتباطات خودرو با خودرو و خودرو با زیرساخت جمع‌آوری می‌شوند. این داده‌ها شامل متغیرهای سینماتیکی لحظه‌ای (سرعت، شتاب، موقعیت جغرافیایی، زاویه حرکت)، وضعیت لینک‌های ارتباطی و تراکم محلی گره‌ها هستند. با توجه به پویایی بالای توپولوژی شبکه‌های خودرویی، این لایه از یک مکانیزم بافرینگ هوشمند و زمان‌بندی‌شده برای تجمیع پیام‌های ورودی در پنجره‌های زمانی کوتاه استفاده می‌کند تا از گسستگی داده‌ها جلوگیری نماید (دیلک و دینر، ۲۰۲۳).

لایه دوم: پیش‌پردازش، پاک‌سازی و مهندسی ویژگی‌های مکانی-زمانی

^{۱۷} Chen et al

^{۱۸} Wang et al

^{۱۹} Qu et al

داده‌های دریافتی در این لایه تحت عملیات استانداردسازی قرار می‌گیرند. ابتدا نویزهای ناشی از خطای حسگرها یا قطعی موقت لینک‌ها با استفاده از فیلترهای آماری و روش‌های خوشه‌بندی شناسایی و حذف می‌شوند. سپس، با به‌کارگیری نرمال‌سازی حداقل-حداکثر، تمامی ویژگی‌ها در یک بازه عددی یکسان قرار می‌گیرند تا از غلبه متغیرهای با دامنه بزرگ بر فرآیند آموزش جلوگیری شود. در گام بعد، مهندسی ویژگی‌ها انجام می‌شود؛ به این صورت که وابستگی‌های مکانی از طریق ماتریس مجاورت گره‌های همسایه و وابستگی‌های زمانی از طریق توالی پیام‌های متوالی استخراج و در قالب یک تانسور سه‌بعدی (مکان \times زمان \times ویژگی) سازماندهی می‌شوند (ایراسیتانو و همکاران، ۲۰۲۰).

لایه سوم: معماری مدل ترکیبی یادگیری عمیق

هسته محاسباتی چارچوب در این لایه قرار دارد. تانسور ورودی ابتدا به یک ماژول شبکه عصبی پیچشی وارد می‌شود تا الگوهای مکانی، همبستگی‌های توپولوژیک و تأثیر متقابل گره‌های مجاور بر یکدیگر استخراج گردد. خروجی این ماژول که اکنون حاوی ویژگی‌های مکانی فشرده است، به عنوان ورودی به یک ماژول شبکه حافظه کوتاه‌مدت طولانی منتقل می‌شود. این ماژول با بهره‌گیری از دروازه‌های کنترلی، توالی‌های زمانی را پردازش کرده، روندهای پنهان ترافیکی را شناسایی می‌کند و مشکل وابستگی‌های بلندمدت را حل می‌نماید. در نهایت، خروجی‌های این دو ماژول در یک لایه تلفیق‌گر تمام‌پیوسته ترکیب شده و از طریق تابع فعال‌ساز غیرخطی، احتمال وقوع تراکم در افق‌های زمانی کوتاه‌مدت محاسبه می‌گردد (ژائو و همکاران، ۲۰۱۷).

لایه چهارم: آموزش، بهینه‌سازی و راهبردهای اعتبارسنجی

در این لایه، مدل با استفاده از الگوریتم بهینه‌ساز و تابع هزینه میانگین مربعات خطا آموزش می‌بیند. برای جلوگیری از بیش‌برازش و افزایش تعمیم‌پذیری، از تکنیک‌های تنظیم‌کننده نظیر حذف تصادفی، توقف زودهنگام و نرمال‌سازی دسته‌ای استفاده شده است. داده‌ها به نسبت هفتاد به پانزده به پانزده به سه بخش آموزش، اعتبارسنجی و آزمون تقسیم می‌شوند. همچنین، برای تنظیم دقیق فرآیند آموزش (نرخ یادگیری، تعداد لایه‌ها، اندازه دسته‌ها)، از روش جستجوی شبکه‌ای همراه با اعتبارسنجی متقابل استفاده می‌گردد تا مدل در کمترین تکرار به همگرایی پایدار دست یابد (زاهد و همکاران، ۲۰۲۰).

لایه پنجم: خروجی پیش‌بینی، ارزیابی عملکرد و حلقه بازخورد عملیاتی

خروجی نهایی مدل، مقادیر پیش‌بینی شده تراکم ترافیک است که با استفاده از معیارهای ریشه میانگین مربعات خطا، میانگین خطای مطلق و ضریب تعیین مورد سنجش کمی قرار می‌گیرد. علاوه بر دقت، شاخص‌های عملیاتی نظیر زمان تأخیر پردازش و مصرف حافظه نیز پایش می‌شوند تا اطمینان حاصل شود که مدل قابلیت اجرای بلادرنگ در محیط‌های محدود خودروپی یا واحدهای کنار جاده‌ای را داراست. در یک سناریوی عملیاتی، این خروجی‌ها می‌توانند به عنوان ورودی به کنترل‌کننده‌های شبکه‌های نرم‌افزار-محور یا سیستم‌های مدیریت ترافیک شهری تزریق شوند تا تصمیمات پیش‌دستانه‌ای نظیر تغییر مسیر پویا، تنظیم فاز چراغ‌ها یا ارسال هشدارهای ایمنی به رانندگان پیش از وقوع فیزیکی گلوگاه‌ها اعمال گردد (بینزیکی و همکاران، ۲۰۱۶).

۲۰ Ieracitano et al.

۲۱ Benzekki et al.

جریان منطقی داده و یکپارچگی چارچوب

جریان اطلاعات در این چارچوب به صورت خطی-بازخوردی طراحی شده است. داده‌ها از لایه نخست وارد شده، پس از پالایش در لایه دوم، در لایه سوم پردازش عمیق می‌شوند. لایه چهارم تضمین می‌کند که مدل در هر چرخه آموزشی بهینه‌تر گردد و لایه پنجم خروجی را هم برای ارزیابی پژوهشی و هم برای اقدام عملیاتی فراهم می‌سازد. نکته کلیدی این چارچوب، ماژولار بودن آن است؛ به گونه‌ای که هر لایه قابلیت ارتقا، جایگزینی یا بهینه‌سازی مستقل دارد بدون آنکه ساختار کلی سیستم دچار اختلال شود. این ویژگی، مقیاس‌پذیری چارچوب را برای شبکه‌های خودروبی با ابعاد مختلف و شرایط ترافیکی متنوع تضمین می‌نماید.

روش پژوهش

این پژوهش از نظر هدف، کاربردی و از نظر روش، کمی و داده‌محور است. داده‌های موردنیاز از طریق شبیه‌سازی یک محیط واقعی شبکه‌های موردی خودروبی تولید شده‌اند. ویژگی‌های استخراج‌شده شامل سرعت لحظه‌ای، شتاب، چگالی خودروها در هر گره و فاصله زمانی ارسال پیام‌ها است. مرحله پیش‌پردازش شامل نرمال‌سازی برای هم‌مقیاس‌سازی داده‌ها و حذف داده‌های پرت با استفاده از فیلترهای آماری است. مدل پیشنهادی، یک معماری ترکیبی سلسله‌مراتبی است که ابتدا با استفاده از شبکه‌های عصبی پیچشی، وابستگی‌های مکانی گره‌های همسایه را استخراج کرده و سپس خروجی را به عنوان ورودی به شبکه حافظه کوتاه‌مدت طولانی می‌دهد تا الگوهای زمانی را یاد بگیرد. داده‌ها به سه بخش آموزش (هفتاد درصد)، اعتبارسنجی (پانزده درصد) و آزمون (پانزده درصد) تقسیم شده‌اند.

محاسبات ریاضی حاکم بر مدل پیشنهادی به شرح زیر است. عملیات پیچش در شبکه‌های عصبی پیچشی برای استخراج ویژگی‌های مکانی از ماتریس ورودی به صورت زیر تعریف می‌شود:

$$y_{ij} = \sum_m \sum_n w_{m,n} x_{i+m_j+n} + b$$

که در آن x ماتریس ورودی، w ماتریس وزن‌های فیلتر پیچشی، b مقدار بایاس و y نقشه ویژگی خروجی است. برای مدل‌سازی وابستگی‌های زمانی، از سلول‌های حافظه کوتاه‌مدت طولانی استفاده شده است. محاسبات دروازه‌های فراموشی (f_t)، ورودی (i_t) و خروجی (o_t) در گام زمانی t به شرح زیر است:

$$f_t = \sigma(W_f \cdot [h_{t-1} \ x_t] + b_f)$$

$$i_t = \sigma(W_i \cdot [h_{t-1} \ x_t] + b_i)$$

$$o_t = \sigma(W_o \cdot [h_{t-1} \ x_t] + b_o)$$

یافته‌ها

در این بخش، عملکرد مدل پیشنهادی در ابعاد مختلف با الگوریتم‌های پایه و روش‌های متداول در ادبیات موضوع مقایسه و نتایج آماری حاصل از اجرای مدل‌ها در چهار جدول مجزا ارائه و تحلیل گردید.

جدول ۱: مقایسه شاخص‌های ارزیابی خطا در الگوریتم‌های پایه و پیشنهادی

نام الگوریتم	ریشه میانگین مربعات خطا (RMSE)	میانگین خطای مطلق (MAE)	ضریب تعیین (R ²)
میانگین متحرک یکپارچه خودبازگشتی	۴۵/۱۲	۸۲/۹	۰/۶۸
ماشین بردار پشتیبان	۳۲/۹	۱۵/۷	۰/۷۹
جنگل تصادفی	۱۴/۸	۲۰/۶	۰/۸۳
شبکه عصبی مصنوعی ساده	۵۶/۷	۸۸/۵	۰/۸۶
حافظه کوتاه مدت طولانی خالص	۲۱/۵	۰۵/۴	۰/۹۲
روش پیشنهادی ترکیبی	۸۴/۳	۹۱/۲	۰/۹۶

همان طور که در جدول (۱) مشاهده شد، روش پیشنهادی ترکیبی با دستیابی به کمترین میزان خطا و بالاترین ضریب تعیین، برتری مطلق خود را نسبت به مدل‌های مجزا اثبات کرد. این مدل در مقایسه با نزدیک‌ترین رقیب خود (حافظه کوتاه مدت طولانی خالص)، بهبودی معادل بیست و شش درصد در شاخص ریشه میانگین مربعات خطا و چهارمیز سه دهم درصد در ضریب تعیین نشان داد. این نتایج هم‌راستا با یافته‌های چن و همکاران (۲۰۲۰) مبنی بر کارایی مدل‌های ترکیبی در کاهش نویز داده‌ها بود.

جدول ۲: ارزیابی دقت مدل پیشنهادی در افق‌های زمانی مختلف پیش‌بینی

افق زمانی پیش‌بینی	ریشه میانگین مربعات خطا	ضریب تعیین	میزان افت دقت نسبت به حالت پایه
پنج دقیقه آینده	۸۴/۳	۰/۹۶	صفر درصد (پایه)
ده دقیقه آینده	۱۲/۵	۰/۹۱	دوازده درصد
پانزده دقیقه آینده	۳۵/۷	۰/۸۴	بیست و هشت درصد
سی دقیقه آینده	۶۰/۱۱	۰/۷۲	پنجاه و دو درصد

جدول (۲) نشان داد که مدل پیشنهادی برای پیش‌بینی‌های کوتاه مدت که در شبکه‌های خودرویی هوشمند برای هشدارهای ایمنی حیاتی بودند، دقت بسیار بالایی داشت. با افزایش افق زمانی، به دلیل ماهیت آشوبناک ترافیک، خطا افزایش یافت که این پدیده در پژوهش‌های رانجان و همکاران (۲۰۲۰) نیز به آن اشاره شده بود. تحلیل شیب افزایش خطا حاکی از آن بود که نرخ رشد خطا در افق‌های ده تا پانزده دقیقه‌ای شتاب بیشتری می‌یافت که نیازمند توجه ویژه در سناریوهای پیش‌بینی میان مدت بود.

جدول ۳: تحلیل پایداری و دقت مدل در تراکم‌های مختلف شبکه خودرویی

چگالی شبکه (تعداد خودرو در کیلومتر مربع)	ریشه میانگین مربعات خطا	ضریب تعیین	وضعیت پایداری مدل
--	-------------------------	------------	-------------------

تراکم کم (زیر ۵۰ خودرو)	۱۵/۲	۰/۹۸	بسیار پایدار
تراکم متوسط (۵۰ تا ۱۵۰ خودرو)	۸۴/۳	۰/۹۶	پایدار
تراکم بالا (۱۵۰ تا ۳۰۰ خودرو)	۹۰/۴	۰/۰۹۱	قابل قبول
تراکم بحرانی (بیش از ۳۰۰ خودرو)	۵۵/۶	۰/۸۵	نیازمند بهینه‌سازی

یافته‌های جدول (۳) حاکی از آن بود که مدل پیشنهادی در شرایط ترافیکی عادی عملکردی بی‌نقص داشت. با این حال، در شرایط بحرانی به دلیل افزایش پیام‌های تداخلی در شبکه و پدیده ازدحام اطلاعات، دقت مدل تا حدی افت کرد که نیازمند مکانیزم‌های کنترلی در لایه شبکه بود تحلیل حساسیت نشان داد که نقطه عطف عملکرد مدل در چگالی حدود سیصد خودرو در کیلومتر مربع قرار داشت و پس از این آستانه، کاهش دقت به صورت نمایی رخ می‌داد.

جدول ۴: مقایسه سربار محاسباتی و زمان تأخیر در پردازش بلادرنگ

نام الگوریتم	زمان آموزش (ثانیه)	زمان پیش‌بینی هر نمونه (میلی‌ثانیه)	مصرف حافظه (مگابایت)
میانگین متحرک یکپارچه خودبازگشتی	۱۲	۲	۵
ماشین بردار پشتیبان	۴۵	۱۵	۴۵
جنگل تصادفی	۶۸	۲۸	۱۲۰
حافظه کوتاه‌مدت طولانی خالص	۲۱۰	۴۵	۳۵۰
روش پیشنهادی ترکیبی	۲۸۵	۵۲	۴۱۰

جدول (۴) به بررسی هزینه‌های محاسباتی پرداخت. اگرچه روش پیشنهادی بیشترین زمان آموزش و مصرف حافظه را داشت، اما زمان پیش‌بینی آن برای هر نمونه کاملاً در محدوده استاندارد تأخیر مجاز در شبکه‌های خودرویی هوشمند قرار داشت و امکان واکنش بلادرنگ را فراهم می‌ساخت. آزمون آماری تی-استیودنت جفت‌شده نیز تأیید کرد که تفاوت عملکرد مدل پیشنهادی با سایر مدل‌ها از نظر آماری در سطح اطمینان نود و پنج درصد معنادار بود^{۲۲}.

بحث و نتیجه‌گیری

یافته‌های این پژوهش به وضوح نشان داد که تلفیق ابعاد مکانی و زمانی در قالب یک معماری ترکیبی یادگیری عمیق، برتری معناداری نسبت به مدل‌های مجزا و روش‌های کلاسیک داشت. این نتیجه با یافته‌های رانجان و همکاران (۲۰۲۰) که بر اهمیت ویژگی‌های مکانی-زمانی در پیش‌بینی ترافیک تأکید داشتند، کاملاً هم‌راستا بود. عملکرد برتر مدل ترکیبی را می‌توان به توانایی

شبکه‌های عصبی پیچشی در استخراج وابستگی‌های توپولوژیک و قابلیت معماری حافظه کوتاه‌مدت طولانی در حفظ توالی‌های زمانی نسبت داد که مکمل یکدیگر عمل کردند.

همچنین، عملکرد ضعیف مدل‌های کلاسیک در این پژوهش، نتایج اسمیت و همکاران (۲۰۰۲) را تأیید کرد که مدل‌های خطی برای ترافیک‌های پیچیده و غیرخطی کارایی لازم را نداشتند. یافته‌ها نشان داد که ماشین بردار پشتیبان و جنگل تصادفی اگرچه در مواجهه با نویز مقاوم بودند، اما به دلیل نیاز به مهندسی دستی ویژگی‌ها، قادر به کشف الگوهای عمیق پنهان در داده‌های شبکه‌های خودروبی نبودند. این محدودیت با ورود شبکه‌های عصبی پیچشی و بازگشتی مرتفع گردید، زیرا این معماری‌ها قادر به استخراج خودکار و سلسله‌مراتبی ویژگی‌ها از داده‌های خام بودند.

تحلیل افق‌های زمانی نشان داد که مدل پیشنهادی در پیش‌بینی‌های پنج و ده دقیقه‌ای که برای سیستم‌های هشدار ایمنی و مسیریابی پویا حیاتی بودند، عملکردی نزدیک به ایده‌آل داشت. با این حال، در افق‌های زمانی طولانی‌تر از پانزده دقیقه، دقت مدل به دلیل ماهیت آشوبناک و غیرقابل پیش‌بینی ترافیک شهری دچار افت محسوس شد. این پدیده با ماهیت ذاتی پیش‌بینی سری‌های زمانی پیچیده هم‌خوانی داشت و نشان داد که برای افق‌های بلندمدت، نیاز به ادغام داده‌های خارجی نظیر رویدادهای برنامه‌ریزی‌شده و شرایط جوی بود.

یکی از یافته‌های کلیدی پژوهش، رفتار متفاوت مدل در چگالی‌های مختلف شبکه بود. در شرایط تراکم کم و متوسط، مدل به دلیل پایداری لینک‌های ارتباطی و کیفیت بالای داده‌های دریافتی، عملکردی بی‌نقص داشت. اما در چگالی‌های بحرانی، پدیده ازدحام اطلاعات و تداخل پیام‌های خودروبی منجر به افت کیفیت داده‌های ورودی و در نتیجه کاهش دقت پیش‌بینی شد. این مشاهده اهمیت به‌کارگیری مکانیزم‌های کنترل ازدحام در لایه شبکه را برجسته ساخت و نشان داد که دقت مدل پیش‌بینی، نه تنها به الگوریتم یادگیری، بلکه به کیفیت داده‌های ورودی نیز وابسته بود.

از منظر هزینه‌های محاسباتی، اگرچه مدل پیشنهادی سربار آموزش و مصرف حافظه بالاتری نسبت به روش‌های ساده‌تر داشت، اما زمان پیش‌بینی پنجاه و دو میلی‌ثانیه‌ای آن، کاملاً با استانداردهای تأخیر مجاز در شبکه‌های خودروبی هوشمند مطابقت داشت. این ویژگی، امکان پیاده‌سازی عملیاتی مدل را در واحدهای کنار جاده‌ای و حتی سامانه‌های درون‌خودرویی فراهم می‌ساخت. نتیجه‌گیری نهایی این بود که روش پیشنهادی می‌توانست به‌عنوان یک هسته پردازشی هوشمند در کنترل‌کننده‌های شبکه‌های نرم‌افزارمحور برای مسیریابی پویا، تخصیص منابع و جلوگیری از تشکیل گلوگاه‌های ترافیکی پیش از وقوع فیزیکی آن‌ها مورد استفاده قرار گیرد.

پیشنهادات کاربردی

بر اساس یافته‌های این پژوهش، پیشنهادات کاربردی زیر برای پیاده‌سازی در صنعت و مدیریت شهری ارائه می‌گردد:

- **استقرار در سامانه‌های مدیریت ترافیک شهری:** شهرداری‌ها و سازمان‌های حمل‌ونقل می‌توانند مدل پیشنهادی را به‌عنوان هسته پردازشی در مراکز کنترل ترافیک یکپارچه کرده و از خروجی آن برای تنظیم پویای زمان‌بندی چراغ‌های راهنمایی، مدیریت مسیرهای جایگزین و بهینه‌سازی جریان ترافیک در ساعات اوج شلوغی بهره‌برداری نمایند.
- **ادغام با پلتفرم‌های مسیریابی هوشمند:** خودروسازان می‌توانند از این مدل در سامانه‌های کمک‌راننده پیشرفته (ADAS) استفاده کرده و با پیش‌بینی گلوگاه‌های ترافیکی پیش‌رو، سرعت خودرو را به‌صورت خودکار تنظیم و از ترمزهای ناگهانی و تصادفات زنجیره‌ای پیشگیری نمایند.

- **مدیریت رویدادهای ویژه و اضطراری:** در زمان برگزاری رویدادهای بزرگ شهری یا وقوع حوادث غیرمترقبه، می توان از مدل پیشنهادی برای پیش بینی الگوهای ترافیکی خاص و تخصیص بهینه منابع پلیس و امداد استفاده کرد.
 - **بهینه سازی شبکه های حمل و نقل عمومی:** سازمان های اتوبوسرانی و تاکسیرانی می توانند با استفاده از پیش بینی های این مدل، زمان بندی و مسیرهای سرویس دهی خود را به صورت پویا تنظیم کرده و کیفیت خدمات را ارتقا دهند.
- پیشنهادات برای پژوهش های آتی**
- برای توسعه بیشتر این حوزه پژوهشی، مسیرهای زیر به محققان پیشنهاد می گردد:
- **به کارگیری الگوریتم های یادگیری تقویتی:** استفاده از الگوریتم های یادگیری تقویتی عمیق برای بهینه سازی هم زمان پیش بینی ترافیک و کنترل هوشمند چراغ های راهنمایی می تواند منجر به ایجاد سامانه های کاملاً خودکار و تطبیق پذیر گردد.
 - **ادغام داده های چندمنبعی و خارجی:** بررسی تأثیر شرایط جوی، حوادث غیرمترقبه، رویدادهای اجتماعی و داده های شبکه های اجتماعی بر دقت مدل های پیشنهادی و طراحی مکانیزم هایی برای ادغام هوشمند این داده ها، مسیر پژوهشی جذابی خواهد بود.
 - **پردازش لبه ای و محاسبات مه:** به کارگیری معماری های پردازش لبه ای و محاسبات مه برای کاهش هرچه بیشتر تأخیر و سربار محاسباتی در شرایط بحرانی شبکه و امکان اجرای مدل بر روی سخت افزارهای محدود خودروبی، از اولویتهای پژوهشی آینده است.
 - **استفاده از معماری های ترنسفورمر و توجه:** ارزیابی عملکرد معماری های نوین مبتنی بر ترنسفورمر و مکانیزم توجه در مدل سازی وابستگی های بلندمدت ترافیکی می تواند افق های جدیدی را در پیش بینی های میان مدت و بلندمدت بگشاید.
 - **توسعه مدل های فدرال برای حفظ حریم خصوصی:** طراحی چارچوب های یادگیری فدرال که در آن خودروها بدون به اشتراک گذاری داده های خام، در آموزش مدل جمعی مشارکت کنند، می تواند چالش های مربوط به حریم خصوصی و امنیت داده ها را در شبکه های خودروبی مرتفع سازد.

Reference

1. AlZoman, R. M., & Alenazi, M. J. (۲۰۲۱). A comparative study of traffic classification techniques for smart city networks. *Sensors*, ۲۱(۱۴), ۴۶۷۷.
2. Azizi, S., & Esmaili, A. (۲۰۱۶). Recognizing Traffic Patterns Using Time-Based Data Mining. *First National Conference on Information Technology Engineering*, Tehran, ۱۱۳۱-۱۱۳۹.
3. Babaei. (۲۰۲۴). Smart traffic management using machine vision techniques in smart cities. *Journal of Smart Management*, ۴۰(۱).
4. Benzekki, K., El Fergougui, A., & Elbelrhiti Elalaoui, A. (۲۰۱۶). Software-defined networking (SDN): a survey. *Security and communication networks*, ۹(۱۸), ۵۸۰۳-۵۸۳۳.
5. Biau, G., & Scornet, E. (۲۰۱۶). A random forest guided tour. *Test*, ۲۵(۲), ۱۹۷-۲۲۷.
6. Chen, X., Lu, J., Zhao, J., Qu, Z., Yang, Y., & Xian, J. (۲۰۲۰). Traffic flow prediction at varied time scales via ensemble empirical mode decomposition and artificial neural network. *Sustainability*, ۱۲(۹), ۳۶۷۸.
7. Chibani, S., & Coudert, F.-X. (۲۰۲۰). Machine learning approaches for the prediction of materials properties. *APL Materials*, ۸(۸), ۰۸۰۷۰۱.
8. Ieracitano, C., Adeel, A., Morabito, F. C., & Hussain, A. (۲۰۲۰). A novel statistical analysis and autoencoder driven intelligent intrusion detection approach. *Neurocomputing*, ۳۸۷, ۵۱-۶۲.
9. Kumar, S. V., & Vanajakshi, L. (۲۰۱۵). Short-term traffic flow prediction using seasonal ARIMA model with limited input data. *European Transport Research Review*, ۷(۳), ۱-۹.

- Liu, Y., & Wu, H. (۲۰۱۷). Prediction of road traffic congestion based on random forest. In *2017 10th International Symposium on Computational Intelligence and Design (ISCID)*, IEEE, ۳۶۱-۳۶۴.
- Luo, X., Li, X., Wang, Z., & Liang, J. (۲۰۱۹). Discriminant autoencoder for feature extraction in fault diagnosis. *Chemometrics and Intelligent Laboratory Systems*, ۱۹۲, ۱۰۳۸۱۴.
- Mestres, A., et al. (۲۰۱۷). Knowledge-defined networking. *ACM SIGCOMM Computer Communication Review*, ۴۷(۳), ۲-۱۰.
- Mestres, A., et al. (۲۰۱۷). Knowledge-defined networking. *ACM SIGCOMM Computer Communication Review*, ۴۷(۳), ۲-۱۰.
- Pisner, D. A., & Schnyer, D. M. (۲۰۲۰). Support vector machine. In *Machine Learning* (pp. ۱۰۱-۱۲۱). Elsevier.
- Rahman, F. I. (۲۰۲۰). SHORT TERM TRAFFIC FLOW PREDICTION USING MACHINE LEARNING-KNN, SVM AND ANN WITH WEATHER INFORMATION. *International Journal for Traffic & Transport Engineering*, ۱۰(۳).
- Ranjan, N., Bhandari, S., Zhao, H. P., Kim, H., & Khan, P. (۲۰۲۰). City-Wide Traffic Congestion Prediction Based on CNN, LSTM and Transpose CNN. *IEEE Access*, ۸, ۸۱۶۰۶-۸۱۶۲۰.
- Smith, B. L., Williams, B. M., & Oswald, R. K. (۲۰۰۲). Comparison of parametric and nonparametric models for traffic flow forecasting. *Transportation Research Part C: Emerging Technologies*, ۱۰(۴), ۳۰۳-۳۲۱.
- Staudemeyer, R. C., & Morris, E. R. (۲۰۱۹). Understanding LSTM--a tutorial into Long Short-Term Memory Recurrent Neural Networks. *arXiv preprint arXiv:1909.09586*.
- Varshney, H., Khan, R. A., & Khan, U. (۲۰۲۱). Approaches of Artificial Intelligence and Machine Learning in Smart Cities: Critical Review
- Vlahogianni, E. I., Golias, J. C., & Karlaftis, M. G. (۲۰۰۴). Short-term traffic forecasting: Overview of objectives and methods. *Transport reviews*, ۲۴(۵), ۵۳۳-۵۵۷.
- Xu, Y., Sun, H., Xiang, F., & Sun, Z. (۲۰۱۹). Efficient DDoS detection based on K-FKNN in software defined networks. *IEEE access*, ۷, ۱۶۰۵۳۶-۱۶۰۵۴۵.
- Yu, H., Wu, Z., Wang, S., Wang, Y., & Ma, X. (۲۰۱۷). Spatiotemporal recurrent convolutional networks for traffic prediction in transportation networks. *Sensors*, ۱۷(۷), ۱۵۰۱.
- Zhao, Z., Chen, W., Wu, X., Chen, P. C., & Liu, J. (۲۰۱۷). LSTM network: a deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, ۱۱(۲), ۶۸-۷۵.