

بهینه‌سازی هوشمند لجستیک شهری با رویکرد یادگیری تقویتی عمیق و تحلیل کلان‌داده

مقاله علمی-پژوهشی

محمدامین ابراهیم‌زاده، گروه عمران برنامه ریزی حمل و نقل، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران

*علی عبدی کردانی (نویسنده مسئول)، استاد، گروه عمران برنامه ریزی حمل و نقل، دانشکده فنی و مهندسی،

دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران

محمد حسین تاتلاری، گروه مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد کرج، ایران

*پست الکترونیکی نویسنده مسئول: aliabdi@eng.ikiu.ac.ir

دریافت: ۱۴۰۴/۰۷/۲۰ - پذیرش: ۱۴۰۴/۱۱/۰۹

صفحه ۳۴۵-۳۵۶

چکیده

افزایش پیچیدگی شبکه‌های حمل‌ونقل شهری، رشد سریع تجارت الکترونیک و نیاز روزافزون به تحویل‌های سریع، ارزان و پایدار، ضرورت به‌کارگیری رویکردهای هوشمند در لجستیک شهری را دوچندان کرده است. این پژوهش یک مدل نوآورانه مبتنی بر یادگیری تقویتی عمیق DQN ارائه می‌دهد که با ادغام کلان‌داده و اطلاعات زمان‌واقعی، مسیرهای تحویل را در محیط‌های پویا به‌صورت تطبیقی بهینه‌سازی می‌کند. مدل پیشنهادی در یک محیط شهری شبیه‌سازی شده شامل ۱۲ منطقه، ۱۲۰ مشتری، ۴ انبار و ۱۰ وسیله نقلیه ارزیابی شده است. نتایج تجربی نشان می‌دهد که الگوریتم DQN نسبت به روش‌های سنتی به‌طور قابل‌ملاحظه‌ای بهتر عمل می‌کند؛ به‌طوری که زمان تحویل تا ۳۵٪، مصرف سوخت تا ۳۳٪ و انتشار CO₂ تا ۵۵٪ کاهش یافته و هم‌زمان، نرخ تحویل به‌موقع به ۹۲٪ و رضایت مشتری تا ۴۰٪ افزایش یافته است. تحلیل حساسیت نیز نشان می‌دهد که مدل در مواجهه با ترافیک سنگین، افزایش تقاضا و داده‌های ناقص، عملکردی پایدار و قابل اتکا دارد. این پژوهش با ادغام هوش مصنوعی، کلان‌داده و تحلیل سناریوهای آینده‌نگر مبتنی بر GPT، چارچوبی مقیاس‌پذیر برای توسعه لجستیک شهری هوشمند ارائه می‌دهد و می‌تواند به‌عنوان مبنایی برای طراحی سیاست‌های داده‌محور در کلان‌شهرهای در حال توسعه مورد استفاده قرار گیرد.

واژه‌های کلیدی: لجستیک شهری، یادگیری تقویتی عمیق، DQN، کلان‌داده، پایداری حمل‌ونقل

۱-مقدمه

می‌دهد که با بهره‌گیری از داده‌های زمان‌واقعی، مسیرهای حمل‌ونقل شهری را به‌صورت پویا و تطبیقی بهینه کرده، اثرات محیط زیستی را کاهش می‌دهد و تاب‌آوری زنجیره تأمین شهری را ارتقا می‌بخشد. با پیچیده‌تر شدن محیط‌های شهری و رشد سریع تجارت الکترونیک، تقاضا برای تحویل‌های سریع، ارزان و پایدار افزایش یافته و فشار قابل توجهی بر سیستم‌های لجستیک شهری وارد کرده است. روش‌های سنتی مدیریت زنجیره تأمین دیگر پاسخگوی این نیازهای نوظهور نیستند و همین امر ضرورت بهره‌گیری از فناوری‌های تحول‌آفرین را برجسته

باجود پیشرفت‌های چشمگیر در دیجیتالی‌سازی لجستیک شهری، بسیاری از مدل‌های موجود همچنان ماهیتی ایستا داشته و در مواجهه با شرایط پویا، نوسانات تقاضا و داده‌های ناقص عملکرد مطلوبی ارائه نمی‌دهند. روش‌های سنتی بهینه‌سازی همچون الگوریتم ژنتیک و بهینه‌سازی ازدحام ذرات، به دلیل فقدان سازوکارهای یادگیری و انطباق بلادرنگ با تغییرات محیطی، توانایی لازم برای بهینه‌سازی تصمیمات عملیاتی در محیط‌های پیچیده شهری را ندارند. در پاسخ به این چالش، پژوهش حاضر یک مدل مبتنی بر یادگیری تقویتی عمیق ارائه

اثری بر زمان تحویل، هزینه‌های عملیاتی و کاهش انتشار آلاینده‌ها دارد؟

- ادغام تحلیل کلان‌داده با الگوریتم‌های هوش مصنوعی چگونه می‌تواند تصمیم‌گیری تطبیقی، تاب‌آوری و پایداری زنجیره تأمین شهری را تقویت کند؟

۲- پیشینه تحقیق

این پارادایم نوظهور، چارچوبی نوین برای برنامه‌ریزی لجستیکی آینده‌نگر و تصمیم‌گیری هوشمند در زنجیره‌های تأمین شهری فراهم می‌آورد. سازمان‌ها در سال‌های اخیر با افزایش چشمگیر حجم داده‌های تولیدشده از منابع متنوع مواجه شده‌اند؛ در نتیجه، بهره‌گیری نظام‌مند از این داده‌ها برای بهبود تصمیم‌گیری در زنجیره تأمین اهمیتی دوچندان یافته است (Gupta et al., 2019). تحلیل کلان‌داده این ظرفیت را فراهم می‌کند که فرآیندهای مرتبط با تأمین، تولید، انبارداری، لجستیک و مدیریت تقاضا به صورت معناداری بهبود یابند و سازمان‌ها به مزیت رقابتی قابل توجه دست پیدا کنند (Govindan et al., 2018). بهره‌برداری مؤثر از کلان‌داده موجب تحول اساسی در طراحی و مدیریت زنجیره‌های تأمین شده است؛ به گونه‌ای که منجر به افزایش کارایی، کاهش خطاهای عملیاتی، بهبود تجربه مشتریان و ارتقای شفافیت در کلیه سطوح فرآیندهای زنجیره تأمین شده است (Zhan & Tan, 2020). با وجود مزایای گسترده کلان‌داده، بسیاری از شرکت‌ها همچنان به دلیل پیچیدگی‌های فنی، محدودیت‌های زیرساختی و چالش‌های امنیتی در بهره‌برداری مؤثر از آن با مشکل مواجه هستند. از این رو، بهینه‌سازی داده‌ها در کنار حاکمیت داده کارآمد، دو رکن بنیادی برای پیاده‌سازی موفق و پایدار تحلیل کلان‌داده در زنجیره‌های تأمین به‌شمار می‌آیند (Grover & Kar, 2017).

مطالعات متعددی که از تکنیک‌های یادگیری ماشینی، تحلیل سری‌های زمانی و فناوری RFID بهره گرفته‌اند، نشان می‌دهند که استفاده مؤثر از کلان‌داده می‌تواند دقت پیش‌بینی تقاضا را به‌طور قابل توجهی افزایش داده و عملکرد عملیات لجستیکی را بهبود بخشد (Papanagnou & Matthews, 2018). Lee (2018) با وجود مزایای گسترده، بهره‌گیری از کلان‌داده در لجستیک شهری با موانع عملیاتی متعددی همراه است و برای رفع این چالش‌ها، توسعه

می‌سازد. مطالعات اخیر نشان داده‌اند که ادغام هوش مصنوعی، اینترنت اشیا و خودروهایی خودران می‌تواند عملکرد لجستیک شهری را به‌طور چشمگیری بهبود دهد؛ به گونه‌ای که با تحلیل کلان‌داده و الگوریتم‌های یادگیری ماشینی، مسیرهای توزیع هوشمندانه‌تر انتخاب شده و مصرف سوخت، زمان سفر و میزان آلاینده‌ها کاهش می‌یابد. این فناوری‌ها علاوه بر ارتقای کارایی عملیاتی، در راستای دستیابی به اهداف پایداری شهری و سیاست‌های بین‌المللی مانند توافق پاریس نیز عمل می‌کنند (Mohsen, 2024). به‌طور خاص، استفاده از تحلیل کلان‌داده در زنجیره‌های تأمین به سازمان‌ها کمک می‌کند الگوهای تقاضا را دقیق‌تر پیش‌بینی کرده و تصمیمات مبتنی بر داده اتخاذ کنند. مطالعات نشان می‌دهد کلان‌داده و یادگیری ماشینی می‌تواند انتشار گازهای گلخانه‌ای را کاهش داده و بهره‌وری سیستم‌های حمل‌ونقلی را تقویت کند (Ojadi et al., 2024). همچنین شواهدی از صنایع لجستیک در ایالات متحده حاکی از آن است که مدل‌های مبتنی بر هوش مصنوعی نه تنها موجب کاهش مصرف سوخت و افزایش بهره‌وری می‌شوند، بلکه مزیت رقابتی قابل توجهی در مواجهه با مقررات سخت‌گیرانه محیط‌زیستی ایجاد می‌کنند (Shawon et al., 2025). با وجود ظرفیت‌های قابل توجه فناوری‌های نوین، همچنان چارچوب جامعی که بتواند نقش کلان‌داده، هوش مصنوعی و تصمیم‌گیری تطبیقی را در تمامی مراحل زنجیره تأمین شهری ادغام کند، در ادبیات علمی محدود است. از سوی دیگر، چالش‌هایی نظیر ترافیک سنگین، محدودیت‌های زیرساختی، عدم قطعیت‌های محیطی و نیاز به واکنش سریع در محیط‌های واقعی، ضرورت توسعه مدل‌هایی هوشمند و چندمعیاره را دوچندان می‌کند. بر همین اساس، پژوهش حاضر با هدف طراحی یک مدل جامع و مبتنی بر یادگیری تقویتی انجام شده است تا تصمیم‌گیری در شرایط عدم قطعیت، نوسانات تقاضا و محدودیت‌های زمانی با دقت و کارایی بیشتری تحقق یابد. چارچوب پیشنهادی ضمن افزایش بهره‌وری عملیاتی، بستر لازم برای مدیریت داده‌محور و تطبیقی لجستیک شهری را فراهم می‌کند. این پژوهش با تمرکز بر این شکاف، به دنبال پاسخ‌گویی به دو سؤال اصلی است:

- مدل پیشنهادی مبتنی بر یادگیری تقویتی چگونه می‌تواند مسیرهای تحویل را در لجستیک شهری واقعی بهینه کند و چه

چالش‌هایی همچون ترافیک سنگین، محدودیت‌های زیرساختی و فشارهای محیط‌زیستی، دستیابی به زنجیره‌های تأمین پایدار در محیط‌های شهری را دشوار می‌سازند. مطالعات اخیر نیز بر نقش راهکارهای مبتنی بر هوش مصنوعی و پردازش داده‌های زمان‌واقعی در غلبه بر این چالش‌ها و ارتقای عملکرد و پایداری لجستیک شهری تأکید دارند (Attah et al, 2024)(Mohsen, 2024). در سال‌های اخیر، هوش مصنوعی به‌عنوان یکی از ابزارهای کلیدی تحول دیجیتال، نقش حیاتی در ارتقای لجستیک شهری پایدار ایفا کرده است. برخلاف رویکردهای سنتی، مدل‌های مبتنی بر هوش مصنوعی از انعطاف‌پذیری بالاتری برخوردارند و قادرند داده‌های زمان‌واقعی را پردازش کرده و مسیرهای تحویل بهینه را با هدف کاهش زمان، هزینه و میزان انتشار آلاینده‌ها شناسایی کنند (Nazari et al, 2018). علاوه بر یادگیری تقویتی، دامنه وسیعی از الگوریتم‌های هوش مصنوعی در سال‌های اخیر برای ارتقای عملکرد لجستیک شهری به‌کار گرفته شده‌اند. در حوزه یادگیری نظارت‌شده، مدل‌هایی نظیر شبکه‌های عصبی بازگشتی و معماری‌های مبتنی بر تبدیل‌گرها در پیش‌بینی تقاضای لحظه‌ای و الگوهای ترافیکی دقت بسیار بالایی ارائه کرده‌اند.

در مقابل، الگوریتم‌های یادگیری بدون نظارت مانند خوشه‌بندی K-Means و DBSCAN برای بخش‌بندی مشتریان، شناسایی الگوهای سفارش‌دهی و تعیین نواحی بهینه تحویل به‌کار رفته‌اند. افزون بر این، رویکردهای متهابوریستیک نظیر الگوریتم ژنتیک، جستجوی هارمونی و بهینه‌سازی ازدحام ذرات در حل مسائل مسیریابی پویا با محدودیت‌های چندگانه، از جمله ظرفیت، پنجره زمانی و ترافیک، کارایی مناسبی نشان داده‌اند؛ هرچند توانایی آن‌ها در سازگاری بلندمدت با شرایط بسیار پویا نسبت به الگوریتم‌های مبتنی بر یادگیری تقویتی محدودتر است. در حوزه یادگیری عمیق، مدل‌هایی همچون شبکه‌های کانولوشنی برای تحلیل تصاویر ماهواره‌ای ترافیک و شبکه‌های عصبی گراف برای مدل‌سازی روابط پیچیده بین گره‌های شبکه حمل‌ونقل شهری به‌طور فزاینده‌ای مورد توجه قرار گرفته‌اند. این توسعه گسترده الگوریتمی، نشانه‌ای از گذار لجستیک شهری از سیستم‌های ایستا و مبتنی بر قواعد ثابت به سوی پلتفرم‌های هوشمند، پویا و چندالگوریتمی است که قادرند محیط‌های شهری پیچیده را به‌طور بلادرنگ تحلیل و مدیریت کنند. تحقیقات اخیر همچنین نشان می‌دهند که طراحی مدل‌های

چارچوب‌های یکپارچه مبتنی بر هوش مصنوعی ضروری به‌نظر می‌رسد. با وجود پیشرفت‌های اخیر، همچنان فقدان چارچوب‌های جامع و منسجمی که بتوانند نقش کلان‌داده و هوش مصنوعی را در تمامی مراحل زنجیره تأمین به‌طور شفاف و نظام‌مند تبیین کنند، یکی از شکاف‌های برجسته ادبیات محسوب می‌شود (Gupta et al, 2017)(Maestrini et al, 2019). علاوه بر این، سیستم‌های لجستیک شهری با چالش‌هایی نظیر ترافیک سنگین، محدودیت‌های مسیر و ضرورت واکنش بلادرنگ در شرایط پویا مواجه‌اند که پیچیدگی مدیریت و تصمیم‌گیری را به‌طور چشمگیری افزایش می‌دهد (Allen et al, 2017). فناوری‌های هوش مصنوعی و مدل‌های زبانی بزرگ فرصت‌های نوینی برای ارتقای شفافیت و تفسیرپذیری نتایج بهینه‌سازی فراهم کرده‌اند؛ به‌گونه‌ای که حتی تصمیم‌گیرندگان غیرتخصصی نیز می‌توانند راه‌حل‌های پیچیده مرتبط با شبکه زنجیره تأمین را با سهولت بیشتری درک کرده و در فرآیندهای تصمیم‌گیری به‌کار گیرند (Barbosa et al, 2018)(Roy et al, 2018). مطالعات اخیر نشان می‌دهند که هوش مصنوعی با توانایی شناسایی و پیش‌بینی ریسک‌ها، افزایش دیدپذیری و مدیریت مؤثر اختلالات، می‌تواند به‌طور قابل‌توجهی تاب‌آوری زنجیره تأمین را تقویت کند. این قابلیت سبب می‌شود سازمان‌ها در مواجهه با بحران‌هایی همچون همه‌گیری‌ها یا بلایای طبیعی، عملکردی پایدار و کارآمد داشته باشند (Attah et al, 2024). هم‌زمان با پیچیده‌تر شدن محیط‌های شهری و افزایش تقاضا برای خدمات تحویل سریع، سیستم‌های لجستیک سنتی که مبتنی بر تجمیع سفارش‌ها، حمل‌ونقل عمده و مسیرهای ثابت هستند. کارایی خود را به‌تدریج از دست داده‌اند. یافته‌های پژوهشی نشان می‌دهند که رشد تجارت الکترونیک و افزایش انتظارات مصرف‌کنندگان برای تحویل سریع، لجستیک شهری را به‌سوی سیستم‌های توزیع انعطاف‌پذیر، داده‌محور و حساس به زمان سوق داده است (Thuraka, 2021). فناوری‌هایی نظیر اینترنت اشیا، کلان‌داده و هوش مصنوعی از محرک‌های اصلی تحول در سیستم‌های لجستیک شهری به‌شمار می‌آیند. در این راستا، مفهوم «زنجیره تأمین پایدار» به یکی از محورهای کلیدی توجه سیاست‌گذاران و پژوهشگران تبدیل شده است؛ مفهومی که سه بعد اقتصادی، محیط‌زیستی و اجتماعی را در بر می‌گیرد و هدف آن ایجاد تعادلی پایدار میان این ابعاد است. با وجود این،

متغیر واسطه‌ای حیاتی را برعهده داشته و زمینه لازم برای تحلیل، پیش‌بینی و بهینه‌سازی تصمیمات لجستیک را فراهم می‌کند. چنین یکپارچگی نه تنها باعث افزایش دقت مدل‌های تصمیم‌یار می‌شود، بلکه پایه‌ای محکم برای ارزیابی آثار هوش مصنوعی بر کارایی، تاب‌آوری و پایداری لجستیک شهری فراهم می‌آورد.

۳- روش‌شناسی تحقیق

روش‌شناسی این پژوهش با الهام از چارچوب پیشنهادی رفرنس طراحی شده است که بر ادغام هوش مصنوعی، تحلیل داده‌های زمان‌واقعی و زیرساخت‌های اینترنت اشیا برای تصمیم‌گیری هوشمند تأکید دارد. در مرحله نخست، داده‌های مرتبط با شبکه حمل‌ونقل شهری، داده‌های ترافیک لحظه‌ای، سرعت جریان، موقعیت جغرافیایی ناوگان، الگوهای تقاضای پویا و اطلاعات محیطی، از طریق حسگرهای IoT، اپلیکیشن‌های موبایلی و سامانه‌های ردیابی جمع‌آوری می‌شود. این داده‌ها پس از انتقال به بستر ابری، تحت فرآیندهای پاک‌سازی، پالایش، نرمال‌سازی و استخراج ویژگی قرار می‌گیرند تا ورودی مناسب برای مدل یادگیری تقویتی فراهم شود. در گام بعد، محیط تصمیم‌گیری براساس ساختار لجستیک شهری مدل‌سازی می‌شود و مؤلفه‌های اصلی یادگیری تقویتی شامل حالات، اقدامات و تابع پاداش تعریف می‌گردند. حالت‌ها بیانگر وضعیت لحظه‌ای شبکه (موقعیت وسیله، ظرفیت باقی‌مانده، وضعیت ترافیک، زمان تحویل و تقاضاهای فعال) هستند و اقدامات شامل انتخاب مشتری بعدی، مسیر مناسب یا بازگشت به انبار می‌باشند. تابع پاداش براساس سه معیار کلیدی، زمان، هزینه و آلودگی، به‌گونه‌ای طراحی شده است که رفتار عامل در جهت پایداری و کارایی هدایت شود. در مرحله سوم، الگوریتم شبکه Q عمیق برای تقریب تابع ارزش و استخراج سیاست بهینه مورد استفاده قرار می‌گیرد. شبکه عصبی DQN با بهره‌گیری از تجربه‌نگار و یادگیری دسته‌ای، تعاملات عامل با محیط را ذخیره کرده و به‌صورت تدریجی سیاست‌های بهینه مسیریابی را یاد می‌گیرد. به‌منظور افزایش پایداری، از شبکه هدف و سیاست ϵ -greedy برای تعادل اکتشاف-بهره‌برداری استفاده می‌شود. در نهایت، کارایی مدل با استفاده از شاخص‌های عملکردی شامل زمان کل تحویل، طول مسیر طی‌شده، مصرف سوخت یا انرژی، میزان CO₂ انحراف از برنامه زمانی و کارایی ناوگان ارزیابی می‌شود.

مفهومی در حوزه لجستیک هوشمند شهری نیازمند شناسایی و طبقه‌بندی دقیق متغیرهای اثرگذار بر عملکرد سیستم‌های حمل‌ونقل است. این متغیرها را می‌توان در سه دسته اصلی طبقه‌بندی کرد: متغیرهای عملیاتی شامل زمان تحویل، مسیر بهینه، هزینه‌های حمل‌ونقل، تعداد توقف‌ها و بهره‌وری ناوگان که مستقیماً کیفیت و کارایی خدمات را تعیین می‌کنند (Nazari et al, 2018) (Crainic & Bektas, 2007). متغیرهای فناوری شامل نوع الگوریتم‌های هوش مصنوعی مورد استفاده، ماهیت داده‌های ورودی (ترافیکی، محیط‌زیستی یا مبتنی بر تقاضا) و سطح اتوماسیون سیستم‌های تصمیم‌یار (Zaman et al, 2025) (Yuan et al, 20223). متغیرهای پایداری شامل انتشار CO₂، مصرف سوخت، آلودگی صوتی، ایمنی، اثرات اجتماعی عملیات لجستیک و میزان رضایت یا ناراضایتی ساکنان شهری از فعالیت‌های حمل‌ونقل (Roy et al, 2018) (Macrina et al, 2020). علاوه بر این، مطالعات اخیر بر نقش فزاینده مدل‌های زبانی بزرگ در برنامه‌ریزی شبکه زنجیره تأمین و پشتیبانی از تصمیم‌گیری‌های پیچیده تأکید دارند. این مدل‌ها با قابلیت پردازش پیشرفته زبان طبیعی و تحلیل داده‌های چندمنبعی، امکان بهینه‌سازی مسیرها را با در نظر گرفتن هم‌زمان معیارهای زمان، هزینه و میزان آلودگی فراهم می‌کنند و بدین ترتیب می‌توانند کارایی و پایداری سیستم‌های لجستیک شهری را به‌طور معناداری ارتقا دهند (Zheng et al, 2025). با وجود پیشرفت‌های چشمگیر در حوزه کلان‌داده، هوش مصنوعی و بهینه‌سازی لجستیک شهری، مرور ادبیات نشان می‌دهد که چالش‌های اساسی همچنان پابرجاست. از جمله، فقدان چارچوب‌های یکپارچه برای ارزیابی چندمعیاره، محدودیت داده‌های استاندارد و کامل، و تعامل محدود انسان، ماشین در سیستم‌های هوشمند، از مهم‌ترین کاستی‌های موجود به‌شمار می‌آیند. این چالش‌ها بیانگر آن است که بسیاری از یافته‌های موجود قابلیت تعمیم کافی به محیط‌های واقعی شهری را ندارند و بخش قابل‌توجهی از مطالعات، مبتنی بر داده‌های شبیه‌سازی شده یا محیط‌های ساده‌سازی شده هستند. با این حال، تحلیل جامع مطالعات پیشین نشان می‌دهد که ادغام سه مؤلفه بنیادین (۱) زیرساخت‌های داده‌محور و فناوری‌محور، (۲) عملیات حمل‌ونقل و مسیریابی شهری، و (۳) شاخص‌های چندبعدی پایداری می‌تواند به شکل‌گیری یک چارچوب مفهومی کارآمد منجر شود؛ چارچوبی که در آن هوش مصنوعی نقش یک

نتایج در یک محیط شبیه‌سازی شده شهری اعتبارسنجی شده و با روش‌های کلاسیک مقایسه می‌گردند.

۳-۱- جمع‌آوری و آماده‌سازی داده‌ها

در مرحله نخست، داده‌های موردنیاز برای توسعه مدل از ترکیبی از داده‌های واقعی و شبیه‌سازی شده گردآوری شده‌اند. داده‌های واقعی شامل اطلاعات زمان سفر، سرعت جریان ترافیک، مسافت طی شده، میزان انتشار آلاینده‌ها، مصرف انرژی و شاخص‌های مرتبط با رضایت مشتری بوده که از منابع ثانویه معتبر، سامانه‌های حمل‌ونقل شهری، پایگاه‌های داده باز و مطالعات پیشین استخراج شده‌اند. برای تکمیل مجموعه داده‌ها و پوشش شرایطی که داده‌های واقعی ناکافی هستند، مانند تقاضاهای غیرایستا، شرایط ترافیکی غیرمعمول یا سطوح بالای عدم قطعیت، از داده‌های شبیه‌سازی شده مبتنی بر مدل‌سازی جریان ترافیک و الگوهای رفتاری سفر نیز استفاده شده است. پس از جمع‌آوری، داده‌ها طی فرآیندی شامل پاک‌سازی، حذف داده‌های پرت، نرمال‌سازی، استانداردسازی و استخراج ویژگی آماده‌سازی شده و برای استفاده در محیط یادگیری تقویتی و مدل DQN ساختاردهی می‌شوند. در این مرحله، متغیرهای کلیدی مانند فاصله، زمان سفر، نرخ انتشار CO_2 ، وضعیت ناوگان، نرخ تحویل به‌موقع و الگوهای تقاضای لحظه‌ای استخراج می‌شوند تا کیفیت یادگیری مدل افزایش یابد. استفاده از داده‌های چندمنبعی و ناهمگن باعث می‌شود که مدل توانایی سازگاری با شرایط واقعی و پویا را داشته باشد و محدودیتی از جهت داده‌های ناقص یا نامنظم نداشته باشد (Zaman, 2025).

۴- مطالعه موردی

برای ارزیابی عملکرد مدل یادگیری تقویتی عمیق توسعه‌یافته، یک مطالعه موردی در یک محیط شهری شبیه‌سازی شده طراحی و اجرا شد. این محیط به‌گونه‌ای تنظیم شده است که ویژگی‌ها و پیچیدگی‌های یک شبکه واقعی لجستیک شهری را بازنمایی کند. اجزای اصلی محیط شامل موارد زیر است:

- ۱۲- منطقه شهری مجزا با سطح‌های متفاوتی از تراکم و الگوی تقاضا
- ۱۲۰- مشتری که موقعیت آن‌ها به‌صورت تصادفی در شبکه شهری پراکنده شده است.

۴- انبار مرکزی که نقش مراکز توزیع اولیه را ایفا می‌کند. در این سناریو، وسایل نقلیه تحویل تحت مجموعه‌ای از محدودیت‌های واقعی فعالیت می‌کنند؛ از جمله ظرفیت بار، پنجره زمانی تحویل، شرایط ترافیک، مصرف انرژی و انتشار آلاینده‌ها، این محدودیت‌ها شرایطی نزدیک به عملیات واقعی حمل‌ونقل شهری ایجاد می‌کنند و پایداری و کارایی مدل را به‌طور جامع ارزیابی می‌نمایند. در این مطالعه، سه شاخص کلیدی عملکرد برای سنجش کارایی مدل مورد بررسی قرار گرفته است.

- هزینه‌های عملیاتی

این معیار شامل مجموع هزینه‌های مرتبط با عملیات تحویل است؛ مانند هزینه مصرف سوخت، دستمزد راننده بر اساس ساعات کاری، هزینه‌های نگهداری وابسته به مسافت طی شده، و جریمه‌های ناشی از تأخیر در تحویل. این شاخص بازتاب مستقیمی از بهره‌وری اقتصادی سیستم دارد.

- نرخ استفاده از ناوگان

این معیار نسبت زمانی را نشان می‌دهد که وسایل نقلیه در طول فرآیند شبیه‌سازی به‌طور فعال مشغول انجام مأموریت‌های تحویل بوده‌اند. نرخ بالای استفاده از ناوگان بیانگر تخصیص بهینه منابع و کاهش زمان‌های بیکاری در سیستم لجستیک است.

- نرخ تحویل به‌موقع

این شاخص درصد سفارش‌هایی را نشان می‌دهد که در بازه زمانی تعیین شده تحویل شده‌اند و به‌طور مستقیم با کیفیت خدمات و سطح رضایت مشتری ارتباط دارد. این معیار از مهم‌ترین عوامل سنجش کارایی عملیات لجستیک شهری محسوب می‌شود. مدل پیشنهادی در این محیط شبیه‌سازی شده مورد آزمون قرار گرفت تا توانایی آن در مدیریت شرایط پویا، تصمیم‌گیری بلادرنگ و بهینه‌سازی چندمعیاره ارزیابی شود.

۵- مدل‌سازی

در این بخش، ساختار مدل‌سازی پژوهش تشریح می‌شود که بر پایه الگوریتم شبکه Q عمیق طراحی شده است. هدف اصلی مدل، یادگیری یک سیاست تصمیم‌گیری تطبیقی برای انتخاب مسیرهای بهینه در محیط پویا و نامطمئن لجستیک شهری است. داده‌های مورد استفاده در این مرحله، ترکیبی از داده‌های واقعی

– پاداش اضافی برای انتخاب مسیرهای کارآمد در شرایط ترافیک سنگین یا بار کاری بالا

یادگیری و بهروزرسانی

عامل با استفاده از تجربه‌نگار، سیاست ϵ -greedy و شبکه هدف، سیاست بهینه را به صورت تدریجی و پایدار یاد می‌گیرد. این ساختار مانع بیش‌برازش شده و همگرایی مدل را تضمین می‌کند.

پارامترهای الگوریتم DQN

پارامترهای کلیدی الگوریتم DQN با توجه به مطالعات پیشین و نتایج حاصل از آزمایش‌های اولیه انتخاب شده‌اند تا تعادل مناسبی میان اکتشاف، بهره‌برداری و پایداری فرآیند یادگیری برقرار شود. جدول شماره ۱ مقادیر نهایی تنظیم‌شده برای این پارامترها را نشان می‌دهد.

انتخاب این پارامترها نقش مهمی در پایداری و همگرایی الگوریتم دارد. نرخ یادگیری پایین (۰,۰۰۱) مانع نوسان در بهروزرسانی وزن‌ها شده و فاکتور تخفیف بالا (۰,۹۹) تضمین می‌کند که عامل تأثیر تصمیمات بلندمدت را نیز در سیاست خود لحاظ کند. علاوه بر این، استفاده از Epsilon Decay تدریجی باعث می‌شود عامل در مراحل اولیه محیط را به خوبی کاوش کرده و پس از مدتی بر تصمیمات بهینه تمرکز کند. ساختار سه‌لایه با ۲۵۶ نورون در هر لایه نیز ظرفیت مناسبی برای مدل‌سازی الگوهای پیچیده شبکه حمل‌ونقل شهری فراهم می‌کند. استفاده از ReLU و Adam نیز باعث سرعت و پایداری بیشتر در همگرایی مدل می‌شود.

جلوگیری از بیش‌برازش و افزایش پایداری مدل

به‌منظور بهبود پایداری مدل و پیشگیری از بیش‌برازش، دو سازوکار کلیدی در طراحی الگوریتم DQN به کار گرفته شده است. نخست، سازوکار بازپخش تجربه که با ذخیره‌سازی تعاملات گذشته و نمونه‌گیری تصادفی از آنها، وابستگی زمانی داده‌ها را کاهش داده و فرآیند یادگیری را پایدارتر می‌سازد. دوم، شبکه هدف که با اعمال بهروزرسانی با تأخیر، از نوسانات شدید در مقدار تابع Q جلوگیری کرده و همگرایی مدل را تضمین می‌کند. افزون بر این، داده‌های زمان‌واقعی استخراج‌شده از حسگرهای شهری، سامانه‌های IoT و پایگاه‌های داده آنلاین نیز در مدل ادغام شده‌اند تا تصمیم‌گیری تطبیقی و سازگار با محیط‌های پویا به‌طور مؤثرتری انجام گیرد. جهت ارزیابی مدل

و شبیه‌سازی‌شده شامل زمان سفر، مسافت، نرخ انتشار آلاینده‌ها، مصرف انرژی و شاخص‌های رضایت مشتری بوده که از پایگاه‌های معتبر و منابع بازگردآوری شده‌اند.

اجزای اصلی مدل یادگیری تقویتی

مدل پیشنهادی از شش مؤلفه اساسی تشکیل شده است.

– محیط

یک محیط شهری شبیه‌سازی‌شده که شامل اطلاعات لحظه‌ای ترافیک، موقعیت مشتریان، سفارش‌های فعال، محدودیت‌های زمانی و شرایط محیطی مانند ازدحام ترافیک، فاصله‌ها و سرعت متوسط جریان است.

– عامل

یک سیستم تصمیم‌یار هوشمند که در هر گام زمانی، اقدام مناسب را انتخاب کرده و سیاست بهینه را از طریق تجربه و یادگیری مداوم استخراج می‌کند.

– اقدامات

مجموعه اقدامات شامل انتخاب مقصد بعدی از میان مشتریان باقیمانده یا تصمیم بازگشت به انبار در شرایط پایان ظرفیت است.

– وضعیت

وضعیت عامل شامل مجموعه‌ای از اطلاعات حیاتی زیر است:

– موقعیت فعلی وسیله نقلیه

– وضعیت سفارش‌های فعال

– تراکم ترافیک لحظه‌ای

– حجم کاری (تعداد سفارش‌های باز)

– ظرفیت باقی‌مانده

– زمان باقیمانده برای تحویل

– نرخ استفاده از ناوگان

– درصد داده‌های ناقص در محیط

این ویژگی‌ها برای یادگیری مؤثر و تصمیم‌گیری تطبیقی ضروری هستند.

تابع پاداش

تابع پاداش به‌گونه‌ای طراحی شده است که رفتار عامل را در راستای اهداف چندگانه زیر هدایت کند:

– کاهش زمان کل تحویل

– کاهش مصرف سوخت و هزینه‌های عملیاتی

– کاهش انتشار آلاینده‌ها

– افزایش احتمال تحویل به موقع

– بهبود رضایت مشتری

نتایج مطالعه موردی

برای سنجش عملکرد مدل پیشنهادی، خروجی‌های آن با روش‌های سنتی مسیریابی در چند شاخص کلیدی مقایسه شد. جدول ۳ نتایج این مقایسه را نشان می‌دهد.

پیشنهادی، یک محیط شهری شبیه‌سازی شده مطابق با شرایط لجستیک واقعی طراحی شد. جدول ۲ ویژگی‌های اصلی این محیط را نشان می‌دهد. این مقادیر با هدف بازنمایی ساختار یک شبکه توزیع شهری متوسط انتخاب شده‌اند تا ارزیابی مدل در شرایط قابل تعمیم و مشابه محیط‌های واقعی انجام گیرد.

جدول ۱. پارامترهای تنظیمی الگوریتم DQN

پارامتر	مقدار	توضیح
نرخ یادگیری	0.001	سرعت به‌روزرسانی وزن‌های شبکه عصبی
فاکتور تخفیف	0.99	اهمیت پاداش‌های بلندمدت نسبت به کوتاه‌مدت
اندازه بافر تجربه	100,000	تعداد تجربیات ذخیره‌شده برای یادگیری مجدد
اندازه دسته	64	تعداد نمونه‌های مورد استفاده در هر به‌روزرسانی
نرخ اکتشاف اولیه	1.0	شروع با اکتشاف کامل
نرخ اکتشاف نهایی	0.01	حداقل سطح اکتشاف
گام‌های کاهش اکتشاف	50,000	تعداد گام‌ها تا رسیدن از ۱ به ۰,۰۱
نرخ به‌روزرسانی شبکه هدف	هر ۱۰۰۰ گام	همگام‌سازی وزن‌های Target Network
تعداد لایه‌های پنهان	3	ساختار شبکه عصبی عمیق
تعداد نورون‌ها در هر لایه	256	ظرفیت مدل برای یادگیری الگوهای پیچیده
تابع فعال‌سازی	ReLU	اعمال غیرخطی‌سازی
بهینه‌ساز	Adam	الگوریتم تنظیم گرادینان

جدول ۲. ویژگی‌های محیط شبیه‌سازی

پارامتر	مقدار
تعداد مشتریان	۱۲۰
تعداد انبارها	۴
تعداد وسایل نقلیه	۱۰
ظرفیت هر وسیله نقلیه	۵۰ واحد بار

جدول ۳. مقایسه عملکرد مدل یادگیری تقویتی و روش‌های سنتی

شاخص	روش سنتی	مدل یادگیری تقویتی	بهبود نسبی
زمان تحویل (دقیقه)	۸۵	۵۵	کاهش ۳۵٪
انتشار CO ₂ (کیلوگرم)	۱۲۰۰	۵۴۰	کاهش ۵۵٪
مصرف سوخت (لیتر)	۳۰۰	۲۰۰	کاهش ۳۳٪
رضایت مشتری (از ۵)	۳,۲	۴,۵	افزایش ۴۰٪
هزینه عملیاتی	۱۰۰,۰۰۰	۶۵,۰۰۰	کاهش ۳۵٪
نرخ استفاده از ناوگان	۶۵٪	۸۵٪	افزایش ۳۱٪
تحویل به موقع	۷۰٪	۹۲٪	افزایش ۳۱٪

تحلیل حساسیت

به منظور بررسی استحکام و قابلیت تعمیم مدل، تحلیل حساسیت در سه بعد کلیدی انجام شد.

-افزایش حجم ترافیک

-افزایش حجم سفارش‌ها

-افزایش داده‌های ناقص

نتایج جدول ۴ نشان می‌دهد که مدل پیشنهادی حتی در شرایط سخت‌تر نیز پایداری عملکرد خود را حفظ می‌کند.

این نتایج نشان می‌دهند که مدل یادگیری تقویتی نه تنها زمان تحویل، مصرف سوخت و انتشار آلاینده‌ها را کاهش داده است، بلکه با بهبود رضایت مشتری، افزایش تحویل به موقع و ارتقای بهره‌وری ناوگان، عملکرد به مراتب کارآمدتری نسبت به روش‌های مرسوم داشته است. این یافته‌ها بیانگر مناسب بودن الگوریتم برای محیط‌های واقعی شهری با نوسانات بالا و محدودیت‌های متعدد هستند.

جدول ۴. تحلیل حساسیت مدل نسبت به متغیرهای محیطی

متغیر	وضعیت	عملکرد مدل یادگیری تقویتی نسبت به روش سنتی	توضیح
حجم ترافیک	افزایش یافته	مقاوم‌تر	زمان تحویل کمی افزایش یافت اما همچنان بهتر از روش سنتی بود.
حجم سفارش	افزایش یافته	مقاوم‌تر	با وجود افزایش بار کاری، نرخ تحویل به موقع حفظ شد.
داده‌های ناقص	افزایش یافته	مقاوم‌تر	مدل حتی با داده‌های ناقص، بهره‌وری ناوگان را بالا نگه داشت.

پیشنهاد سیاستی: سرمایه‌گذاری گسترده در IoT، ناوگان برقی، سامانه‌های تصمیم‌یار هوشمند و استانداردهای داده است.

سناریوی واقع بینانه

در این وضعیت، پیاده‌سازی فناوری‌ها تدریجی و محدود است اما روند نوسازی ادامه دارد:

-کاهش ۲۰٪-۲۵٪ زمان تحویل

-کاهش ۳۰٪ انتشار CO₂

-کاهش ۱۵٪ هزینه‌ها

-تحویل به موقع $\approx 85\%$

-رضایت مشتری ≈ 3.8

سیاست پیشنهادی: آموزش کارکنان برای استفاده از AI، نوسازی تدریجی ناوگان، تدوین استانداردهای تبادل داده.

سناریوی بدبینانه

در این سناریو، مقاومت سازمانی در برابر تغییر و محدودیت زیرساخت داده سبب افت عملکرد می‌شود:

-افزایش ۱۵٪ زمان تحویل

-افزایش ۲۰٪ هزینه‌ها

-کاهش تحویل به موقع به $< 70\%$

-کاهش چشمگیر رضایت مشتری

سیاست پیشنهادی: اصلاح ساختار سازمانی، توسعه زیرساخت داده، ایجاد طرح‌های پشتیبان اضطراری سناریوهای سه‌گانه نشان

نتایج تحلیل حساسیت نشان می‌دهد که مدل پیشنهادی نسبت به تغییرات محیطی واکنش انعطاف‌پذیری دارد و تحت فشارهای عملیاتی، کاهش عملکرد آن بسیار کمتر از روش‌های مرسوم است.

طراحی سناریوها بر اساس GPT

در راستای تحلیل آینده‌نگر و پشتیبانی از تصمیم‌گیری داده‌محور، سه سناریو با بهره‌گیری از چارچوب‌های تبیینی مبتنی بر GPT طراحی شد. این سناریوها شرایط متفاوتی از وضعیت زیرساخت، سیاست‌گذاری و آمادگی فناوری را در بازه میان‌مدت (۳-۵ سال) بررسی می‌کنند.

سناریوی خوش بینانه

در این سناریو، فرض بر این است که زیرساخت‌های شهری هوشمند به طور کامل توسعه یافته، سامانه‌های ارتباطی V2X عملیاتی شده و ادغام کامل داده‌های زمان‌واقعی در زنجیره تأمین امکان‌پذیر است. در این وضعیت:

-کاهش ۴۰٪ زمان تحویل

-کاهش ۵۵٪ انتشار آلاینده

-کاهش ۳۵٪ هزینه عملیاتی

-نرخ تحویل به موقع $\approx 92\%$

-نرخ استفاده از ناوگان $\approx 85\%$

-رضایت مشتری ≈ 5

می‌دهند که سرمایه‌گذاری هدفمند در زیرساخت داده، پذیرش هوش مصنوعی و ادغام فناوری‌های هوشمند، مهم‌ترین عوامل اثرگذار بر آینده لجستیک شهری هستند. نتایج مطالعه نشان می‌دهد که مدل پیشنهادی DRL قادر است حتی در شرایط نامطمئن نیز عملکردی برتر ارائه دهد و پیش‌نیازهای تحول پایدار در زنجیره تأمین شهری را فراهم کند.

ارزیابی مدل پیشنهادی با استفاده از هفت شاخص کلیدی عملکرد (زمان تحویل، مصرف سوخت، انتشار CO₂، هزینه‌های عملیاتی، نرخ استفاده از ناوگان، تحویل به موقع و رضایت مشتری) در یک محیط شهری شبیه‌سازی شده شامل ۱۲ منطقه، ۱۲۰ مشتری، ۴ انبار و ۱۰ وسیله نقلیه انجام شد. نتایج شبیه‌سازی نشان داد که مدل یادگیری تقویتی مبتنی بر DQN عملکردی به مراتب بهتر از روش‌های سنتی داشته و موفق شده است زمان تحویل را ۳۵٪، مصرف سوخت را ۳۳٪، انتشار آلاینده‌ها را ۵۵٪ و هزینه‌های عملیاتی را ۳۵٪ کاهش دهد. همچنین نرخ استفاده از ناوگان ۳۱٪ و نرخ تحویل به موقع به بیش از ۹۰٪ افزایش یافته و رضایت مشتری نیز بهبود چشمگیری داشته است. تحلیل حساسیت نشان داد که مدل در مواجهه با ترافیک سنگین، افزایش تقاضا و داده‌های ناقص نیز رفتار پایدار و قابل اعتمادی از خود نشان می‌دهد. این نتایج بیانگر آن است که مدل پیشنهادی می‌تواند به طور هم‌زمان کارایی اقتصادی، پایداری محیطی و کیفیت خدمات را در لجستیک شهری ارتقا داده و نسبت به روش‌های مرسوم انعطاف‌پذیری بیشتری ارائه دهد. نتایج این پژوهش نشان می‌دهد که مدل پیشنهادی مبتنی بر یادگیری تقویتی عمیق عملکردی به مراتب برتر از روش‌های سنتی در بهینه‌سازی مسیرهای لجستیک شهری دارد. کاهش ۳۵٪ زمان تحویل و ۵۵٪ انتشار CO₂ نه تنها کارایی عملیاتی را افزایش داده، بلکه با اهداف توسعه پایدار و سیاست‌های کاهش آلودگی شهری نیز هم‌سو است. این بهبودها به دلیل توانایی DQN در یادگیری پویا و انطباق لحظه‌ای با شرایط متغیر ترافیکی حاصل شده‌اند؛ قابلیتی که در روش‌های ایستا مانند GA و PSO وجود ندارد. مقایسه با مطالعات پیشین نیز برتری مدل را تأیید می‌کند. در حالی که روش‌های ژنتیک معمولاً حدود ۱۵٪ کاهش زمان تحویل و الگوریتم‌های هیوریستیک نزدیک به ۲۵٪ کاهش مصرف سوخت را ثبت کرده‌اند، مدل حاضر به ترتیب ۳۵٪ و ۳۳٪ بهبود ایجاد کرده است. استفاده مؤثر از داده‌های زمان‌واقعی و مدیریت عدم قطعیت‌ها از مهم‌ترین دلایل این برتری محسوب می‌شود. از منظر کاربردی، این مدل می‌تواند برای شرکت‌های توزیع و ناوگان حمل‌ونقل شهری به کاهش حدود ۳۵٪ هزینه‌های عملیاتی و افزایش ۴۰٪ رضایت مشتری منجر شود. از جنبه زیست محیطی نیز کاهش ۵۵٪ انتشار CO₂ معادل حذف حدود ۶۶۰ کیلوگرم آلاینده در هر ۱۲۰ مأموریت تحویل

۶- نتیجه‌گیری

نتایج این پژوهش نشان می‌دهد که مدل یادگیری تقویتی عمیق می‌تواند به طور معناداری عملکرد سیستم‌های لجستیک شهری را در شرایط پویا و نامطمئن بهبود دهد. مدل پیشنهادی توانست زمان تحویل را تا ۳۵٪ کاهش دهد و هم‌زمان مصرف سوخت و انتشار CO₂ را به ترتیب ۳۳٪ و ۵۵٪ کاهش دهد؛ این میزان کاهش انتشار آلاینده‌ها با اهداف توسعه پایدار شهری و سیاست‌های کاهش آلودگی هوا هم‌سو است. در بعد اقتصادی نیز هزینه‌های عملیاتی ۳۵٪ کاهش یافته و بهره‌وری ناوگان با افزایش ۳۱٪ به سطح مطلوب‌تری رسیده است. همچنین نرخ تحویل به موقع (۹۲٪) و رضایت مشتری (۴,۵ از ۵) نشان می‌دهد که مدل قادر است کیفیت خدمات و تجربه کاربران را به طور قابل توجهی ارتقا دهد. تحلیل حساسیت نیز ثابت کرد که مدل در مواجهه با شرایط پیچیده‌ای مانند ترافیک سنگین، افزایش تقاضا و داده‌های ناقص همچنان پایدار و قابل اعتماد باقی می‌ماند. این یافته‌ها بیانگر آن است که سیستم‌های هوشمند مبتنی بر RL می‌توانند نقش مهمی در مدیریت شبکه‌های توزیع شهری آینده ایفا کنند. از منظر نوآوری، این پژوهش برای نخستین‌بار ادغام کلان‌داده با الگوریتم DQN را در چارچوبی یکپارچه برای بهینه‌سازی هم‌زمان شاخص‌های زمانی، اقتصادی و محیط زیستی بررسی کرده است. همچنین استفاده از سناریوهای آینده‌نگر مبتنی بر GPT رویکردی جدید برای پیش‌بینی پیامدهای فناورانه و ارائه راهبردهای سیاستی ارائه می‌دهد. نهایتاً، مدل طراحی شده به دلیل مقیاس‌پذیری و قابلیت انطباق با ساختار شهری ایران، می‌تواند به عنوان یک الگوی هوشمند برای توسعه لجستیک پایدار در کلان‌شهرها مورد استفاده قرار گیرد.

پژوهش‌های آینده می‌توانند با توسعه مدل‌های یادگیری تقویتی چندعاملی، تعامل میان ناوگان‌های متعدد و هماهنگی هم‌زمان آن‌ها را به صورت واقع‌گرایانه‌تری مدل‌سازی کنند. استفاده از رویکرد دولوی دیجیتال و داده‌های زمان‌واقعی نیز می‌تواند امکان اعتبارسنجی دقیق‌تر و تحلیل سناریوهای پیچیده شهری را فراهم کند. همچنین پیشنهاد می‌شود الگوریتم‌های مقاوم در برابر داده‌های ناقص و نویز، مانند Robust RL یا Bayesian RL.

ریسک و تفسیرپذیری تصمیمات کمک کند. در نهایت، انجام آزمایش‌های میدانی در مقیاس واقعی شهری و تحلیل اقتصادی محیط زیستی بلندمدت می‌تواند به ارزیابی عملی و سیاست‌گذاری دقیق‌تر در حوزه لجستیک هوشمند کمک نماید.

برای کاهش وابستگی مدل به کیفیت داده‌ها به کار گرفته شوند. ترکیب مدل‌های RL با ناوگان‌های برقی و خودران و تحلیل اثرات محیط زیستی آن‌ها نیز مسیر مهمی برای گسترش کار است. علاوه بر این، ادغام مدل‌های زبانی بزرگ با سیستم‌های تصمیم‌یار لجستیکی می‌تواند به بهبود پیش‌بینی تقاضا، تحلیل

۷-مراجع

- Maestrini, V., Luzzini, D., Maccarrone, P., & Caniato, F. (2017). Supply chain performance measurement systems: A systematic review and research agenda. *International Journal of Production Economics*, 183, 299–315.
- Mohsen, B. M. (2024). AI-driven optimization of urban logistics in smart cities: Integrating autonomous vehicles and IoT for efficient delivery systems. *Sustainability*, 16(24).
- Nazari, M., Oroojlooy, A., Snyder, L. V., & Takác, M. (2018). Reinforcement learning for solving the vehicle routing problem. *Advances in Neural Information Processing Systems*, 31, 9839–9849.
- Nguyen, T. T., Pathirana, P. N., & Ding, M. (2018). Big data analytics in supply chain management: Challenges and opportunities. *Computers & Industrial Engineering*, 115, 337–349.
- Ojadi, J. O., Odionu, C. S., Onukwulu, E. C., & Owulade, O. A. (2024). Big data analytics and AI for optimizing supply chain sustainability and reducing greenhouse gas emissions in logistics and transportation. *International Journal of Multidisciplinary Research and Growth Evaluation*, 5(1), 1536–1548.
- Papanagnou, A., & Matthews-Amune, C. (2018). Applications of RFID technology in logistics and supply chain management. *International Journal of Logistics Research and Applications*, 21(4), 345–360.
- Roy, S., Sarkar, B., & Sinha, P. (2018). Multi-objective optimization for sustainable supply chain management under uncertainty. *Journal of Cleaner Production*, 183, 916–928.
- Shawon, R. E. R., Hasan, M. R., Rahman, M. A., Al Jobaer, M. A., Islam, M. R., Kawsar, M., & Akter, R. (2025). Designing and deploying AI models for sustainable logistics optimization: A case study on eco-efficient supply chains in the USA. *Journal of Ecohumanism*, 4(2), 2143–2159.
- Allen, J., Browne, M., & Cherrett, T. (2017). Logistics management and urban freight transport: Challenges and solutions. *Transport Reviews*, 37(5), 647–671.
- Attah, R. U., Garba, B. M. P., Gil-Ozoudeh, I., & Iwuanyanwu, O. (2024). Enhancing supply chain resilience through artificial intelligence: Analyzing problem-solving approaches in logistics management. *International Journal of Management & Entrepreneurship Research*, 6(12), 3883–3901.
- Barbosa, M. W., Vicente, A., de la Calle, M. B., Ladeira, M. B., & Oliveira, M. P. V. (2018). Managing supply chain resources with big data analytics: A systematic review. *International Journal of Logistics Research and Applications*, 21(3), 177–200.
- Crainic, T. G., & Bektas, T. (2007). Urban logistics planning: Models and applications. *European Journal of Operational Research*, 200(3), 561–572.
- Govindan, K., Cheng, T. C. E., Mishra, N., & Shukla, N. (2018). Big data analytics and application for logistics and supply chain management. *Transportation Research Part E: Logistics and Transportation Review*, 114, 343–349.
- Grover, P. & Kar, A. K. (2017). Big data analytics: A review on theoretical contributions and tools used in literature. *Global Journal of Flexible Systems Management*, 18(3), 203–229.
- Gupta, A., Singh, R., & Kumar, V. (2019). Big data analytics in supply chain management: A systematic review and future research agenda. *Journal of Business Research*, 101, 533–546.
- Lee, H. L. (2018). Big data and the innovation cycle. *Production and Operations Management*, 27(9), 1642–1646.
- Macrina, G., Longo, F., & Musmanno, R. (2020). Human factors in smart logistics decision making: A review. *International Journal of Logistics Management*, 31(2), 403–421.

-Zheng, G., Imahri, S., Xu, L., & Minaricova, M. (2025). LLMs in supply chain management: Opportunities and a case study. *IFAC-Papers On Line*, 59(10), 2951–2956. doi.org/10.1016/j.ifacol.2025.09.496

-Ebrahimzadeh, M. A., Saffarzadeh, M., & Norouzi, A. (2025). Evaluation and Prediction of Risk Management Impacts in the Supply Chain and Logistics with a Long-Term Approach. *Journal of Transportation Research*, 22(1), 423-436.

-Ebrahimzadeh, M. A., & Norouzi, A. (2024). Predicting the effects of risk management in logistics and supply of long-term facilities (case study of Zaytoun Logistics Park). *Road*.

-Thuraka, B. (2021). AI-driven adaptive route optimization for sustainable urban logistics and supply chain management. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, 7(3), 667–684.

-Yuan, H., Li, Y., & Wang, J. (2023). Deep learning-based real-time urban logistics optimization. *Sustainability*, 15(9), 4562.

-Zaman, J., Shoomal, A., Jahanbakht, M., & Ozay, D. (2025). Driving supply chain transformation with IoT and AI integration: A dual approach using bibliometric analysis and topic modeling. *IoT*, 6(2), 21.

-Zhan, Y., & Tan, B. (2020). The impact of big data analytics capabilities on supply chain performance: A resource-based view. *Journal of Business & Industrial Marketing*, 35(10), 1606–1618.

Intelligent Optimization of Urban Logistics Using Deep Reinforcement Learning (DQN) and Big Data Analytics

*Mohammad Amin Ebrahimzadeh, Transportation Planning Civil Engineering Group,
Faculty of Engineering, Imam Khomeini International University (IKIU), Qazvin, Iran.*

*Ali Abdi Kordani, Professor, Department of Civil Engineering (Transportation Planning),
Faculty of Engineering, Imam Khomeini International University, Qazvin, Iran*

*Mohammad Hossein Tatlari, Department of Industrial Engineering, Faculty of Engineering,
Islamic Azad University, Karaj Branch, Iran.*

E-mail: aliabdi@eng.ikiu.ac.ir

Received: September 2025- Accepted: February 2026

ABSTRACT

The increasing complexity of urban transportation networks, the rapid growth of e-commerce, and the rising demand for fast, low-cost, and sustainable deliveries have intensified the need for intelligent approaches in urban logistics. This study presents an innovative Deep Q-Network (DQN) reinforcement learning model that integrates big data analytics and real-time information to adaptively optimize delivery routes in highly dynamic environments. The proposed model is evaluated within a simulated urban setting consisting of 12 districts, 120 customers, 4 distribution centers, and 10 delivery vehicles. Experimental results demonstrate that the DQN-based approach significantly outperforms traditional optimization methods; specifically, delivery time is reduced by up to 35%, fuel consumption by 33%, and CO₂ emissions by 55%, while on-time delivery performance improves to 92% and customer satisfaction increases by 40%. Sensitivity analysis further confirms the robustness and reliability of the model under conditions of heavy traffic, increased demand, and incomplete data. By integrating artificial intelligence, big data analytics, and GPT-driven foresight scenario design, this research offers a scalable framework for advancing smart urban logistics. The findings provide a solid foundation for developing data-driven policies and decision-support systems in rapidly growing metropolitan areas.

Keywords: Urban Logistics, Deep Reinforcement Learning (DRL), Deep Q-Network (DQN), Big Data Analytics, Transport Sustainability