

ارائه یک رویکرد ترکیبی یادگیری عمیق (Conv-LSTM) با هدف پیش‌بینی حجم ترافیک کوتاه‌مدت راه‌های دوخطه برون‌شهری (مطالعه موردی: جاده کرج-چالوس)

مقاله علمی - پژوهشی

مهرداد خرمی، دانشجوی کارشناسی ارشد، گروه مهندسی عمران، واحد ملارد، دانشگاه آزاد اسلامی، ملارد، تهران، ایران

علی پایدار، استادیار، گروه مهندسی عمران، واحد ملارد، دانشگاه آزاد اسلامی، ملارد، تهران، ایران

*سهیل رضاشعار (نویسنده مسئول)، دانشجوی دکتری، گروه برنامه‌ریزی حمل‌ونقل، دانشکده فنی و مهندسی،

دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران

*پست الکترونیکی نویسنده مسئول: soheilshoar@edu.ikiu.ac.ir

دریافت: ۱۴۰۵/۰۱/۰۵ - پذیرش: ۱۴۰۵/۰۵/۰۵

صفحه ۴۵۸-۴۳۹

چکیده

در سال‌های اخیر، افزایش سریع تعداد و سایل نقلیه منجر به مشکلات ترافیکی گسترده‌ای شده است. پیش‌بینی دقیق جریان ترافیک می‌تواند به کاهش ازدحام، بهینه‌سازی زیرساخت‌های حمل‌ونقل، ارتقای ایمنی سفرها و کاهش اثرات زیست‌محیطی کمک کند. هدف این پژوهش، پیش‌بینی حجم ترافیک یک ساعت آینده در محور کرج-چالوس به عنوان یکی از پرترددترین جاده‌های ایران با شرایط جوی و توپوگرافی پیچیده، است. برای این منظور، داده‌های تردد از دو دستگاه ترددشمار و داده‌های هواشناسی سینوپتیک (با فواصل زمانی سه‌ساعته) گردآوری شدند. با توجه به توانایی شبکه‌های کانولوشنی (CNN) در استخراج ویژگی‌های پنهان و الگوهای فضایی-زمانی و همچنین کارایی شبکه‌های حافظه‌طولانی کوتاه‌مدت (LSTM) در مدل‌سازی سری‌های زمانی، مدل ترکیبی Conv-LSTM پیشنهاد شد. این مدل با بهره‌گیری از نقاط قوت هر دو روش، برای پیش‌بینی دقیق حجم ترافیک در بستر پایتون توسعه یافت و بین نتایج آن با نتایج مدل حافظه‌طولانی کوتاه‌مدت مبتنی بر مکانیسم توجه (A-LSTM) مقایسه صورت گرفت. نتایج ارزیابی حاکی از آن است که مدل Conv-LSTM در مجموعه داده‌های آزمون، ضریب تعیین (R^2) ۸۲/۴۵٪ را کسب کرد و در مقایسه با الگوریتم A-LSTM، R^2 برابر ۸۱/۹۳٪، عملکرد بهتری ارائه کرد. همچنین، معیارهای میانگین مربع خطا (MSE) و جذر میانگین مربعات خطا (RMSE)، که نشان‌دهنده اختلاف بین مقادیر پیش‌بینی‌شده و واقعی هستند، برای مدل Conv-LSTM به ترتیب ۱۴،۳۱۱ و ۱۲۰ و برای A-LSTM به ترتیب ۱۴،۷۴۰ و ۱۲۲ گزارش شدند. این مقادیر حاکی از پراکندگی کمتر و دقت بالاتر پیش‌بینی‌های Conv-LSTM در مقایسه با A-LSTM است. کاربرد مدل پیشنهادی در پیش‌بینی حجم ترافیک محور کرج-چالوس، اطلاعات ارزشمندی برای شناسایی مسیرهای پرازدحام، توزیع مجدد ترافیک، پیشگیری از تصادفات، برنامه‌ریزی پویای مسیر و مدیریت بهینه زمان سفر فراهم می‌کند. این رویکرد همچنین با کاهش مصرف سوخت و آلودگی هوا، می‌تواند کمک شایانی به بهبود پایداری زیست‌محیطی و افزایش کارایی حمل‌ونقل کند.

واژه‌های کلیدی: حجم ترافیک، شبکه‌عصبی، حافظه‌طولانی کوتاه‌مدت، کانولوشن، Conv-LSTM

۱- مقدمه

ترافیک نیز حل این مشکلات بود (Ren et al., 2021). با پیشرفت فناوری و گسترش کلان‌داده‌ها و روش‌های هوش مصنوعی، الگوریتم‌های یادگیری عمیق به بخشی ضروری از ITS برای مدیریت ترافیک تبدیل شدند. یکی از کاربردهای

شبکه‌های حمل‌ونقل شهری و برون‌شهری در سالیان اخیر با مشکلاتی نظیر تراکم ترافیک، ایمنی کاربران و نوسانات زمان سفر مواجه شده‌اند. یکی از اهداف توسعه‌ی سامانه‌های حمل‌ونقل هوشمند (ITS) به‌عنوان بخشی حیاتی از مدیریت

پیش‌بینی‌های انجام‌شده با این روش‌ها، غیرقابل اعتماد است (Kashyap et al., 2022). در نقطه مقابل، روش‌های یادگیری ماشین می‌توانند الگوهای پیچیده و غیرخطی داده‌های ترافیکی را نسبت به مدل‌های آماری، با عملکرد بهتری ثبت کنند (Hou et al., 2021). پژوهش بر انواع مدل‌های شبکه عصبی، منجر به پیدایش مدل‌هایی با قابلیت‌های منحصربه‌فرد شده است. شبکه عصبی بازگشتی (RNN) و حافظه طولانی کوتاه‌مدت (LSTM) دو مورد از مهم‌ترین مدل‌های توسعه‌یافته بر مبنای شبکه‌های عصبی هستند. در این مدل‌ها، هر مشاهده از مشاهدات پیشین آن تأثیر می‌پذیرد و این ارتباط به ماهیت سری زمانی داده‌های ترافیکی نزدیک‌تر است. به عنوان مثال، در پژوهش راماکریشنان و سونی (Ramakrishnan & Soni, 2018)، مدل RNN برای پیش‌بینی حجم ترافیک به کار رفت و نتایج نشان داد که این مدل در مقایسه با مدل‌های آماری، دقت پیش‌بینی بیشتری دارد.

مدل RNN تنها ارتباط مشاهدات پیشین در گذشته نزدیک را در نظر می‌گیرد و این مسئله یکی از معایب آن است. در مقابل، در مدل LSTM علاوه بر ارتباط مشاهدات اخیر با مشاهدات گذشته نزدیک، مشاهدات گذشته دور نیز در نظر گرفته می‌شود. این مزیت سبب شد که ژائو و همکاران (Zhao et al., 2017) در پژوهش خود از این مدل برای پیش‌بینی حجم ترافیک استفاده نمایند. مدل پیشنهادی ژانگ و همکاران (Y. Zhang et al., 2020) یک گراف پیچشی و یک ساختار LSTM باقیمانده را با یکدیگر ادغام می‌کرد. این مدل بر روی یک مجموعه داده سرعت ترافیکی، ارزیابی شد و پیش‌بینی بهتری نسبت به شش مدل پایه ارائه داد. در پژوهش انجام‌شده توسط کاشیاپ و همکاران (Kashyap et al., 2022) در سال ۲۰۲۱ در آمریکا، پژوهشگران با کمک روش‌های LSTM، CNN، خودرمزگذار انباشته (SAE)، ماشین بردار پشتیبان (SVM) و ماشین بولتزمن محدود شده (RBM) پیش‌بینی جریان ترافیک را مورد ارزیابی قرار دادند. معیارهای ارزیابی این پژوهش، میانگین خطای مطلق (MAE) و جذر میانگین مربعات خطا (RMSE) بودند. نتایج نشان داد که MAE و RMSE در طول روز در مقایسه با شب بیشتر است. همچنین، این مطالعه نشان داد که مدل‌های پیچیده‌تر همیشه نتایج بهتری در پیش‌بینی به همراه ندارند. در مطالعه‌ای دیگر، هو و همکاران (Hou et al., 2021) در سال ۲۰۲۱ در آمریکا، از معیارهای ارزیابی میانگین درصد قدر مطلق خطا

عملی هوش مصنوعی، پیش‌بینی الگوهای ترافیکی کوتاه‌مدت است (Chai et al., 2022; K. Zhang et al., 2020). محققان، طیف وسیعی از مدل‌های آماری، یادگیری ماشین و یادگیری عمیق را با هدف پیش‌بینی ویژگی‌های ترافیک با دقت بالا ارائه دادند (Ahmed & Cook, 1979; Chai et al., 2022; Ren et al., 2021; Van Der Voort et al., 1996). برخی از این مطالعات، جریان ترافیک (Ma et al., 2021; Ren et al., 2021; Zheng et al., 2020) و برخی دیگر، سرعت ترافیک (Wu et al., 2020) را پیش‌بینی کردند. عمده تمرکز این مطالعات، پیش‌بینی جریان و سرعت ترافیک در آزادراه‌ها و راه‌های شهری بود (Ma et al., 2021; Wu et al., 2020; K. Zhang et al., 2020) و تنها تعداد کمی از آن‌ها، راه‌های دوطرفه دو خطه برون‌شهری را مورد بررسی قرار داده‌اند (Rasaizadi et al., 2021; Rasaizadi et al., 2022).

علی‌رغم گسترش پژوهش‌های انجام‌شده، پیش‌بینی دقیق ویژگی‌های ترافیکی در برخی از بخش‌ها در شبکه راه‌های دو خطه برون‌شهری، همچنان چالش برانگیز است. نخستین چالش، تفاوت رفتار سفر در این جاده‌ها با جاده‌های شهری است که بیشتر به متغیرهای زمانی بستگی دارد. پژوهش عبدالرحیم و همکاران نشان داد میزان ترافیک در جاده‌های دو خطه برون‌شهری در طول تعطیلات افزایش می‌یابد (Abdel-Rahim et al., 2015). این موضوع حاکی از آن است که این راه‌ها نیاز به تحلیل ترافیک و پیش‌بینی منحصربه‌فردی دارند. چالش دوم، مشکل ایمنی در این نوع جاده‌ها است. به‌طور خلاصه، پیش‌بینی ترافیک در جاده‌های دو خطه برون‌شهری با هدف افزایش ایمنی، بهینه‌سازی استفاده از منابع و حصول اطمینان از اینکه طراحی جاده‌ها نیاز شرایط ترافیکی فعلی و آینده را برآورده می‌کنند، حیاتی است. این رویکرد پیشگیرانه می‌تواند به‌طور قابل توجهی احتمال تصادفات را کاهش دهد و ایمنی کلی جاده‌ها را بهبود ببخشد (Harwood et al., 2000).

۲- پیشینه تحقیق

یکی از شیوه‌های اصلی پیش‌بینی متغیرهای ترافیکی، تحلیل مشاهدات پیشین متغیرها و کشف روابط اثرگذار بر آن است. از آنجا که داده‌های ترافیک ذاتاً دارای ویژگی‌های غیرخطی و تصادفی هستند، مدل‌های آماری عملکرد غیرقابل‌قبولی دارند و

(MAPE)، میانگین درصد قدر مطلق خطا متقارن (SMAPE)، MAE، میانگین مربعات خطا (MSE) و RMSE برای پیش‌بینی جریان ترافیک استفاده کردند.

روش‌های تحلیل شامل مدل ترکیبی SAE، تابع پایه شعاعی (RBF) بودند و نتایج نشان داد که مدل پیشنهادی دقت پیش‌بینی بالاتری در مقایسه با مدل‌های پایه دارند، به‌ویژه در پیش‌بینی‌های چندمرحله‌ای. همچنین، ادغام شرایط آب‌وهوایی در مدل، به‌طور قابل‌توجهی دقت پیش‌بینی جریان ترافیک را افزایش داد. ژائو و همکاران (Zhao et al., 2017) در سال ۲۰۱۷ در چین، با استفاده از معیارهای MAE، MSE و میانگین خطای نسبی (MRE) و روش تحلیل LSTM، به بررسی پیش‌بینی ترافیک کوتاه‌مدت پرداختند. مدل پیشنهادی LSTM عملکرد بهتری نسبت به دیگر مدل‌های پیش‌بینی مرسوم نشان داد و اثربخشی آن با در نظر گرفتن همبستگی‌های زمانی-مکانی در داده‌های ترافیک تأیید شد. شرافت و همکاران (Sherafat et al., 2023) در سال ۲۰۲۳ در ایران، از معیار ارزیابی MSE و روش‌های تحلیل A-LSTM و LSTM استفاده کردند. نتایج حاکی از آن بود که A-LSTM در پیش‌بینی حجم و سرعت ترافیک در بازه‌های ۵ و ۱۵ دقیقه‌ای از مدل مرسوم LSTM بهتر عمل کرد و به کمترین MSE برابر با ۰,۰۰۳۲، برای بازه ۱۵ دقیقه‌ای رسید. چن و همکاران (Chen et al., 2020) در سال ۲۰۲۰ در آمریکا، معیارهای MAE، RMSE، MAPE و ضریب رگرسیون (R) را با روش‌های تحلیل Conv-LSTM، (LSTM دوجته) Bi-LSTM و Two-Layer LSTM بررسی کردند. مدل Conv-LSTM برای پیش‌بینی جریان ترافیک کوتاه‌مدت از مدل‌های مرسوم مانند LSTM، Two-Layer LSTM و Bi-LSTM بهتر عمل کرد و به بالاترین دقت و کمترین MAE و RMSE دست یافت. دونگ و سان (Dong & Sun, 2022) در سال ۲۰۲۲ در آمریکا، با استفاده از معیارهای MAE و

RMSE و روش‌های تحلیل (LSTM دوجته با مکانیزم توجه) AB-Bi-LSTM و Bi-LSTM، به این نتیجه رسیدند که مدل AB-Bi-LSTM در پیش‌بینی جریان ترافیک بهتر از مدل Bi-LSTM عمل می‌کند. لی و همکاران (Li et al., 2020) در سال ۲۰۲۰ در چین، با معیارهای MAE و RMSE و روش تحلیل Conv-Bi-LSTM، دقت پیش‌بینی بالاتری را نسبت به روش‌های سنتی نشان دادند.

نتایج این مطالعه، کارآمدی پیش‌بینی تراکم ترافیک با مدل مذکور را تأیید کرد. در نهایت، هو و همکاران (Hu et al., 2022) در سال ۲۰۲۲ در چین، با استفاده از معیارهای MAE، RMSE و MAPE و روش‌های تحلیل AB-Conv-LSTM و Bi-LSTM، نشان دادند که مدل AB-Conv-LSTM شبکه‌های جاده‌ای شهری بهتر از مدل Bi-LSTM عمل می‌کند. یکی از مراحل کلیدی در فرآیند پیش‌بینی متغیرهای ترافیکی، انتخاب متغیرهای پیش‌بینی‌کننده است. به‌طور کلی، این متغیرها به دو دسته تقسیم می‌شوند: دسته اول شامل مشاهدات پیشین همان متغیر ترافیکی است و دسته دوم شامل اطلاعاتی مانند شرایط جوی، تقویم، تعطیلات و رویدادها می‌شود.

جدول ۱ متغیرهای دسته دوم را که در مطالعات پیشین استفاده شده‌اند، به همراه شکاف‌های پژوهشی موجود، نشان می‌دهد. در پژوهش‌های پیشین، مدل‌هایی مانند Conv-LSTM کمتر مورد توجه قرار گرفته‌اند، در حالی که این مدل‌ها می‌توانند با استفاده از ساختار کانولوشنی، ویژگی‌های محلی را به‌صورت کارآمد استخراج کرده و همبستگی‌های مکانی-زمانی را در داده‌های جریان ترافیک بهتر شناسایی کنند، ضمن اینکه پیچیدگی مدل را کاهش می‌دهند. از منظر زمانی، هر دوره تاریخی تأثیر متفاوتی بر یک مکان در آینده دارد.

به همین ترتیب، از منظر مکانی، رابطه بین مکان‌ها در بازه‌های زمانی مختلف متفاوت است.

جدول ۱. متغیرهای پیش‌بینی‌کننده استفاده‌شده در مطالعات پیشین

ردیف	پژوهشگران	پایگاه داده	شکاف پژوهش
۱	کاشیاپ و همکاران (Kashyap et al., 2022)	مجموعه داده‌های ترافیکی جمع‌آوری شده از کلانشهرهای کالیفرنیا.	بیش‌برازش به دلیل وجود داده‌های تاریخی بزرگ که باعث نوسانات در جریان ترافیک می‌شود.
۲	هو و همکاران (Hou et al., 2021)	مجموعه داده‌های جمع‌آوری شده مرکز مدیریت حمل و نقل منطقه‌ای شهرهای دوقلو سنت پل و مینیاپولیس.	مدل‌های موجود فاقد تأثیرات شرایط آب و هوایی هستند که بر دقت پیش‌بینی جریان ترافیک تأثیر می‌گذارد. نیاز به پژوهش در مورد پیش‌بینی جریان ترافیک با ادغام داده‌های آب و هوا.
۳	ژائو و همکاران (Zhao et al., 2017)	داده‌های ترافیک جمع‌آوری شده از دفتر مدیریت ترافیک شهر پکن.	عدم مقایسه با مدل‌های جدید پیش‌بینی ترافیک توسط روش‌های یادگیری عمیق. بحث محدود در مورد مقیاس‌پذیری مدل LSTM.
۴	شرافت و همکاران (Sherafat et al., 2023)	داده‌های ترافیک جمع‌آوری شده از آشکارسازهای حلقه‌ای در جاده برون‌شهری چالوس.	عدم وجود مدل‌های یادگیری چند وظیفه‌ای برای داده‌های ترافیک جاده مورد بررسی.
۵	چن و همکاران (Chen et al., 2020)	داده‌های جریان ترافیک از آشکارساز ۴۰۳۳۲۴ در بزرگراه I280-S ایالات متحده آمریکا.	عدم مقایسه با سایر مدل‌های پیش‌بینی ترافیک. بحث محدود در مورد مقیاس‌پذیری مدل Conv-LSTM.
۶	دونگ و سان (Dong & Sun, 2022)	مجموعه داده‌های مسیر تاکسی در دنیای واقعی برای تجزیه و تحلیل سرعت ترافیک.	عدم مقایسه با مدل‌های یادگیری عمیق متنوع‌تر. پژوهش‌های آینده برای گسترش مدل به ویژگی‌های نمودار پویا مورد نیاز است.
۷	لی و همکاران (Li et al., 2020)	داده‌های ترافیکی جمع‌آوری شده از ترددشمارها.	عدم مقایسه با مدل‌های یادگیری عمیق جدیدتر. بحث محدود در مورد مقیاس‌پذیری مدل Conv-BiLSTM.
۸	هو و همکاران (Hu et al., 2022)	داده‌های ترافیک جمع‌آوری شده شهر نانجینگ چین از پلتفرم Amap.	عدم مقایسه با مدل‌های آماری سنتی. بحث محدود در مورد تعمیم‌پذیری مدل پیشنهادی.

با توجه به مطالعات انجام‌شده بین سال‌های ۲۰۱۷ تا ۲۰۲۳، مدل‌های یادگیری عمیق مانند LSTM، A-LSTM و ترکیب آن‌ها با CNN در پیش‌بینی جریان ترافیک در کشورهای مختلف با استفاده از کلان‌داده‌ها، دقت بالایی داشته و خطای پیش‌بینی را به حداقل رسانده‌اند. با این حال، در محور کرج-چالوس، یکی از پرترددترین مسیرهای ایران با شرایط جوی متغیر و توپوگرافی کوهستانی، کمبود مطالعات جامع با استفاده از این مدل‌های پیشرفته مشهود است. این شکاف پژوهشی، ضرورت استفاده از مدل‌های A-LSTM و Conv-LSTM با داده‌های محلی در این محور را برجسته می‌کند تا دقت پیش‌بینی جریان ترافیک در شرایط پیچیده بهبود یابد. انجام این پژوهش به دلیل نقش حیاتی

این محور در ایمنی جاده‌ای، اقتصاد محلی و مدیریت منابع، از اهمیت بالایی برخوردار است و می‌تواند به تصمیم‌گیری‌های داده‌مبنا و توسعه پایدار زیرساخت‌های حمل‌ونقل کمک کند. هدف این پژوهش، تطبیق مدل‌های یادگیری عمیق با داده‌های ایرانی شامل ترددشمار دوطرفه، اطلاعات هواشناسی و عوامل تقویمی است تا ضمن ایجاد یک بانک اطلاعاتی جامع، دقت پیش‌بینی‌ها افزایش یابد و راهکارهایی برای سیستم‌های هوشمند حمل‌ونقل ارائه شود. نوآوری این پژوهش در بهره‌گیری از داده‌های محلی و ترکیب آن‌ها با مدل‌های پیشرفته برای ارائه راه‌حل‌های عملی است.

۳- معرفی روش پژوهش

۳-۱- ساختار الگوریتم‌های معرفی شده

۳-۱-۱-۳ مدل LSTM

RNN به عنوان یک شبکه عصبی، تحول چشمگیری در حوزه‌ی پیش‌بینی داده‌های سری زمانی ایجاد کرد. این شبکه‌ها دارای یک لایه بازخورد هستند که در آن خروجی فعلی را به همراه اطلاعات گذشته به عنوان ورودی به شبکه ارسال می‌کنند. RNN پایه به دلیل مشکل محوشدگی گرادیان، در دریافت اطلاعات طولانی مدت عملکرد مناسبی ندارد. برای برطرف کردن این چالش، LSTM در راستای حل مسئله محوشدگی گرادیان پیشنهاد شده است (Ren et al., 2021). شبکه‌های LSTM به دلیل توانایی در مدل‌سازی ماهیت سری زمانی متغیرهای

ترافیکی، پتانسیل بالایی برای پیش‌بینی دقیق متغیرهای حجم و سرعت ترافیک نشان داده‌اند. مدل LSTM پتانسیل و توانایی در نظر گرفتن داده‌های پیشین و وابستگی‌های زمانی را دارد. در این بخش، برای معرفی مدل پیشنهادی خود، ابتدا مبانی ریاضی پشت هر دروازه در بلوک‌های ساختمان LSTM توضیح داده خواهد شد. در این ساختار از سه تابع فعال ساز سیگموئید (معادله ۱)، تانژانت هپربولیک (معادله ۲) و خطی اصلاح‌شده (معادله ۳) استفاده شده است:


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

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

$$\text{ReLU}(x) = \max(0, x) \quad (3)$$

است که هر یک از آن‌ها پردازشی را بر روی داده‌ها با اهداف مختلف اعمال می‌کند.

با توجه به شکل ۱، مدل LSTM از سه درگاه اصلی با عناوین درگاه فراموشی، درگاه ورودی و درگاه خروجی تشکیل شده



شکل ۱. بلوک ساختمانی برای یک مرحله زمانی واحد در LSTM، شامل دروازه‌های ورودی، فراموشی و خروجی

ورودی این درگاه شامل وضعیت پنهان از درگاه قبلی و ورودی فعلی در معادله ۴ است.

در درگاه فراموشی مدل LSTM تصمیم گرفته می‌شود که کدام اطلاعات جاری و گذشته حفظ شود و کدام یک فراموش شوند.

$$f_t = \sigma(W_f[x_t] + b_f) \quad (4)$$

منتقل شود. این درگاه شامل تابع فعال‌سازی دیگری با نام $\tanh$ است که در معادلات ۵، ۶ و ۷ مشخص می‌کند اطلاعات وضعیت سلول قبلی تا چه حد تحت تأثیر داده ورودی جدید قرار بگیرد.

وظیفه حفظ اطلاعات مهم در مدل LSTM بر عهده درگاه ورودی است. در این درگاه، اگر اطلاعات مهم باشند، برای شبکه معین می‌کند که بخش زیادی از داده ورودی به اطلاعات وضعیت سلول فعلی (C_t) اضافه شود تا به مرحله بعدی شبکه

$$\begin{aligned} i_t &= \sigma(W_i[x_t] + b_i) & (5) \\ \tilde{C}_t &= \tanh(W_c[x_t] + b_c) & (6) \\ C_t &= f_t \times C_{t-1} + i_t \times \tilde{C}_t & (7) \end{aligned}$$

را دریافت کرده و عمل ضرب را روی آن‌ها انجام می‌دهد و نتیجه به تابع فعال‌سازی سیگموئید ارسال می‌شود. در انتها، بر اساس معادلات ۸ و ۹، مقدار خروجی تابع سیگموئید در مقدار وضعیت سلول که از تابع تانژانت $\tanh$ عبور کرده است، ضرب می‌شود تا مقدار نهایی (h_t) حاصل شود.

$$\begin{aligned} o_t &= \sigma(W_o[x_t] + b_o) & (8) \\ h_t &= o_t \times \tanh(C_t) & (9) \end{aligned}$$

۳-۱-۲- مدل A-LSTM

به‌تازگی مکانیسم Attention به‌طور گسترده‌ای مورد استفاده قرار گرفته است و در کاربردهایی نظیر نوشتن شرح تصاویر (Yu et al., 2017)، پاسخ به سؤالات بصری (Lu et al., 2017) و تشخیص گفتار (Kim et al., 2017) عملکرد خوبی از خود نشان داده‌اند. Attention می‌تواند توالی‌های ورودی را به‌طور مؤثرتری انتخاب کرده و معانی آن‌ها را در حافظه بلندمدت رمزگذاری کند تا قابلیت‌های پردازش اطلاعات چندمنظوره شبکه‌های عصبی را بهبود بخشد. ایده اصلی این است که برخی از بخش‌های ورودی اهمیت بیشتری دارند و در تولید خروجی نسبت به سایر بخش‌ها نقش برجسته‌تری ایفا می‌کنند. در مقایسه با استفاده از LSTM، تنها مکانیسم Attention با ساختن همبستگی مکانی-زمانی سراسری و انتخاب اطلاعات مرتبط زمینه، پیش‌بینی بهتر را با شبکه عمیق فراهم می‌کند. به عبارتی مکانیسم Attention به‌طور کمی، وزن‌های اهمیت را برای هر مرحله زمانی خاص در ویژگی‌های پی در پی اختصاص می‌دهد تا نقص پراکندگی توجه در LSTM را بهبود بخشد. این امر LSTM را قادر می‌سازد که وابستگی‌های طولانی‌مدت توالی‌ها را در طی مراحل زمانی گذشته حفظ کند و نمونه‌گیری مبتنی بر اهمیت را نیز کنترل کند.

۳-۱-۳- مدل CNN

CNN یک شبکه عصبی پیش‌خور با ساختار عمیق است و عمدتاً از لایه کانولوشن، لایه ادغام و لایه اتصال کامل تشکیل شده است (Gu et al., 2018). لایه کانولوشن نقش کلیدی در این فرآیند ایفا می‌کند و با استفاده از هسته‌های کانولوشن، عملیات کانولوشن را روی داده‌های لایه ورودی انجام می‌دهد تا ویژگی‌های کانولوشنی استخراج شوند. در مدل‌های CNN با چندین لایه کانولوشن، تعداد پارامترهای خروجی این لایه‌ها

می‌تواند بسیار زیاد باشد. برای کاهش تعداد پارامترها و جلوگیری از بیش‌برازش، از عملیات نمونه‌برداری فرعی (Pooling) در لایه‌های کانولوشنی استفاده می‌شود تا بخشی از اطلاعات استخراج‌شده حفظ شود. در نهایت، لایه کاملاً متصل (Fully Connected) ویژگی‌های زائد را کاهش داده، آن‌ها را یکپارچه می‌کند و خروجی نهایی را تولید می‌کند.

۳-۱-۴- توسعه مدل مفهومی پژوهش (Conv-LSTM)


در این پژوهش، تحلیل جامع خصوصیات زمانی-مکانی با تحلیل‌های سری زمانی ادغام می‌شود. به همین منظور از مدل Conv-LSTM استفاده شد تا ویژگی‌های مکانی در داده‌های چند بعدی ثبت گردد.

بنابراین Conv-LSTM یک مدل پردازشی سری‌های زمانی است که ویژگی‌های مکانی را استخراج می‌کند. در شکل ۲، علامت * نشان‌دهنده عملگر پیچشی W ماتریس وزن هر لایه، I_t وضعیت گیت ورودی و F_t وضعیت گیت فراموشی (برای تعیین اینکه چه مقدار از وضعیت قبلی c_{t+1} برای زمان کنونی نگهداری شود) هستند. وضعیت سلول در زمان کنونی و O_t وضعیت گیت خروجی را نشان می‌دهد و هر دو پارامتر C_t و O_t برای تشخیص وضعیت لایه پنهان H_t مورد استفاده قرار می‌گیرند. سپس ماتریس وزن به‌ترتیب با ورودی و وضعیت‌های پنهان ضرب می‌شود تا ویژگی‌های مکانی در داده‌های ترافیکی توسط افزودن هسته‌های پیچشی استخراج شوند.


برای پیش‌بینی حجم ترافیک از Conv-LSTM به‌عنوان یک بلوک پایه استفاده گردید تا بتوان با طراحی یک شبکه متراکم، ویژگی‌ها را لایه به لایه استخراج کرد تا پس از نگاشت آن‌ها، پیش‌بینی انجام شود. بنابراین لایه CNN استفاده‌شده در این مدل مفهومی، به‌عنوان نوآوری در طراحی الگوریتم در نظر گرفته‌شده

شکل ۳، چارچوب کلی فرآیند پیش‌بینی حجم ترافیک در محور کرج- چالوس را نشان می‌دهد. این روند شامل مراحل کلیدی مانند جمع‌آوری داده‌های ترددشمار و هواشناسی سینوپتیک، پیش‌پردازش داده‌ها، طراحی و آموزش مدل ترکیبی Conv-LSTM با بهره‌گیری از قابلیت‌های CNN و LSTM، ارزیابی مدل با معیارهای R2، MSE و RMSE، و مقایسه عملکرد آن با مدل A-LSTM است.

است. CNN به دلیل پتانسیل بالا در استخراج ویژگی‌ها با استفاده از لایه‌های مختلف، با موفقیت در پیش‌بینی ترافیک اعمال شده است. یک CNN معمولی عمدتاً از چندین لایه پیچشی و لایه‌های ادغام تشکیل شده است. اولی به استخراج وابستگی‌های مکانی بخش‌های جاده کمک می‌کند، زیرا هر لایه توسط فیلترهای مختلف یک ویژگی متمایز را بازیابی می‌کند، در حالی که دومی به کاهش تعداد پارامترهای مورد نیاز برای آموزش CNN با فرض اطمینان از دقت پیش‌بینی کمک می‌کند.




شکل ۲. ساختار مدل Conv-LSTM



شکل ۳. روند انجام مراحل پژوهش حاضر

در تجزیه و تحلیل داده‌های سری زمانی مورد استفاده قرار می‌گیرد. در الگوریتم پیچش یک‌بعدی، کرنل فقط در یک بُعد حرکت می‌کند و ورودی و خروجی این لایه نیز دو بُعدی هستند. این داده‌ها به‌طور معمول از نوع سری زمانی هستند. در نهایت، به‌منظور بررسی و مقایسه نتایج به‌دست آمده از الگوریتم پیشنهادی، مدل A-LSTM مدنظر قرار گرفت.

در الگوریتم پیشنهادی و شکل ۴، مدل مفهومی Conv-LSTM ارائه شده است. این مدل از یک لایه CNN یک‌بعدی استفاده می‌کند که وظیفه این لایه، پردازش سیگنال و ارتباط میان حفظ پیوستگی داده‌ها در بازه‌های زمانی پنج‌ساعته است. الگوریتم پیچش یک‌بعدی (Conv1D)، لایه‌ای در شبکه‌های عصبی عمیق است که برای داده‌های یک‌بعدی استفاده می‌شود. این لایه معمولاً



شکل ۴. ساختار شبکه عصبی عمیق پیشنهادی Conv-LSTM

۲-۳- جاده مورد مطالعه و جمع‌آوری داده‌ها

تحلیل از داده‌های دو ترددشمار استفاده شده است. از آنجایی که جاده‌ی مورد بررسی، دوطرفه می‌باشد، بنابراین داده‌های ترددشماری مسیر مخالف، هم به‌عنوان متغیرهای ورودی در نظر گرفته شده است. بازه زمانی جمع‌آوری داده‌های ذکر شده از (۱۴۰۱/۰۱/۰۱) الی (۱۴۰۳/۰۱/۰۱) می‌باشد.


جاده مورد بررسی در این پژوهش یعنی جاده چالوس، با نام رسمی جاده ۵۹، یکی از مهم‌ترین جاده‌های دسترسی به شمال ایران برای ساکنین شهرهای کرج و تهران است. این جاده از استان البرز آغاز می‌شود و شهر کرج و تهران را به چالوس در نزدیکی سواحل دریای مازندران متصل می‌کند. جاده چالوس برای بسیاری از مردم تهران جهت رفتن به سمت جاذبه‌های گردشگری شمال در تعطیلات آخر هفته نقشی اساسی دارد. این جاده با چشم‌اندازهای طبیعی و بکر، از پرطرفدارترین راه‌های مواصلاتی به شمال کشور است و به همین دلیل در ایام تعطیل سال اغلب با ترافیک سنگین همراه می‌شود.

۲-۲-۳- داده‌های هواشناسی

داده‌های هواشناسی از ایستگاه سینوپتیک سازمان هواشناسی کشور (IRIMO) (IRIMO. I.R. of Iran Meteorological Organization) با نام ایستگاه سیاه‌بیشه با شماره ایستگاه ۴۰۷۳۵ در ارتفاع ۱۸۵۵٫۴ متری از سطح دریا و طول جغرافیایی ۵۱٫۳۰۳ و عرض جغرافیایی ۳۶٫۲۳۱ واقع در استان مازندران به صورت سینوپتیک (برداشت سه ساعت به سه ساعت) جمع‌آوری شده است. داده‌های هواشناسی سینوپتیک بر اساس تاریخ میلادی از (۲۰۲۲/۰۳/۲۱) الی (۲۰۲۴/۰۳/۲۰) که معادل شمسی (۱۴۰۱/۰۱/۰۱) الی (۱۴۰۳/۰۱/۰۱) است، گردآوری شده‌اند. در شکل ۵، مکان جغرافیایی ترددشمارها و ایستگاه هواشناسی نشان داده شده است.

۲-۳-۱- داده‌های ترددشماری

داده‌های ترددشماری از ترددشمارهای سازمان راهداری و حمل و نقل جاده‌ای ایران (RMTO) (RMTO. Road Maintenance and Transportation Organization) توسط دو ترددشمار به کد محورهای ۱۸۳۱۲۰ برای مسیر کرج - چالوس (کندوان) با پسوند (kc) و ۱۸۳۱۷۰ برای مسیر چالوس - کرج (کندوان) با پسوند (ck) جمع‌آوری شدند. نکته حائز اهمیت، این می‌باشد که برای طراحی الگوریتم و تجزیه و



شکل ۵. تصویر نقشه ماهواره‌ای جاده چالوس و مکان‌های جمع‌آوری داده‌ها (ترددشمارهای ۱۸۳۱۷۰ و ۱۸۳۱۲۰ و ایستگاه هواشناسی ۴۰۷۳۵)


۳-۲-۳- پیش‌پردازش و متغیرهای استفاده‌شده در پژوهش

پیش‌پردازش داده‌های هواشناسی و ترافیکی برای استفاده در مدل‌های یادگیری عمیق مانند A-LSTM و Conv-LSTM از اهمیت ویژه‌ای برخوردار است، زیرا کیفیت و صحت داده‌ها به طور مستقیم بر عملکرد مدل تأثیر می‌گذارد. داده‌های ترددشمار، مانند حجم ترافیک ثبت‌شده توسط حسگرهای جاده‌ای، اغلب با نویز، مقادیر گم‌شده یا ناهنجاری‌هایی مانند ثبت نادرست مواجه هستند که نیازمند پاکسازی، نرمال‌سازی و پر کردن مقادیر گم‌شده با روش‌هایی مانند میانگین‌گیری است. داده‌های هواشناسی نیز که معمولاً با فواصل زمانی سه‌ساعته جمع‌آوری می‌شوند، باید با داده‌های ترافیکی از لحاظ تطابق زمانی همگام شوند و ناسازگاری‌هایی مانند خطاهای حسگر یا تغییرات ناگهانی غیرواقعی اصلاح گردند. حذف داده‌های پرت

با روش IQR انجام شد. انجام به ترتیب این مراحل در فرآیند پیش‌پردازش، با ایجاد یک پایگاه داده و یکپارچه، دقت پیش‌بینی را بهبود می‌بخشد و امکان مدل‌سازی الگوهای فضایی-زمانی را فراهم می‌کند. در جدول ۲، متغیرهای بانک اطلاعاتی برای طراحی الگوریتم‌ها و تجزیه و تحلیل داده‌ها، شامل ۳۳ پارامتر، معرفی شدند. متغیرهای به‌دست آمده از ترددشمارها برای هر دو جهت رفت و مخالف جاده در نظر گرفته‌شده، بنابراین ۱۲ متغیر مربوط به ترددشمارها تبدیل به ۲۴ متغیر می‌شود که ۱۲ متغیر مربوط به ترددشمار مسیر کرج به چالوس و ۱۲ متغیر مربوط به ترددشمار مسیر چالوس به کرج می‌باشد. در شکل ۶، متغیرهایی که در کنار آن‌ها ستاره قرمز رنگ وجود دارد، به آن معناست که به این متغیرها در پژوهش‌های پیشین کمتر توجه شده‌است.

جدول ۲. متغیرهای ورودی

ویژگی ورودی	توضیحات
متغیرهای تقویمی	
DateTime	تاریخ.
Hour	متغیر از ساعت ۱ تا ساعت ۲۴ در هر روز.
Day of week	متغیر از شنبه تا جمعه در هر هفته.
Day of month	متغیر بین روز ۱ تا روز ۳۱ در هر ماه.
Holidays	تعطیلات رسمی و روزهای آخر هفته بر اساس تقویم فارسی.
متغیرهای ترافیکی	
Operating time (Minutes)	مدت زمان فعالیت ترددشمار بر حسب دقیقه در ساعت.
Total number of vehicles	مجموع وسایل نقلیه در بازه زمانی فعالیت ترددشمار.
Number of class 1 vehicles	تعداد خودروهای سواری و وانت.
Number of class 2 vehicles	تعداد کامیون‌های کوچک، کامیونت‌ها و مینی‌بوس‌ها.
Number of class 3 vehicles	تعداد کامیون‌های معمولی کمتر از ۱۰ متر و سه محوره‌ها.
Number of class 4 vehicles	تعداد اتوبوس‌ها.
Number of class 5 vehicles	تعداد تریلرها و باربرهای بالاتر از سه محور.
Average speed	میانگین سرعت ترافیک بر اساس سرعت‌های ثبت‌شده برای انواع وسایل نقلیه محاسبه می‌شود.
Speeding violation	تخلفات سرعت به تعداد وسایل نقلیه‌ای اطلاق می‌شود که در یک بازه زمانی معین از حد مجاز سرعت اعلام‌شده در یک بخش جاده تجاوز کرده است.
Violation of following distance	عدم رعایت فاصله حداقل دو ثانیه از خودروی قبلی تخلف عدم رعایت فاصله ایمن محسوب می‌شود.
Unauthorized overtaking violation	تعداد تخلف‌های سبقت غیر مجاز.
Estimated number	تخمین تعداد وسایل نقلیه در مدت زمان یک ساعت.
متغیرهای هواشناسی	
Horizontal visibility	دید افقی بر حسب متر.
Temperature	دما بر حسب سانتیگراد.
Relative humidity	رطوبت نسبی بر حسب درصد.
Cloud cover	وضعیت پوشش ابر بر اساس امتیاز بین ۱ تا ۱۰.



شکل ۶. متغیرهای وابسته و مستقل در نظر گرفته شده در این پژوهش

۳-۲-۴- نحوه عملکرد الگوریتم‌ها و برنامه‌های استفاده شده

بر اساس تحلیل داده‌ها مشخص شد که انتخاب داده‌های پنج ساعت قبل برای پیش‌بینی متغیر حجم ترافیک در یک ساعت آینده می‌تواند مناسب باشد. در جدول ۳، در ابتدا داده‌های پنج

ساعت اخیر مجموعه داده‌ها به الگوریتم‌ها به عنوان ورودی داده می‌شوند و الگوریتم‌ها باید تعداد خودروهای ترددی ساعت ششم را به عنوان خروجی پیش‌بینی کنند. در این پژوهش از زبان برنامه‌نویسی Python و محیط Jupyter Notebook استفاده شده است.

جدول ۳. نحوه عملکرد الگوریتم‌ها برای پیش‌بینی حجم ترافیک در یک ساعت آینده

ورودی	خروجی
داده‌های ساعت ۰ تا ۵	پیش‌بینی تعداد خودرو در ساعت ۶
داده‌های ساعت ۱ تا ۶	پیش‌بینی تعداد خودرو در ساعت ۷
داده‌های ساعت ۲ تا ۷	پیش‌بینی تعداد خودرو در ساعت ۸
...	...
داده‌های ساعت ۲۳ تا ۴	پیش‌بینی تعداد خودرو در ساعت ۵

آموزش، باید بتواند یک قانون و الگوی پیش‌بینی خروجی را برای ورودی‌های جدید (یعنی داده‌های آزمون) ایجاد کند. در مرحله آزمون، مدل آموزش‌یافته بر روی داده‌های جدید اعمال می‌شود. به‌طور کلی، باید بررسی شود که الگوی ساخته شده در مرحله آموزش، برای پیش‌بینی خروجی داده‌های آزمون مناسب است یا خیر.

در جدول ۴، نحوه تقسیم‌بندی بانک اطلاعاتی برای مراحل آموزش و آزمون الگوریتم مشخص شده است. آموزش و آزمون، دو مرحله اصلی در ساخت و استفاده از یک مدل یادگیری عمیق هستند. در مرحله آموزش، مدل با استفاده از داده‌های آموزش، روی مجموعه‌ای از الگوهای موجود، آموزش داده می‌شود. به‌طور کلی، مدل در این مرحله با توجه به ویژگی‌های داده‌های

جدول ۴. نرخ تقسیم‌بندی بانک اطلاعاتی برای آموزش، اعتبارسنجی و آزمون مدل‌ها

آموزش	اعتبارسنجی	آزمون
۱۲,۰۳۴	۱,۰۰۰	۳,۰۰۰

برای بررسی عملکرد مدل‌های ساخته‌شده، از پارامترهای آماری در نظر گرفته‌شده در معادله‌های ۱۰، ۱۱ و ۱۲ استفاده شده است.

$$MSE = \frac{1}{T} \sum_{t=1}^T (\hat{y}_t - y_t)^2 \quad (10)$$

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (\hat{y}_t - y_t)^2} \quad (11)$$

$$R^2 = 1 - \frac{\sum_{t=1}^T (\hat{y}_t - y_t)^2}{\sum_{t=1}^T (\frac{1}{T} \sum_{t=1}^T y_t - \hat{y}_t)^2} \quad (12)$$

MSE و $RMSE$ به عدد صفر و مقدار R^2 به عدد یک نزدیکتر باشد، مدل‌های موردنظر عملکرد بهتری دارند.

y_t ، مقدار خروجی هدف، $\hat{y}_t$ ، خروجی پیش‌بینی شده در زمان t و T ، تعداد کل نمونه‌های پیش‌بینی شده است. هر چه مقادیر

۴- نتایج و بحث

وزن‌های جدید. اندازه Batch و تعداد Epoch به‌ترتیب روی ۱۶ و ۵۰ انتخاب شدند.

مورد سوم، نرخ یادگیری Learning Rate است و تعیین می‌کند آیا می‌توان با یک مقدار مناسب به راه‌حل بهینه در پارامترهای مدل دست پیدا کرد یا خیر. اگر مقدار آن خیلی کوچک باشد احتمال دارد جواب مسأله یک بهینه محلی باشد و اگر مقدار آن خیلی بزرگ باشد احتمال دارد به جواب بهینه همگرا نشود. مقدار نرخ یادگیری در هر دو مدل برابر با $1e-5$ تنظیم شد. مورد آخر، عمق شبکه، نیز فاکتور مؤثری بر عملکرد مدل است.

هر چه تعداد لایه‌های یک شبکه بیشتر باشد، توانایی در استخراج ویژگی‌ها بیشتر می‌شود. با این وجود، افزایش تعداد لایه‌ها، بهبود عملکرد و سرعت آموزش را به میزان قابل‌توجهی کاهش می‌دهد. بدین ترتیب، در این پژوهش، جزئیات دقیق و مشخصات در نظر گرفته‌شده هر یک از لایه‌ها در مدل‌های نهایی در جدول ۵، ارائه شده است.


در این پژوهش به‌منظور تجزیه و تحلیل مجموع داده‌های موردنظر با هدف پیش‌بینی کوتاه‌مدت حجم ترافیک برای یک ساعت آینده از دو الگوریتم A-LSTM و Conv-LSTM استفاده شد. دقت این مدل‌ها بستگی به تنظیم فرآپارامترهای آن دارد. انتخاب فرآپارامترها بر نحوه عملکرد الگوریتم تأثیر می‌گذارد. ترکیبات مختلف فرآپارامترها به راه‌حل‌های مختلف منجر می‌شود. به‌منظور یافتن مقادیر بهینه فرآپارامترها از روش آزمون و خطا و مقایسه نتایج مدل‌های ساخته‌شده استفاده گردید. اولین فرآپارامتر، بهینه‌ساز است که در مدل‌های A-LSTM و Conv-LSTM، الگوریتم Adam به‌همراه تابع هزینه MSE به‌کار گرفته شده است (Wang et al., 2022). مورد دوم، انتخاب اندازه Batch و Epoch است. هرچه Batch کوچک‌تر باشد، آموزش سریع‌تر و پایدارتر است، اما Batch بزرگ باعث کندی بهینه‌سازی می‌شود. هر Epoch شامل مشاهده‌ی کل داده، محاسبه‌ی خطا و به‌روزرسانی وزن‌ها از طریق پس‌انتشار برای کاهش خطا است. Epoch‌های بعدی مشابه اولی هستند با

جدول ۵. مشخصات معماری و لایه‌های پیشنهادی مدل‌ها


مدل‌ها	نوع لایه‌ها	ابعاد خروجی	تعداد پارامترها	تعداد کل پارامترهای آموزش پذیر
A-LSTM	input_layer (InputLayer)	(None, ۵, ۳۳)	۰	۱۳۳,۴۴۱
	lstm (LSTM)	(None, ۵, ۱۲۸)	۸۲,۹۴۴	
	lstm_1 (LSTM)	(None, ۵, ۶۴)	۴۹,۴۰۸	
	attention (Attention)	(None, ۳۲)	۰	
	dense (Dense)	(None, ۳۲)	۱,۰۵۶	
	dense_1 (Dense)	(None, ۱)	۳۳	
Conv-LSTM	conv1d (Conv1D)	(None, ۵, ۱۶)	۵۴۴	۲۳,۳۹۳
	lstm_2 (LSTM)	(None, ۶۴)	۲۰,۷۳۶	
	flatten (Flatten)	(None, ۶۴)	۰	
	dense_2 (Dense)	(None, ۳۲)	۲,۰۸۰	
	dense_3 (Dense)	(None, ۱)	۳۳	

تبدیل به یک بردار ۳۲ بعدی می‌شود. لایه آخر با یک واحد خروجی، مقدار پیش‌بینی حجم ترافیک را برای ساعت بعدی تولید می‌کند. در شکل ۷-ب، یعنی مدل Conv-LSTM، ابتدا از یک لایه پیچشی یک‌بعدی با ۱۶ فیلتر استفاده می‌کند که داده‌های ورودی را با ابعاد (None, ۵, ۳۳) دریافت کرده و به ابعاد (None, ۵, ۱۶) تبدیل می‌کند. خروجی لایه پیچشی، سپس به لایه LSTM با ۶۴ واحد عصبی وارد می‌شود. در ادامه، لایه Dense با ۳۲ واحد به‌عنوان لایه میانی، ویژگی‌های خلاصه‌شده را پردازش می‌کند.

ساختار گرافیکی مدل‌های پیشنهادی و فرآیندهای اعمال‌شده در شکل ۷ آورده شده است. در شکل ۷-الف، یعنی مدل A-LSTM، ورودی مدل شامل دنباله‌ای از داده‌های ترافیکی پنج ساعت قبل می‌باشد که هر ساعت با ۳۳ ویژگی توصیف می‌شود. ویژگی‌های موردنظر شامل اطلاعات متنوعی از قبیل ترددشمارها، شرایط آب‌وهوایی و داده‌های تقویمی هستند. اولین لایه مدل، لایه ورودی است که داده‌ها را با ابعاد (None, ۵, ۳۳) دریافت می‌کند. سپس داده‌ها از دو لایه LSTM عبور می‌کنند که به ترتیب دارای ۱۲۸ و ۶۴ واحد هستند. خروجی (لایه‌های قبل) به لایه Attention ارسال می‌شود که با کاهش ابعاد آن،




الف) A-LSTM




ب) Conv-LSTM

شکل ۷. ارائه معماری گرافیکی مدل‌ها

با توجه به مقدار R^2 بدست آمده در جدول ۶، که هر چه این عدد به مقادیر یک نزدیکتر باشد، پیش‌بینی دقیق‌تر بوده است و هر چه این مقدار به صفر نزدیکتر باشد، الگوریتم نتوانسته مقدار نهایی را به‌درستی پیش‌بینی کند، Conv-LSTM توانست در بخش آزمون با ۸۲/۴۵٪ امتیاز بیشتری کسب کند. بخش آزمون، داده‌هایی هستند که الگوریتم آن‌ها را ندیده است، بنابراین، ملاک ارزیابی داده‌های آزمون هستند. در نتیجه می‌توان گفت Conv-LSTM توانست عملکرد بهتری نسبت به A-LSTM با R^2 برابر با ۸۱/۹۳٪ داشته باشد.



الف) A-LSTM



ب) Conv-LSTM


شکل ۸. روند کاهش میانگین مربعات خطا در حین یادگیری مدل‌ها

جدول ۶. نتایج پیش‌بینی توسط الگوریتم‌های A-LSTM و Conv-LSTM


روش/معیارهای ارزیابی	A-LSTM		Conv-LSTM	
	آموزش	آزمون	آموزش	آزمون
MSE	۱۳۶۲۰٫۸۴	۱۴۷۳۹٫۲۹	۱۵۳۲۴٫۴۹	۱۴۳۱۰٫۱۸
$RMSE$	۱۱۶٫۷۰	۱۲۱٫۴۰۵۴	۱۲۳٫۷۹	۱۱۹٫۶۲
R^2	۰٫۸۶۹	۰٫۸۱۹۳	۰٫۸۵۲۷	۰٫۸۲۴۵

اختصاص دارد. از تطابق خروجی‌های مدل و داده‌های واقعی مشخص است که رگرسیون این داده‌ها در شکل ۹-ب به مقدار یک نزدیک‌تر است که این گویای دقت بالای Conv-LSTM است. شیب این خط مبنا، برابر مقدار یک است و هر چه داده‌ها به خط نزدیک‌تر باشند، ارتباط بیشتری بین خروجی‌های مدل و داده‌های واقعی وجود دارد، که در Conv-LSTM با پراکندگی مناسب، خروجی‌های مدل به داده‌های واقعی نزدیک است.

شاخص‌های MSE و $RMSE$ معیارهایی برای سنجش خطای پیش‌بینی هستند و نزدیکی این مقادیر به صفر، بیانگر دقت بالاتر مدل در برآورد خروجی‌های واقعی می‌باشد. مقدار حاصل برای آن‌ها در داده‌های آزمون توسط Conv-LSTM به ترتیب حدود ۱۴،۳۱۱ و ۱۲۰ و برای A-LSTM به ترتیب حدود ۱۴،۷۴۰ و ۱۲۲ گزارش شدند، در نتیجه پیش‌بینی‌های انجام‌شده توسط Conv-LSTM نسبت به A-LSTM دارای پراکندگی اندک هستند. مورد بعدی در شکل ۹ به رگرسیون بخش آزمون مدل‌ها



A-LSTM (الف)




Conv-LSTM (ب)


شکل ۹. مقادیر پیش‌بینی شده در مقابل مقادیر واقعی

(رنگ نارنجی) تفاوت زیادی وجود ندارد و تنها در مقادیری دارای انحراف از داده‌ها است که نشان‌دهنده خطای کم و نشان از قدرت و دقت Conv-LSTM نسبت به A-LSTM در شکل ۱۰-ب می‌باشد.

موضوع بعدی، بررسی میزان همپوشانی و تطابق بین خروجی‌های پیش‌بینی‌شده توسط مدل‌ها و مقادیر واقعی است. همان‌طور که در شکل ۱۰-الف مشخص است Conv-LSTM روند تغییرات را در بخش داده‌های آزمون با دقت مناسبی تخمین زده است. بین مقادیر واقعی (رنگ آبی) با مقادیر تخمین‌زده‌شده



A-LSTM (الف) حجم ترافیک پیش‌بینی شده توسط الگوریتم



Conv-LSTM (ب) حجم ترافیک پیش‌بینی شده توسط الگوریتم

شکل ۱۰. مقایسه حجم‌های پیش‌بینی شده در مقابل مقادیر واقعی برای ۵۰۰ داده اول

کامل وابستگی مکانی-زمانی داده‌های جریان ترافیک را در نظر نمی‌گیرند. باید توجه داشت که داده‌ها، مدل‌ها، معیارهای ارزیابی و همچنین افق‌های زمانی در نظر گرفته‌شده در این پژوهش‌ها با مطالعه حاضر از جنبه‌های مختلف دارای تفاوت‌هایی هستند، بنابراین، نمی‌توان در مقایسه برتری مدل‌ها نسبت به یکدیگر اظهار نظر کرد، اما به‌طور کلی با مقایسه می‌توان گفت که در مدل

در نهایت، نتایج به‌دست آمده در این مطالعه با دو پژوهش مشابه در جدول ۷ مقایسه شدند. در پژوهش (Rasaizadi et al., 2022)، صرفاً از مدل LSTM برای طبقه‌بندی وضعیت ترافیکی شامل روان، نیمه سنگین و سنگین استفاده شده است. همچنین در پژوهش (Sherafat et al., 2023)، افق‌های زمانی ۱۵ و ۳۰ دقیقه‌ای را توسط LSTM و A-LSTM بررسی شد، که به‌طور

Conv-LSTM مدلی موفق جهت پیش‌بینی‌های سری زمانی در دوره‌های کوتاه‌مدت و یک‌ساعته پیش‌بینی حجم ترافیک است. بنابراین Conv-LSTM برای پیش‌بینی توالی داده‌های ترافیکی به دلیل اثربخشی آن در پردازش داده‌های مکانی-زمانی عملکرد قابل‌توجهی دارد. برای بکارگیری مدل‌های A-LSTM و Conv-LSTM در سایر محورهای برون‌شهری ایران با ویژگی‌های مشابه، ابتدا باید داده‌های محلی هر محور را جمع‌آوری و پیش‌پردازش کرد.

سپس، مدل A-LSTM با مکانیزم Attention می‌تواند بر الگوهای زمانی فصلی تمرکز کند، مانند افزایش تردد در ایام نوروز، در حالی که Conv-LSTM با لایه‌های کانولوشنی، روابط فضایی بین نقاط ورودی/خروجی محور را مدل‌سازی می‌کند.

پیشنهادی، علاوه بر متغیرهای رایج در نظر گرفته شده در این دو پژوهش، از ترکیب جامع‌تری از داده‌ها (شامل، سرعت متوسط، مدت زمان کارکرد، تخلفات و کلاس‌بندی خودروها در جهت و خلاف جهت مسیر، ساعت روز، روز هفته و نوع روز (روز تعطیل یا عادی)، دما، رطوبت، دید افقی، ابرناکی، تعطیلات، روزهای آخر هفته) استفاده شد که هر کدام به‌طور غیرمستقیم و مستقیم نحوه عملکرد جریان ترافیک را منعکس می‌کنند. همچنین از مدل ترکیبی و پیچیده‌تر Conv-LSTM استفاده شد که می‌تواند با یکپارچه کردن اطلاعات مکانی-زمانی، اثر استخراج ویژگی را بهبود بدهد. ارزیابی‌ها، نشان دادند این مدل ترکیبی دارای دقتی مشابه و در راستای نتایج به‌دست آمده توسط مدل‌های LSTM و A-LSTM به کار گرفته شده در پژوهش‌های (Rasaizadi et al., 2022) و (Sherafat et al., 2023) می‌باشد، که می‌تواند بیانگر اعتبار این فرضیه باشد که

جدول ۷. مقایسه نتایج با پژوهش‌های پیشین

پژوهش	رساءیزدی و همکاران (Rasaizadi et al., 2022)	شرافت و همکاران (Sherafat et al., 2023)	پژوهش حاضر
هدف	سرعت ترافیک و حجم ترافیک	سرعت ترافیک و حجم ترافیک	حجم ترافیک
متغیرهای پیش‌بینی کننده	- ساعت روز، روز هفته و نوع روز (روز تعطیل یا عادی) - وضعیت آفتابی، بارانی و برفی - تعطیلات، روزهای آخر هفته و روزهای قبل از تعطیلی - انسداد همان مسیر، مسیر مقابل و مسیر موازی	- سرعت متوسط در جهت و خلاف جهت مسیر - ساعت روز، روز هفته و نوع روز (روز تعطیل یا عادی) - طلوع و غروب خورشید، بارانی، آفتابی، برفی - تعطیلات، روزهای آخر هفته	- سرعت متوسط، مدت زمان کارکرد، تخلفات و کلاس‌بندی خودروها در جهت و خلاف جهت مسیر - ساعت روز، روز هفته و نوع روز (روز تعطیل یا عادی) - دما، رطوبت، دید افقی، ابرناکی - تعطیلات، روزهای آخر هفته
روش	SVM - - جنگل تصادفی (RF) LSTM -	LSTM - A-LSTM -	A-LSTM - Conv-LSTM -
سال	۲۰۲۲	۲۰۲۳	۲۰۲۴
نتایج	مدل حافظه طولانی کوتاه‌مدت با دقتی معادل با ۹۰/۱۱ دقیق‌ترین مدل پیش‌بینی کننده وضعیت ترافیک با افق کوتاه‌مدت است. این مدل برای افق بلندمدت نیز متغیر وضعیت ترافیک را با ۸۲/۰۷ دقیق‌تر از دو مدل دیگر پیش‌بینی کرده است و بیشترین مقادیر شاخص F برای پیش‌بینی سه وضعیت ترافیک سبک، نیمه‌سنگین و سنگین را به همراه داشته که به ترتیب برابر با ۰/۹۳، ۰/۸۶ و ۰/۸۱ به‌دست آمده‌اند.	مدل A-LSTM در فواصل ۵ و ۱۵ دقیقه بهتر از LSTM عمل می‌کند. در مقابل، هیچ تفاوت معناداری بین دو مدل برای فاصله زمانی ۳۰ دقیقه وجود ندارد. با مقایسه عملکرد مدل‌ها بر اساس افق‌های زمانی مختلف، مدل افق ۱۵ دقیقه‌ای با رسیدن به کمترین افت میزان MSE برابر ۰/۰۰۳۲ و پس از آن افق‌های ۳۰ و ۵ دقیقه‌ای برابر ۰/۰۰۰۴ و ۰/۰۰۵۱ از سایرین پیشی می‌گیرد.	با توجه به نتایج به‌دست آمده Conv-LSTM با کسب کردن R^2 معادل ۰/۸۲ توانسته است بهتر از A-LSTM که R^2 برابر ۰/۸۱ را کسب کرده است، عمل کند. همچنین A-LSTM به نسبت به Conv-LSTM کمی دچار بیش‌برازش شده است.

۵- نتیجه گیری

ویژگی‌های مکانی از داده‌های ترافیکی نیست، عملکرد نهایی آن ضعیف‌تر از مدل‌های رقیب گزارش شده است. پیشنهاد می‌شود در پژوهش‌های آتی از الگوریتم‌های فراابتکاری نظیر روش گوزن قرمز (Red Deer Algorithm) (Rezashoar & Rassafi, 2025) (Grey Wolf Optimizer) (Khorshidi et al., 2025) در کنار کتابخانه بهینه‌سازی Optuna (Rezashoar et al., 2024) برای بهبود وزن‌ها یا معماری مدل‌های یادگیری عمیق مانند Conv-LSTM و A-LSTM استفاده شود تا دقت پیش‌بینی جریان ترافیک، به‌ویژه در محور کرج-چالوس، افزایش یابد. روش گوزن قرمز با الهام از رفتار طبیعی گوزن‌ها، توانایی بالایی در جستجوی بهینه در فضاها پیچیده دارد و می‌تواند برای تنظیم دقیق فرآیندهای مدل‌های یادگیری عمیق مؤثر باشد. به‌طور مشابه، الگوریتم گرگ خاکستری با تقلید از سلسله‌مراتب اجتماعی و راهبردهای شکار گرگ‌ها، در بهینه‌سازی معماری‌های پیچیده شبکه‌های عصبی عملکرد قدرتمندی ارائه می‌دهد. استفاده از کتابخانه Optuna نیز امکان جستجوی خودکار و هوشمندانه فرآیندهای یادگیری عمیق را فراهم می‌کند که با ترکیب این روش‌ها، می‌توان به مدل‌هایی با کارایی بالاتر و خطای کمتر در پیش‌بینی‌های کوتاه‌مدت و بلندمدت دست یافت. این الگوریتم‌های معرفی‌شده نه تنها برای محور کرج-چالوس، بلکه برای پیش‌بینی جریان ترافیک در بازه‌های زمانی طولانی‌مدت و در شرایط جوی و توپوگرافی متنوع قابل‌تعمیم هستند. این رویکرد نوآورانه با استفاده از داده‌های تردد، آب‌وهوا و تقویم، به توسعه سیستم‌های حمل‌ونقل هوشمند با دقت بالا کمک می‌کند. مدیریت پیشگیرانه ترافیک و برنامه‌ریزی مسیر، امکان کاهش ازدحام را فراهم می‌آورد، به‌ویژه برای افزایش ناگهانی ترافیک در بازه‌های کوتاه‌مدت.

پیش‌بینی دقیق جریان ترافیک کوتاه‌مدت یکی از اهداف اصلی سیستم‌های حمل‌ونقل هوشمند است که امکان نظارت و پشتیبانی فنی از جریان ترافیک را در بازه‌های زمانی مشخص در آینده فراهم می‌کند. در این پژوهش، مدل Conv-LSTM برای پیش‌بینی حجم ترافیک ساعتی پیشنهاد شده است. برای ارزیابی روش پیشنهادی، محور برون‌شهری کرج-چالوس در بازه زمانی ۱۴۰۱/۰۱/۰۱ الی ۱۴۰۳/۰۱/۰۱ به عنوان مطالعه موردی انتخاب شد. داده‌های دو تردد شمار در مسیرهای رفت و برگشت به عنوان متغیرهای ورودی استفاده شدند، به‌طوری‌که ۱۲ متغیر تردد شمار به ۲۴ متغیر تبدیل شدند. همچنین، داده‌های هواشناسی سینوپتیک به صورت برداشت‌های سه‌ساعته جمع‌آوری شدند. در نهایت، مدل‌سازی با استفاده از روش پیشنهادی Conv-LSTM و مقایسه آن با روش A-LSTM در زبان برنامه‌نویسی Python انجام شد. نتایج نشان داد که Conv-LSTM توانست در بخش آزمون، R^2 برابر با ۰/۸۲/۴۵ را کسب کند، در نتیجه نسبت به A-LSTM با R^2 برابر با ۰/۸۱/۹۳ عملکرد بهتری را ارائه داد. در ادامه، مقادیر مربوط به MSE و RMSE حاصل‌شده برای مرحله آزمون Conv-LSTM به ترتیب حدود ۱۴,۳۱۱ و ۱۲۰ و برای A-LSTM به ترتیب حدود ۱۴,۷۴۰ و ۱۲۲ گزارش شد، که نشان‌دهنده پراکندگی بسیار اندک داده‌ها و نزدیکی مقادیر پیش‌بینی شده با مقادیر واقعی Conv-LSTM نسبت به A-LSTM است. در توجیه برتری Conv-LSTM باید گفت این مدل، عملیات کانولوشنی را در معماری LSTM ادغام می‌کند. LSTM وابستگی‌های دورتر را در داده‌های متوالی حفظ می‌کند در حالی که قابلیت لایه‌های کانولوشن، استخراج ویژگی‌های مکانی را در خود جای می‌دهد. اگرچه مدل A-LSTM به‌خوبی می‌تواند اهمیت دوره‌های مختلف تاریخی را تشخیص داده و وزن‌های متناسبی به آن‌ها اختصاص دهد، اما از آنجا که قادر به استخراج

۶- مراجع

Model Based on Deep Learnings. *Journal of Advanced Transportation*, 2022(1), 1702766.
-Chen, X., Xie, X., & Teng, D. (2020). Short-term traffic flow prediction based on ConvLSTM model. *2020 IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC)*.
-Dong, W., & Sun, W. (2022). Traffic flow prediction based on Bi LSTM and attention.

-Abdel-Rahim, A., Dixon, M. P., Bacon, C. J., & Gonzalez, A. (2015). *Measures to Alleviate Congestion at Rural Intersections*.
-Ahmed, M. S., & Cook, A. R. (1979). Analysis of freeway traffic time-series data by using Box-Jenkins techniques.
-Chai, C., Ren, C., Yin, C., Xu, H., Meng, Q., Teng, J., & Gao, G. (2022). A Multifeature Fusion Short-Term Traffic Flow Prediction

- based on time series analysis and LSTM_BILSTM method. *IEEE Transactions on Intelligent Transportation Systems*, 23(6), 5615-5624.
- Ramakrishnan, N., & Soni, T. (2018). Network traffic prediction using recurrent neural networks. 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA).
- Rasaizadi, A., Seyedabrishami, S., & Saniee Abadeh, M. (2021). Short-Term Prediction of Traffic State for a Rural Road Applying Ensemble Learning Process. *Journal of Advanced Transportation*, 2021(1), 3334810.
- Rasaizadi, A., Sherafat, E., & Seyedabrishami, S. (2022). Short-term prediction of traffic state: Statistical approach versus machine learning approach. *Scientia Iranica*, 29(3), 1095-1106.
- Ren, C., Chai, C., Yin, C., Ji, H., Cheng, X., Gao, G., & Zhang, H. (2021). Short-Term Traffic Flow Prediction: A Method of Combined Deep Learnings. *Journal of Advanced Transportation*, 2021(1), 9928073.
- Rezashoar, S., Kashi, E., & Saeidi, S. (2024). A hybrid algorithm based on machine learning (LightGBM-Optuna) for road accident severity classification (case study: United States from 2016 to 2020). *Innovative Infrastructure Solutions*, 9(8), 319.
- Rezashoar, S., & Rassafi, A. A. (2025). Analyzing the Performance of the Red Deer Optimization Algorithm in Comparison to Other Metaheuristic Algorithms. *Journal of AI and Data Mining*, 13(1), 53-61.
- RMTO. Road Maintenance and Transportation Organization (RMTO), Iran Road Traffic Data Website. <https://141.ir/> (2024). Accessed: 2024-03-20.
- Sherafat, E., Farooq, B., Karbasi, A. H., & Seyedabrishami, S. (2023). Attention-LSTM for Multivariate Traffic State Prediction on Rural Roads. *arXiv preprint arXiv:2301.02731*.
- Van Der Voort, M., Dougherty, M., & Watson, S. (1996). Combining Kohonen maps with ARIMA time series models to forecast traffic flow. *Transportation Research Part C: Emerging Technologies*, 4(5), 307-318.
- Wang, Y., Xiao, Z., & Cao, G. (2022). A convolutional neural network method based on Adam optimizer with power-exponential learning rate for bearing fault diagnosis. *Journal of Vibroengineering*, 24(4), 666-678.
- International Core Journal of Engineering*, 8(3), 439-444.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., & Cai, J. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.
- Harwood, D. W., Council, F., Hauer, E., Hughes, W., & Vogt, A. (2000). Prediction of the expected safety performance of rural two-lane highways.
- Hou, Y., Deng, Z., & Cui, H. (2021). Short-Term Traffic Flow Prediction with Weather Conditions: Based on Deep Learning Algorithms and Data Fusion. *Complexity*, 2021(1), 6662959.
- Hu, X., Liu, T., Hao, X., & Lin, C. (2022). Attention-based Conv-LSTM and Bi-LSTM networks for large-scale traffic speed prediction. *The Journal of Supercomputing*, 78(10), 12686-12709.
- IRIMO. I.R. of Iran Meteorological Organization (IRIMO), Iran Road Meteorological Data Website. <https://irimo.ir/> (2024). Accessed: 2024-03-20.
- Kashyap, A. A., Raviraj, S., Devarakonda, A., Nayak K, S. R., KV, S., & Bhat, S. J. (2022). Traffic flow prediction models—A review of deep learning techniques. *Cogent Engineering*, 9(1), 2010510.
- Khorshidi, N., Zargari, S. A., Rezashoar, S., & Mirzahosseini, H. (2025). Optimizing Travel Time Reliability with XAI: A Virginia Interstate Network Case Using Machine Learning and Meta-Heuristics. *Machine Learning with Applications*, 100709.
- Kim, S., Hori, T., & Watanabe, S. (2017). Joint CTC-attention based end-to-end speech recognition using multi-task learning. 2017 IEEE international conference on acoustics, speech and signal processing (ICASSP).
- Li, T., Ni, A., Zhang, C., Xiao, G., & Gao, L. (2020). Short-term traffic congestion prediction with Conv-BiLSTM considering spatio-temporal features. *IET Intelligent Transport Systems*, 14(14), 1978-1986.
- Lu, J., Xiong, C., Parikh, D., & Socher, R. (2017). Knowing when to look: Adaptive attention via a visual sentinel for image captioning. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Ma, C., Dai, G., & Zhou, J. (2021). Short-term traffic flow prediction for urban road sections

deep learning model for short-term network-based traffic forecasting. *International Journal of Geographical Information Science*, 34(5), 969-995.

-Zhao, Z., Chen, W., Wu, X., Chen, P. C., & Liu, J. (2017). LSTM network: a deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, 11(2), 68-75.

-Zheng, H., Lin, F., Feng, X., & Chen, Y. (2020). A hybrid deep learning model with attention-based conv-LSTM networks for short-term traffic flow prediction. *IEEE Transactions on Intelligent Transportation Systems*, 22(11), 6910-6920.

-Wu, P., Huang, Z., Pian, Y., Xu, L., Li, J., & Chen, K. (2020). A combined deep learning method with attention-based LSTM model for short-term traffic speed forecasting. *Journal of Advanced Transportation*, 2020(1), 8863724.

-Yu, Z., Yu, J., Fan, J., & Tao, D. (2017). Multi-modal factorized bilinear pooling with co-attention learning for visual question answering. *Proceedings of the IEEE International Conference on Computer Vision*.

-Zhang, K., Wu, L., Zhu, Z., & Deng, J. (2020). A multitask learning model for traffic flow and speed forecasting. *IEEE Access*, 8, 80707-80715.

-Zhang, Y., Cheng, T., Ren, Y., & Xie, K. (2020). A novel residual graph convolution

Presenting a Hybrid Deep Learning Approach (Conv-LSTM) With the Aim of Predicting Short-Term Traffic Volume on Two-Lane Suburban Roads (Case Study: Karaj-Chalus Road)

*Mehrdad Khorrami, M.Sc., Student, Department of Civil Engineering, Malard Branch,
Islamic Azad University, Malard, Tehran, Iran.*

*Ali Paydar, Assistant Professor, Department of Civil Engineering, Malard Branch,
Islamic Azad University, Malard, Tehran, Iran.*

***Soheil Rezashoar, Ph.D., Candidate, Department of Transportation Planning,
Faculty of Engineering, Imam Khomeini International University, Qazvin, Iran.***

E-mail: soheilshoar@edu.ikiu.ac.ir

Received: March 2026- Accepted: August 2026

ABSTRACT

In recent years, the rapid increase in the number of vehicles has led to widespread traffic problems. Accurate prediction of traffic flow can help reduce congestion, optimize transportation infrastructure, enhance travel safety, and mitigate environmental impacts. This study aimed to predict the traffic volume for the next hour on the Karaj-Chalus axis, one of Iran's busiest roads with complex weather and topographic conditions. To this end, traffic data from two traffic counters and synoptic weather data (with three-hour intervals) were collected. Given the capability of Convolutional Neural Networks (CNN) in extracting hidden features and spatial-temporal patterns, as well as the efficiency of Long Short-Term Memory (LSTM) networks in modeling time series, a hybrid Conv-LSTM model was proposed. This model, leveraging the strengths of both approaches, was designed for accurate traffic volume prediction. The proposed model was implemented in the Python programming language and compared with an Attention-based Long Short-Term Memory (A-LSTM) model. Evaluation results showed that the Conv-LSTM model achieved a coefficient of determination (R^2) of 82.45% on the test dataset, outperforming the A-LSTM model with an R^2 of 81.93%. Additionally, the Mean Squared Error (MSE) and Root Mean Squared Error (RMSE), which indicate the discrepancy between predicted and actual values, were reported as 14.311 and 120 for Conv-LSTM, and 14.740 and 122 for A-LSTM, respectively. These values indicate lower dispersion and higher prediction accuracy for Conv-LSTM compared to A-LSTM. The application of the proposed model in predicting traffic volume on the Karaj-Chalus axis provides valuable insights for identifying congested routes, redistributing traffic, preventing accidents, dynamic route planning, and optimizing travel time management. Furthermore, this approach contributes to improved environmental sustainability and transportation efficiency by reducing fuel consumption and air pollution.

Keywords: Traffic Volume, Neural Network, Long Short Term Memory, Convolution, Conv-LSTM