

استنتاج ساختار شهری به شکل کارآمد توسط پویایی جریان ترافیک با استفاده از آتاماتای یادگیری

حمید یاسینیان، گروه کامپیوتر، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران

سعید یاسینیان (مسئول مکاتبات)، گروه معماری، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران

E-mail: hyasinian@gmail.com

امیر عبدی مقدم، گروه مهندسی صنایع، دانشکده فنی مهندسی، دانشگاه آزاد اسلامی، ملایر، ایران

پذیرش: ۱۴۰۳/۱۲/۰۱

دریافت: ۱۴۰۱/۱۱/۱۵

چکیده

در برنامه‌ریزی شهری، ارتباط بهینه بین مناطق نقش حیاتی ایفا می‌کند. این امر را می‌توان به عنوان یک مسئله بهینه‌سازی در نظر گرفت که در آن از جریان ترافیک برای کشف روابط پنهان استفاده می‌شود. اطلاعات ارزشمندی در ترافیک و ساختار فعلی شهر نهفته است. کلید حل این معما، فرمول‌بندی درست مسئله برای استفاده از این اطلاعات است. در این مقاله، دو الگوریتم مبتنی بر یادگیری تقویتی (LA) برای استنتاج ساختار بهینه ارائه می‌شود: ۱- رویکرد مبتنی بر آتاماتای یادگیر توزیع‌شده (DLA): در این روش، مسئله توسط شبکه‌ای از آتامات‌ها که به صورت همکاری جمعی عمل می‌کنند، حل می‌شود. ۲- رویکرد مبتنی بر آتاماتای یادگیر سلولی (CLA): در این روش، مسئله به عنوان یک مسئله محاسباتی در نظر گرفته می‌شود و با استفاده از شبکه‌ای از سلول‌ها که با هم تعامل دارند، حل می‌شود. برای تخمین ساختار مورد نظر یا ساختار بهینه از دو سیکنال محیطی استفاده می‌شود: ۱- ساختار فعلی شهر ۲- پویایی جریان ترافیک برای ارزیابی عملکرد الگوریتم‌ها از یک بستر آزمایشی استفاده می‌شود که شامل داده‌های ساختگی و واقعی است. نتایج نشان می‌دهد که روش مبتنی بر CLA در بیشتر موارد عملکرد بهتری نسبت به روش دیگر دارد. خروجی نهایی این الگوریتم‌ها، یک ماتریس اتصالات بهینه است که شامل ساختار شهری فعلی و پیوندهای جدید ضروری برای ایجاد ساختاری کارآمدتر می‌باشد.

واژه‌های کلیدی: آتاماتای یادگیر توزیع‌شده، آتاماتای یادگیر سلولی، پویایی ترافیک، ساختار اتصالات بهینه، ساختار شهری

۱. مقدمه

بنابراین ترافیک را می‌توان جزء اصلی یک اکوسیستم شهری دانست [Poco et al., 2015].

ترافیک شهری پدیده‌ای پویا و پیچیده است که با گذشت زمان الگوهای متفاوتی را به نمایش می‌گذارد. تنوع مکانی فراوان در این الگوها، توزیع ترافیک را به طور ناهموار در سطح شهر رقم می‌زند و چالش‌های بزرگی را برای برنامه‌ریزان و مهندسين ترافیک به وجود می‌آورد؛ که می‌توان آن را، مدل‌سازی الگوهای ترافیکی جهانی در یک شبکه پیچیده جاده‌ای که دارای تعداد زیادی تقاطع است نامید [Tonguz et al., 2009]. داده‌های ترافیکی بلادرنگ حاوی اطلاعات بسیار مفیدی در مورد جریان ترافیک بین مناطق اصلی یک شهر هستند. یک ساختار ارتباط ترافیکی مؤثر را می‌توان با استفاده از پویایی ترافیک، که در طول زمان متغیر است، استنتاج کرد و تصویری پویا از مناطق نزدیک در شهر بر اساس اطلاعات جریان ترافیک در زمان‌های مختلف در طول هفته نشان داد [Baskar, 2018].

فعالیت‌های مختلفی که در یک شهر اتفاق می‌افتد، تحت تأثیر ساختار آن شهر قرار می‌گیرد. به نظر می‌رسد که بین برخی از مناطق شهر که از نظر ساختاری ارتباط مستقیمی با یکدیگر ندارند، هیچ تعاملی وجود ندارد. با این حال، مطالعات نشان داده است که در بسیاری از موارد، بین این مناطق تبادل و وابستگی قابل توجهی وجود دارد. همیشه این سؤال مطرح است؛ که آیا در شهرها مناطق غیرمرتبطی وجود دارند که با یکدیگر تعامل زیادی دارند؟ مسئله دیگر می‌تواند یافتن مناطقی باشد که فقط در ساعات خاصی از روز با یکدیگر تعامل بیشتری دارند؟ ساختار اتصال بهینه^۲ می‌تواند رابطه کاربردی مترکم جریان ترافیک در مناطق مختلف یک شهر را توضیح دهد؛ که نشان می‌دهد کدام مناطق در شهر از نظر ویژگی‌های جریان تردد در زمان‌های مختلف روز بیشتر شبیه یکدیگر هستند. بنابراین، ساختار اتصال مؤثر را می‌توان با توجه به ساختار ثابت شبکه‌های جاده‌ای و پویایی عملکردی ترافیک جمع‌آوری شده توسط داده‌های

رشد فزاینده وسایل نقلیه مانند اتومبیل، بزرگراه و مترو در شهرهای مدرن، نقشی محوری در توسعه اجتماعی و اقتصادی آنها ایفا می‌کند [moghadam, 2022]. کلان‌شهرها با تکیه بر گسترش شبکه‌های ترافیکی، پیشرفت کرده‌اند و در عین حال، تحولات شهری نیز ساختار شبکه ترافیک را تحت شعاع خود قرار می‌دهد. برنامه‌ریزی ترافیک شهری شامل فرآیندهای اساسی مختلفی از جمله بررسی ترافیک، پیش‌بینی سوابق، پیش‌بینی ترافیک، طرح‌بندی کلی و ارزیابی پروژه می‌شود [Long & Shen, 2015] [pahlevani, 2019]. مهم‌ترین نکته در طرح‌بندی، طراحی دقیق شبکه ترافیک است. این شبکه، ستون فقرات توسعه اقتصادی و کارآمدی عملیاتی شهر در آینده خواهد بود [Ding, Ujang, et al., 2019]. مطالعات مربوط به ساختار شبکه ترافیکی که بر توزیع ترافیک شهری تأثیر می‌گذارد، در سال‌های اخیر به دلیل دشواری توسعه و تغییر الگوی شهری مورد توجه بسیاری قرار گرفته است [Ding, Ujang, et al., 2019].

شبکه‌های ترافیکی در شهرهای بزرگ، به دلیل وجود تقاطع‌های متعدد، تقاضای متغیر و رفتارهای رانندگی متنوع، دارای درجه بالایی از هم‌زمانی هستند. این موضوع، مدیریت ترافیک و یافتن مدل‌های مناسب برای این سیستم‌ها را به چالشی پیچیده تبدیل می‌کند. به‌طور خاص، چنین سیستم‌ها را می‌توان به‌عنوان سیستم‌های رویداد محور و هم‌زمان در نظر گرفت.

فعل و انفعالات پیچیده رویدادهای مختلف گسسته می‌تواند پایه‌ای برای پویایی آن‌ها باشد. اطلاعات ارزشمندی در مورد رفتار اجزای شهری توسط داده‌های جمع‌آوری شده از پویایی ترافیک^۱ در اختیار است. با تحلیل این داده‌ها، می‌توان الگوهای پنهان را کشف کرد، روندها را پیش‌بینی کرد و به سوالات کلیدی در مورد چالش‌ها و فرصت‌های مرتبط با ترافیک شهری پاسخ داد.

استنتاج ساختار شهری به شکل کارآمد توسط پویایی جریان ترافیک با استفاده از آتاماتای یادگیری

محدودیت بهینه بودن ساختار جدید برای روبرو شدن با جریان ترافیک است.

یافتن کاربرد پویایی ترافیک در استنتاج ساختار شهری، تعیین ساختار شهری که از ساختار ایستای شهری و پویایی ترافیک منشعب شود، پیدا کردن روش‌های ریاضی جهت فرموله کردن مسئله استنتاج ساختار شهری، پیدا کردن راه‌حل‌های یادگیری تقویتی و به طور خاص آتاماتای یادگیر برای حل مسئله استنتاج ساختار شهری و تعیین برتری روش‌های یادگیری تقویتی و به طور خاص آتاماتای یادگیر از لحاظ کارآمدی حل این مسئله نسبت به سایرین را می‌توان از اهداف این پژوهش برشمرد.

این پژوهش بر حل معضل نوظهور استنتاج ساختار بهینه شهرها متمرکز است. به این منظور، مسئله به صورت مدل ریاضی فرمول‌بندی شده و روشی تعاملی برای حل آن ارائه می‌شود. بخش ۲ به بررسی پیشینه تحقیق و دستاوردهای انجام شده در زمینه استنتاج ساختار بهینه شهرها می‌پردازد. در بخش ۳، مسئله به طور دقیق تعریف و فرمول‌بندی می‌شود. بخش ۴ به تشریح الگوریتم پیشنهادی برای استنباط ساختار مؤثر شهری می‌پردازد. در بخش ۵، دو نوع داده برای ارزیابی الگوریتم و اعتبارسنجی نتایج ارائه می‌شود. بخش ۵،۱ به بررسی داده‌ها می‌پردازد و بخش ۵،۲ نتایج تجربی را ارائه می‌دهد. در نهایت، بخش ۶ به نتیجه‌گیری و بحث در مورد دستاوردهای این تحقیق اختصاص دارد.

۲. ادبیات پژوهش

با وجود پیشرفت‌های چشمگیر در حوزه حمل‌ونقل هوشمند، تحلیل دقیق و پویای ترافیک همچنان چالشی جدی به شمار می‌رود. مدل‌های تقاطع‌های شهری و مدل‌های تعامل چندجانبه خودروها و سایر وسایل نقلیه به دلیل پیچیدگی ذاتی، کاربرد آن‌ها در مقیاس‌های بزرگ را دشوار کرده است. مسئله‌ای که در [Angius et al., 2012] مورد توجه قرار گرفت، بهینه‌سازی طرح ترافیک شهری با استفاده از شبیه‌سازی محاسباتی کارآمد بود. هر تقاطع برای درک الگوهای مختلف ترافیکی شبیه‌سازی

حسگر بلادرنگ از مناطق شهری برحسب زمان استنتاج کرد [Sarkar et al., 2017].

استنتاج ساختار شهری بهینه با استفاده از داده‌های تردد بلادرنگ بین مناطق اصلی یک شهر، باید فرموله شود و برای کشف همبسته‌ترین مناطق با استفاده از این فرمول، روشی لازم است. جریان ترافیکی متغیر با زمان و ساختار شهری ورودی‌های این روش هستند.

روش ارائه شده در این مقاله بر اساس آتاماتای یادگیر سلولی است [Poco et al., 2015]. یک مدل ریاضی برای سامانه‌هایی با اجزای ساده است؛ به طوری که رفتار هر جزء بر اساس رفتار همسایگانش و نیز تجربیات گذشته‌اش تعیین و اصلاح می‌شود [the United Nations, 2020]. CLA^2 آتاماتای سلولی (CA)^۴ و آتاماتای یادگیری (LA) را به عنوان یک رویکرد یادگیری پیشرفته جدید ترکیب می‌کند؛ که توسط گروهی از سلول‌های به هم پیوسته تشکیل شده است و به شکل‌های منظمی مانند شبکه یا حلقه مرتب شده‌اند. حداقل یک LA در هر سلول وجود دارد. یک مدل توزیع شده با قدرت محاسباتی بالای CA و توانایی یادگیری LA، توجه خوبی برای یک آتاماتای یادگیر سلولی است. می‌توان بیان کرد که CLA به دلیل توانایی ایجاد الگوهای پیچیده‌تر از LA قدرتمندتر است. CLA می‌تواند عملکرد قدرتمندی را در رویارویی با مشکلاتی که شامل یادگیری، کنترل، مدل‌سازی و شبیه‌سازی است نشان دهد و در محیط‌های پیچیده و نامطمئن اعمال شود [Krugman, 1991].

در این مقاله، ساختار شبکه ثابت فرض شده است. داده‌های ترافیکی یک جریان بلادرنگ است. با توجه به تعریف مسئله، شرایطی فراهم می‌شود که می‌توان از داده‌های ترافیکی موجود برای استنتاج ساختار بهینه شهر استفاده کرد. این روش نوین قادر است ساختار ایده‌آل را به صورت آنلاین و آفلاین استنتاج کند. ساختار بهینه برای برآوردن دو محدودیت پیکربندی شده است. محدودیت اول شباهت بین ساختار بهینه و فعلی است و دومین

بسیار مورد تقاضا و چالش برانگیز است. دو جنبه وجود دارد که مسئله را با پیچیدگی زیادی روبه‌رو می‌کند:

(۱) همبستگی‌های مکانی-زمانی پیچیده ترافیک، از جمله همبستگی مکانی بین مکان‌ها در میان سری‌های زمانی همراه با همبستگی‌های زمانی.

(۲) تنوع چنین همبستگی‌های مکانی-زمانی، که به اطلاعات جغرافیایی اطراف بستگی دارد و از مکانی به مکان دیگر متغیر است؛ به‌عنوان مثال، نقاط مورد علاقه و شبکه‌های جاده‌ای.

یک مدل مبتنی بر یادگیری عمیق به نام ST-MetaNet در [Pan et al., 2019] برای رسیدگی به چالش‌های ذکر شده در مجموع پیش‌بینی ترافیک در همه مکان‌ها به طور هم‌زمان ارائه شد. یک معماری توالی به توالی در ST-MetaNet به کار رفته است؛ که شامل یک رمزگذار برای یادگیری اطلاعات تاریخی و یک رمزگشا برای پیش‌بینی گام به گام است. رمزگذار و رمزگشای هر دو شبکه عصبی^۴ برای رمزگذاری ترافیک هستند. برای استفاده از آزمایش‌های گسترده و نشان دادن توانایی ST-MetaNet، از دو مجموعه داده در دنیای واقعی استفاده شد.

مدل‌های سنتی مورد استفاده در دستگاه‌های پیچیده دارای محدودیت نظری هستند و این موضوع به این دلیل است که جریان‌های عظیم داده‌های شهری به یک رویکرد جدید برای مدل‌سازی نیاز دارند؛ که محققان را به پیشنهاد رویکرد جدیدی در [Moosavi & Hovestadt, 2013] سوق می‌دهد. در پژوهش مورد اشاره، چارچوبی مفهومی برای مدل‌سازی پویایی ترافیک شهر شرح داده شد؛ که راهی برای محدود کردن پیچیدگی بر اساس قدرت انتزاعی زنجیره‌های مارکوف ارائه می‌دهد.

[Ding, Yin, et al., 2019] به دنبال کشف توانایی‌ها و ویژگی‌های مختلف ساختارهای شبکه‌های ترافیک شهری چندلایه در شرایط ازدحام ترافیک بودند. آنها دریافتند که شبکه‌های تک‌لایه در مدیریت حجم بالای ترافیک ناکارآمد هستند و به همین دلیل به سراغ بررسی شبکه‌های چندلایه رفتند.

شد. برای اعتبارسنجی مدل و به دست آوردن تأخیر متوسط سفر، از توپولوژی واقع‌گرایانه منهن با انواع مختلف تقاطع استفاده شد.

در [Zhao, 2017]، یک روش مبتنی بر چارچوب مارکوف برای مدل‌سازی ترافیک شبکه پویا ارائه شد. برای اعتبارسنجی مدل، از یک مطالعه موردی در مرکز شهر بالتیمور استفاده شد. فناوری‌های جدید قادر به جمع‌آوری داده‌های بلادرنگ در مورد مناطق شهری و توزیع ترافیک آن برای تجزیه و تحلیل بیشتر هستند. مدلی بر اساس موارد مهم رخ داده در شبکه‌های پیچیده در [Solé-Ribalta et al., 2016] ارائه شد؛ که می‌تواند برای استخراج نقاط متراکم در مناطق شهری استفاده شود. محققان نشان دادند که این مدل قادر است نقاط حساس را شناسایی کند؛ که در صورت افزایش تقاضای سفر^۵ ممکن است به نقاط کانونی تبدیل شوند.

هوا و تعامل انسانی نمونه‌ای از عناصر غیرقابل پیش‌بینی است؛ که می‌تواند در یک شبکه ترافیک خودرو دیده شود و منجر به یک سیستم دینامیکی بسیار پیچیده و غیرخطی شود. بنابراین تکامل^۶ زمانی دستگاه‌های ترافیکی با استفاده از مدل‌های ریاضی یا مدرن دشوار است. رویکردهای قوی تجزیه و تحلیل و پیش‌بینی ترافیک، تقاضای زیادی برای دستگاه‌های حمل و نقل دارند. در [Avila & Mezić, 2020]، از تجزیه حالت کوپمن^۷ استفاده شد؛ تا یک روش مبتنی بر داده بدون مدل برای پیش‌بینی و تجزیه و تحلیل پویایی ترافیک ایجاد کند. آن‌ها داده‌های مشاهده شده را بازسازی کردند. با استفاده از مجموعه داده‌های ارائه شده توسط اداره حمل و نقل کالیفرنیا و اداره بزرگراه‌های فدرال، سلسله مراتبی از الگوهای مکانی که از قبل شناسایی شده و همچنین هرگز از قبل شناسایی نشده بودند را بدست آوردند. ادعا می‌شود پیش‌بینی شرایط شبکه بزرگراه با استفاده از این روش امکان‌پذیر است.

ایمنی عمومی و دستگاه‌های حمل و نقل هوشمند از اهمیت زیادی برخوردار هستند و پیش‌بینی ترافیک شهری به دلیل این مسائل

استنتاج ساختار شهری به شکل کارآمد توسط پویایی جریان ترافیک با استفاده از آتاماتای یادگیری

همان L_f یال‌های بیان‌کننده ارتباط عملکردی بین مناطق هستند. F با استفاده از ماتریسی با ابعاد $n \times T$ به نام D به دست می‌آید؛ که D نشان‌دهنده جریان ترافیک یا تعداد خودروهایی است که از مسیر i در زمان t عبور می‌کنند. اتصال عملکردی شباهت عملکردی بین مناطق را نشان می‌دهد و با استفاده از

$$F = D \bullet D \quad (2)$$

محاسبه می‌شود؛ که \bullet یک اپراتور محاسبه‌کننده شباهت با استفاده از مقدار مطلق یک منهای فاصله است. در این فرمولاسیون فاصله باتجارایا [Djouadi et al., 1990] مورد استفاده قرار می‌گیرد؛ که فاصله بین توزیع‌های نرمال گسسته و پیوسته را محاسبه می‌کند. این معیار نزدیکی یا شباهت را اندازه‌گیری می‌نماید:

$$F_{ij} = \begin{cases} 1 - \left(\frac{\sqrt{D_{ii} \times D_{jj}}}{\sqrt{\sum_{t=1}^T D_{it} \sum_{t=1}^T D_{jt}}} \right) & i \neq j \\ 1 & i = j \end{cases} \quad (3)$$

که T کل دوره‌ها و F یک ماتریس متقارن است. در اینجا مسئله اصلی استنتاج ماتریس اتصال بهینه (O) است. O هم باید ساختار موجود (S) را منعکس کند و هم سایر ارتباطات ساختاری وابسته به زمان را نشان دهد. ماتریس می‌تواند ارتباط استنباطی بین مناطق را که باید بر اساس پویایی ترافیک شکل گیرند را نشان دهد؛ که در ساختار کنونی پنهان شده است. O باید بحرانی‌ترین یال‌های موجود در O را حفظ کند؛ همچنین باید پیوندهای جدیدی را نشان دهد که بسیار مورد تقاضا و از نظر تعداد کم هستند.

هدف به حداکثر رساندن مقدار یک تابع هدف، شامل دو تابع فرعی است. اولین مورد (Y_1) شباهت بین ماتریس اتصال بهینه برآورد شده (\hat{O}) و اتصال ساختاری موجود (S) است؛ که باید تا حد ممکن زیاد باشد. تابع فرعی دوم Y_2 کیفیت اضافه شده به شبکه ترافیکی با افزایش یا کاهش برخی پیوندها در شبکه

با شبیه‌سازی و آزمایش‌های مقایسه‌ای، توپولوژی مطلوب برای شبکه‌های ترافیک شهری چندلایه تحت شرایط مختلف ازدحام ترافیک به دست آمد. نتایج نشان داد که شبکه‌های چندلایه مرتبط با مقیاس، به طور قابل توجهی توانمندتر از شبکه‌های تک‌لایه در پشتیبانی از حجم بالای ترافیک هستند. تحقیق در مورد رشد شبکه چند لایه در شناسایی پویایی شهری، راهی جدید برای محققان در مورد روند تغییر ساختار و تأثیرات مربوط به آن فراهم می‌کند. روش تحقیق کمی برای بررسی، مرکزیت شبکه، دسترسی به شبکه استفاده می‌شود.

تاکنون تحقیق گسترده‌ای در زمینه استنتاج ساختار شهری به شکل کارآمد توسط پویایی جریان ترافیک با استفاده از یادگیری تقویتی صورت نگرفته است؛ که در این تحقیق با یک فرمولاسیون جدید این مسئله مدل شد.

۳. فرمول‌های مسئله

فاصله، زمان سفر، حتی مجاورت، یا سایر اطلاعات در مورد اتصالات مناطق می‌تواند اتصال ساختاری S را بیان کند. اتصال ساختاری می‌تواند یک ماتریس مجاورت $n \times n$ از یک گراف وزن‌دار $G_S = (V, L_S)$ باشد که V مجموعه‌ای از n گره یا منطقه است و L_S یال‌هایی هستند؛ که اتصال ساختاری بین مناطق را ایجاد می‌کنند. g را می‌توان با استفاده از ماتریسی با ابعاد $n \times m$ به نام B محاسبه کرد؛ که در آن $B_{ij} = 1$ در صورتی که از بین مناطق i و j یالی عبور کند. اتصال ساختاری به ما در مورد قدرت اتصال بین مناطق می‌گوید و با

$$S = BB^T \quad (1)$$

محاسبه می‌شود. S_{ij} تعداد جاده‌های اصلی است؛ که i و j را به هم متصل می‌کند.

علاوه بر اتصال ساختاری یک عامل اتصال دیگر به نام اتصال عملکردی F بین مناطق وجود دارد. اتصال عملکردی ماتریس مجاورتی $n \times n$ متقارن از یک گراف وزن‌دار $G_f = (V, L_f)$ است که V همچنان مجموعه گره‌ها است و

۴-۱-۱ آتاماتای یادگیر

آتاماتای یادگیر، موجوداتی انتزاعی با تعداد محدودی عمل هستند که می‌توانند با محیط اطراف خود تعامل داشته باشند و از آن یاد بگیرند. این موجودات ساده، با انتخاب یکی از اعمال خود و اعمال آن بر محیط، عمل می‌کنند. سپس محیط به صورت تصادفی عمل آنها را ارزیابی می‌کند و آتاماتا از این بازخورد برای انتخاب عمل بعدی خود استفاده می‌کند.

در طول این فرآیند یادگیری، آتاماتا به تدریج عمل بهینه را برای رسیدن به هدف خود انتخاب می‌کند. نحوه استفاده از بازخورد محیط برای انتخاب عمل بعدی، توسط الگوریتم یادگیری آتاماتا تعیین می‌شود.

آتاماتای یادگیر به دو دسته اصلی تقسیم می‌شوند: آتاماتای با ساختار ثابت^{۱۴} و آتاماتای با ساختار متغیر^{۱۵}. در آتاماتای تصادفی^{۱۶} با ساختار ثابت، احتمال انتخاب هر عمل ثابت است و در طول زمان تغییر نمی‌کند. در مقابل، در آتاماتای تصادفی با ساختار متغیر، احتمال انتخاب هر عمل در هر تکرار به طور تصادفی تعیین می‌شود. این موجودات ساده، به رغم ظاهر ابتدایی، کاربردهای متنوعی در حوزه‌های مختلف از جمله هوش مصنوعی، یادگیری تقویتی و رباتیک دارند.

۴-۱-۲ آتاماتای تصادفی با ساختار متغیر

در آتاماتای یادگیری با ساختار متغیر، احتمال اعمال تغییرات بر اساس الگوریتم یادگیری انجام می‌شود. در این نوع خودکار، حالت درونی اتوماتا (ϕ^i) با احتمال اعمال نشان داده می‌شود که بردار احتمال $(p^i = \{p_1^i, p_2^i, \dots, p_r^i\})$ نامیده می‌شود. الگوریتم یادگیری یک رابطه تکراری است و برای اصلاح بردار احتمال حالت استفاده می‌شود.

اگر پاسخ محیط مطلوب^{۱۷} (موفقیت) باشد، عمل پاداش داده می‌شود (معادله (۷)) و iot در غیر این صورت جریمه می‌شود (معادله (۸)).

بدیهی است که عامل تعیین‌کننده عملکرد آتاماتای یادگیری، الگوریتم یادگیری برای به‌روزرسانی احتمال اقدامات است.

فصلنامه مهندسی حمل‌ونقل / سال شانزدهم / شماره چهارم (۶۵) / تابستان ۱۴۰۴

است. تخصیص مسیرهای بیشتر به مناطق مشابه و پویا به‌عنوان کیفیت ساختار برآوردشده در نظر گرفته می‌شود. بنابراین تابع هدف Y به شرح زیر است:

$$Y = \alpha \times Y_1 + \beta \times Y_2 \quad (۴)$$

که:

$$Y_1 = \frac{1}{\sum_{i=1}^{n-1} \sum_{j=i+1}^n (\hat{o}_{ij} - s_{ij})^2 + 1} \quad (۵)$$

$$Y_2 = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \frac{\left(\frac{\hat{o}_{ij}}{\max(\hat{o})} \right) \times F_{ij}}{\sum_{i=1}^{n-1} \sum_{j=i+1}^n F_{ij}} \quad (۶)$$

در فرمول دوم α و β پارامترهای ثابتی هستند که ضریب تأثیر زیر توابع را در تابع هدف تنظیم می‌کنند ($\alpha + \beta = 1$).

۴. روش پژوهش

قبل از ارائه روش پیشنهادی که مبتنی بر آتاماتای یادگیری است، ابتدا برخی مفاهیم توضیح داده شده است:

۴-۱-۴ یادگیری تقویتی

به‌عنوان یکی از شاخه‌های گسترده و پرکاربرد هوش مصنوعی، یادگیری ماشین روش‌ها و الگوریتم‌هایی را تنظیم و بررسی می‌کند که رایانه‌ها و دستگاه‌ها می‌توانند بر اساس آن‌ها بیاموزند. هدف یادگیری ماشینی این است که کامپیوترها در کلی‌ترین معنای آن‌ها بتوانند با استفاده از داده‌های بیشتر به تدریج عملکرد بهتری پیدا کنند. یادگیری تقویتی یا RL یک رویکرد تعاملی است و با یادگیری از طریق نظارت متفاوت است. در این نوع یادگیری از سیگنال‌ها و اندازه‌گیری‌های ضمنی برای یادگیری غیرمستقیم برای تشخیص درستی یا نادرستی فرآیند یادگیری استفاده می‌شود. به عبارت دیگر، دانش ذخیره شده فعلی با پاداش^{۱۲} یا مجازات^{۱۳} تقویت یا تضعیف می‌شود [Sutton & Barto, 2018]

استنتاج ساختار شهری به شکل کارآمد توسط پویایی جریان ترافیک با استفاده از آتاماتای یادگیری

p^j بردار احتمال عمل برای آتاماتای یادگیر A_j باشد، p_m^j احتمال انتخاب اقدام α_m توسط آن آتاماتا است.

۴-۱-۴ آتاماتای سلولی

آتاماتای سلولی (CA) یک مدل محاسباتی توزیع شده است؛ که بستری را برای انجام محاسبات پیچیده با استفاده از تعاملات محلی فراهم می‌کند. CA شبکه‌ای از واحدهای یکسان ساده است که سلول نامیده می‌شود. وقتی سلول‌ها به مقدار زیاد کنار هم قرار می‌گیرند، الگوهای رفتاری پیچیده‌ای را می‌توان از طریق تعامل سلول‌ها با همسایگان‌شان تولید کرد. وضعیت هر سلول بر اساس وضعیت فعلی خود و همسایگان‌ش، بر اساس قانون به‌روزرسانی CA به‌روز می‌شود. آتاماتای سلولی d بعدی یک چندتایی $CA = (Z^d, \phi, N, F)$ است به‌طوری‌که:

Z^d - یک شبکه از d تایی‌های مرتب از اعداد صحیح است. هر سلول در آن با (Z_1, Z_2, \dots, Z_d) و $F = f_1; 2; \dots; m$ کیلوگرم مجموعه‌ای محدود از حالات سلولی است. $N = \{X_1, X_2, \dots, X_m\}$ که بردار همسایه نامیده می‌شود، زیرمجموعه متناهی از Z^d . بردار همسایه موقعیت‌های نسبی سلول‌های همسایه را برای هر سلول معین در Z^d تعیین می‌کند. بردار همسایگی، موقعیت نسبی همسایگان را برای هر سلول u در شبکه سلولی به صورت $N(u) = \{u + \bar{x}_i | i = 1, \dots, \bar{m}\}$ مشخص می‌کند و در نهایت، $F: \Phi^m \rightarrow \Phi$ قاعده محلی CA است که وضعیت جدید سلول را با توجه به وضعیت فعلی همسایگان‌ش می‌دهد [Ahangaran et al., 2017].

از زمان شروع آن، تغییرات ساختاری مختلف CA پیشنهاد شده است.

CAها را می‌توان بر اساس ویژگی‌های مختلف طبقه‌بندی کرد. با توجه به حالت‌های ممکن برای سلول‌ها، CAها را می‌توان به دوتایی و چند ارزشی طبقه‌بندی کرد. قانون محلی اعمال شده برای هر سلول ممکن است یکسان یا متفاوت باشد. از این دو احتمال به عنوان CAهای یکنواخت و ترکیبی یاد می‌شود. به

الگوریتم‌های یادگیری متفاوتی در ادبیات وجود دارد [Masoumi & Meybodi, 2012].

شکل کلی الگوریتم یادگیری به شرح زیر است. اگر عمل در مرحله انتخاب‌شده باشد، در مرحله بعد خواهیم داشت:

الف- پاسخ مطلوب از محیط:

$$\begin{aligned} p_i(n+1) &= p_i(n) + a[1 - p_i(n)] \\ p_j(n+1) &= (1-a)p_j(n) \quad \forall j, j \neq i \end{aligned} \quad (7)$$

ب- پاسخ نامطلوب^{۱۸} (شکست)^{۱۹} از محیط:

$$\begin{aligned} p_i(n+1) &= (1-b)p_i(n) \\ p_j(n+1) &= \frac{b}{r-1}p_j(n) + (1-b)p_j(n) \quad \forall j, j \neq i \end{aligned} \quad (8)$$

با توجه به مقادیر a و b در روابط فوق، سه حالت را می‌توان در نظر گرفت. اگر مقادیر a و b برابر باشند، آتاماتای یادگیر نامیده می‌شود. زمانی که b مساوی با صفر باشد آتاماتای یادگیر نامیده می‌شود. اگر $b \leq a$ باشد، آتاماتای یادگیر نامیده می‌شود.

۳-۱-۴ آتاماتای یادگیر توزیع شده (DLA)^{۲۰}

یک شبکه آتاماتا که به‌طور هماهنگ برای حل یک مسئله خاص همکاری می‌کند، آتاماتای یادگیر توزیع شده نامیده می‌شود. یک گراف جهت‌دار می‌تواند یک DLA را مدل‌سازی کند؛ که در آن مجموعه گره‌های نمودار مجموعه‌ای از آتاماتا را نشان می‌دهد. یک گروه از یال‌های خروجی برای هر گره، نمایانگر مجموعه اقدامات مربوط به آتاماتای مربوطه است. هنگامی که یک آتاماتا یک عمل را انتخاب می‌کند، یک آتاماتا دیگر در طرف دیگر لبه فعال می‌شود؛ که مربوط به عملکرد انتخاب شده است. فقط یک آتاماتا در شبکه در هر زمان فعال است. یک DLA با n آتاماتای یادگیر، رسماً به‌عنوان یک گراف (A, E) تعریف می‌شود. $A = \{A_1, A_2, \dots, A_n\}$ یک مجموعه از آتاماتا و $E \subset A \times A$ مجموعه یال‌ها در گرافی است، که یک یال (i, j) به عمل α_j از آتاماتا A_i اشاره دارد. با فرض این‌که

توجه به بردارهای احتمال LA های ساکن در آن سلول تعیین می‌شود. وضعیت اولیه CLA بر اساس آزمایش‌ها قبلی یا خودسرانه تعیین می‌شود. در مرحله دوم قانون محلی هر سلول سیگنال تقویتی آن سلول را تعیین می‌کند و در نهایت هر LA بردار احتمال خود را بر اساس سیگنال تقویتی و عمل انتخابی سلول به‌روز می‌کند. این روند تا زمانی که شرایطی برآورده شود ادامه می‌یابد. در اکثر برنامه‌ها، تمام سلول‌ها با یک ساعت سراسری همگام‌سازی می‌شوند و در نمونه‌های هم‌زمان کار می‌کنند. با این حال، در برخی موارد، LA سلول‌های مختلف به‌صورت ناهم‌زمان فعال می‌شوند. این نوع CLA. آتاماتای

یادگیری سلولی ناهم‌زمان (ACLA) نامیده می‌شود [Beigy & Meybodi, 2008]. استاندارد CLA & Meybodi, 2008]. نامیده می‌شود. زیرا هر سلول فقط با محیط محلی خود متشکل از سلول‌های همسایه تعامل دارد. در برخی از برنامه‌ها، یک محیط جهانی نیز وجود دارد. هر سلول هم با محیط محلی خود و هم با محیط خارجی جهانی تعامل دارد. این نوع CLA. آتاماتای یادگیری سلولی باز (OCLA) نامیده می‌شود [Long & Shen, 2015]. نوع دیگری از CLA. CLA با چندین LA در هر سلول است. در این شکل از CLA. هر سلول دارای چندین LA است و این LA ها ممکن است به‌صورت هم‌زمان یا ناهم‌زمان فعال شوند. برای اطلاعات بیشتر در مورد CLA با چندین LA در هر سلول به [Black, 2018] مراجعه کنید. با توجه به قدرت محاسباتی CLA، این مدل در کاربردهای مختلفی مورد استفاده قرار گرفته است.

۲-۴ الگوریتم ۱: استنباط اتصال بهینه با استفاده از

[Yasinian & Esmailpour, 2021] DLA

در این بخش روشی برای استنتاج اتصال ساختاری پیشنهاد شده است. اتصال بهینه یک ساختار پنهان است که توسط DLA یافت می‌شود. هر گره در نمودار که $G_S = (V, L_S)$ نشان‌دهنده یک منطقه است که مجهز به یادگیری خودکار است. نمودار کاملاً متصل است، بنابراین یک خودکار دارای $n-1$

طور کلی، حکومت محلی قطعی است. اگرچه تغییراتی وجود دارد که در آن قاعده محلی احتمالی [Thathachar & Sastry, 2002] یا فازی [Beigy & Meybodi, 2004] است. قانون محلی اغلب بر اساس وضعیت سلول‌ها است، و بنابراین، همه سلول‌ها حالت خود را به طور هم‌زمان به‌روز می‌کنند. این CA ها هم‌زمان نامیده می‌شوند. برعکس، یک قانون محلی ممکن است وابسته به حالت و زمان باشد که منجر به یک CA ناهم‌زمان می‌شود. انتخاب یک مدل مناسب به کاربرد داده شده بستگی دارد.

۵-۱-۴ آتاماتای یادگیر سلولی (CLA)

در آتاماتای یادگیری سلولی، مجموعه‌ای از آتاماتای یادگیری به هر سلول اختصاص داده می‌شود. آتاماتای یادگیری ساکن در هر سلول، وضعیت سلول مربوطه را بر اساس بردارهای احتمال عمل آن تعیین می‌کند. مشابه آتاماتای سلولی، قانونی وجود دارد که CLA بر اساس آن عمل می‌کند. قانون CLA و اقدامات انتخاب شده توسط آتاماتای یادگیری همسایه هر سلول، سیگنال تقویتی داده شده به آتاماتای یادگیری ساکن در آن سلول را تعیین می‌کند. در CLA، آتاماتای یادگیری همسایه هر سلول، محیط محلی آنها را تشکیل می‌دهد. این محیط غیر ثابت است زیرا با تغییر بردارهای احتمال عمل آتاماتای یادگیری همسایه تغییر می‌کند [Torkestani & Meybodi, 2011]. آتاماتای یادگیر سلولی d بعدی یک چندتایی $CLA = (Z^d, \phi, A, N, F)$ است که، Z^d یک شبکه از d تایی های مرتب از اعداد صحیح است. این شبکه می‌تواند یک شبکه متناهی، نیمه متناهی یا متناهی باشد، ϕ یک مجموعه متناهی از حالت‌ها است. A ، یک مجموعه از آتاماتاهای یادگیر (LA) است که هر آتاماتای یادگیر به یک سلول نسبت داده می‌شود. یک زیرمجموعه متناهی از است که بردار همسایگی خوانده می‌شود. قانون محلی CLA است، به طوری که مجموعه مقادیری است که می‌تواند به‌عنوان سیگنال تقویتی پذیرفته شود. کار CLA به شرح زیر است: در ابتدا، وضعیت هر سلول با

استنتاج ساختار شهری به شکل کارآمد توسط پویایی جریان ترافیک با استفاده از آتاماتای یادگیری

پس از رسیدن به معیار توقف، آخرین \hat{O} با بالاترین مقدار هدف بهترین ماتریس اتصالات بهینه برآوردشده در طول تکرار این الگوریتم است. روش از یک نقطه تصادفی دیگر با استفاده از بردار احتمال به‌روزشده شروع می‌شود تا \hat{O} دیگری را تشکیل دهد. پس از $n1$ بار تکرار، بهترین \hat{O} با توجه به مقدار Y مربوطه انتخاب می‌شود. این الگوریتم $n2$ بار تکرار می‌شود؛ تا الگوریتم از دام بهینه‌های محلی به دلیل همگرایی به یک بردار احتمال غیربهینه رها شود. شبه‌کد الگوریتم پیشنهادی مبتنی بر DLA به شرح زیر است:

استنتاج اتصال بهینه مبتنی بر DLA

ورودی: V, S, F, a, b, α و β

خروجی: O

۱. $n2$ بار تکرار کن.
۲. P را مقداردهی اولیه کن.
۳. $n1$ بار تکرار کن.
۴. \hat{O} را مقداردهی اولیه کن.
۵. یک منطقه تصادفی را انتخاب کن.
۶. تکرار کن.
۷. یک اقدام توسط اتوماتای فعلی بر اساس S انتخاب کن (رابطه ۹).
۸. ماتریس اتصال بهینه تخمینی \hat{O} را به‌روزرسانی کن.
۹. تابع هدف Y را محاسبه کن (رابطه ۴).
۱۰. P را به‌روزرسانی کن (روابط ۷ و ۸).
۱۱. رسیدن به معیار توقف را بررسی کن.
۱۲. \hat{O}_{best} را با \hat{O} مقایسه کن و اگر مقدار تابع هدف Y بزرگ‌تر بود \hat{O}_{best} را با \hat{O} جایگزین کن.

اقدامات است و اقدامات در حال انتخاب مناطق دیگر شهر هستند. یک خودکار مربوط به یک منطقه، یک عمل را بر اساس بردار احتمال آن انتخاب می‌کند. سپس خودکار انتخاب شده برای ادامه روند فعال می‌شود. ماتریس اتصالات مطلوب تخمین زده شده \hat{O} یک ماتریس $n \times n$ است. همه عناصر \hat{O} در ابتدای الگوریتم صفر هستند. ابتدا یک عمل توسط یک آتاماتان مربوط به منطقه‌ای تصادفی انتخاب می‌شود. با انتخاب عمل j توسط آتاماتای i ,

$$\hat{O}_{ji} = \hat{O}_{ji} + 1 \quad \text{و} \quad \hat{O}_{ij} = \hat{O}_{ij} + 1$$

هنگامی که \hat{O} توسط عمل آتاماتان به‌روز می‌شود؛ آن آتاماتان با به‌روزرسانی بردار احتمال مربوطه پاداش یا مجازات می‌شود. پاداش یا مجازات بر اساس افزایش یا کاهش مقدار تابع هدف Y (رابطه ۴) در مقایسه با مقدار قبلی Y انجام می‌شود. اگر مقدار Y مربوط به \hat{O} جدید بیشتر از مقدار مربوط به بالاترین دستاورد باشد، آتاماتان پاداش می‌گیرد و در غیر این صورت مجازات می‌شود. تکرار الگوریتم ماتریس اتصالات بهینه را تشکیل می‌دهد. در صورتی که در مقدار Y برای بیش از تعداد از پیش تعیین شده انتخاب عمل ne پیشرفتی وجود نداشته باشد، حلقه تکرار داخلی به پایان می‌رسد. تعریف بردار هموارتر برای انتخاب اقدامات به جای احتمال به شرح زیر است:

$$s_j^i = \frac{\left(\frac{P_i}{r-1-\deg(v_i)} + \bar{v}_{ij} \right)^\theta}{\sum_{k=1}^r \left(\frac{P_i}{r-1-\deg(v_i)} + \bar{v}_{ij} \right)^\theta} \quad (9)$$

در رابطه (۹)، یک عامل متعادل‌کننده و ماتریس کواریانس اتصالات عملکردی نرمال شده به صورت زیر است:

$$\bar{v}_{ij} = \frac{v_{ij}}{\sum_{j=1}^n v_{ij}} \quad (10)$$

V ماتریس کواریانس اتصالات عملکردی به شرح زیر تعریف شده است:

$$V = DD^T \quad (11)$$

برآورده شود، ماتریس اتصالات بهینه به روز می شود. در مرحله ۶ نواحی متصل به هر ناحیه دیگر توسط رشته داخل CLA مربوطه مشخص می شود. اگر j, n بار در رشته متعلق به CLA ظاهر شود، سپس $s_n = \hat{O}_{ij} = s_n$ و $\hat{O}_{ji} = s_n$. در مرحله ۶، ابتدا مقدار تابع برازندگی برای ساختار فعلی محاسبه می شود؛ سپس دو رشته با بیشترین اتصال بین رئوس خود (لبه های بین گره های دو رشته حداکثر هستند) ترکیب می شوند و تابع برازندگی دوباره محاسبه می شود. اگر مقدار تابع هدف افزایش یابد، فرآیند ترکیب ادامه می یابد، در غیر این صورت متوقف می شود. حلقه داخلی خاتمه می یابد و ساختار بهینه تخمین زده می شود. شبه کد الگوریتم پیشنهادی مبتنی بر CLA به شرح زیر است:

استنتاج اتصال بهینه مبتنی بر CLA

ورودی: V, S, F, a, b, α و β

خروجی: O

۱. $n2$ بار تکرار کن.
۲. P را مقداردهی اولیه کن.
۳. $n1$ بار تکرار کن.
۴. \hat{O} را مقداردهی اولیه کن.
۵. یک آتاماتای سلولی به هر منطقه تخصیص بده و یک اتوماتا در هر CLA قرار بده.
۶. تکرار کن.
۷. برای همه سلول ها به صورت موازی انجام بده.
۸. یک اقدام توسط اتوماتای فعلی بر اساس S انتخاب کن (رابطه ۹).
۹. بررسی کن که آیا مناطق انتخاب شده بیش از درجه آن ها هستند و \hat{O} به طور متناسب به روزرسانی کن.
۱۰. رسیدن به معیار توقف را بررسی کن.
۱۱. مقدار تابع هدف Y را محاسبه کن.
۱۲. P را به روزرسانی کن (روابط ۷ و ۸).
۱۳. \hat{O}_{best} را با \hat{O} مقایسه کن و اگر مقدار تابع هدف Y بزرگ تر بود \hat{O}_{best} را با \hat{O} جایگزین کن.

۱۳. O را با \hat{O}_{best} مقایسه کن و اگر مقدار تابع هدف Y بزرگ تر بود O را با \hat{O}_{best} جایگزین کن.

۳-۴ الگوریتم ۲: استنتاج اتصال بهینه با استفاده از CLA

CLA

الگوریتم ۲ روشی برای شناسایی بخش های غیر مرتبط و سپس ادغام آنها، به حداکثر رساندن تابع تناسب است. یادگیری ماهیت آتاماتای یادگیری سلولی ما را به اتصال بهینه سوق می دهد. در متن زیر، الگوریتم پیشنهادی در ۷ مرحله مورد بحث قرار گرفته است:


۱. ایجاد آتاماتای یادگیر سلولی نامنظم.
 ۲. تخصیص یک سلول به هر ناحیه و یک LA به هر سلول.
 ۳. انتخاب اقدام های تمام سلول ها به صورت موازی و افزودن ناحیه انتخابی به رشته درون هر سلول.
 ۴. اگر ناحیه ای بیش از درجه آن در شبکه انتخاب شود، مقدار تابع تناسب قبل و بعد از انتخاب عمل محاسبه می شود و اگر مقدار افزایش یابد، به روزرسانی ساختار بهینه انجام می شود.
 ۵. بازگشت به مرحله سه تا زمان رسیدن به شرط توقف.
 ۶. کشف نواحی متصل به هر ناحیه توسط رشته های درون هر سلول.
 ۷. تجمیع رشته های به دست آمده با استفاده از یک الگوریتم جستجوی حریصانه برای بیشینه سازی مقدار برازندگی.
 ۸. محاسبه مقدار برازندگی به دست آمده نهایی.
 ۹. بررسی بهبود در مقدار تابع برازندگی (پاداش برای همه اقدامات در صورت افزایش یا جریمه در غیر این صورت).
 ۱۰. بازگشت به مرحله دوم تا رسیدن به شرط توقف.
- در مرحله یک // آتاماتای سلولی با یک رشته خالی تولید می شود. این رشته ها می توانند همسایگان مناطق کشف شده توسط روش باشند. هر CLA به یک منطقه اختصاص داده شده و مجهز به یک LA است. در مرحله ۳، CLA ها اقدامات را با استفاده از رابطه (۹) انتخاب می کنند. اگر شرایط توصیف شده در مرحله ۴

استنتاج ساختار شهری به شکل کارآمد توسط پویایی جریان ترافیک با استفاده از آتاماتای یادگیری


برای مقیاس (σ) پراکندگی نامیده می‌شود. فرمول تابع چگالی احتمال توزیع نرمال به شرح زیر است:

$$f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (12)$$

فرض بر این است که تعداد C_i وسیله نقلیه از منطقه i عبور می‌کند. زمان عبور هر یک، یک عدد صحیح تصادفی نرمال است؛ که از یک تابع چگالی احتمال توزیع نرمال مشتق شده است. بر اساس مفروضات، برای هر منطقه تصمیماتی برای ایجاد ماتریس اتصال عملکردی وجود دارد. اول تعداد کل وسایل نقلیه C_i و مورد بعدی تعداد توابع چگالی احتمال توزیع نرمال f و μ و σ آن‌ها است. تصمیم نهایی در مورد فاصله زمانی است. در شکل ۲ نمونه‌ای از ترافیک ایجاد شده در فواصل زمانی مختلف روز نشان داده می‌شود. در این الگو، ۷۰۰ وسیله نقلیه از منطقه عبور می‌کنند. زمان عبور ۵۰۰ وسیله نقلیه از تابع گوسی با $\sigma=3$ و $\mu=12$ و بقیه از تابع دیگری با $\mu=20$ و $\sigma=1$ گرفته شده است.



شکل ۱. نمونه‌ای از یک منطقه شهری ساختگی با $n=10$



شکل ۲. نمونه‌ای از الگوی ترافیک منطقه شهری

۱۴. O را با \hat{O}_{best} مقایسه کن و اگر مقدار تابع هدف Y بزرگ‌تر بود O را با \hat{O}_{best} جایگزین کن.

۵. نتایج تجربی

دو معیار برای ارزیابی روش‌ها وجود دارد: شباهت بین ماتریس اتصال ساختاری و بهینه (فرمول (۵)) و قیاس بین ماتریس ساختار بهینه و ماتریس اتصال عملکردی (فرمول (۶)). برای انجام آزمایش‌ها از دو مجموعه داده (مصنوعی و واقعی) استفاده شد. داده‌های ترکیبی برای نشان دادن اثربخشی کلی رویکرد پیشنهادی و تعریف مسئله جدید استفاده می‌شود. داده‌های دوربین که با استفاده از حسگرهای شهرداری مستقر در مناطق شهری شهر همدان جمع‌آوری شده‌اند نیز برای نشان دادن کاربرد فرمول ریاضی مسئله در کاربردهای دنیای واقعی استفاده شدند.


۱-۵ آزمایش بر روی داده‌های ساختگی

در اینجا از سه مجموعه داده مصنوعی با تعداد مناطق مختلف استفاده شده است ($n=10, n=100, n=1000$). یک عدد صحیح تصادفی بین صفر و $2 \log n$ به هر یال اختصاص داده می‌شود که نشان‌دهنده تعداد جاده‌های متصل‌کننده مناطق مربوطه است. یک ماتریس متقارن نیز همین‌طور است و عناصر آن اعدادی در محدوده ذکر شده هستند.

ماتریس جریان ترافیک D برای تشکیل ماتریس F مورد نیاز است. هر سطر در D نشان‌دهنده الگوی ترافیک یک منطقه شهری در دوره‌های مختلف است. تعداد خودروهایی که از مسیر های هر منطقه شهری عبور می‌کنند در طول زمان متفاوت است. یک تابع تولید اعداد تصادفی این اعداد را تولید می‌کند. توزیع های مختلفی برای تولید اعداد تصادفی وجود دارد. تابعی که برای این کاربرد انتخاب می‌شود؛ توزیع نرمال یا گوسی است؛ که به‌طور گسترده برای مدل‌سازی فرایندهای تصادفی مانند ترافیک کاربرد دارد. در این تابع احتمال، دو پارامتر وجود دارد. اولین مورد برای مکان (μ) به‌عنوان میانگین توزیع و دومی

از β بزرگ‌تر باشد؛ در غیر این صورت اگر ساختار فعلی کارا نباشد، استنتاج ساختار جدید از پویایی ترافیک مطلوب است؛ بنابراین β باید از α بزرگ‌تر باشد. در آزمایش‌ها بر روی این داده‌ها $\alpha = 0.4$ و $\beta = 0.4$ در نظر گرفته می‌شود. پس از گذراندن تکرارها در حلقه داخلی، ممکن است بهبودی در مقدار تابع هدف مشاهده نشود. الگوریتم، ساختاری با بالاترین γ به عنوان ساختار بهینه تخمین‌زده شده انتخاب می‌کند. در صورت عدم بهبود در مقدار تابع هدف پس از سپری شدن ne تکرار، حلقه داخلی به طور خودکار خاتمه می‌یابد.

$$\gamma = 0.2640$$



شکل ۳. برآورد ساختار بهینه موجود در حلقه داخلی الگوریتم مبتنی بر **DLA** اجرا شده بر روی داده‌های ساختگی با $n = 10$

رویه حلقه داخلی الگوریتم با استفاده از تنظیم بردارهای احتمال امیدوار است که ساختار بهتری از لحاظ مقدار تابع هدف پیدا کند. در طول این حلقه، ماتریس احتمال مجدداً مطابق با ساختار بهینه به‌روز می‌شود. تعداد تکرارهای حلقه خارجی $n1$ است. کل فرایند $n2$ بار برای بررسی توانایی الگوریتم تکرار می‌شود. پارامترهای معیار توقف در جدول 2 نشان داده شده است.

جدول ۲. معیار توقف الگوریتم پیشنهادی مبتنی بر **DLA** در

آزمایش‌ها بر روی داده‌های ساختگی

تعداد مناطق	$n1$	$n2$	s
۱۰	۲۰	۳۰	۲۰
۱۰۰	۲۰۰	۳۰	۴۰
۱۰۰۰	۲۰۰۰	۳۰	۶۰

سه الگوریتم در این بخش برای حل مسئله مورد استفاده قرار می‌گیرد؛ که روش‌ها در ادامه معرفی می‌شوند:

در تمام آزمایش‌هایی که در فصول بعد انجام خواهد شد، دو تابع گوسین با μ و σ مشخص برای تولید الگوی ترافیکی به کار می‌رود و هرکدام یک عدد صحیح معین تولید می‌کند. بنابراین تعداد الگوها برای $n = 10, n = 100, n = 1000$ به ترتیب برابر سه، شش و نه است. هر الگو تعداد وسایل نقلیه خاص خود را دارد؛ که به‌طور تصادفی از بین بازه $n^2 - n^3$ و $n^2 + n^3$ انتخاب می‌شود. کسری تصادفی از C_i به توزیع اول تخصیص داده می‌شود و باقیمانده به دومین توزیع می‌رسد.

جدول ۱. مثالی از پارامترهای مورد استفاده در تولید پترین‌ها برای

$n = 10$		
جزئیات	C_i	i
$C_{i1} = 858, \mu = 12, \sigma = 3$	۱۰۸۳	۱
$C_{i2} = 225, \mu = 20, \sigma = 1$		
$C_{i1} = 716, \mu = 13, \sigma = 3.5$	۱۰۹۲	۲
$C_{i2} = 376, \mu = 19, \sigma = 2$		
$C_{i1} = 770, \mu = 11.5, \sigma = 4$	۹۰۷	۳
$C_{i2} = 137, \mu = 21, \sigma = 1.5$		

ترافیک هر منطقه در شبکه با روش تولید ترافیک با تنظیمات پارامترها ایجاد و باعث می‌شود برخی از مناطق دارای الگوی یکسانی باشند. الگوهای تولیدشده با استفاده از روش معرفی شده با پارامترهای خاص را می‌توان برای تشکیل جریان ترافیک برای یک روز کامل اعمال کرد (به عنوان مثال، شکل ۲). این رویکرد برای ایجاد الگوهای هفتگی یا ماهانه تکرار می‌شود. همچنین می‌توان یک روز را به فواصل دلخواه تقسیم کرد. روش توضیح داده شده داده‌های جریان هفتگی را با فواصل ۱۵ دقیقه برای تمام آزمایش‌ها تولید می‌کند. دو پارامتر قابل تنظیم دز تابع هدف مسئله وجود دارد (β, a) ؛ که هرکدام اهمیت هر زیرتابع را نشان می‌دهند. اگر هزینه حذف اتصالی از شبکه یا افزودن به آن زیاد باشد زیرتابع اول از اهمیت بالاتری برخوردار است و α باید

استنتاج ساختار شهری به شکل کارآمد توسط پویایی جریان ترافیک با استفاده از آتاماتای یادگیری

مناطق متصل در ساختار اتصال بهینه در نظر گرفته می‌شوند. ما می‌توانیم از این مناطق برای محاسبه مقدار تابع هدف بر اساس رابطه (۴) استفاده کنیم. جدول ۴ حداقل، حداکثر، میانگین و واریانس مقدار تابع هدف را که پس از پیاده‌سازی الگوریتم‌ها بر روی سه داده ساختگی محاسبه شده است را نشان می‌دهد.

همان‌طور که می‌بینیم، مقدار حداقل، حداکثر و میانگین تابع هدف به دست آمده توسط الگوریتم پیشنهادی بیشتر از الگوریتم‌های دیگر در اجرا بر روی داده‌های ساختگی است و واریانس در همه موارد کمتر است؛ که بسیار مطلوب به حساب می‌آید. الگوریتم پیشنهادی پویایی ترافیک را به صورت تکراری می‌آموزد. این مزیت الگوریتم است که با در نظر گرفتن ساختار فعلی، پیوندهای نهفته را پیدا می‌کند.

جدول ۴. نتایج بدست آمده از الگوریتم‌ها در اجرا بر روی

مجموعه داده‌های مختلف ساختگی.

تابع هدف	الگوریتم			
	تعداد گره‌های شبکه در دادگان ساختگی	۱۰	۱۰۰	۱۰۰۰
حداقل	۱	۰/۲۱۵۲	۰/۲۲۸۶	۰/۲۵۲۱
	۲	۰/۲۱۳۲	۰/۲۴۱۵	۰/۲۶۲۹
	۳	۰/۲۳۴۲	۰/۲۷۴۴	۰/۲۹۸۹
حداکثر	۱	۰/۲۳۹۲	۰/۲۶۲۱	۰/۳۰۲۳
	۲	۰/۲۵۱۰	۰/۳۰۲۸	۰/۳۵۱۱
	۳	۰/۲۸۱۸	۰/۳۲۷۲	۰/۳۶۰۵
میانگین	۱	۰/۲۲۶۵	۰/۲۴۱۰	۰/۲۶۱۱
	۲	۰/۲۳۱۴	۰/۲۸۰۹	۰/۲۷۵۹
	۳	۰/۲۵۴۶	۰/۳۰۴۳	۰/۲۹۷۸
انحراف معیار	۱	۰/۰۰۰۵۸۱	۰/۰۰۰۶۶۷	۰/۰۰۱۰۲۳
	۲	۰/۰۰۰۴۹۱	۰/۰۰۰۴۲۱	۰/۰۰۰۹۹۱
	۳	۰/۰۰۰۲۱۳	۰/۰۰۰۲۸۷	۰/۰۰۰۹۳۲

۲-۵ آزمایش بر روی داده‌های دنیای واقعی

این آزمایش‌ها بر روی ساختار شبکه شامل مناطق همدان است که از ۴۰ قسمت مجزا (شکل ۴) و اتصالات بین آنها تشکیل شده است. داده‌های ترافیکی تعداد خودروهایی است؛ که در

جدول ۳. الگوریتم‌های مورد استفاده در حل مسئله در مقایسه با

الگوریتم پیشنهادی مبتنی بر DLA

#	مرجع	نام
۱	[Kamw et al., 2019]	مدل‌سازی و بصری‌سازی دسترسی به ساختار شهری برای محدودیت‌های فضایی و زمانی مشترک
۲	[Wang et al., 2018]	یادگیری ساختارهای جامعه شهری: دیدگاه تعبیه شده تجمعی با نمودارهای تحرک مکانی-زمانی دوره‌ای
۳	الگوریتم ۱	رویکرد مبتنی بر آتاماتای یادگیری توزیع شده برای استنتاج ساختار شهری از طریق جریان ترافیک
۴	الگوریتم ۲	استنتاج ساختار شهری از جریان ترافیک با استفاده از آتاماتای یادگیری سلولی

مجموعه‌ای از نقاط مورد علاقه و بردار تحرک انسان برگرفته از خطوط GPS در [Wang et al., 2018] برای یادگیری نمایش بردار جامعه استفاده می‌شود؛ که می‌تواند پیکربندی فضایی ایستا و ارتباط پویای تحرک انسان را در جامعه توصیف کند. در تعریف مسئله ما، نمایش جامعه ثابت است. ما از عبارت دوم تعریف‌شده در روش [Wang et al., 2018] برای تدوین و حل مسئله بر اساس داده‌های توضیح داده‌شده قبلی استفاده می‌کنیم. بین دو POI^{۲۱} شباهتی وجود دارد؛ که با استفاده از شباهت کسینوسی محاسبه می‌شود و در این روش هر یال وزن می‌گیرد. چارچوب یادگیری یک نمایش را ارائه می‌دهد؛ که ما آن را به عنوان یک ارتباط مطلوب تخمین زده‌شده در نظر می‌گیریم. سپس می‌توان مقدار تابع هدف را با استفاده از رابطه (۴) محاسبه کرد. مدل‌های محاسباتی در [Kamw et al., 2019] برای استخراج ساختارهای پویا با محدوده مشخص در شهرها توسعه داده شده‌اند؛ که برای نشان دادن دسترسی مفید هستند. مدلی به نام USAGraph مناطقی را تشکیل می‌دهد که برخی محدودیت‌ها را برآورده می‌کند. مناطق ترافیکی اولیه (PTRs)^{۲۲} را می‌توان با توجه به محدودیت‌ها تعریف کرد. مناطق در PTR به عنوان

حلقه داخلی را همان‌طور که قبلاً توضیح داده شد خاتمه می‌دهد. حلقه داخلی روش بار تکرار می‌شود؛ تا بهترین ساختار تخمینی بهینه را پیدا کند. پس از اجرای الگوریتم پیشنهادی بر روی مجموعه داده‌های واقعی، حداقل، حداکثر، میانگین و واریانس مقدار تابع برازندگی محاسبه می‌شود (جدول ۶).

جدول ۶. نتایج بدست آمده از الگوریتم‌ها در اجرا بر روی

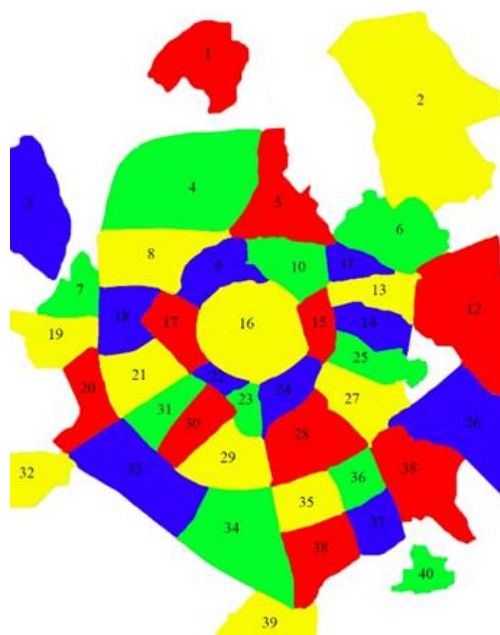
مجموعه داده واقعی		
مقدار	الگوریتم	تابع هدف
۰/۸۱۹۱	۱	حداقل
۰/۸۳۳۹	۲	
۰/۸۵۹۰	۳	
۰/۸۵۹۸	۴	
۰/۸۹۷۶	۱	حداکثر
۰/۹۱۰۰	۲	
۰/۹۳۱۰	۳	
۰/۹۳۲۲	۴	
۰/۸۵۱۱	۱	میانگین
۰/۸۹۶۲	۲	
۰/۹۲۱۳	۳	
۰/۹۲۱۸	۴	
۰/۰۰۰۳۲۱	۱	انحراف معیار
۰/۰۰۰۲۹۹	۲	
۰/۰۰۰۲۳۶	۳	
۰/۰۰۰۲۳۰	۴	

۳-۵ بررسی پیچیدگی زمانی

دو حلقه ثابت در الگوریتم مبتنی بر DLA وجود دارد که $n1$ و $n2$ بار تکرار می‌شود. حلقه دیگری با چرخه‌های تکرار نامشخص وجود دارد. این حلقه به شدت به مسئله (ساختار شبکه، جریان ترافیک و پارامترهای تنظیم‌کننده در تابع برازندگی) وابسته است. اگر الگوریتم را به ایجاد فقط یک پیوند بین دو گره مجزا محدود کنیم، در بدترین حالت، $ne + n$ بار تکرار خواهد شد. بنابراین پیچیدگی زمانی $n1(n2(ne + n))$

فصلنامه مهندسی حمل و نقل / سال شانزدهم / شماره چهارم (۶۵) / تابستان ۱۴۰۴

فواصل ۱۵ دقیقه‌ای مسیریابی را که مناطق را به هم متصل می‌کنند طی می‌نمایند و توسط دوربین‌های نصب شده در خیابان‌ها به دست می‌آید. همان‌طور که در فصل پیش گفتیم ایجاد یا حذف یک مسیر جدید به ساختار شهری هزینه گزافی دارد؛ بنابراین اولین تابع فرعی (Y_1) از اهمیت بالایی برخوردار بوده و k باید به همان اندازه $\hat{\theta}$ تا حد امکان نزدیک شود در نتیجه $\alpha = 0.9$ و $\beta = 0.1$ انتخاب‌های مناسبی هستند.



شکل ۴. نقشه شهر همدان شامل ۴۰ منطقه

پارامترهای پاداش و جریمه مورد استفاده در الگوریتم پیشنهادی عبارتند از: $\alpha = 0.1$ و $\beta = 0.01$ در این آزمون هستند که بر اساس بررسی‌های فراوان به دست آمده‌اند. پارامترهای معیار توقف برای این مورد را می‌توان در جدول ۵ یافت.

جدول ۵. معیار توقف در آزمایش بر روی داده‌های واقعی

تعداد مناطق	$n1$	$n2$	ne
۴۰	۸۰	۳۰	۳۲

همان‌طور که توضیح داده شد ماتریس اتصال بهینه تخمین زده شده که نماینده ساختار بهینه است را می‌توان در طول حلقه داخلی یافت؛ که باعث افزایش جریان در مقدار تابع هدف با انتخاب عمل آتاماتا می‌شود. ساختاری با بالاترین به‌عنوان ساختار بهینه تخمینی توسط الگوریتم انتخاب می‌شود و الگوریتم

12. Reward
13. Penalty
14. Fixed Structure Automata
15. Variable Structure Automata
16. Stochastic Automata
17. Favorable
18. Unfavorable
19. Failure
20. Distributed Learning Automata
21. Points of Interest
22. Primary Traffic Regions

خواهد بود. مانند الگوریتم مبتنی بر DLA، در الگوریتم مبتنی بر CLA نیز دو حلقه ثابت وجود دارد که $n1$ و $n2$ بار تکرار می‌شود. با در نظر گرفتن همین محدودیت، حلقه دیگر به دلیل ماهیت موازی انتخاب عمل، $ne + 1$ تا $ne + n$ را در بدترین سناریو تکرار می‌کند. بنابراین پیچیدگی زمانی آن به طور متوسط $n1 \left(n2 \left(ne + \frac{n+1}{2} \right) \right)$ خواهد بود.

۶. جمع‌بندی

۸. مراجع

– Ahangaran, M., Taghizadeh, N., & Beigy, H. (2017). Associative cellular learning automata and its applications. *Applied Soft Computing*, 53, 1-18.

– Angius, F., Reineri, M., Chiasserini, C.-F., Gerla, M., & Pau, G. (2012). Towards a realistic optimization of urban traffic flows. 2012 15th International IEEE Conference on Intelligent Transportation Systems.

– Avila, A., & Mezić, I. (2020). Data-driven analysis and forecasting of highway traffic dynamics. *Nature communications*, 11(1), 1-16.

– Baskar, B. (2018). Effective Urban Structure Inference from Traffic Flow Dynamics. *Software Engineering and Technology*, 10(2), 35-38.

– Beigy, H., & Meybodi, M. R. (2004). A mathematical framework for cellular learning automata. *Advances in Complex Systems*, 7(03n04), 295-319.

– Beigy, H., & Meybodi, M. R. (2008). Asynchronous cellular learning automata. *Automatica*, 44(5), 1350-1357.

– Black, J. (2018). *Urban transport planning: Theory and practice*. Routledge.

یک رویکرد مبتنی بر آتاماتای یادگیر سلولی برای حل مسئله استنتاج ساختار بهینه شهری ارائه شد. این روش برای بهینه‌سازی یک تابع هدف که دارای ساختار ترکیبی است، پیشنهاد شد. برای نشان دادن کارایی الگوریتم از دو نوع داده ساختگی و واقعی استفاده شده است. الگوریتم پیشنهادی بر روی داده‌های مختلف در مقایسه با سایر الگوریتم‌ها قرار گرفت. الگوریتم مبتنی بر CLA به‌طور بالقوه دارای نرخ عملکرد بهتری در مقایسه با سایر الگوریتم‌ها بر روی داده‌های واقعی و مصنوعی است. الگوریتم‌ها با استفاده از حداقل، حداکثر، میانگین و واریانس تابع هدف با یکدیگر مقایسه شدند. آزمایش‌ها نشان داد که الگوریتم مبتنی بر CLA در همه موارد بهتر از سایرین عمل می‌کند و الگوریتم مبتنی بر DLA دومین الگوریتم است. این عملکرد می‌تواند به دلیل ماهیت یادگیری الگوریتم‌ها برای استنتاج ساختار بهینه باشد.

۷. پی‌نوشت‌ها

1. Traffic Dynamics
2. Optimal Connection Structure
3. Cellular Learning Automata
4. Cellular Automata
5. Travel Demand
6. Evolution
7. Koopman
8. Neural Network
9. Structural Connectivity
10. Functional Connectivity
11. Bhattacharyya distance

ACM SIGKDD International Workshop on Urban Computing.

– Pan, Z., Liang, Y., Wang, W., Yu, Y., Zheng, Y., & Zhang, J. (2019). Urban traffic prediction from spatio-temporal data using deep meta learning. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining.

– Poco, J., Doraiswamy, H., Vo, H. T., Comba, J. L., Freire, J., & Silva, C. T. (2015). Exploring Traffic Dynamics in Urban Environments Using Vector-Valued Functions. Computer Graphics Forum.

– poor arab, m., & pahlevani, p. (2019). مدلسازی تعقیب خودرو با استفاده از روش رگرسیون اسپیلاین تطبیقی - چندگانه در حوزه بزرگراهی. فصلنامه مهندسی حمل و نقل

– Sarkar, S., Chawla, S., Ahmad, S., Srivastava, J., Hammady, H., Filali, F., Znaidi, W., & Borge-Holthoefer, J. (2017). Effective urban structure inference from traffic flow dynamics. IEEE Transactions on Big Data, 3(2), 181-193.

– Solé-Ribalta, A., Gómez, S., & Arenas, A. (2016). A model to identify urban traffic congestion hotspots in complex networks. Royal Society open science, 3(10), 160098.

– Sutton, R. S., & Barto, A. G. (2018). Reinforcement learning: An introduction. MIT press.

– Thathachar, M. A., & Sastry, P. S. (2002). Varieties of learning automata: an overview. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 32(6), 711-722.

– Tonguz, O. K., Viriyasitavat, W., & Bai, F. (2009). Modeling urban traffic: a cellular

– Ding, R., Ujang, N., Hamid, H. B., Abd Manan, M. S., Li, R., Albadareen, S. S. M., Nochian, A., & Wu, J. (2019). Application of complex networks theory in urban traffic network researches. Networks and Spatial Economics, 19(4), 1281-1317.

– Ding, R., Yin, J., Dai, P., Jiao, L., Li, R., Li, T., & Wu, J. (2019). Optimal Topology of Multilayer Urban Traffic Networks. Complexity, 2019.

– Djouadi, A., Snorrason, O., & Garber, F. (1990). The quality of training sample estimates of the bhattacharyya coefficient. IEEE Transactions on Pattern analysis and machine intelligence, 12(1), 92-97.

– Kamw, F., Shamal, A.-D., Zhao, Y., Eynon, T., Sheets, D., Yang, J., Ye, X., & Chen, W. (2019). Urban structure accessibility modeling and visualization for joint spatiotemporal constraints. IEEE Transactions on Intelligent Transportation Systems.

– Krugman, P. (1991). Geography and trade MIT Press. Cambridge, MA.

– Long, Y., & Shen, Z. (2015). Geospatial analysis to support urban planning in Beijing. Springer.

– Masoumi, B., & Meybodi, M. R. (2012). Learning automata based multi-agent system algorithms for finding optimal policies in Markov games. Asian Journal of Control, 14(1), 137-152.

– moghadam, a. (2022). مسئله مسیریابی-موجودی فاسدشدنی کالاهای civilica. <https://civilica.com/doc/1553437/>

– Moosavi, V., & Hovestadt, L. (2013). Modeling urban traffic dynamics in coexistence with urban data streams. Proceedings of the 2nd

automata approach. IEEE Communications Magazine, 47(5), 142-150.

– Torkestani, J. A., & Meybodi, M. R. (2011). A cellular learning automata-based algorithm for solving the vertex coloring problem. Expert Systems with Applications, 38(8), 9237-9247.

– the United Nations. (2020). <https://www.un.org/development/desa/en/>

– Wang, P., Fu, Y., Zhang, J., Li, X., & Lin, D. (2018). Learning urban community structures: A collective embedding perspective with periodic spatial-temporal mobility graphs. ACM Transactions on Intelligent Systems and Technology (TIST), 9(6), 63.

– Yasinian, H., & Esmaeilpour, M. (2021). Distributed learning automata based approach to inferring urban structure via traffic flow. Applied Intelligence, 1-13.

– Zhao, X. (2017). Modeling transportation networks and urban traffic dynamics: A Markovian framework [Johns Hopkins University].

حمید یاسینیان، سعید یاسینیان، امیر عبدی مقدم

حمید یاسینیان، درجه کارشناسی و کارشناسی ارشد و دکتری در رشته مهندسی کامپیوتر را به ترتیب در سال‌های ۱۳۸۱ و ۱۳۸۴ و ۱۴۰۱ از دانشگاه‌های اصفهان، آزاد اراک و آزاد تهران مرکز اخذ نمود. زمینه‌های پژوهشی مورد علاقه ایشان بینایی ماشین و ترافیک هوشمند شهری بوده و در حال حاضر عضو هیأت علمی با مرتبه استادیار در دانشگاه آزاد اسلامی واحد همدان می‌باشد.



سعید یاسینیان، کارشناسی ارشد در رشته مهندسی معماری در سال ۱۳۷۸ از دانشگاه آزاد همدان اخذ نمود. زمینه‌های پژوهشی مورد علاقه ایشان و معماری هوشمند شهری بوده و در حال حاضر عضو هیأت علمی با مرتبه مربی در دانشگاه آزاد اسلامی واحد همدان و همچنین پژوهشگر برتر گروه معماری در سال ۱۳۹۰ و عضو هیأت رییسه نظام مهندسی همدان می‌باشد.



امیر عبدی مقدم، کارشناسی و کارشناسی ارشد خود را به ترتیب در رشته مهندسی صنایع- تولید صنعتی و مهندسی صنایع- کیفیت و بهره‌وری از دانشگاه آزاد اسلامی واحد قزوین و واحد ملایر در سال‌های ۱۳۹۲ و ۱۳۹۸ اخذ نمود. زمینه‌های پژوهشی مورد علاقه ایشان الگوریتم‌های فراابتکاری برای حل مسائل مسیریابی و حمل نقل و همچنین بهینه‌سازی زنجیره تامین است.

