

پیش‌بینی کوتاه‌مدت سرعت ترافیک با استفاده از شبکه‌های عصبی بازگشتی (RNN)

عماد توکلی، کارشناسی ارشد، گروه مهندسی راه و ترابری، دانشکده مهندسی عمران، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران،

ایران

منصور حاجی حسینلو (مسئول مکاتبات)، دانشیار، گروه مهندسی راه و ترابری، دانشکده مهندسی عمران، دانشگاه صنعتی خواجه

نصیرالدین طوسی، تهران، ایران

E-mail: mansour@kntu.ac.ir

پذیرش: ۱۴۰۱/۰۵/۱۹

دریافت: ۱۴۰۱/۰۲/۲۵

چکیده

پیش‌بینی ترافیک، به عنوان بخش مهمی از سیستم‌های حمل و نقل هوشمند، نقش مهمی در نظارت بر وضعیت ترافیک ایفا می‌کند. با توجه به اینکه بسیاری از مطالعات کار پیش‌بینی سرعت ترافیک را با مدل‌های یادگیری عمیق انجام داده‌اند، همچنان پژوهشی بر روی پیش‌بین سرعت ترافیک در فصل‌های مختلف انجام نشده است. همچنین با توجه به تأثیرات مهم عوامل مکانی-زمانی و عملکرد عالی شبکه‌های عصبی بازگشتی (RNN) در زمینه تحلیل سری‌های زمانی، در این مقاله، یکی از شبکه‌های عصبی یادگیری عمیق که ویژگی‌های واحد بازگشتی گیتی تزریقی (FI-GRU) در داده‌های زمانی متوالی را ترکیب می‌کنند، پیشنهاد شده است. داده‌های مورد استفاده در این پژوهش از شبکه تجسم و ارزیابی فعال در شهر سیاتل ایالت متحده بدست آمده است. این پژوهش سه فصل بهار، تابستان و پاییز و چهار مدل یادگیری عمیق شامل LSTM و GRU و ConvLSTM و BiLSTM و یک مدل کم عمق SVM در سه گام زمانی ۵ دقیقه، ۱۰ دقیقه و ۱۵ دقیقه باهم مقایسه کرده است. نتایج این تحقیق نشان می‌دهد، مدل پیشنهادی در فصل‌های مختلف اختلافی چشمگیری نداشته است، و همچنین چهار مدل یادگیری عمیق و مدل SVM، در فصل‌های مختلف اختلاف قابل توجه نداشته‌اند، نتایج دیگر نشان می‌دهد هرچه بازه گام‌های زمانی بیشتر می‌شود خطاها بیشتر و دقت مدل کاهش پیدا می‌کند، با توجه به نتایج بدست آمده دقت مدل FI-GRU نسبت به کمترین دقت مدل یادگیری عمیق (BiLSTM) ۵۲٪ درصد بیشتر است، و دقت مدل پیشنهادی نسبت به مدل کم عمق (SVM) ۲۴٪ درصد بیشتر است و همچنین مدل پیشنهادی برای پیش‌بینی سرعت ترافیک در گام زمانی ۵ دقیقه ۱/۴۴ درصد بهتر عمل کرده است.

واژه‌های کلیدی: پیش‌بینی سرعت ترافیک، یادگیری عمیق، شبکه‌های GRU، شبکه‌های LSTM

۱. مقدمه

تأثیرگذار عموماً باهم به وجود می‌آیند، بنابراین بازتولید و توصیف الگوی سرعت جریان ترافیک به صورت علمی مشکل است.

پیش‌بینی جریان ترافیک آینده از پایه ارزیابی و شناسایی الگوهای جریان ترافیک آینده است. روش‌های موجود رایج یادگیری عمیق شامل استفاده از داده‌های جریان ترافیک، برای رسیدن به تخمین دقیق حالت جریان ترافیک آینده است، تا در هر نقطه از زمان پارامترهای جریان ترافیک به دست آید. برای پیش‌بینی جریان ترافیک مدل‌ها و داده‌ها پیش نیاز هستند. در فواصل زمانی مختلف ۵ دقیقه، ۱۰ دقیقه و غیره داده‌های ترافیکی تاریخی معمولاً به ترتیب سازماندهی می‌شوند که نسبتاً آسان بدست می‌آیند. با این وجود، اغلب اطلاعات عوامل تأثیرگذار دیگر که باعث اختلالات غیرعادی و نوسانات تصادفی در جریان ترافیک می‌شوند، وجود ندارند.

همیشه داده‌های اضافی زیادی، هنگام جمع‌آوری داده‌های ترافیکی مانند مکان، منبع، نوع داده، شرایط آب و هوا، زمان و سایر اطلاعات وجود دارد. تمام این داده‌های اضافی، در این مقاله، داده‌های زمینه‌ای یا داده‌های ویژگی نامیده می‌شوند. هرچند همراه با داده‌های جریان ترافیک بیشتر این داده‌ها ذخیره نمی‌شوند، اما همه آن‌ها خصیصه اساسی داده‌های وضعیت ترافیک هستند و نمی‌توان پس از تولید آن‌ها را تغییر داد. آن‌ها در کل دوره عمر داده‌های ترافیک وجود دارند و بخشی جدایی‌ناپذیر از داده‌های جریان ترافیک هستند.

این داده‌های زمینه‌ای را می‌توان به دو گروه تقسیم کرد. یکی داده‌های متنی ثابت، مانند مصالح روسازی، درجه جاده، نوع دستگاه و غیره است که تغییر قابل توجهی در مدت زمان طولانی نخواهد داشت. نوع دیگر، داده‌های زمینه پویا مانند سال، فصل، هفته، تعطیلات، تاریخ، زمان و غیره است که به طور قابل توجهی در طول دوره مشاهده تغییر می‌کنند. اگرچه داده‌های بافت ثابت نسبتاً پایدار هستند و بر جریان ترافیک تأثیر می‌گذارند، اما نمی‌توانند تغییرات شدید در داده‌های ترافیک را ایجاد کنند،

پیش‌بینی ترافیک به عنوان بخش مهمی از سیستم حمل و نقل هوشمند^۱، نقش بزرگی در هدایت سفر و مدیریت حمل و نقل و غیره ایفا می‌کند [Song et al.2018]. در تئوری جریان ترافیک، معمولاً از سه پارامتر حجم، سرعت و چگالی برای تعریف کمی جریان ترافیک استفاده می‌شود. هر پارامتر می‌تواند وضعیت عملیاتی جریان ترافیک را از دیدگاهی خاص تعریف کند و شامل رویه تغییر الگوی جریان ترافیک و قانون عملیات است. در این بین، سرعت جریان ترافیک که نشان دهنده میانگین سرعت تمامی وسایل نقلیه در یک بازه زمانی مشخص شده است، به کانون پژوهش‌ها تبدیل شده است به این دلیل که قادر است وضعیت حرکت وسایل نقلیه را منعکس کند و احساسات ذهنی شرکت کنندگان در ترافیک را مستقیماً بیان کند. [Cheng

et al.2022, Qu et al.2021, Bin and Lin.2022]

به طور کل، پیش‌بینی جریان ترافیک را می‌توان به دو نوع تقسیم کرد: پیش‌بینی کوتاه مدت، که پیش‌بینی کمتر از ۱۵ دقیقه را بیان می‌کند. و پیش‌بینی بلندمدت، که پیش‌بینی جریان ترافیک را در بازه ۱۵ دقیقه تا ۱ ساعت یا حتی بیشتر از چند روز انجام می‌دهد. سرعت جریان ترافیک، بر خلاف حجم جریان ترافیک به شدت تغییر می‌کند و در بازه‌های زمانی کوتاهی در نوسان است. میانگین سرعت بلندمدت عموماً یک میزان ثابت است که برای مدیریت کردن سیگنال ترافیک و برنامه ریزی سفر شخصی زیاد معنی ندارد. بنابراین، پژوهشگران بیشتر به پیش‌بینی کوتاه مدت سرعت توجه دارند.

سرعت جریان ترافیک با شرایط جاده و وضعیت وسایل نقلیه مستقیماً ارتباط دارد که ممکن است تحت تأثیر عوامل زیادی باشد. به عنوان مثال، عوامل انسانی (به عنوان مثال اقدامات نظارتی و رویدادهای مهم [Liu and Sharma.2006])، عوامل عینی (مانند شرایط محیطی و آب و هوایی [Xu et al.2018])، عوامل تصادفی (مانند حوادث ترافیکی و بلایای طبیعی [Cetin and Comert.2006])، و غیره. این عوامل

پیش‌بینی کوتاه‌مدت سرعت ترافیک با استفاده از شبکه‌های عصبی بازگشتی (RNN)

پارامتری: مدل میانگین متحرک یکپارچه رگرسیون خودکار^۴ و مدل فیلتر کالمن و در روش‌های غیر پارامتری: مدل‌های شبکه‌های عصبی، K نزدیک‌ترین همسایه^۵، یادگیری ماشین^۶، یادگیری عمیق^۷، ماشین بردار پشتیبانی^۸، شبکه‌های بیزی^۹ هستند. و رویکردهای تحلیلی شامل سه رویکرد، ماکروسکوپی، میکروسکوپی و مزوسکوپی می‌باشند.

مدل سری زمانی که به طور گسترده مورد استفاده قرار می‌گیرد، که به عنوان مدل باکس-جنکینز نیز شناخته می‌شود، میانگین متحرک یکپارچه رگرسیون خودکار است. احمد و کوک از مدل باکس-جنکینز در زمینه پیش‌بینی جریان ترافیک استفاده کردند [Kumar and Vanajakshi.2015] و مدل‌های مختلفی مانند باکس-جنکینز فصلی بر روی این مبانی استخراج شد. روش‌های پیش‌بینی مبتنی بر تئوری آماری و ریاضیات ساده و آسان برای پیاده‌سازی هستند، اما بیشتر مدل‌ها، مدل‌های پارامتری هستند. تنظیم پارامترها فرآیند بسیار پیچیده دارد و عملکرد آنلاین آن ضعیف است. فقط می‌توان آن را با شرایط عملیاتی نسبتاً پایدار برای پیش‌بینی جریان ترافیک اعمال کرد و مقابله با نوسانات تصادفی و پیچیده جریان ترافیک دشوار است. با بهبود مستمر نظریه هوش مصنوعی، برای پیش‌بینی جریان ترافیک تعداد زیادی از الگوریتم‌های یادگیری ماشین استفاده شده است، مانند ماشین بردار پشتیبان [Yin et al.2016]، درخت تصمیم^{۱۰} [Alajali et al.2018]، مدل تصادفی [Zhang et al.2020]، نزدیک‌ترین همسایه [Kuang et al.2018]، مدل‌های رگرسیون غیرخطی مختلف، شبکه عصبی کم عمق و غیره. روش‌های یادگیری ماشین می‌توانند قابلیت‌های قدرتمند تقریب غیرخطی را ارائه دهند، که می‌تواند جریان‌های ترافیکی کوتاه‌مدت را به بهترین شکل با تصادفی قوی منطبق کند و بهتر ارائه دهد. لیبی و همکاران [Lippi, Bertini, and Frasconi.2013] مدل‌های مختلف پیش‌بینی موجود را مقایسه کردند و به این نتیجه رسیدند روش‌های یادگیری ماشین اغلب نسبت به روش‌های آماری ریاضی کلاسیک برتر هستند

بنابراین در پیش‌بینی جریان ترافیک نمی‌توانند نقش مهمی ایفا کنند. داده‌های زمینه‌ای پویا همواره با داده‌ها ترافیکی تولید می‌شوند و دارای ویژگی زمانی قدرتمندی هستند. از آنجایی که در مقیاس‌های مختلف آن‌ها چندین تغییر دوره‌ای وجود دارد، این داده‌ها بر الگوی جریان ترافیک تأثیر بیشتری دارند و می‌توانند در پیش‌بینی جریان ترافیک به عنوان عوامل مهم در نظر گرفته شوند.

در این مقاله، با توجه به عملکرد عالی شبکه‌های عصبی بازگشتی در حوزه پردازش سری‌های زمانی و اهمیت عوامل مکانی - زمانی، برای پیش‌بینی کوتاه‌مدت سرعت ترافیک یک مدل واحد بازگشتی گیتی تزریقی^۲ (FI-GRU) پیشنهاد شده است. ابتدا، داده‌های تاریخی زدایش و به ترتیب با طول ثابت سازمان‌دهی شده‌اند و یک شبکه بازگشتی GRU برای یادگیری ویژگی‌های توالی الگوی جریان ترافیک ایجاد شده است. در همان زمان، عوامل زمینه‌ای سری‌های زمانی به یک رمزگذار خودکار پراکنده^۲ برای گسترش ویژگی‌های زمینه‌ای و یادگیری، و نمایش انتزاعی سطح بالا از عوامل زمینه، وارد شدند. در نهایت، یک سازوکار ترکیبی برای تزریق ویژگی‌های گسترش‌یافته به ویژگی‌های دنباله و خوراندن ویژگی‌های پیوند خورده به پیش‌بینی‌کننده برای پیش‌بینی چگونگی ترافیک آینده مورد بررسی قرار گرفت. سازماندهی این مقاله به شرح زیر است. بخش ۱ مقدمه‌ای برای پیش‌بینی سرعت ترافیک. بخش ۲ ادبیات و کارهای مرتبط را مرور می‌کند. بخش ۳ روش پژوهش را ارائه می‌دهد. بخش ۴ مطالعه موردی و تجزیه و تحلیل نتایج است. در نهایت، در بخش ۵ نتیجه‌گیری و کارهای آتی آورده شده است.

۲. ادبیات و کارهای مرتبط

با توجه به مبانی اولیه و پیاده‌سازی، روش‌های پیش‌بینی جریان ترافیک را می‌توان تقریباً به رویکردهای تحلیلی و رویکردهای داده محور تقسیم کرد.

رویکردهای داده محور را می‌توان به روش هیبریدی، روش‌های پارامتری و روش‌های غیرپارامتری تقسیم کرد که در روش‌های

زمینه تحلیل سری‌های زمانی و تأثیرات مهم عوامل مکانی- زمانی، پیشنهاد کردند. خود جریان ترافیک با توجه به ویژگی‌های سری زمانی، مدل‌های شبکه‌ها عصبی بازگشتی متمرکز بر پردازش سری‌های زمانی به طور طبیعی محبوب‌ترین و مورد علاقه‌ترین مدل‌ها عمیق هستند. ایولی و همکاران [Ma et al.2015] یک معماری حافظه کوتاه مدت طولانی^{۱۶} پیشنهاد کرد که در طول انتشار برگشتی بر مشکل کاهش خطای واحد حافظه شبکه چرخه‌ای غلبه می‌کند و به سری‌های زمانی وابستگی طولانی مدت برتری دارد. به طور موثر توانایی پیش‌بینی می‌تواند دینامیک ترافیک غیرخطی را ثبت کند. مدل حافظه کوتاه مدت طولانی می‌تواند بهترین عملکرد پیش‌بینی را از نظر دقت و پایداری را با مقایسه با روش‌های رایج پیش‌بینی سری‌های زمانی مانند مدل میانگین متحرک یکپارچه رگرسیون خودکار و ماشین بردار پشتیبانی به دست آورد. تیان و همکاران [Tian et al.2018] که از هموارسازی زمان چند مقیاسی برای استنتاج داده‌های از دست رفته استفاده می‌کرد یک روش یادگیری مبتنی بر حافظه بلند مدت و کوتاه مدت پیشنهاد کرد و باقیمانده‌های پیش‌بینی را از طریق مدل حافظه کوتاه مدت طولانی آموخت. ژائو و همکاران [Zhao et al.2017] برای در نظر گرفتن همبستگی مکانی-زمانی در سیستم حمل‌ونقل یک مدل پیش‌بینی جریان مبتنی بر شبکه‌های حافظه بلندمدت و کوتاه مدت پیشنهاد کرد و تأیید شد که مدل حافظه کوتاه مدت طولانی نسبت به شبکه‌های باور عمیق، تابع پایه شعاعی و غیره می‌تواند عملکرد بهتری داشته باشد. دگی چن و همکاران [Chen et al.2022] برای استخراج سریع یک سری از پارامترهای ترافیکی از داده‌های ماشین شناور^{۱۷} یک مدل شبکه جدید مبتنی بر شبکه‌های حافظه کوتاه مدت طولانی ارائه دادند. سرعت ترافیک را برای بهبود دقت پیش‌بینی، ویژگی‌های مکانی- زمانی در نظر گرفتند (یعنی میانگین سرعت تاریخی، سرعت بالادست و پایین دست و غیره).

[Jiang et al.2016]. با این وجود، از آنجایی که روش‌های یادگیری ماشین، بیشتر معماری‌های کم عمقی هستند و بدون قابلیت‌های نمایش عمیق‌تر هستند، بین داده‌های ترافیک استخراج روابط انتزاعی عمیق برای اکثر مدل‌های پیش‌بینی یادگیری ماشین دشوار است. در عین حال، بسیاری از الگوریتم‌ها به تنظیم دستی پارامتر زمان زیادی را نیاز دارند که این روش‌ها را برای کاربرد عملی محدود می‌کند. هیتون و سالاکودینوف [Hinton and Salakhutdinov.2006] در سال ۲۰۰۶، با آموزش شبکه‌های عصبی چند لایه بردارهای ورودی با ابعاد بالا را بازسازی کردند و همچنین برای حل مشکل آموزش پارامتر شبکه‌های عصبی عمیق^{۱۱} یک روش آموزش اولیه‌سازی لایه به لایه را ارائه کردند. از آن زمان، دوره جدید یادگیری عمیق آغاز شد. یادگیری عمیق در اصل گسترش تعداد لایه‌های یک شبکه عصبی کم عمق است. قابلیت انتزاع و نمایش غیرخطی این روش‌ها بیشتر ناشی از افزایش تعداد لایه‌ها به شبکه عصبی عمیق است. به عنوان مثال، هوانگ و همکاران [Huang et al.2014] لایه‌های رگرسیون چند وظیفه‌ای و شبکه‌های باور عمیق^{۱۲} را برای پیش‌بینی جریان ترافیک و برای ارائه یک معماری عمیق ترکیب کرد. الوی و همکاران [Lv et al.2014] با در نظر گرفتن همبستگی مکانی- زمانی یک روش پیش‌بینی جریان ترافیک یادگیری عمیق را پیشنهاد کرد و برای یادگیری ویژگی‌های عمومی ترافیک از رمزگذار خودکار پشته‌ای^{۱۳} استفاده کرد. نتایج پیش‌بینی گزارش شده نسبت به مدل شبکه عصبی پس انتشار کم عمق و ماشین بردار پشتیبانی برتر است. ژانگ و همکاران [Zhang et al.2019] بر اساس چارچوب یادگیری عمیق شبکه‌ها عصبی پیچشی^{۱۴} یک مدل کوتاه مدت پیش‌بینی جریان ترافیک را پیشنهاد کرد. لیچینگ و همکاران [Qu et al.2021] ویژگی‌های شبکه‌های عصبی بازگشتی که داده‌های زمانی متوالی را ترکیب می‌کند با توجه به عملکرد عالی شبکه‌های عصبی بازگشتی^{۱۵}، در

پیش‌بینی کوتاه‌مدت سرعت ترافیک با استفاده از شبکه‌های عصبی بازگشتی (RNN)

بین و لین [Bin and Lin.2022] یک روش بهینه‌سازی گراف شبکه عصبی پیچشی با مدل واحد بازگشتی گیتی دو جهت^{۲۲} را برای بهینه‌سازی پیش‌بینی ترافیک پیشنهاد می‌کنیم. این تحقیق بیان می‌کند مدل پیشنهادی به نتایج خوبی دست یافته است و دیدگاه جدیدی برای مطالعه چنین مسائلی ارائه می‌کند.

مانند یادگیری عمیق، نوعی دیگر از یادگیری ماشینی یادگیری گروهی است. که برای تکمیل وظایف یادگیری چندین یادگیرنده را ایجاد می‌کند و می‌تواند از جنبه‌های مختلف به طور جامع ویژگی‌های همبستگی و عملیات الگوهای جریان ترافیک را بررسی کند تا نتایج دقیق‌تری نسبت به مدل واحد به دست آورد. مدل‌های ترکیبی مختلفی به منظور استفاده کامل از مزایای روش‌های مختلف پیش‌بینی، توسعه داده شده است. برای مثال، ترکیب رگرسیون بردار پشتیبان و نظریه آشوب، ترکیب تحلیل موجک و سری‌های زمانی فصلی [Zhang et al.2018]، ترکیب بردار پشتیبان و تبدیل فوریه گسسته [Luo, Li and Zhang.2019]، ترکیب از k نزدیکترین همسایه و مدل حافظه کوتاه‌مدت طولانی [Luo, and Yang.2019]، ترکیب خودکار سلولی و شبکه عصبی BP [Liu et al.2019] و غیره. مدل یادگیری عمیق، در بین همه این مدل‌ها، بیشتر مورد توجه قرار گرفته است. آن جیاو و همکاران [An et al.2019] یک روش جدید شبکه‌ها عصبی پیچشی مبتنی بر فازی را پیشنهاد کرد که در آن نشان دادن ویژگی‌های تصادفات ترافیکی هنگام معرفی اطلاعات تصادفات رانندگی یک رویکرد فازی نامشخص برای اولین بار در شبکه‌ها عصبی پیچشی استفاده شده است. این می‌تواند از جنبه‌های مختلف به طور جامع ویژگی‌های ارتباط و عملیاتی الگوهای جریان ترافیک را بررسی کند، در نتیجه نسبت به یک مدل نتایج پیش‌بینی دقیق‌تری را به دست می‌آورد. امیدوار کننده‌ترین روش پیش‌بینی در آینده ممکن است مدل ترکیبی باشد. در پیش‌بینی جریان ترافیک همه این مدل‌ها نتایج خوبی به دست آورده اند. با این حال، اکثر آن‌ها تأثیر عوامل زمینه را بررسی نکرده اند.

محققان توجه بیشتری به این مدل با توجه به عملکرد عالی شبکه‌های عصبی حافظه کوتاه‌مدت در سری‌های زمانی، معطوف کرده‌اند و بر این اساس مدل‌های بهبود یافته زیادی را توسعه داده‌اند. به عنوان مثال، مدل حافظه کوتاه‌مدت طولانی پیچشی^{۱۸} برای استخراج ویژگی‌های مکانی-زمانی با ترکیب ویژگی‌های شبکه‌ها عصبی پیچشی و شبکه‌های عصبی بازگشتی [Ma et al.2018]، مدل واحد بازگشتی گیتی^{۱۹} [Dai, Ma and Xu.2019] بر اساس مدل حافظه کوتاه‌مدت طولانی ساده شده، و مدل حافظه کوتاه‌مدت طولانی دو جهت^{۲۰} [Saleh, Hossny, and Nahavandi.2019] برای استخراج ویژگی سری‌های زمانی از هر دو جهت منفی و مثبت و غیره. مدل‌های پیش‌بینی یادگیری عمیق می‌توانند از طریق دنباله‌های تبدیل غیرخطی نیمه وابسته ویژگی‌های با ابعاد بالا داده‌ها را استخراج کنند و می‌توانند روابط غیر ثابت و غیر خطی بین متغیرها را یاد بگیرند. که می‌تواند به نتایج خوبی در اغلب کاربردهای عملی دست یابد.

رسل و همکاران [Abduljabbar, Dia and Tsai.2021] با استفاده از مدل‌های حافظه کوتاه‌مدت طولانی دو جهت با استفاده از داده‌های یک مدل شبیه‌سازی میکرو کالیبره شده برای یک آزادراه متراکم در ملبورن، استرالیا و با استفاده از شبیه‌سازی داده‌های آینده از جمله سرعت، جریان و اشغال پیش‌بینی ترافیک کوتاه‌مدت را انجام داده‌اند، نتایج این تحقیق نشان می‌دهد، مدل حافظه کوتاه‌مدت طولانی دو جهت از سایر مدل‌های برای افق‌های مختلف پیش‌بینی بهتر عمل می‌کند.

چنگ و همکاران [Cheng et al.2022] یک استراتژی مبتنی بر ماشین تقویت کننده گرادبان نور^{۲۱} و مدل واحد بازگشتی گیتی برای ایجاد ویژگی‌هایی برای بهبود توانایی بیان ویژگی‌های محدود برای پیش‌بینی جریان ترافیک ایجاد می‌کند، نتایج این تحقیق بیان می‌کند که مدل پیشنهادی پیشرفت‌های قابل توجه‌ای در دقت و عملکرد هر جزء داشته است.

و مجموعه داده‌ها و معیارهای ارزیابی به تفصیل معرفی می‌شوند.

۳-۱ تعریف داده

دو نوع داده به مدل ما وارد می‌شود. یکی عوامل زمینه‌ای و دیگری سری‌های زمانی سرعت ترافیک تاریخی.

به طور کلی، در بازه‌های زمانی معین (به عنوان مثال، ۵ دقیقه، ۱۰ دقیقه، و غیره) داده‌های جریان ترافیک جمع‌آوری می‌شود. داده‌های ترافیک را به عنوان یک سری زمانی، می‌توان با بردار x نشان داد، که در آن $x = (x_1, x_2, \dots, x_t)$ و x_t داده‌های جریان ترافیک (سرعت متوسط وسایل نقلیه یا تعداد کل) در نقطه t ام، $t \in \mathbb{N}^*$ است. اگر فاصله زمانی ۵ دقیقه باشد، در روز $24 \times (60/5) = 288$ نمونه داده را می‌توان گرفت. به همین ترتیب، برای فاصله ۱۰ دقیقه ۱۴۴ نمونه و برای فاصله زمانی ۱۵ دقیقه ۹۶ نمونه.

معمولاً سری‌های زمانی دنباله‌ای با طول نامشخص هستند، که نمی‌توان تمام مجموعه داده‌ها را به مدل وارد کرد. و باید داده‌ها با دقت به زیر سری‌های کوچکتر، $x_t = (x_{t-L}, x_{t-L+1}, \dots, x_{t-1})$ در آن L تاخیرهای سری زمانی است و معمولاً یک عددی کوچک است، $L \in \mathbb{N}^*$ این سری‌های جدید با طول ثابت برای یادگیری ویژگی‌های دنباله در نقطه زمانی t استفاده خواهند شد. سری‌های زمانی اغلب با عوامل زیادی مانند مکان، آب و هوا، رویدادها، تاریخ و غیره همراه هستند. نمی‌توان آن را از خصیصه‌های توالی جدا کرد. این عوامل زمینه‌ای به طور مشابه، به صورت Z تعریف می‌شوند، جایی که $x = (z_1, z_2, \dots, z_t)^T$ است و Z را به عنوان ماتریس به صورت زیر نشان می‌دهد:

$$Z = \begin{pmatrix} z_1 \\ \dots \\ z_t \end{pmatrix} = \begin{pmatrix} z_1^1 z_1^2 \dots z_1^M \\ \dots \dots \dots \\ z_t^1 z_t^2 \dots z_t^M \end{pmatrix} \quad (1)$$

جایی که z_t^i i امین عامل زمینه‌ای در نقطه زمانی t است، $i \in \{1, \dots, M\}$ ، تعداد نوع عوامل زمینه‌ای، $M \in \mathbb{N}^*$ است. بردار ستون Z^i ماتریس نشان‌دهنده نوع i ام عوامل پیوسته شده در سری‌های زمانی است، مانند مکان، تعطیلات، تاریخ و غیره.

فصلنامه مهندسی حمل و نقل / سال پانزدهم / شماره اول (۵۸) / پاییز ۱۴۰۲

عوامل زمینه‌ای بر الگوهای جریان ترافیک به روش‌های ضمنی و پیچیده تأثیر می‌گذارند. تأثیر عوامل زمینه‌ای را اکثر روش‌های پیش‌بینی جریان ترافیک موجود، نادیده می‌گیرند یا آن را دست‌کم می‌گیرند و در مورد اهمیت عوامل زمینه‌ای در الگوهای جریان ترافیک هیچ مطالعه و بررسی جامع و عمیقی وجود ندارد. از طرفی دیگر، داده‌های تاریخی دقیق جریان ترافیک بسیار ارزشمند است. همه عوامل خارجی و داخلی به طور غیرمستقیم یا مستقیم نحوه عملکرد جریان ترافیک را منعکس می‌کنند. دشواری کمی در به دست آوردن داده‌های زمینه‌ای پویا در مقایسه با جمع‌آوری داده‌های خارجی (مانند آب و هوا و حوادث)، وجود دارد. علاوه بر این، به عنوان یک خصوصیت ذاتی داده‌های جریان ترافیک، باید عوامل زمینه‌ای ارتباط‌های مختلفی با الگوهای جریان ترافیک داشته باشند. یک فضای کاملاً جدید برای پیش‌بینی دقیق جریان ترافیک تا زمانی که این وابستگی‌ها استخراج شوند، باز خواهد شد.

می‌توان توجه داشت که در این مطالعات تمرکز، بیشتر بر کاوش ویژگی‌های ترافیکی، مکانی و زمانی هنگام پیش‌بینی جریان ترافیکی با استفاده از مدل‌های گفته شده وجود دارد. با این حال، مطالعات کمی بر روی ادغام داده‌های ترافیکی و داده‌های زمینه‌ای مانند: نقطه زمانی، ساعت، روز، تعطیلات و غیره با مدل پیشنهادی در سه گام زمانی بررسی کرده‌اند. همچنین این مقاله سرعت ترافیک را برای سه فصل سال که در هیچ ادبیات قبلی در مورد این موضوع پژوهشی نشده است، بررسی می‌کند.

در این مقاله، با توجه به اهمیت عوامل مکانی-زمانی و عملکرد عالی شبکه‌های عصبی مکرر در قلمرو پردازش سری‌های زمانی، یک مدل شبکه عصبی بازگشتی تریقی (FI-GRU) برای پیش‌بینی کوتاه‌مدت سرعت ترافیک پیشنهاد شده است.

۳ روش تحقیق

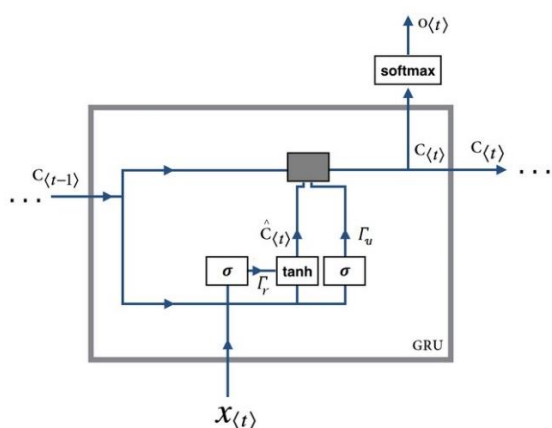
در این بخش، روش‌های توسعه مدل پیشنهادی شامل تعریف داده‌ها، یادگیری ویژگی‌های مدل استفاده شده، یادگیری ویژگی‌های پایه در حال توسعه، آموزش مدل، مشخصات سیستم

پیش‌بینی کوتاه‌مدت سرعت ترافیک با استفاده از شبکه‌های عصبی بازگشتی (RNN)

Roy and Cheriet.2015, [و غیره قابل استفاده باشند. معماری مدل واحد بازگشتی گیتی در سال ۲۰۱۴ توسط چو و همکاران معرفی شد است. این معماری به منظور برطرف سازی کاستی های شبکه عصبی بازگشتی سنتی نظیر کاهش سربار موجود در معماری حافظه کوتاه‌مدت طولانی و همچنین مشکل محو شدگی گرادیان ارائه شده است. مدل واحد بازگشتی گیتی عموماً به عنوان نسخه ای تغییر یافته از معماری حافظه کوتاه‌مدت طولانی در نظر گرفته می‌شود چرا که هر دو این معماری ها در بعضی از موارد بصورت یکسان نتایج عالی بدست آمده است و از طراحی مشابه ای بهره میبرند.

این نوع معماری از مفهوم هایی بنام دروازه بازنشانی^{۲۴} و دروازه بروزرسانی^{۲۵} استفاده می‌کند. این دو اصطلاحاً گیت یا دروازه در اصل دو بردار اند که با استفاده از آنها تصمیم گرفته می‌شود چه اطلاعاتی منتقل شود به خروجی و چه اطلاعاتی منتقل نشود. نکته خاص در باره این دروازه ها این است که این دروازه ها را میتوان آموزش داد تا اینطور اطلاعات مربوط به گام های زمانی بسیار قبل را بدون آنکه در حین گذر زمان (طی گام های زمانی مختلف) دستخوش تغییر شوند حفظ کند. سلول GRU در شکل ۱ و روابط ۳ تا ۷ نشان داده شده است [FRANÇOIS

CHOLLET.2017].



شکل ۱. نمایش سلول GRU. [FRANÇOIS

CHOLLET.2017]

$$\hat{c}_t = \tanh(\Gamma_r(w_1 c_{t-1} + w_1 x_t) + b_c) \quad (3)$$

برای سهولت در توضیح، از Z_t استفاده می‌شود. برای نمایش بردار ردیف عوامل زمینه ای در زمان t ، مجموعه ای از بردار عوامل زمینه و سری های زمانی ترافیک در زمان t به دست می‌آید. همه آنها داده های ورودی مدل پیشنهادی هستند و می‌توانند در یک بردار ورودی به صورت زیر ترکیب شوند:

$$X_t = [x_t, z_t] \quad (2)$$

$$= [(x_{t-L}, x_{t-L+1}, \dots, x_{t-1}), (z_t^1, z_t^2, \dots, z_t^M)]$$

داده های سری ترافیک، در اینجا از $(t - L)$ تا $(t - 1)$ است و مجموعه ای از انواع عوامل درونی داده های عوامل زمینه ای در زمان t هستند. تعریف و دامنه متغیرها مانند موارد فوق است. با توجه به ابعاد مختلف داده های ورودی، به عنوان مثال، سرعت ترافیک معمولاً به حدود ۶۰ متر بر ثانیه محدود می‌شود، در حالی که ساعت معمولاً بین ۰ تا ۲۳ است، برای اینکه اطمینان حاصل شود که همه داده ها در ابعاد استاندارد هستند و توزیع متعادلی را حفظ می‌کنند، بسیار مهم است که هر جزء سری های زمانی را به طور مستقل عادی کنید.


متغیر هدف \hat{y}_t که نشان دهنده هدف پیش بینی یا خروجی مدل است، در زمان t ، تعریف می‌شود. بنابراین، یافتن یک تابع نقشه برای ارضای تبدیل از x_t به \hat{y}_t هدف مدل پیشنهادی خواهد بود.

۲-۳ یادگیری ویژگی های مدل GRU

بر اساس کار دیوید روملهارت در سال ۱۹۸۶ [Rumelhart, Hinton and Williams.1985] شبکه های عصبی بازگشتی (RNN) ساخته شده است. شبکه‌ها عصبی بازگشتی دسته ای از شبکه های عصبی مصنوعی هستند که در آن اتصالات بین گره ها یک گراف جهت دار را در امتداد یک توالی زمانی تشکیل می‌دهند. که به آن اجازه می‌دهد تا رفتار پویا زمانی را نشان دهد. شبکه‌ها عصبی بازگشتی برخلاف شبکه‌های عصبی پیش‌خور^{۳۳} می‌توانند از حالت داخلی (حافظه) خود برای پردازش دنباله‌ای از ورودی‌ها، استفاده کنند. این باعث می‌شود که آن‌ها برای کارهای پویای زمانی مانند تشخیص گفتار [Yao et al.2020] یا تشخیص دست‌نویس بدون بخش، متصل [Chherawala,

توصیف می کند، سپس از همان تعداد لایه های پنهان برای بازتولید این کد استفاده می کند.

شکل ۲ نمای کلی یک رمزگذار خودکار را نشان می دهد. که از دو بخش اصلی تشکیل شده است: یک رمزگذار که ورودی را به کد نگاشت می کند، و یک رمزگشا که کد را به بازسازی ورودی اصلی نگاشت می کند که می تواند به عنوان انتقال ϕ و φ به گونه ای تعریف شود که: [Qu et al.2021]



شکل ۲. نمای کلی یک رمزگذار خودکار [Qu et al.2021]

$$\phi: Z \rightarrow \Theta$$

$$\varphi: \Theta \rightarrow Z \quad (8)$$

$$\phi, \varphi: \arg \min_{\phi, \varphi} \|Z - (\phi \circ \varphi)\|^2$$

سه مرحله در فرآیند کدگذاری وجود دارد. اول، مرحله رمزگذار یک کدگذاری، ورودی $Z \in \mathbb{R}^{1 \times M}$ را به $\Theta \in \mathbb{R}^{1 \times N}$ نگاشت می کند:

$$\Theta = \phi(WZ + b) \quad (9)$$

این تصویر Θ معمولاً به عنوان نمایش تاخیری یا کد نامیده می شود. می توان آن را یاد گرفت و لایه به لایه ترکیبی تر و به نمایش کمی انتزاعی تبدیل کرد. در اینجا، b یک بردار بایاس و W یک ماتریس وزن است، ϕ یک تابع فعال سازی مانند تابع سیگموئید است. ثانیاً مرحله رمزگشای کدگذاری Θ به Z' را به صورت زیر نشان می دهد:

$$Z' = \varphi(W'\Theta + b') \quad (10)$$

نماد φ ، W' و b' برای رمزگشا برابر با ϕ ، W و b برای رمزگذار است، اما تنها یک تبدیل معکوس ساده نیست. اگرچه Z' به عنوان اصطلاح بازسازی Z با همان شکل تعریف

$$\Gamma_u = \sigma(w_2 c_{t-1} + w_2 x_t + b_u) \quad (4)$$

$$\Gamma_r = \sigma(w_3 c_{t-1} + w_3 x_t + b_r) \quad (5)$$

$$C_t = \Gamma_u * \hat{C}_t + (1 - \Gamma_u) * c_{t-1} \quad (6)$$

$$o_t = \text{soft max}(w_4 C_t + b_o) \quad (7)$$

در اینجا C_t یا همان سلول حافظه^{۳۶} در اصل همان h_t است، و اگر خیلی راحت این عبارات را با هم جایگزین کنیم عبارت اول در شبکه عصبی بازگشتی سنتی بدست می آید. در نتیجه عملیات اصلی یکی است اما دو عملیات دیگر نیز در اینجا وجود دارد که در شبکه عصبی بازگشتی سنتی وجود ندارد. ابهامات موجود عملیات جدید این است که چطور قبلاً یک ماتریس وزن وجود داشت (در عبارت اول) اما بعد از ساده سازی این عبارت تعداد ماتریس های وزن افزایش پیدا کرد، در حالت اول چطور یک ماتریس وزن برای ضرب با دو بردار (C_{t-1} و x_t) که ابعاد متفاوتی دارند استفاده میشود؟ آیا نتایج این دو واقعا با هم برابر است؟

هر دو این روش ها یک نتیجه را در بر دارند. در روش اول هر دو ماتریس وزن در قالب یک ماتریس وزن قرار داده شده است و به همین صورت نیز ورودی ها در قالب یک ورودی در محاسبات شرکت داده می شوند. برای انجام اینکار خیلی راحت آرایه ها را در راستای یک محور مشترک بهم متصل می شوند.

۳-۳ یادگیری ویژگی های پایه در حال توسعه

در یادگیری ماشینی، یادگیری ویژگی^{۳۷} یا یادگیری بازنمایی^{۳۸} [Nazar and Bramer.1998] مجموعه ای از تکنیک ها است که به یک سیستم اجازه می دهد تا به طور خودکار بازنمایی های مورد نیاز برای طبقه بندی یا تشخیص ویژگی را از داده های خام پیدا کند. این جایگزین مهندسی خصوصیت های دستی می شود و به ماشین اجازه می دهد هم خصیصه ها را یاد بگیرد و هم از آنها برای انجام یک کار ویژه استفاده کند. یکی از انواع شبکه های عصبی عمیق رمزگذار خودکار است که یاد می گیرد ورودی خود را در خروجی خود جایگذاری کند. چندین لایه داخلی دارد که برای نمایش ورودی استفاده می شود، که کدی را

پیش‌بینی کوتاه‌مدت سرعت ترافیک با استفاده از شبکه‌های عصبی بازگشتی (RNN)

به شبکه، وضعیت داخلی لایه‌ها و نورون‌ها با توجه به ورودی تغییر می‌کند و سطح بالای گسترش یافته نشان‌دهنده فاکتورها بر اساس تابع فعال‌سازی و جمع وزنی غیرخطی تولید می‌شود. آخرین لایه شبکه عصبی کدگذاری، کد توسعه یافته ویژگی‌های متنی نهایی را خروجی می‌دهد.

نورون k در آخرین لایه در زمان t و K آخرین بعد کد یا تعداد نورون‌های لایه کدکننده، $K \in \mathbb{N}^*$ است.

۳-۴ آموزش مدل

از آنجایی که هر جزء از مدل پیشنهادی یک شبکه عصبی مستقل است، آموزش آن با روش‌های آموزشی متداول امکان‌پذیر می‌شود. الگوریتم‌های نزولی پس انتشار و گرادیان تصادفی را می‌توان گام به گام برای به حداقل رساندن خطای انتقال و آموزش هر جزء به ترتیب استفاده کرد.

شکل ۴ انتشار رو به جلو و عقب اجزای مدل پیشنهادی را نشان می‌دهد. خطوط جامد انتشار رو به جلو را در همه اجزاء نشان می‌دهد. بردارهای ورودی x_t و z_t به ترتیب توسط شبکه‌های عصبی بازگشتی و رمزگذار خودکار به h و Θ تبدیل شدند. سپس، h و Θ در A ادغام شدند و به شبکه عصبی سوم، پیش‌بینی کننده، برای تولید هدف پیش‌بینی شده، منتقل شدند. این روش انتشار رو به جلو را می‌توان در معادله زیر توصیف کرد:

[Qu et al.2021]

$$\hat{y} = \sigma(W_a(\text{softmax}(\Theta) \circ h) + b_a) \quad (12)$$

در شکل ۵ خطوط خط تیره انتشار معکوس خطاها را از \hat{y} تا ∇A و سپس به ∇h و $\nabla \Theta$ نشان می‌دهد. بدیهی است که وقتی خطاهای خروجی هر جزء بدست می‌آید، پارامترهای بایاس و مشتقات جزئی وزن‌ها را می‌توان به راحتی محاسبه کرد. قبل از شروع محاسبه مشتقات جزئی، تابع هزینه J به صورت زیر تعریف می‌شود:

می‌شود، اما در واقع همیشه به عنوان خود Z اختصاص داده می‌شود.

مرحله آخر مرحله بهینه است. در این مرحله، یک آموزش روال و مداوم به روز رسانی برای بهینه سازی پارامترهای شبکه اتخاذ می‌شود. این پارامترها به طراحی رمزگذار خودکار بستگی دارد و خطاهای بازسازی مانند رایج ترین خطاهای مربعی که به حداقل می‌رساند:

$$\begin{aligned} \ell(Z, Z') &= \frac{1}{2} \|Z - Z'\|^2 \\ &= \frac{1}{2} \|Z - \varphi(W'(\varphi(WZ + b)) + b')\|^2 \end{aligned} \quad (11)$$

Θ کدنویسی انتزاعی است و Z مجموعه آموزشی ویژگی‌ها است که می‌خواهیم از آن یاد بگیریم. اگر فضای ویژگی Θ ابعاد کمتری نسبت به فضای ورودی Z داشته باشد، کد ویژگی Θ را می‌توان به عنوان نمایش فشرده ورودی Z به شکل پروانه مانند در نظر گرفت. اگر فضای ویژگی ابعاد بیشتری نسبت به فضای ورودی داشته باشد، کد ویژگی را می‌توان به عنوان یک نمایش گسترده از فضای ورودی مشاهده کرد.

در آن صورت، لایه پنهان تعداد نورون‌های بیشتری از لایه‌های خروجی یا ورودی خواهد داشت. اگرچه نمایش ساده و کوتاه ویژگی در فضای نورون متراکم‌تر منتشر می‌شود، ساختار جالب و ویژگی‌های اصلی را می‌توان با اعمال محدودیت‌های دیگر بر روی شبکه «پراکنده» [Wu et al.2019] کشف کرد.

رمزگذارهای خودکار پراکنده در واقع به کد رمزگذار خودکار محدودیت‌های پراکنده‌ای را اضافه می‌کنند و پراکندگی ویژگی‌های خوبی دارد. این می‌تواند به طور موثر بیان اصلی ویژگی‌ها را در همان زمان برجسته کند و فاصله بین ویژگی‌ها را افزایش دهد. این رمزگذار خودکار پشته‌ای زیتونی که می‌توان از آن برای یافتن ویژگی‌های دقیق‌تر استفاده کرد، دارای اثر گسترش ابعاد است و علاوه بر این به ناچار مقداری نویز به همراه دارد. در واقع، برای اینکه تاثیر نویز را تا حد امکان به حداقل برساند رمزگذار خودکار پشته‌ای را به طور مداوم می‌توان آموزش داد و به روز کرد. پس از تغذیه بردار عامل زمینه‌ای

$$\begin{aligned} \frac{\partial J}{\partial A} &= \frac{\partial J}{\partial \hat{y}} \cdot \frac{\partial \hat{y}}{\partial A} = \frac{\partial J}{\partial \hat{y}} \cdot \sigma'(W_a A + b_a) \\ &\quad \cdot W_a \\ \frac{\partial J}{\partial h} &= \frac{\partial J}{\partial \hat{y}} \cdot \frac{\partial \hat{y}}{\partial A} \cdot \frac{\partial A}{\partial h} \\ &= \frac{\partial J}{\partial A} \circ \text{softmax}(\Theta) \quad (16) \\ \frac{\partial J}{\partial \Theta} &= \frac{\partial J}{\partial \hat{y}} \cdot \frac{\partial \hat{y}}{\partial A} \cdot \frac{\partial A}{\partial \Theta} \\ &= \frac{\partial J}{\partial A} \circ h \\ &\quad \circ \frac{\partial \text{softmax}(\Theta)}{\partial \Theta} \end{aligned}$$

طریقه محاسبه مشتق جزئی تابع softmax در زیر نشان داده شده است:

$$\begin{aligned} \frac{\partial \text{softmax}(\Theta)}{\partial \Theta} &= \frac{\partial \exp(\theta^k)}{\partial \theta^i \sum_j \exp(\theta^i)} \\ &= \frac{\exp(\theta^k) [(\sum_j \exp(\theta^i)) - \exp(\theta^i)]}{(\sum_j \exp(\theta^i))^2} \\ &= \text{softmax}(\theta^k) \cdot (1 - \theta^i) \text{ if } i \\ &= k \quad (17) \\ &= 0 \cdot \sum_j \exp(\theta^i) - \exp(\theta^k) \cdot \exp(\theta^i) \\ &\quad \frac{(\sum_j \exp(\theta^i))^2} \\ &= -\text{softmax}(\theta^k) \cdot \text{softmax}(\theta^i) \text{ if } i \\ &= \neq k \end{aligned}$$

در آخر، شبکه‌ها عصبی بازگشتی و رمزگذار خودکار می‌توانند توسط الگوریتم‌های پس انتشار پس از محاسبات گرادیان h و H به روز شوند. با توجه به بازگشتی بودن سری‌های زمانی، آموزش شبکه‌ها عصبی بازگشتی بر اساس انتشار برگشتی در طول زمان^{۲۹} و یک نسخه اصلاح شده از یادگیری تکراری زمان واقعی^{۳۰} با استفاده از روش بهینه سازی نزول گرادیان [Vlachas et al.2020] خواهد بود.

۳-۵ اجرای مدل


این مدل با استفاده از زبان برنامه‌نویسی پایتون و کتابخانه معروف Keras که زیر مجموعه کتابخانه Tensorflow و متعلق به شرکت گوگل است اجرا می‌شود.

معماری مدل پیشنهادی که در شکل ۴ نشان داده شده است. از سه قسمت به ترتیب شامل: ورودی داده، ادغام داده و خروجی سرعت پیش بینی شده تشکیل شده است. ورودی داده از دو

فصلنامه مهندسی حمل و نقل / سال پانزدهم / شماره اول (۵۸) / پاییز ۱۴۰۲

$$\begin{aligned} J(\hat{y}, y) &= \frac{1}{2} \|\hat{y} - y\|^2 \\ &= \frac{1}{2} \|\sigma(W_a A + b_a) - y\|^2 \quad (13) \\ &= \frac{1}{2} \|\hat{y} - y\|^2 \\ &= \frac{1}{2} \|\sigma(W_a(\text{softmax}(\Theta) \circ h) + b_a) - y\|^2 \end{aligned}$$

یک مفهوم مهم در یادگیری ماشینی تابع هزینه است، زیرا نشان می‌دهد یک راه حل خاص تا چه حد از راه حل بهینه مسئله ای که باید حل شود فاصله دارد. یافتن پارامترهای بهینه با جستجوی مقدار شدید تابع هزینه آسان است. دو پارامتر که باید به روز شوند در شبکه پیش بینی وجود دارد. در مرحله اول، گرادیان های W_a و b_a را می‌توان به ترتیب با قوانین زنجیره ای محاسبه کرد.



شکل ۳. انتشار به جلو و عقب اجزای ماژول [Qu et al.2021]

$$\begin{aligned} \frac{\partial J}{\partial \hat{y}} &= \frac{\partial \frac{1}{2} \|\hat{y} - y\|^2}{\partial \hat{y}} = \hat{y} - y \\ \frac{\partial J}{\partial W_a} &= \frac{\partial J}{\partial \hat{y}} \cdot \frac{\partial \hat{y}}{\partial W_a} = \frac{\partial J}{\partial \hat{y}} \cdot \sigma'(W_a A + b_a) \quad (14) \end{aligned}$$

$\sigma'(x) = \sigma(x)(1 - \sigma(x))$ تابع مشتق تابع سیگموئید σ و $\sigma(x)$ در عین حال، پارامترهای به روز رسانی می‌توانند به صورت تکرار شونده به گونه ای باشند که:

$$W(t+1) = W(t) + \eta \frac{\partial J}{\partial W} + \xi(t) \quad (15)$$

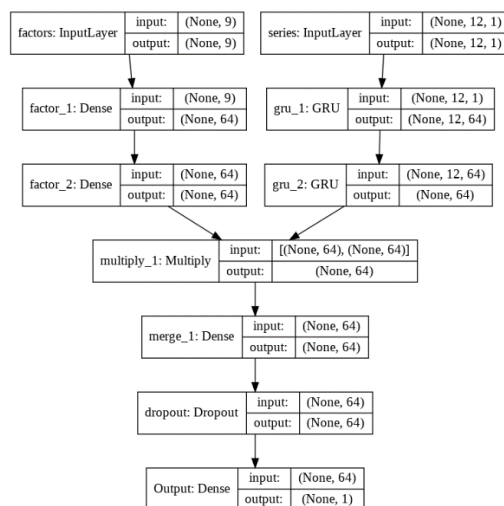
$\xi(t)$ یک جمله تصادفی و η نرخ یادگیری است. در عین حال برای به روز رسانی پارامتر b می‌توان از این مکانیسم استفاده کرد. ثانیاً، قوانین زنجیره ای مجدد برای محاسبه گرادیان های h ، A ، و Θ به کار گرفته شد به طوری که:

پیش‌بینی کوتاه‌مدت سرعت ترافیک با استفاده از شبکه‌های عصبی بازگشتی (RNN)

شبکه تجسم و ارزیابی فعال^{۳۱}، یک پلت فرم حمل و نقل آنلاین با هدف یکپارچه سازی، اشتراک گذاری، تجزیه و تحلیل و تجسم داده‌ها است. که بودجه آن توسط وزارت حمل و نقل ایالت واشنگتن تامین می‌شود و توسط آزمایشگاه کاربردی و تحقیقاتی حمل و نقل هوشمند (آزمایشگاه STAR) نگهداری می‌شود. در مجموع بیش از ۴۴۸۰۰ شناسگر حلقه‌ای به طور گسترده در یک شبکه جاده‌ای از جمله I-99، SR-520 توزیع شده است. داده‌های تولید شده به وسیله این حلقه‌ها و توسط WSDOT جمع‌آوری و مدیریت می‌شود، از جمله درصد اشغال، حجم ترافیک و سرعت نقطه‌ای در جاده‌های شریانی سیاتل، واشنگتن. داده‌های خام از حلقه‌ها و حسگرها در بازه زمانی ۲۰ ثانیه گرفته شد و پس از جمع‌آوری آنها در فاصله زمانی ۵ دقیقه ذخیره شد. در این پژوهش، داده‌های حلقه آشکارساز آزادراه I-۵ در سه بازه زمانی (۵ دقیقه، ۱۰ دقیقه، ۱۵ دقیقه) دانلود و جمع‌آوری شد، طول این مسیر بزرگراه حدود ۲۷ کیلومتر است، که در مجموع در آن ۳۴ شناسگر وجود دارد، مطابق شکل ۵.

مجموعه داده‌های ۳۴ شناسگر حلقه به دو گروه تقسیم شدند. داده‌های ۱ دسامبر ۲۰۱۴ تا ۳۰ نوامبر ۲۰۱۵ به عنوان مجموعه داده آموزشی استفاده شده است و ۲۰ درصد داده‌های تصادفی به عنوان داده‌های اعتبارسنجی مورد استفاده قرار گرفته است. داده‌های ۱ مارس ۲۰۱۶ تا ۳۱ مه ۲۰۱۶ به عنوان هدف پیش‌بینی سه ماه بهار، داده‌های ۱ جون ۲۰۱۶ تا ۳۱ اوت ۲۰۱۶ به عنوان هدف پیش‌بینی سه ماه تابستان و داده‌های ۱ سپتامبر ۲۰۱۶ تا ۳۰ نوامبر ۲۰۱۶ به عنوان هدف پیش‌بینی سه ماه پاییز، برای ارزیابی عملکرد و دقت مدل انتخاب شده اند.

قسمت تشکیل شده است که از یک طرف داده‌های زمینه‌ای مانند: سال، ماه، روز، ساعت، دقیقه، روز هفته، تعطیلات رسمی و نقطه زمانی روزانه (جمع زمان‌های روز در لحظه) و پس از عبور از دو لایه Dense به اندازه ۶۴ واحد خارج می‌شوند و از طرف دیگر داده‌های سرعت ترافیک همراه با داده‌های زمینه‌ای به دو لایه GRU وارد میشوند و با اندازه ۶۴ واحد خارج می‌شوند و در نهایت این دو لایه با استفاده از لایه Multiply باهم ادغام می‌شود. در نهایت بعد از گذشت یک لایه Dense و یک لایه dropout به لایه dense رسیده و با اندازه یک واحد، که سرعت پیش‌بینی شده ترافیک است خارج می‌شود. در مدل پیشنهادی از دو تابع فعال ساز tanh و softmax و برای اعتبارسنجی از ۲۰ درصد داده‌های آموزش به صورت تصادفی استفاده شده است، همچنین ۲۰ درصد داده‌ها برای جلوگیری از بیش‌برازش به صورت تصادفی حذف شده است. در مدل گام‌ها (epochs) به صورت خودکار عمل می‌کند و قبل از بیش‌برازش، مدل آموزش را متوقف می‌کند.



شکل ۴. معماری مدل

۳-۶ مشخصات سیستم و مجموعه داده‌ها

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n [AE(t)^2]} \quad (22)$$

که در آن n تعداد نمونه ها در محدوده آماری است.

۴. پیش بینی نتایج

نتایج پیش بین کوتاه مدت سرعت ترافیکی با استفاده از مدل FI-GRU در سه فصل سال، بهار، تابستان و پاییز و برای سه گام زمانی ۵ دقیقه، ۱۰ دقیقه و ۱۵ دقیقه و همچنین مقایسه با چهار مدل شبکه های یادگیری عمیق شامل LSTM و GRU و BiLSTM و ConvLSTM و SVM یک مدل کم عمق SVM بدست آمد، که در ادامه مقاله به آن ها پرداخته شده است.

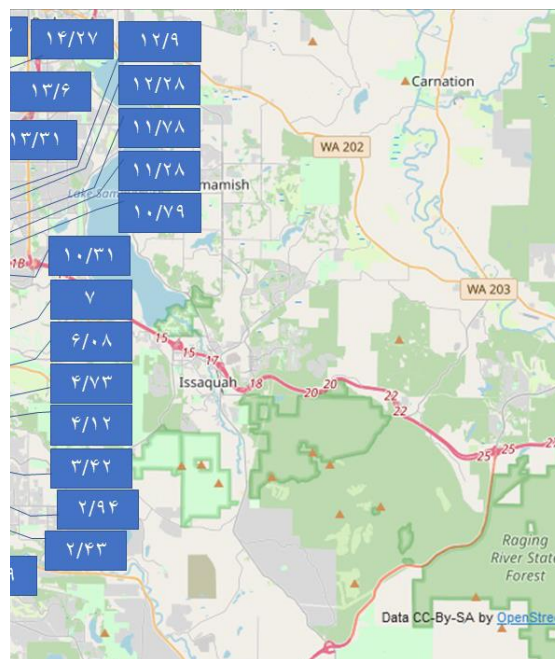
۴-۱ نتایج پیش بینی کوتاه مدت فصل بهار

نتایج پیش بینی سه ماه فصل بهار از ۱ مارس ۲۰۱۶ تا ۳۱ مه ۲۰۱۶ برای سه بازه زمانی و پنج مدل یادگیری عمیق و یک مدل کم عمق در اشکال و جداول زیر مشاهده می شوند.

در شکل ۶ سرعت پیش بینی (خط بنفش) و سرعت واقعی (خط قرمز) نشان داده شده است. مطابق نمودار، مدل FI-GRU با دقت خوبی سرعت ترافیک را پیش بینی کرده است.

در شکل های ۷ و ۸ خطای مطلق و درصد خطای مطلق مشاهده می شود طبق این نمودار در روز ۱۶ آوریل ۲۰۱۶ بیشترین خطا شکل گرفته است و برای فهمیدن دلیل شدت این خطا پیش بینی های، خطاها و سرعت در این روز بررسی شده است.

شکل ۹ سرعت واقعی و سرعت پیش بینی شده و در شکل ۱۰ و ۱۱ شدت خطاهای در بازه زمانی حدود ساعت ۲۴ تا ۴ صبح را نشان می دهد، این روز، روز شنبه و تعطیل رسمی در شهر سیاتل است خطاها می تواند به این دلیل باشد که در این بازه سفرها متغیر است.



شکل ۵. مکان شناسگرهای بزرگراه 1405 شهر سیاتل

۳-۷ معیارهای ارزیابی

برای ارزیابی فاصله مطلق و فاصله نسبی به ترتیب بین مقدار واقعی و هدف پیش بینی شده از دو معیار عملکرد مانند خطای درصد مطلق^{۳۳} و خطای مطلق^{۳۳} استفاده شد که به صورت: [Qu et al.2021]

$$APE(t) = \frac{|\hat{y}(t) - y(t)|}{y(t)} \times 100\% \quad (18)$$


$$AE(t) = |\hat{y}(t) - y(t)| \quad (19)$$

که در این روابط $y(t)$ مقدار واقعی داده های ترافیک در نقطه زمانی t است. مقدار پیش بینی شده در همان نقطه زمانی $\hat{y}(t)$ است. برای مقایسه مدل پیشنهادی با مدل های دیگر، از میانگین درصد مطلق خطا^{۳۴}، میانگین خطای مطلق^{۳۵} و ریشه میانگین مربع خطا^{۳۶} برای ارزیابی نتایج استفاده شده است: [Qu et al.2021]


$$MAE = \frac{1}{n} \sum_{t=1}^n AE(t) \quad (20)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n MAPE(t) \quad (21)$$


پیش‌بینی کوتاه‌مدت سرعت ترافیک با استفاده از شبکه‌های عصبی بازگشتی (RNN)




شکل ۶. پیش‌بینی سرعت ترافیک در بازه سه ماه فصل بهار




شکل ۷. پیش‌بینی درصد خطا مطلق در بازه سه ماه فصل بهار




شکل ۸. پیش‌بینی خطا مطلق در بازه سه ماه فصل بهار



شکل ۹. پیش‌بینی سرعت ترافیک در ۱۶ آوریل



شکل ۱۰. پیش‌بینی درصد خطا مطلق در ۱۶ آوریل



شکل ۱۱. پیش‌بینی خطا مطلق در ۱۶ آوریل

BiLSTM و یک مدل کم عمق SVM مقایسه شده است، مطابق با جدول مدل پیشنهادی نسبت به دیگر مدل‌ها بهتر عمل کرده است.

• مقایسه مدل پیشنهادی با دیگر مدل‌های شبکه‌های بازگشتی

در جدول ۱ مدل پیشنهادی FI-GRU با چهار مدل شبکه‌های یادگیری عمیق شامل LSTM و GRU و ConvLSTM

پیش‌بینی کوتاه‌مدت سرعت ترافیک با استفاده از شبکه‌های عصبی بازگشتی (RNN)

جدول ۱. مقایسه مدل پیشنهادی با دیگر مدل‌های بازگشتی

Model	MAPE	MAE	RMSE	Predictive accuracy
SVM	۱/۵۹۲	۰/۹۱۳	۱/۱۷۸	۰/۹۶۲
BiLSTM	۱/۴۲۵	۰/۸۳۲	۱/۰۸۷	۰/۹۶۹
convLSTM	۱/۳۴۸	۰/۷۸۹	۱/۰۳	۰/۹۷۲
GRU	۱/۳۴۷	۰/۷۸۷	۱/۰۳۸	۰/۹۷۱
LSTM	۱/۳۴۱	۰/۷۸۳	۱/۰۲۴	۰/۹۷۲
FI-GRU	۱/۳	۰/۷۵۶	۰/۹۸۹	۰/۹۷۴

• مقایسه مدل پیشنهادی در سه گام زمانی پیش‌بینی سرعت ترافیک

در جدول ۲ مدل FI-GRU در سه گام زمانی ۵ دقیقه، ۱۰ دقیقه


جدول ۲. مقایسه مدل پیشنهادی در سه گام زمانی پیش‌بینی سرعت ترافیک

گام زمانی	MAPE	MAE	RMSE	Predictive accuracy
۱۵ دقیقه	۱/۶۰۱	۰/۹۲	۱/۲۳	۰/۹۶
۱۰ دقیقه	۱/۳۸۶	۰/۸۰۴	۱/۰۵۴	۰/۹۶۹
۵ دقیقه	۱/۳	۰/۷۵۶	۰/۹۸۹	۰/۹۷۴


بیشترین خطا در روز ۱۳ جوئن ۲۰۱۶ وجود دارد. و برای فهمیدن دلیل شدت این خطا پیش‌بینی‌های، خطاها و سرعت در این روز بررسی شده است. شکل ۱۵ سرعت واقعی و سرعت پیش‌بینی شده و در شکل ۱۶ و ۱۷ شدت خطاهای در بازه زمانی حدود ساعت ۱۲ تا ۱۵ عصر نشان می‌دهد، که احتمالاً در این روز حادثه شدید تصادفی شکل گرفته که باعث پایین آمدن سرعت وسایل نقلیه و ازدحام وسایل نقلیه شده است.

۴-۲ نتایج پیش‌بینی کوتاه‌مدت فصل تابستان


نتایج پیش‌بینی سه ماه فصل تابستان از اجوئن ۲۰۱۶ تا ۳۱ اوت ۲۰۱۶ برای سه بازه زمانی و پنج مدل یادگیری عمیق و یک مدل کم عمق در اشکال و جداول زیر مشاهده می‌شوند. در شکل ۱۲ سرعت پیش‌بینی (خط بنفش) و سرعت واقعی (خط قرمز) نشان داده شده است. در شکل‌های ۱۳ و ۱۴ خطای مطلق و درصد خطای مطلق مشاهده می‌شود طبق نمودارها



شکل ۱۲. پیش‌بینی سرعت ترافیک در بازه سه ماه فصل تابستان

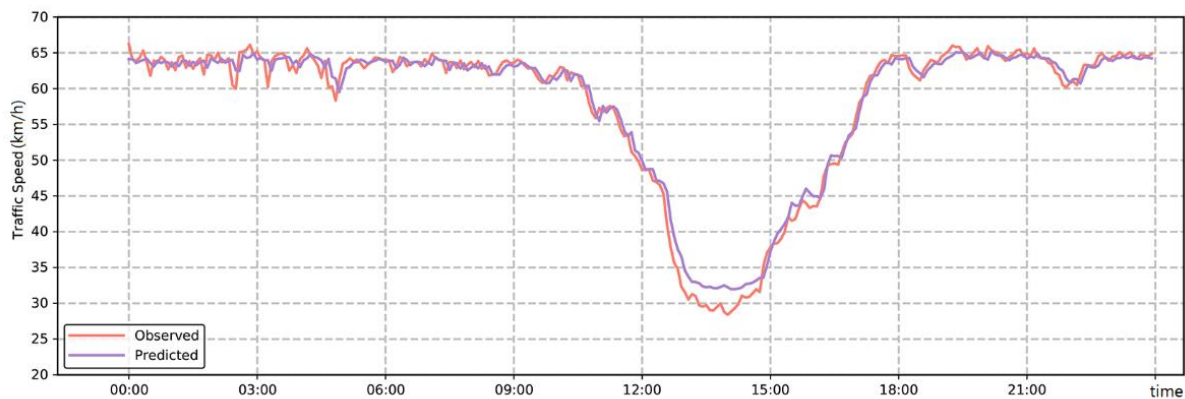


شکل ۱۳. پیش‌بینی درصد خطا مطلق در بازه سه ماه فصل تابستان




شکل ۱۴. پیش‌بینی خطا مطلق در بازه سه ماه فصل تابستان


پیش‌بینی کوتاه‌مدت سرعت ترافیک با استفاده از شبکه‌های عصبی بازگشتی (RNN)



شکل ۱۵. پیش‌بینی سرعت ترافیک در ۱۳ جوئن



شکل ۱۶. پیش‌بینی درصد خطا مطلق در ۱۳ جوئن



شکل ۱۷. پیش‌بینی خطا مطلق در ۱۳ جوئن

BiLSTM و یک مدل کم عمق SVM مقایسه شده است، مطابق با جدول مدل پیشنهادی نسبت به دیگر مدل‌ها بهتر عمل کرده است.

• مقایسه مدل پیشنهادی با دیگر مدل‌های شبکه‌های بازگشتی

در جدول ۳ مدل پیشنهادی FI-GRU با چهار مدل شبکه‌های یادگیری عمیق شامل LSTM و GRU و ConvLSTM

جدول ۳. مقایسه مدل پیشنهادی با دیگر مدل‌های بازگشتی

Model	MAPE	MAE	RMSE	Predictive accuracy
SVM	۱/۵۷۷	۰/۸۹۹	۱/۱۶	۰/۹۶۴
BiLSTM	۱/۴۱۱	۰/۸۱۹	۱/۰۷	۰/۹۷
convLSTM	۱/۳۴۸	۰/۷۸۹	۱/۰۳	۰/۹۷۲
GRU	۱/۳۴۷	۰/۷۸۷	۱/۰۳۸	۰/۹۷۱
LSTM	۱/۳۴۱	۰/۷۸۳	۱/۰۲۴	۰/۹۷۲
FI-GRU	۱/۳	۰/۷۵۶	۰/۹۸۹	۰/۹۷۴

• مقایسه مدل پیشنهادی در سه گام زمانی پیش‌بینی سرعت ترافیک در جدول ۴ مدل FI-GRU در سه گام زمانی ۵ دقیقه، ۱۰ دقیقه و ۱۵ دقیقه بررسی شده است. مطابق جدول، و مشابه با فصل قبل با افزایش بازه پیش‌بینی دقت مدل کاهش می‌یابد.

جدول ۴. مقایسه مدل پیشنهادی در سه گام زمانی پیش‌بینی سرعت ترافیک

گام زمانی	MAPE	MAE	RMSE	Predictive accuracy
۱۵ دقیقه	۱/۶۰۱	۰/۹۲	۱/۲۳	۰/۹۶
۱۰ دقیقه	۱/۴۵۵	۰/۸۳۶	۱/۰۸۳	۰/۹۷
۵ دقیقه	۱/۳	۰/۷۵۶	۰/۹۸۹	۰/۹۷۴


شدت این خطا پیش‌بینی‌های، خطاها و سرعت در این روز بررسی شده است.

شکل ۲۱ سرعت واقعی و سرعت پیش‌بینی شده و در شکل ۲۲ و ۲۳ شدت خطاها در بازه زمانی حدود ساعت ۷ تا ۸ صبح نشان می‌دهد، و همچنین خطایی در حدود ساعت ۲۳:۳۰ دقیقه اتفاق افتاده، احتمالاً نشان دهنده آن است که در هر دو زمان حادثه‌ای رخ داده است که در بازه ۲۳:۳۰ دقیقه به سرعت این مشکل رفع شده است. مطابق نمودار مدل پیشنهادی این تغییر سرعت‌های ناگهانی را تشخیص داده و به سرعت دقت پیش‌بینی را به حالت نرمال بر می‌گرداند.


۴-۳ نتایج پیش‌بینی کوتاه‌مدت فصل پاییز

نتایج پیش‌بینی سه ماه فصل پاییز از اسپتامبر ۲۰۱۶ تا ۳۰ نوامبر ۲۰۱۶ برای سه بازه زمانی و پنج مدل یادگیری عمیق و یک مدل کم عمق در اشکال و جداول زیر مشاهده می‌شوند. در شکل ۱۸ سرعت پیش‌بینی (خط بنفش) و سرعت واقعی (خط قرمز) نشان داده شده است. در شکل‌های ۱۹ و ۲۰ خطای مطلق و درصد خطای مطلق مشاهده می‌شود طبق این نمودار در روز ۱۷ نوامبر ۲۰۱۶ بیشترین خطا دیده می‌شود و برای فهمیدن دلیل


پیش‌بینی کوتاه‌مدت سرعت ترافیک با استفاده از شبکه‌های عصبی بازگشتی (RNN)




شکل ۱۸. پیش‌بینی سرعت ترافیک در بازه سه ماهه فصل پاییز




شکل ۱۹. پیش‌بینی درصد خطا مطلق در بازه سه ماهه فصل تابستان




شکل ۲۰. پیش‌بینی خطا مطلق در بازه سه ماهه فصل تابستان



شکل ۲۱. پیش بینی سرعت ترافیک در ۱۷ نوامبر



شکل ۲۲. پیش بینی درصد خطا مطلق در ۱۷ نوامبر



شکل ۲۳. پیش بینی خطا مطلق در ۱۷ نوامبر

BiLSTM و یک مدل کم عمق SVM مقایسه شده است، مطابق با جدول مدل پیشنهادی نسبت به دیگر مدل‌ها بهتر عمل کرده است.

• مقایسه مدل پیشنهادی با دیگر مدل‌های شبکه‌های بازگشتی

در جدول ۵ مدل پیشنهادی FI-GRU با چهار مدل شبکه‌های یادگیری عمیق شامل LSTM و GRU و ConvLSTM

پیش‌بینی کوتاه‌مدت سرعت ترافیک با استفاده از شبکه‌های عصبی بازگشتی (RNN)

جدول ۵. مقایسه مدل پیشنهادی با دیگر مدل‌های بازگشتی

Model	MAPE	MAE	RMSE	Predictive accuracy
SVM	۱/۵۷۷	۰/۸۹۹	۱/۱۶	۰/۹۶۴
BiLSTM	۱/۴۱۱	۰/۸۱۹	۱/۰۷	۰/۹۷
convLSTM	۱/۳۴۸	۰/۷۸۹	۱/۰۳	۰/۹۷۲
GRU	۱/۳۴۷	۰/۷۸۷	۱/۰۳۸	۰/۹۷۱
LSTM	۱/۳۴۱	۰/۷۸۳	۱/۰۲۴	۰/۹۷۲
FI-GRU	۱/۳	۰/۷۵۶	۰/۹۸۹	۰/۹۷۴

و ۱۵ دقیقه بررسی شده است. مطابق جدول، و مشابه با فصل قبل با افزایش بازه پیش‌بینی دقت مدل کاهش می‌یابد.

• مقایسه مدل پیشنهادی در سه گام زمانی پیش‌بینی

سرعت ترافیک

در جدول ۶ مدل FI-GRU در سه گام زمانی ۵ دقیقه، ۱۰ دقیقه

جدول ۶. مقایسه مدل پیشنهادی در سه گام زمانی پیش‌بینی سرعت ترافیک

گام زمانی	MAPE	MAE	RMSE	Predictive accuracy
۱۵ دقیقه	۱/۶۰۱	۰/۹۲۱	۱/۲۳	۰/۹۶
۱۰ دقیقه	۱/۴۸۷	۰/۸۵۱	۱/۱۰۴	۰/۹۷۲
۵ دقیقه	۱/۳	۰/۷۵۶	۰/۹۸۹	۰/۹۷۴

تغییری در دقت مدل صورت نگرفته است.

۵. نتیجه‌گیری

در ادامه سه گام زمانی ۵ دقیقه، ۱۰ دقیقه و ۱۵ دقیقه برای مدل FI-GRU مورد ارزیابی و مقایسه قرار گرفته‌اند که نتایج جداول ۴، ۲ و ۶ نشان می‌دهد هرچه بازه زمانی پیش‌بینی بالا می‌رود دقت مدل کاهش پیدا می‌کند، و در سه فصل سال در مدل FI-GRU در گام زمانی ۵ دقیقه هیچ گونه تغییری شکل نگرفته است و در دو گام زمانی ۱۰ و ۱۵ دقیقه تغییراتی شکل گرفته است.

با توجه به نتایج بدست آمده دقت مدل FI-GRU نسبت به کمترین دقت مدل یادگیری عمیق (BiLSTM) ۰/۵۲ درصد بیشتر است، و دقت مدل پیشنهادی نسبت به مدل کم‌عمق (SVM) ۱/۲۴ درصد بیشتر است و همچنین مدل پیشنهادی برای پیش‌بینی سرعت ترافیک در گام زمانی ۵ دقیقه ۱/۴۴ درصد بهتر عمل کرده است. دقت پیش‌بینی به‌دست آمده

بیشتر به نتایج پیش‌بین کوتاه‌مدت سرعت ترافیک با استفاده از مدل FI-GRU در سه فصل سال، بهار، تابستان و پاییز برای سه گام زمانی ۵ دقیقه، ۱۰ دقیقه و ۱۵ دقیقه و همچنین مقایسه با چهار مدل شبکه‌های یادگیری عمیق شامل LSTM و GRU و ConvLSTM و BiLSTM و یک مدل کم عمق SVM پرداخته شده است.

مطابق با جداول ۳، ۱ و ۵ دقت سرعت ترافیک پیش‌بینی شده برای سه فصل بهار، تابستان و پاییز، بسیار نزدیک به هم هستند و در دو فصل تابستان و پاییز در هیچ یک از مدل‌ها تغییری در نتایج وجود نداشته است که این نتایج نشان می‌دهد تغییر فصل تاثیر چشم‌گیری در دقت مدل‌های پیش‌بینی سرعت ترافیک نمی‌گذارد، مطابق این جداول مدل FI-GRU نسبت به دیگر مدل‌ها بهتر عمل کرده است. همچنین در سه فصل سال هیچ

فصلنامه مهندسی حمل و نقل / سال پانزدهم / شماره اول (۵۸) / پاییز ۱۴۰۲

۹. پی‌نوشت‌ها

1. Intelligent transportation system (ITS)
2. Features injected gated recurrent unit (FI_GRU)
3. Sparse Autoencoders
4. Auto-regression integrated moving average (ARIMA)
5. k-nearest neighbor (k-NN)
6. Machine Learning
7. Deep Learning
8. Support vector machine (SVM)
9. Bayesian network
10. Decision tree (DT)
11. Deep neural networks (DNN)
12. Deep belief networks (DBN)
13. Stacked autoencoder (SAE)
14. Convolutional Neural Network (CNN)
15. Recurrent Neural Networks (RNN)
16. Long-Short Term Memory (LSTM)
17. Floating car data (FCD) (<https://www.invaringenieria.com/>)
18. Convolutional LSTM(ConvLSTM)
19. Gated recurrent unit (GRU)
20. Bidirectional LSTM (BiLSTM)
21. Light Gradient Boosting Machine (LightGBM or LGB)
22. Bidirectional GRU(Bi-GRU)
23. Feed-forward neural networks
24. Output gate
25. Update gate
26. Memory Cell
27. Feature learning
28. Representation learning
29. Back Propagation Through Time (BPTT)
30. Real Time Recurrent Learning (RTRL)
31. DRIVE Net (<http://uwdrive.net/STARLab>)
32. Absolute percentage error (APE)
33. Absolute error (AE)
34. Mean absolute percentage error (MAPE)
35. Mean absolute error (MAE)
36. Root mean square error (RMSE)

۱۰. مراجع

از مدل پیشنهادی شبکه‌های عصبی بازگشتی که مورد استفاده این تحقیق است حدود ۹۸ درصد را نشان می‌دهد، با توجه به شرایط کلی دقت بدست آمده، دقت بسیار خوبی است.

۶. محدودیت پژوهش

محدودیت پژوهش حاضر عدم استفاده از داده‌های ایران می‌باشد، با توجه به اینکه برداشت داده‌های مورد نیاز در ایران به صورت ساعتی است، نمی‌توان از آن برای پیش‌بینی کوتاه‌مدت سرعت ترافیک استفاده کرد، و برای پیش‌بینی بلندمدت هم، به دلیل پایین بودن تعداد شناسگرها در جاده‌های ایران و دقت پایین برداشت داده‌ها ایران در این پژوهش از داده‌های ایرانی استفاده نشده است. و از داده‌های سایت شبکه تجسم و ارزیابی فعال که دقت بالایی دارد استفاده شده است، همچنین در این سایت فقط از داده‌های ۱ ژانویه ۲۰۱۲ تا داده‌های ۳۱ دسامبر ۲۰۱۶ می‌توان استفاده کرد، و استخراج و استفاده داده‌ها، برای پژوهشگران در این بازه زمانی امکان‌پذیر است. به همین دلیل، در این پژوهش امکان استفاده از داده‌های بروزتر مقدور نبود است. هرچند در این تحقیق تاریخ داده‌ها به هیچ عنوان مهم نبوده است.

۷. پیشنهاد کارهای آینده

در این پژوهش بر روی گام‌های زمانه ۵ تا ۱۵ دقیقه کار شده است که در کارهای آیندی می‌توان بازه‌های بلندمدت‌تری در پیش‌بینی ترافیک استفاده شود.

داده‌های زمینی‌ای که در این پژوهش استفاده شد داده‌های تاریخی و زمان بود، در کارهای آینده پژوهشگران می‌توانند بر روی داده‌های همچون آب‌وهوا و تاثیر تصادفات و... را بر پیش‌بینی سرعت ترافیک بدست آورند.

۸. تقدیر و تشکر

از سازمان کتابخانه‌ها، موزه‌ها و مرکز اسناد آستانه قدس رضوی که فضا را برای انجام این تحقیق فراهم کرده‌اند، صمیمانه تشکر می‌کنم.

- Kuang, Li, Han Yan, Yujia Zhu, Shenmei Tu, and Xiaoliang Fan. "Predicting duration of traffic accidents based on cost-sensitive Bayesian network and weighted K-nearest neighbor." *Journal of Intelligent Transportation Systems* 23, no. 2 (2019): 161-174.
- Zhang, Weibin, Yaoyao Feng, Kai Lu, Yuhang Song, and Yinhai Wang. "Speed prediction based on a traffic factor state network model." *IEEE Transactions on Intelligent Transportation Systems* 22, no. 5 (2020): 3112-3122.
- Lippi, Marco, Matteo Bertini, and Paolo Frasconi. "Short-term traffic flow forecasting: An experimental comparison of time-series analysis and supervised learning." *IEEE Transactions on Intelligent Transportation Systems* 14, no. 2 (2013): 871-882.
- Jiang, Han, Yajie Zou, Shen Zhang, Jinjun Tang, and Yinhai Wang. "Short-term speed prediction using remote microwave sensor data: machine learning versus statistical model." *Mathematical Problems in Engineering* 2016 (2016).
- Hinton, Geoffrey E., and Ruslan R. Salakhutdinov. "Reducing the dimensionality of data with neural networks." *science* 313, no. 5786 (2006): 504-507.
- Huang, Wenhao, Guojie Song, Haikun Hong, and Kunqing Xie. "Deep architecture for traffic flow prediction: deep belief networks with multitask learning." *IEEE Transactions on Intelligent Transportation Systems* 15, no. 5 (2014): 2191-2201.
- Lv, Yisheng, Yanjie Duan, Wenwen Kang, Zhengxi Li, and Fei-Yue Wang. "Traffic flow prediction with big data: a deep learning approach." *IEEE Transactions on Intelligent Transportation Systems* 20, no. 1 (2018): 232-243.
- Song, Yongze, Xiangyu Wang, Graeme Wright, Dominique Thatcher, Peng Wu, and Pascal Felix. "Traffic volume prediction with segment-based regression kriging and its implementation in assessing the impact of heavy vehicles." *Ieee transactions on intelligent transportation systems* 20, no. 1 (2018): 232-243.
- Xu, Chengcheng, Yong Wang, Pan Liu, Wei Wang, and Jie Bao. "Quantitative risk assessment of freeway crash casualty using high-resolution traffic data." *Reliability Engineering & System Safety* 169 (2018): 299-311.
- Liu, Zhaobin, and Satish Sharma. "Statistical investigations of statutory holiday effects on traffic volumes." *Transportation research record* 1945, no. 1 (2006): 40-48.
- Cetin, Mecit, and Gurcan Comert. "Short-term traffic flow prediction with regime switching models." *Transportation Research Record* 1965, no. 1 (2006): 23-31.
- Kumar, S. Vasantha, and Lelitha Vanajakshi. "Short-term traffic flow prediction using seasonal ARIMA model with limited input data." *European Transport Research Review* 7, no. 3 (2015): 1-9.
- Alajali, Walaa, Wei Zhou, Sheng Wen, and Yu Wang. "Intersection traffic prediction using decision tree models." *Symmetry* 10, no. 9 (2018): 386.
- Yin, Shen, Yuchen Jiang, Yang Tian, and Okyay Kaynak. "A data-driven fuzzy information granulation approach for freight volume forecasting." *IEEE Transactions on Industrial Electronics* 64, no. 2 (2016): 1447-1456.

- Ma, Dongfang, Bowen Sheng, Sheng Jin, Xiaolong Ma, and Peng Gao. "Short-term traffic flow forecasting by selecting appropriate predictions based on pattern matching." *IEEE Access* 6 (2018): 75629-75638.
- Saleh, Khaled, Mohammed Hossny, and Saeid Nahavandi. "Contextual recurrent predictive model for long-term intent prediction of vulnerable road users." *IEEE Transactions on Intelligent Transportation Systems* 21, no. 8 (2019): 3398-3408.
- Abduljabbar, Rusul L., Hussein Dia, and Pei-Wei Tsai. "Development and evaluation of bidirectional LSTM freeway traffic forecasting models using simulation data." *Scientific reports* 11, no. 1 (2021): 1-16.
- Cheng, Wei, Jiang-lin Li, Hai-Cheng Xiao, and Li-na Ji. "Combination predicting model of traffic congestion index in weekdays based on LightGBM-GRU." *Scientific reports* 12, no. 1 (2022): 1-13.
- Bin, Mu, and Zhen Lin. "GCN model combined with Bi-GRU for traffic prediction." In *2nd International Conference on Applied Mathematics, Modelling, and Intelligent Computing (CAMMIC 2022)*, vol. 12259, pp. 613-618. SPIE, 2022.
- Zhang, Hong, Xiaoming Wang, Jie Cao, Minan Tang, and Yirong Guo. "A multivariate short-term traffic flow forecasting method based on wavelet analysis and seasonal time series." *Applied Intelligence* 48, no. 10 (2018): 3827-3838.
- Luo, Xianglong, Danyang Li, and Shengrui Zhang. "Traffic flow prediction during the holidays based on DFT and SVR." *Journal of Sensors* 2019 (2019).
- Ma, Xiaolei, Zhimin Tao, Yinhai Wang, Haiyang Yu, and Yunpeng Wang. "Long short-term memory neural network for traffic speed prediction using remote microwave sensor data." *Transportation Research Part C: Emerging Technologies* 54 (2015): 187-197.
- Tian, Yan, Kaili Zhang, Jianyuan Li, Xianxuan Lin, and Bailin Yang. "LSTM-based traffic flow prediction with missing data." *Neurocomputing* 318 (2018): 297-305.
- Zhao, Zheng, Weihai Chen, Xingming Wu, Peter CY Chen, and Jingmeng Liu. "LSTM network: a deep learning approach for short-term traffic forecast." *IET Intelligent Transport Systems* 11, no. 2 (2017): 68-75.
- Chen, Deqi, Xuedong Yan, Shurong Li, Xiaobing Liu, and Liwei Wang. "Long Short-Term Memory Neural Network for Traffic Speed Prediction of Urban Expressways Using Floating Car Data." In *Green Connected Automated Transportation and Safety*, pp. 773-787. Springer, Singapore, 2022.
- Dai, Guowen, Changxi Ma, and Xuecai Xu. "Short-term traffic flow prediction method for urban road sections based on space-time analysis and GRU." *IEEE Access* 7 (2019): 143025-143035.

learning." Knowledge-Based Systems 11, no. 5-6 (1998): 275-283.

– Wu, Kai, Jing Liu, Penghui Liu, and Shanchao Yang. "Time series prediction using sparse autoencoder and high-order fuzzy cognitive maps." IEEE transactions on fuzzy systems 28, no. 12 (2019): 3110-3121.

– Vlachas, Pantelis R., Jaideep Pathak, Brian R. Hunt, Themistoklis P. Sapsis, Michelle Girvan, Edward Ott, and Petros Koumoutsakos. "Backpropagation algorithms and reservoir computing in recurrent neural networks for the forecasting of complex spatiotemporal dynamics." Neural Networks 126 (2020): 191-217.

– Liu, Meiyu, and Jing Shi. "A cellular automata traffic flow model combined with a BP neural network based microscopic lane changing decision model." Journal of Intelligent Transportation Systems 23, no. 4 (2019): 309-318.

– Luo, Xianglong, Danyang Li, Yu Yang, and Shengrui Zhang. "Spatiotemporal traffic flow prediction with KNN and LSTM." Journal of Advanced Transportation 2019 (2019).

– An, Jiyao, Li Fu, Meng Hu, Weihong Chen, and Jiawei Zhan. "A novel fuzzy-based convolutional neural network method to traffic flow prediction with uncertain traffic accident information." Ieee Access 7 (2019): 20708-20722.

– Rumelhart, David E., Geoffrey E. Hinton, and Ronald J. Williams. Learning internal representations by error propagation. California Univ San Diego La Jolla Inst for Cognitive Science, 1985.

– Chherawala, Youssof, Partha Pratim Roy, and Mohamed Cheriet. "Feature set evaluation for offline handwriting recognition systems: application to the recurrent neural network model." IEEE transaction (2015).

– Yao, Zengwei, Zihao Wang, Weihuang Liu, Yaqian Liu, and Jiahui Pan. "Speech emotion recognition using fusion of three multi-task learning-based classifiers: HSF-DNN, MS-CNN and LLD-RNN." Speech Communication 120 (2020): 11-19.

– FRANÇOIS CHOLLET, (Deep Learning with Python), Toni Arritola, (2017).

– Nazar, Kamal, and Max A. Bramer. "Concept dispersion, feature interaction and their effect on particular sources of bias in machine

عماد توکلی، منصور حاجی حسینلو

عماد توکلی، درجه کارشناسی در رشته مهندسی عمران را در سال ۱۳۹۶ از دانشگاه صنعتی سجاد مشهد اخذ نمود. ایشان در سال ۱۴۰۰ موفق به کسب درجه کارشناسی ارشد در رشته مهندسی عمران- حمل و نقل از دانشگاه خواجه نصیر الدین طوسی ایران گردید. زمینه های پژوهشی مورد علاقه ایشان، حمل و نقل هوشمند، پیش بینی جریان ترافیک، داده های حجیم حمل و نقل، بینایی ماشین، وسایل نقلیه هوشمند، رفتار سفر و شبیه سازی ترافیک است.



منصور حاجی حسینلو، درجه کارشناسی در رشته مهندسی عمران را در سال ۱۳۶۵ از دانشگاه تبریز اخذ نمود. و درجه کارشناسی ارشد در رشته مهندسی عمران- حمل و نقل را در سال ۱۳۷۳ از دانشگاه هوکایدو ژاپن اخذ نمود. ایشان در سال ۱۳۷۶ موفق به کسب درجه دکتری در رشته مهندسی عمران- حمل و نقل از دانشگاه هوکایدو ژاپن گردید. زمینه های پژوهشی مورد علاقه ایشان مدل سازی تصادفات رانندگی و تحلیل رفتار رانندگی، ایمنی حمل و نقل، شبیه سازی ترافیک، تجزیه و تحلیل پیامدهای زیست محیطی ترافیک، برنامه ریزی حمل و نقل، مدلسازی انتخاب گسسته، حمل و نقل هوایی، انتخاب حالت تحلیل نقش عوامل روانشناختی در مشکلات حمل و نقل و مدل سازی تصمیمات فازی و کاربرد آن در حمل و نقل است. ایشان در حال حاضر عضو هیأت علمی دانشگاه خواجه نصیر الدین طوسی ایران می باشد.

