

مروری بر روش‌های بهبود پیش‌بینی جریان ترافیک

مهدی شاکری*^۱، نرگس حبیبی^۲

۱- دانشجوی کارشناسی ارشد، دانشگاه آزاد اسلامی واحد اصفهان (خوراسگان)، ایران

shakery.m@gmail.com

۲- استادیار، دانشگاه آزاد اسلامی واحد اصفهان (خوراسگان)، ایران

narges.habibi@gmail.com

چکیده:

پیش‌بینی جریان ترافیک یکی از نیازهای اساسی سفر راحت است، اما این وظیفه در سیستم‌های سایبری-فیزیکی به دلیل افزایش روزافزون ترافیک و عدم قطعیت داده‌های بزرگ ترافیک، چالش برانگیز است. اگرچه روش‌های یادگیری عمیق (DL) با عملکرد برجسته به تازگی محبوب شده‌اند، بسیاری از مدل‌های DL موجود برای پیش‌بینی جریان ترافیک به طور کامل قطعی هستند و هیچ‌گونه عدم اطمینان داده‌ای را در اختیار ندارند. در این مقاله با بررسی و مقایسه روش‌های گذشته پیش‌بینی جریان ترافیک می‌توانیم به این نتیجه می‌رسیم که بهترین روش استفاده از نظریه فازی و مدل شبکه یادگیری عمیق می‌باشد.

واژگان کلیدی: یادگیری عمیق، نمایندگی فازی، پیش‌بینی جریان ترافیک

۱- مقدمه:

در جامعه مدرن، تعداد وسایل نقلیه در شهرها و بزرگراه‌ها افزایش یافته است. بسیاری از مشکلات مربوط به این افزایش، مانند تراکم ترافیک، ممکن است منجر به زمان طولانی در سفر شود و بنابراین ممکن است به از دست دادن پول و همچنین تصادفات رانندگی منجر شود [۵، ۱۶]. دریافت اطلاعات دقیق و به موقع ترافیک برای مسافران ضروری است. با انفجار جریان داده‌های جریان ترافیک، پیش‌بینی جریان ترافیک با استفاده از داده‌های بزرگ برای اطمینان از سفر ایمن و طراحی ناوبری فوق‌العاده ضروری است که ممکن است به مسافران در تصمیم‌گیری‌های مربوط به سفر و بهبود امنیت عمومی کمک کند [۱۱].

پیش‌بینی جریان ترافیک در مقیاس بزرگ به شدت به اطلاعات ترافیکی گذشته و سایر اطلاعات مربوطه (به عنوان مثال شرایط آب و هوایی و حوادث ترافیکی) بستگی دارد و به عنوان جزء اصلی کلید در سیستم فیزیکی سایبری خودرو (VCPS) محسوب می‌شود. VCPS یک سیستم پیچیده با یکپارچه‌سازی یکپارچه از محاسبات، ارتباطات و تکنولوژی کنترل است و پیشرفت در VCPS امکان راحتی، ایمنی و امنیت را فراهم می‌کند [۲۵، ۲۶]. یادگیری عمیق (DL) که روش جدیدی برای یادگیری ماشین است، با ایجاد یک مدل چند لایه برای دستیابی به طبقه‌بندی دقیق تصویر یا شناسایی ابعاد، ویژگی‌های مفید را می‌آموزد. این روش می‌تواند یادگیری مفهومی را فراتر از حد و توانایی یادگیری پیچیده‌تر دانست [۴]. DL در موفقیت

^۱ deep-learning

^۲ vehicular cyber-physical system

سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده‌های حجیم

وظایف، پیش‌بینی، پردازش زبان طبیعی، تشخیص شیء و مدل‌سازی حرکت موفقیت‌آمیز است. پیش‌بینی جریان ترافیک از پیچیدگی در طبیعت، الگوریتم‌های یادگیری عمیق می‌تواند برای نشان دادن ویژگی‌های ترافیکی بدون دانش قبلی استفاده شود که عملکرد خوبی را برای پیش‌بینی جریان ترافیک نشان می‌دهد [۱۸].

۲- مواد و روش‌ها

۲-۱- نمایش منطق فازی

نمایش منطق فازی نشان دادن دانش بر اساس منطق فازی است، که اطلاعات نامشخص را با استفاده از قوانین IF-THEN ساده پردازش می‌کند. به دلیل عدم اطمینان در میان داده‌های ترافیکی، منطق فازی در پیش‌بینی جریان ترافیک استفاده می‌شود [۱۷].

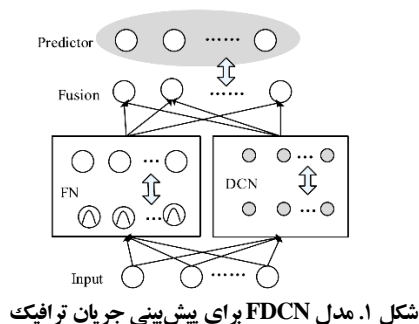
ارائه منطق فازی ارائه دهنده راه‌حل مؤثر برای یادگیری از داده‌های نامشخص است. معمولاً یک سیستم فازی شامل یک لایه ورودی، یک لایه فازی، یک لایه قانون و یک لایه فازی‌سازی است. در لایه ورودی سیستم منطق فازی، گره تنها مقدار ورودی را مستقیماً به لایه بعدی منتقل می‌کند. در لایه فازی، تابع عضویت برای یک گره تک انجام می‌شود و خروجی این گره باید ارزش تابع باشد. گره‌ها در لایه ورودی به توابع عضو متصل می‌شوند و برچسب‌های زبان‌شناس به هر متغیر ورودی اختصاص داده می‌شوند. در لایه قوانین، ارتباط بین گره‌ها برای انجام تطبیق قوانین منطقی فازی استفاده می‌شود. عملیات منطقی فازی، مانند AND، بر روی گره‌های قانون انجام می‌شود. در لایه فازی‌سازی، عملیات OR برای ترکیب نتایج از قوانین استفاده می‌شود. قوانین باید به صورت دستی در سیستم منطق فازی سنتی وارد شوند. به همین ترتیب یک سیستم منطقی فازی با یک اجزای سازنده ظاهر می‌شود که در آن قوانین و فرایند تخریب‌پذیری با یادگیری نظارت شده سازگار می‌شوند.

۲-۲- شبکه‌های کانولوشن عمیق

شبکه‌های کانولوشن عمیق (DCN) که در شکل ۱ نمایش داده شده است به شبکه عمیق شامل چند لایه پیچ و تاب و شبکه عصبی کانولوشن (CNN) بر اساس LeNet کلاسیک یکی از رایج‌ترین DCNها می‌باشد [۱۱]. CNN توسط انبساط لایه‌های چندگانه ساخته شده است و شامل تبدیل‌های کانولوشن، تبدیل غیرخطی، تلفیقی و لایه‌های کاملاً متصل و همچنین ورودی و خروجی است و منجر به یک سری پیشرفت‌هایی برای وظایف، پیش‌بینی شده است. انحطاط در لایه کانولوشن انجام می‌شود تا ویژگی‌های محلی را بر روی نقشه‌های ویژگی در لایه قبلی استخراج کند. سپس نتیجه همراه با تعصبات افزایشی از طریق یک تابع فعال غیرخطی به لایه بعدی منتقل می‌شود.

شبکه‌های عمیق به طور طبیعی ویژگی‌های سلسله‌مراتبی را یکپارچه کرده و بسیاری از وظایف، پیش‌بینی شده نیز از مدل‌های عمیق به دلیل اهمیت عمق بهره‌مند شده‌اند. با این حال، یک مانع برای شبکه با لایه‌های بیشتر شیب، ناپدید شده است که مانع همگرایی از ابتدا می‌شود. راه‌حل این مشکل اضافه کردن لایه به عنوان نقشه‌برداری باقی‌مانده در مدل CNN، مانند شبکه‌های باقی‌مانده است [۸]. وجود این راه‌حل ساخته شده نشان می‌دهد که یک مدل عمیق نباید خطای آموزش عالی بالاتر از همتای اصلی خود تولید کند. در این مطالعه، ساختار دیگری از شبکه عمودی کانولوشن یعنی یک شبکه عمیق باقی‌مانده معرفی شده است.


سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده‌های حجیم



۲-۳- مدل شبکه‌ای فازی جامد فازی

روش پیشنهادی برای پیش‌بینی جریان ترافیک مبتنی بر مدل FDCN است، مدل FDCN شامل پنج ماژول است: ورودی، شبکه عمیق کانولوشن عمق (DCN)، شبکه فازی (FN) که در شکل ۲ نمایش داده شده است، ادغام و پیش‌بینی کننده. در ابتدا داده ورودی از طریق دو کانال زیر جریان می‌یابد: یکی FN برای نمایش فازی است و دیگری DCN برای نمایندگی عصبی است. پس از اینکه دو ماژول داده‌ها را پردازش می‌کنند، نتایج هر دوره از FN و DCN با ماژول ترکیب ادغام می‌شوند. در این مرحله، گره‌های موجود در ماژول ترکیب ممکن است دو حالت کارکرد را اجرا کنند: انتقال برق و انتقال اتوماتیک. حالت گیربکس اتوماتیک باید نتیجه ترکیب را به پیش‌بینی انتقال دهد، و حالت گیربکس اتوماتیک ممکن است مقدار تابع زیان برای تنظیم پارامترهای گام بعدی را محاسبه کند. در مرحله آموزش مدل، پارامترها می‌توانند با حداقل کردن مقدار تابع زیان به روز شوند. وقتی مدل آموزش دیده باشد، نتایج پیش‌بینی شده با وارد کردن داده‌های درون مدل به دست می‌آید.

ساختار FN در شکل ۲ نشان داده شده است. هر گره در لایه ورودی با لایه فازی‌سازی متصل می‌شود و تابع عضویت برای محاسبه درجه‌ای که یک ورودی گره متعلق به یک مجموعه فازی خاص است. با این حال، تعیین اهمیت عضویت در یک شبکه فازی بسیار مهم است.



شکل ۲. نمایش فازی و FN برای پیش‌بینی جریان ترافیک


در بخش DCN، ساختار باقی مانده عمیق به کار رفته است، زیرا اثر بخشی آموزش به عمق مدل DCN بستگی دارد. توجه داشته باشید که شبکه عصبی عمیق فازی [۶] از ساختار شبکه عصبی عمیق برای طبقه‌بندی داده استفاده می‌کند. مدل با نمایش فازی و ساختار CNN به عنوان FCNN مشخص می‌شود. در این مطالعه، ساختار عمیق با چارچوب شبکه باقی مانده برای وظایف، پیش‌بینی استفاده می‌شود، زیرا نشان داده شده است که برای آموزش یک شبکه عمیق بسیار موثر است [۸].

سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده‌های حجیم

ورودی ممکن است برای یک مسئله پیش‌بینی مکانی-زمانی، یک دنباله طولانی از مشاهدات باشد، که خواص مکانی-زمانی می‌تواند برای یادگیری چالش برانگیز باشد. در بخش DCN، یک لایه وارونه می‌تواند تقریباً وابستگی را در مناطق فضایی توضیح دهد و یک پشته از لایه‌های وابستگی‌های مکانی بیشتری را به دست می‌آورد. بنابراین مدل پیشنهادی FDCN ویژگی‌های زمانی و مکانی جریان ترافیک را برای پیش‌بینی دقیق بررسی می‌کند.

۲-۴- الگوریتم یادگیری FDCN

روش FDCN که در شکل ۳ نمایش داده شده است به بررسی نمایش فازی و یادگیری عمیق برای کاهش عدم قطعیت داده‌های ترافیک می‌پردازد. چنین چند جمله‌ای یادگیری تضمین ویژگی‌های استخراج از دیدگاه‌های مختلف را برای ضبط ساختار پیچیده و ویژگی‌های سطح بالا داده‌ها برای، پیش‌بینی تضمین می‌کند [۲۰].



شکل ۳. نمایشندگی عمیق و DCN برای پیش‌بینی جریان ترافیک

بعد از ایجاد ساختار شبکه سپس شبکه سیستم یادگیری می‌شود، پارامترهای تابع عضویت، وزن اتصال و تعصبات را تنظیم می‌کند. در مدل FDCN، ما نمایندگی فازی و DL را با هم ترکیب می‌کنیم تا عملکرد پیش‌بینی جریان ترافیک را بهبود بخشیم.

پس از مقداردهی اولیه پارامتر، مدل برای پیش‌بینی جریان ترافیک استفاده شده است.

۳- مروری بر مقالات

پیش‌بینی جریان ترافیکی، عنصری مهم و اساسی در ITS^۱ است. در طول چند دهه‌ی اخیر، تعداد زیادی مدل پیش‌بینی جریان ترافیک برای کمک به مدیریت ترافیک جهت بهبود کارایی شبکه‌ی حمل و نقل من جمله هدایت مسیر، مسیریابی خودرو و هماهنگی سیگنال‌ها، پیشنهاد شده‌اند.

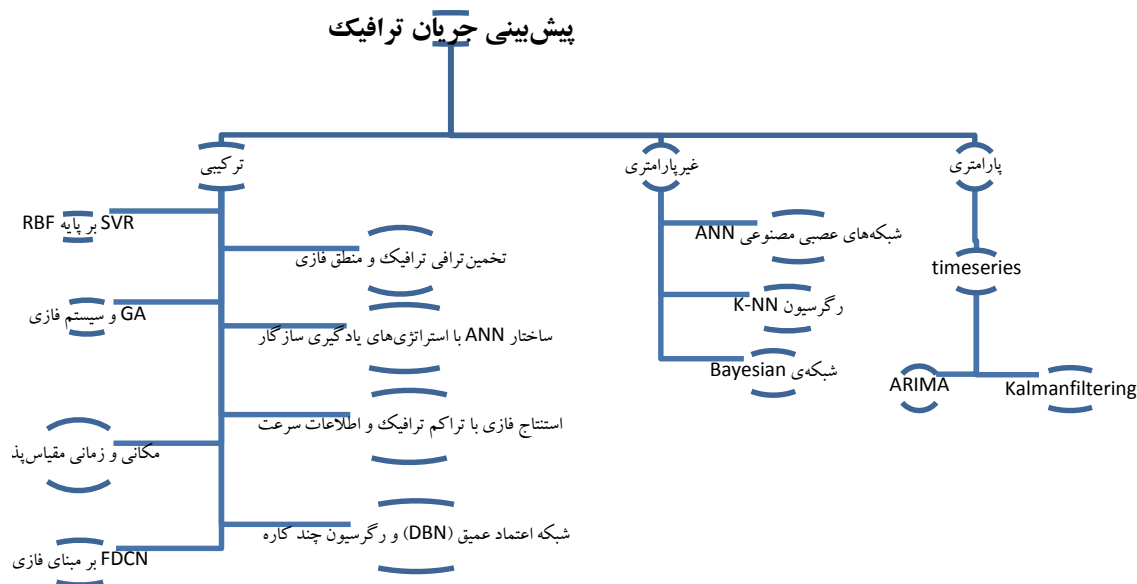
در سال ۱۹۷۰، مدل میانگین حرکت یکپارچه خودکار رگرسیون^۲ (ARIMA)، برای پیش‌بینی کوتاه مدت جریان ترافیک آزادراه مورد استفاده قرار گرفت. از آن زمان تاکنون، تنوع گسترده‌ای از مدل‌ها برای پیش‌بینی جریان ترافیک توسط محققان بسیاری از حوزه‌های مختلف علوم، مانند مهندسی حمل و نقل، آمار، یادگیری ماشین، مهندسی کنترل و اقتصاد ارائه شده

^۱ Intelligent Transportation Systems

^۲ Auto Regressive Integrated Moving Average

سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده‌های حجیم

است. روش‌های پیش‌بینی جریان ترافیک را به توجه به شکل ۴ می‌توان به سه دسته‌ی اصلی زیر تقسیم‌بندی کرد: روش‌های پارامتری، روش‌های غیرپارامتری و روش‌های ترکیبی.



شکل ۴. ساختار درختی پیش‌بینی جریان ترافیک

۳-۱- روش‌های پارامتری

جواد عبدی و همکاران (۲۰۱۳) در تحقیقی یک مدل میانگین حرکت یکپارچه خودکار رگرسیونی (ARIMA) برای پیش‌بینی جریان ترافیکی کوتاه مدت طراحی کرد [۱]. شنگ جین و همکاران (۲۰۱۳) در تحقیقی تکنیک‌های پارامتر مدل‌های ARIMA-based و مدل‌های Kalmanfiltering هستند که مبتنی بر رویکردهای timeseries است [۱۳]. کنگ و همکاران (۲۰۱۳) در تحقیقی از یک پارامتر (به عنوان مثال سرعت) استفاده کردند که به طور مؤثر وضعیت ترافیک را پیش‌بینی می‌کند، که در آن اطلاعات توسط سیستم موقعیت‌یابی جهانی (GPS) جمع‌آوری می‌شود و از مکانیزم‌های منحنی و مکانیزم حمل و نقل استفاده می‌شود [۱۴].

۳-۲- روش‌های غیرپارامتری

کومار و همکاران (۲۰۰۶) در تحقیقی روش شبکه بیسین^۱ برای پیش‌بینی جریان ترافیک را پیشنهاد کرد [۲۴]. چانگ و همکاران (۲۰۱۲) در تحقیقی مدل توزیع دینامیکی چند متغیری را بر اساس رگرسیون غیر پارامتری K-NN^۲ ارائه کرد [۲].

^۱ Bayesian

^۲ K- Nearest Neighbor

سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده‌های حجیم

جانگ و همکاران (۲۰۱۳) در تحقیقی روش رگرسیون حمایتی را از طریق یادگیری الکترونیکی برای پیش‌بینی جریان‌های کوتاه‌مدت ارائه داد [۱۲].

کومار و همکاران (۲۰۱۳) در تحقیقی مدل شبکه عصبی مصنوعی (ANN) که برای پیش‌بینی کوتاه مدت جریان ترافیکی استفاده شده است که در آن حجم ترافیک، سرعت، تراکم، زمان و روز هفته به عنوان متغیرهای ورودی گنجانده شده‌اند [۱۵].

۳-۳- روش‌های ترکیبی

سو و همکاران (۲۰۰۷) در تحقیقی مدل پیش‌بینی جریان ترافیکی ترکیبی را پیشنهاد کرد که در آن الگوریتم ژنتیک (GA)^۲ برای بهینه‌سازی پارامترهای ورودی مورد استفاده قرار گرفت و ماشین بردار پشتیبانی برای به روزرسانی پارامترهای عملکرد پیش‌بینی استفاده شد [۲۳].

پانگ‌پای‌بول و همکاران در تحقیقی (۲۰۰۷) سیستم تخمین ترافی ترافیک را با استفاده از منطق فازی تنظیم شده دستی طراحی کرد [۲۱].

هنگ و همکاران (۲۰۱۱) در تحقیقی مدل SVR^۳ را ارائه دادند که در آن یک الگوریتم ژنتیکی با آنالیز شبیه‌سازی شده برای به دست آوردن پارامترهای مناسب عملکرد پایه شعاع گاوس (RBF)^۴ به طور دقیق برای، پیش‌بینی جریان ترافیک ارائه شد [۹].

دان و همکاران (۲۰۱۱) در تحقیقی با استفاده از یک ساختار ANN^۵ با استراتژی‌های یادگیری سازگار برای تکمیل پیش‌بینی وضع موجود استفاده کرد [۷].

مین و همکاران (۲۰۱۱) در تحقیقی مدل پیشنهادی مکانی و زمانی مقیاس‌پذیر را برای پیش‌بینی حجم و سرعت ترافیکی به طور مشترک پیشنهاد کرد [۱۹].

اگرچه روش‌های ترکیبی فوق‌الذکر سازگار هستند، اما دشوار است که بگوییم یک روش در هر موقعیتی بهتر از روش دیگری است. یکی از دلایل این مشکل این است که روش‌های پیشنهادی در مقایسه با داده‌های بزرگ ترافیک با مقدار کمی از اطلاعات، توسعه داده می‌شوند. علاوه بر این، دقت پیش‌بینی جریان ترافیک بستگی به ویژگی‌های جاسازی شده در داده‌های ترافیکی مکانی-زمانی و عوامل خارجی دارد.

شانکار و همکاران در تحقیقی (۲۰۱۲) سیستم استنتاج فازی را با استفاده از تراکم ترافیک و اطلاعات سرعت برای ارزیابی سطح ترافیک جاده‌ای ارائه کرد [۲۲].

هوانگ و همکاران (۲۰۱۴) در تحقیقی یک ساختار عمیق برای پیش‌بینی جریان ترافیک پیشنهاد کرد که شامل دو بخش است: یک شبکه اعتقاد عمیق (DBN)^۶ در پایین و یک لایه رگرسیون چند کاره در بالای صفحه [۱۰]. عدم قطعیت داده‌های ترافیکی به طور مداوم تمرکز پژوهش است. برای حل این مشکل، روش فازی معرفی شده است [۲۱، ۲۲، ۲۷].

ژانگ و همکاران در تحقیقی (۲۰۱۴) یک روش پیش‌بینی تراکم ترافیک را پیشنهاد کرد که GA را با یک سیستم فازی سلسله مراتبی برای بهینه‌سازی پایگاه قانون برای پیش‌بینی دقیق پیشنهاد کرد [۲۷].

^۱ Artificial Neural Networks

^۲ genetic algorithm

^۳ support vector regression

^۴ Radial Basis Function

^۵ artificial neural network

^۶ deep belief network

سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده‌های حجیم

در همین حال، نتایج تجربی نشان داد که سیستم فازی یک روش مؤثر برای ارائه داده‌ها در تخمین و پیش‌بینی وضعیت ترافیک است. با این وجود، توابع عضویت یا قوانین منطقی فازی در این روش‌ها به طور ذهنی انتخاب می‌شوند و یادگیری هوشمند در سیستم فازی برای پیش‌بینی جریان ترافیک هنوز حل نشده است. در این مطالعه، مایک رویکرد فازی برای بهبود حل مسئله عدم قطعیت در پیش‌بینی جریان بزرگ ترافیک ارائه می‌دهیم. هدف ما دستیابی به دقت عملکرد سیستم با استفاده از روش یادگیری فازی با ساختار بهینه شده است. چن و همکاران در تحقیقی (۲۰۱۸) یک روش ترکیبی پیشنهاد کرد که از ترکیب منطق فازی با یادگیری عمیق استفاده می‌کرد [۳].

۴- بحث و نتیجه‌گیری

روش ARIMA یک روش پیش‌بینی عمومی بر اساس داده‌های سری زمانی است. روش DeepST یک مدل پیش‌بینی DNNbased برای داده‌های مکانی-زمانی است که ترکیبی از ویژگی نزدیک بودن با دوره و ویژگی‌های روند برای پیش‌بینی جریان‌های جمعیت با نتایج Statefulheart است. روش CNN یک روش پیش‌بینی با استفاده از مدل CNN است که لایه‌های متعدد لایه کنوولاسیون و لایه فعال را می‌بندد. روش FCNN یک روش پیش‌بینی بر اساس نظریه فازی گاوسی و CNN است. روش FDCN که در آن از نمایندگی فازی و مدل شبکه باقی مانده استفاده می‌شود. با توجه به مطالعات انجام شده پیش‌بینی جریان ترافیک به دلیل عدم قطعیت داده‌های بزرگ ترافیک، چالش برانگیز است. به همین علت روش‌های یادگیری عمیق محبوب شده‌اند و اغلب مدل‌های بازسازی شده دیگر برای پیش‌بینی جریان ترافیک کاملاً قطعی هستند و هیچ‌گونه عدم قطعیت داده‌ای را در اختیار ندارند. با مقایسه روش‌های اصلی پارامتری، غیرپارامتری و ترکیبی به نظر می‌رسد روش‌های ترکیبی می‌توانند عملکرد بهتری داشته باشند. یادگیری عمیق فازی باعث کاهش تأثیر عدم قطعیت داده‌ها و بهبود پیش‌بینی جریان ترافیک می‌شود که در مقایسه با تمامی روش‌ها می‌تواند عملکرد بهتری را داشته باشد.

۵- منابع

- [۱]. Abdi J. , Moshiri B. , Abdulhai B. , Sedigh A. K. **2013**. "Short-term traffic flow forecasting: parametric and nonparametric approaches via emotional temporal difference learning", *Neural Computing and Applications*, [0941-0643], **23**(1):141-159.
- [۲]. Chang H. , Lee Y. , Yoon B. , Baek S. **2012**. "Dynamic near-term traffic flow prediction: system-oriented approach based on past experiences", *IET intelligent transport systems*, [1751-9578], **6**(3):292-305.
- [۳]. Chen W. , An J. , Li R. , Fu L. , Xie G. , Bhuiyan M. Z. A. , Li K. **2018**. "A novel fuzzy deep-learning approach to traffic flow prediction with uncertain spatial-temporal data features", *Future Generation Computer Systems*, [0167-739X], **89**:78-88.
- [۴]. Chen W. , An J. , Li R. , Li W. **2017**. "Review on deep-learning-based cognitive computing", *Acta Automat. Sinica*, **43**(11):1886-1897.
- [۵]. De La Torre G. , Rad P. , Choo K.-K. R. **2018**. "Driverless vehicle security: Challenges and future research opportunities", *Future Generation Computer Systems*, [0167-739X].
- [۶]. Deng Y. , Ren Z. , Kong Y. , Bao F. , Dai Q. **2016**. "A hierarchical fused fuzzy deep neural network for data classification", *IEEE Transactions on Fuzzy Systems*, [1063-6706], **25**(4):1006-1012.

- [۷] Dunne S. , Ghosh B. **2011**. "Regime-based short-term multivariate traffic condition forecasting algorithm", *Journal of Transportation Engineering*, [0733-947X], **138**(4):455-466.
- [۸] He K. , Zhang X. , Ren S. , Sun J. **2016**. "Deep residual learning for image recognition". *Proceedings of the IEEE conference on computer vision and pattern recognition*:770-778.
- [۹] Hong W.-C. , Dong Y. , Zheng F. , Wei S. Y. **2011**. "Hybrid evolutionary algorithms in a SVR traffic flow forecasting model", *Applied Mathematics and Computation*, [0096-3003], **217**(15):6733-6747.
- [۱۰] Huang W. , Song G. , Hong H. , Xie K. **2014**. "Deep architecture for traffic flow prediction: deep belief networks with multitask learning", *IEEE Transactions on Intelligent Transportation Systems*, [1524-9050], **15**(5):2191-2201.
- [۱۱] Jabbarpour M. R. , Zarrabi H. , Khokhar R. H. , Shamshirband S. , Choo K.-K. R. **2018**. "Applications of computational intelligence in vehicle traffic congestion problem: a survey", *Soft Computing*, [1432-7643], **22**(7):2299-2320.
- [۱۲] Jeong Y.-S. , Byon Y.-J. , Castro-Neto M. M. , Easa S. M. **2013** ".Supervised weighting-online learning algorithm for short-term traffic flow prediction", *IEEE Transactions on Intelligent Transportation Systems*, [1524-9050], **14**(4):1700-1707.
- [۱۳] Jin S. , Wang D.-h. , Xu C. , Ma D.-f. **2013**. "Short-term traffic safety forecasting using Gaussian mixture model and Kalman filter", *Journal of Zhejiang University SCIENCE A*, [1673-565X], **14**(4):231-243.
- [۱۴] Kong Q.-J. , Zhao Q. , Wei C. , Liu Y. **2012**. "Efficient traffic state estimation for large-scale urban road networks", *IEEE Transactions on Intelligent Transportation Systems*, [1524-9050], **14**(1):398-407.
- [۱۵] Kumar K. , Parida M. , Katiyar V. **2013**. "Short term traffic flow prediction for a non urban highway using artificial neural network", *Procedia-Social and Behavioral Sciences*, [1877-0428], **104**:755-764.
- [۱۶] Liu J. , Yu X. , Xu Z. , Choo K. K. R. , Hong L. , Cui X. **2017**. "A cloud- based taxi trace mining framework for smart city", *Software: Practice and Experience*, [0038-0644], **47**(8):1081-1094.
- [۱۷] Lopez-Garcia P. , Onieva E. , Osaba E. , Masegosa A. D. , Perallos A. **2015**. "A hybrid method for short-term traffic congestion forecasting using genetic algorithms and cross entropy", *IEEE Transactions on Intelligent Transportation Systems*, [1524-9050], **17**(2):557-569.
- [۱۸] Lv Y. , Duan Y. , Kang W. , Li Z. , Wang F.-Y. **2014**. "Traffic flow prediction with big data: a deep learning approach", *IEEE Transactions on Intelligent Transportation Systems*, [1524-9050], **16**(2):865-873.
- [۱۹] Min W. , Wynter L. **2011**. "Real-time road traffic prediction with spatio-temporal correlations", *Transportation Research Part C: Emerging Technologies*, [0968-090X], **19**(4):606-616.
- [۲۰] Ngiam J. , Khosla A. , Kim M. , Nam J. , Lee H. , Ng A. Y. **2011**. "Multimodal deep learning". *Proceedings of the 28th international conference on machine learning (ICML-11)*:689-696.
- [۲۱] Pongpaibool P. , Tangamchit P. , Noodwong K. **2007**. "Evaluation of road traffic congestion using fuzzy techniques". *TENCON 2007-2007 IEEE Region 10 Conference: IEEE*:1-4.
- [۲۲] Shankar H. , Raju P. , Rao K. R. M. **2012**. "Multi model criteria for the estimation of road traffic congestion from traffic flow information based on fuzzy logic", *Journal of Transportation Technologies*, **2**(01):50.

سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده‌های حجیم

- [۲۳] Su H. , Yu S. **2007**. "Hybrid GA based online support vector machine model for short-term traffic flow forecasting". *International Workshop on Advanced Parallel Processing Technologies: Springer*:743-752.
- [۲۴] Sun S. , Zhang C. , Yu G. **2006**. "A Bayesian network approach to traffic flow forecasting", *IEEE Transactions on intelligent transportation systems*, [1524-9050], **7**(1):124-132.
- [۲۵] Xie G. , Zeng G. , Jiang J. , Fan C. , Li R. , Li K. **2017**. "Energy management for multiple real-time workflows on cyber-physical cloud systems", *Future Generation Computer Systems*, [0167-739X].
- [۲۶] Xie G. , Zeng G. , Li Z. , Li R. , Li K. **2017**. "Adaptive dynamic scheduling on multifunctional mixed-criticality automotive cyber-physical systems", *IEEE Transactions on Vehicular Technology*, [0018-9545], **66**(8):6676-6692.
- [۲۷] Zhang X. , Onieva E. , Perallos A. , Osaba E. , Lee V. C. **2014**. "Hierarchical fuzzy rule-based system optimized with genetic algorithms for short term traffic congestion prediction", *Transportation Research Part C: Emerging Technologies*, [0968-090X], **43**:127-142.