



شرکت پخش سایه سمن

هشتمین نمایشگاه و کنفرانس بین‌المللی صنعت پخش ایران

عنوان مقاله: توسعه یک الگوریتم فراابتکاری یادگیری‌محور جهت هوشمندسازی لجستیک توزیع (مطالعه موردی: شرکت پخش سایه سمن)

نگارنده:

مجتبی‌گودرزی
محمد رسول‌کیایی

تابستان ۱۴۰۵

چکیده

در سال‌های اخیر، ضرورت گذار از روش‌های سنتی توزیع به سمت سیستم‌های هوشمند و تاب‌آور، به یکی از چالش‌های بنیادین شبکه‌های تامین تبدیل شده است. در این مقاله، یک مدل ریاضی نوین و یک الگوریتم فراابتکاری¹ پیشرفته با هدف بهینه‌سازی عملیات لجستیک و هوشمندسازی فرآیند پخش مویرگی ارائه شده است. برخلاف مدل‌های VRP² که تنها بر کمینه‌سازی هزینه‌های مسافت تمرکز دارند، مدل پیشنهادی با رویکردی انسان‌محور، ترجیحات رانندگان ناوگان توزیع را از طریق جلوگیری از پراکندگی مشتریان در مسیرها مدل‌سازی می‌کند. برای حل این مدل در ابعاد واقعی کسب‌وکار، یک الگوریتم ALNS³ مبتنی بر یادگیری توسعه یافته است. این رویکرد از الگوریتم Q-learning به عنوان یک روش Reinforcement Learning جهت انتخاب هوشمند عملگرهای جستجو بهره می‌برد.

به منظور اعتبارسنجی عملیاتی، مدل پیشنهادی بر روی شبکه توزیع شرکت سایه سمن، به عنوان یکی از بازیگران کلیدی صنعت پخش در توزیع محصولات دارویی و غذایی در ایران، پیاده‌سازی گردیده است. نتایج حاصل از اجرای الگوریتم بر روی داده‌های واقعی شرکت سایه سمن نشان می‌دهد که الگوریتم پیشنهادی نه تنها عملکرد بهتری نسبت به روش‌های سنتی چرخ رولت⁴ و انتخاب تصادفی دارد، بلکه با کنترل بخش عظیمی از هزینه‌های نامرئی ناشی از پراکندگی مسیرها، مقدار تابع هدف را به شکل چشمگیری بهبود می‌بخشد. این دستاوردها نشان می‌دهد که ادغام تکنیک‌های یادگیری ماشین با متدهای تحقیق در عملیات، می‌تواند به طور چشمگیری بهره‌وری شبکه‌های توزیع را در شرکت‌های بزرگ پخش ارتقا دهد.

کلمات کلیدی: صنعت پخش، هوشمندسازی لجستیک، VRP، ALNS، یادگیری ماشین، شرکت سایه سمن.

¹ Meta-heuristic

² Vehicle Routing Problem

³ Adaptive Large Neighborhood Search

⁴ Roulette Wheel

1. مقدمه

در فضای رقابتی و به شدت متغیر زنجیره‌های تامین امروزی، لجستیک نقشی حیاتی و استراتژیک در توزیع کارآمد کالاها و تضمین سطح کیفیت خدمات ایفا می‌کند. مدیریت بهینه هزینه‌های مرتبط با این شبکه، یکی از مهم‌ترین چالش‌های پیش‌روی مدیران صنعت پخش است، چرا که هزینه‌های لجستیکی عمده‌تاً بر سیستم‌های توزیع متمرکز بوده و سهم قابل توجهی (بین ۲۵ تا ۴۵ درصد) از کل هزینه‌های عملیاتی را به خود اختصاص می‌دهند؛ به گونه‌ای که این هزینه‌ها می‌توانند بسته به نوع صنعت و مدل کسب‌وکار، تا ۲۰ درصد بر قیمت نهایی محصولات تأثیر مستقیم بگذارند (کیلباردا و همکاران، ۲۰۱۶). با توجه به تغییر پارادایم‌های حاکم بر بازار و بروز عدم قطعیت‌های محیطی، رویکردهای سنتی دیگر پاسخگوی نیازهای پیچیده شبکه‌های توزیع نیستند و ضرورت حرکت به سوی هوشمندسازی فرآیندها و افزایش تاب‌آوری^۵ در شرایط بحرانی، بیش از پیش احساس می‌شود.

مسئله VRP به عنوان یکی از ابزارهای قدرتمند تحقیق در عملیات، دهه‌هاست که برای کمینه‌سازی هزینه‌ها در سیستم‌های لجستیک به کار می‌رود. اگرچه مدل‌های کلاسیک VRP تمرکز خود را منحصرأً بر کاهش مسافت و بهینه‌سازی هزینه‌های سوخت و استهلاک ناوگان قرار داده‌اند، اما در پیاده‌سازی‌های دنیای واقعی، متغیرهای پنهان و بسیار مهم دیگری نیز وجود دارند که نادیده گرفتن آن‌ها می‌تواند تاب‌آوری و کارایی سیستم را مختل سازد. یکی از این متغیرهای کلیدی، توجه به رضایت منابع انسانی، به ویژه رانندگان ناوگان پخش است. شواهد میدانی نشان می‌دهد که رانندگان تمایل مبرمی دارند تا برنامه‌های کاری آن‌ها در یک منطقه جغرافیایی واحد و متمرکز تعریف شود. به عبارت دیگر، خدمت‌رسانی به مجموعه‌ای از مشتریان متراکم و خوشه‌ای^۶، همواره بر رانندگی در نواحی مختلف و پراکنده جغرافیایی ترجیح داده می‌شود. تمرکز صرفِ مدل‌های ریاضی کلاسیک بر کمینه‌سازی مسافت، لزوماً به معنای کاهش پراکندگی مسیرها نیست و در بسیاری از موارد منجر به شکل‌گیری مسیرهای متقاطع^۷ و تخصیص چندین وسیله نقلیه به یک منطقه واحد می‌گردد که این امر علاوه بر نارضایتی نیروی انسانی، باعث افزایش گره‌های ترافیکی و افت بهره‌وری سیستم می‌شود.

در راستای پاسخگویی به این چالش‌ها و همگام با تحولات جهانی صنعت پخش در حوزه‌های تحول دیجیتال و هوش مصنوعی، این مقاله یک مدل ریاضی نوین و یک چارچوب حل الگوریتمیک برای بهینه‌سازی توزیع محصولات دارویی و غذایی در شبکه‌های پیچیده دو سطحی^۸ ارائه می‌نماید. پژوهش حاضر با مطالعه عمیق بر

^۵ Resilience

^۶ Clustered Customers

^۷ Intersected Routes

^۸ Two-Echelon Supply Chains

روی شبکه توزیع مویرگی شرکت سایه سمن، به دنبال ایجاد توازن هوشمندانه میان ترجیحات مالی مدیران ارشد (کاهش هزینه‌ها) و نیازمندی‌های عملیاتی رانندگان (جلوگیری از پراکندگی) است. شرکت سایه سمن به عنوان یکی از توزیع‌کنندگان پیشرو، با توزیع کالاهای حیاتی در مقیاس وسیع، بستر بسیار مناسبی برای سنجش عیار عملیاتی الگوریتم‌های توسعه‌یافته در این پژوهش به شمار می‌رود.

نوآوری برجسته این پژوهش در بخش متدولوژی، توسعه الگوریتم ALNS مبتنی بر یادگیری ماشین است. در حالی که الگوریتم‌های سنتی معمولاً از مکانیسم‌های تصادفی یا مبتنی بر احتمالات ساده برای هدایت فرآیند جستجو استفاده می‌کنند، این پژوهش با بهره‌گیری از الگوریتم Q-learning، یک مکانیسم تطبیقی نوین برای انتخاب عملگرها⁹ معرفی کرده است. این رویکرد هوشمند، الگوریتم را قادر می‌سازد تا در طول فرآیند حل مسئله، از تجربیات گذشته خود بیاموزد و با استفاده از Dual Epsilon-Greedy Phases، تعادلی بی‌نظیر میان اکتشاف¹⁰ راه‌حل‌های جدید و بهره‌برداری¹¹ بهینه از داده‌های موجود ایجاد نماید.

علاوه بر تقویت هسته یادگیری الگوریتم، این مقاله چهار عملگر کاملاً جدید تخریب و تعمیر¹² را معرفی می‌کند که به طور خاص برای جلوگیری از پراکندگی مشتریان در مسیرها طراحی شده‌اند. این عملگرها با توانمندی منحصربه‌فرد خود در بهبود مقادیر تابع هدف در مراحل پایانی جستجو (تکرارهای نهایی الگوریتم)، کیفیت راه‌حل‌های لجستیکی را به شکل ملموسی ارتقا می‌دهند. در نهایت، کاربرد عملی این مدل در زیرساخت‌های پیچیده شرکت سایه سمن نشان خواهد داد که چگونه ابزارهای پیشرفته تحلیل داده و هوش مصنوعی می‌توانند به عنوان محرکی قدرتمند در جهت بهینه‌سازی پخش، کاهش هزینه‌ها، و ایجاد پایداری و تاب‌آوری در صنعت پخش ایران عمل کنند.

2. پیشینه پژوهش

بررسی ادبیات و پیشینه تحقیقات انجام شده در حوزه لجستیک و مسیریابی، نقش مهمی در شناسایی شکاف‌های مطالعاتی و تبیین نوآوری‌های پژوهش حاضر ایفا می‌کند. مطالعات پیشین در این حوزه را می‌توان از منظر رویکردهای حل مسئله و ابزارهای مورد استفاده، در سه دسته کلیدی طبقه‌بندی و تحلیل نمود.

⁹ Operators

¹⁰ Exploration

¹¹ Exploitation

¹² Destruction and Repair Operators

2.1. رویکردهای کلاسیک در مدل‌های مسیریابی زنجیره تامین

در سال‌های گذشته، تمرکز عمده محققان بر توسعه مدل‌های VRP به منظور بهینه‌سازی هزینه‌های شبکه توزیع بوده است. ماهشواری و همکاران (۲۰۲۴) در مطالعه خود، برتری یک رویکرد ترکیبی متشکل از برنامه‌ریزی پویا¹³ و الگوریتم PSO¹⁴ را برای حل مسائل مسیریابی توأم با دریافت و تحویل¹⁵ به اثبات رساندند. از سوی دیگر، با پررنگ شدن مفاهیم پایداری زیست‌محیطی، سویسال و چیمین (۲۰۱۷) تلاش‌های خود را بر توسعه مدل‌های مسیریابی سبز و وابسته به زمان متمرکز کردند. در حوزه تصمیم‌گیری‌های استراتژیک‌تر مانند مکان‌یابی تسهیلات، ژو و اورساواس (۲۰۱۸) شبکه‌ای را طراحی کردند که مکان‌یابی انبارها و مسیریابی ناوگان را با در نظر گرفتن محدودیت‌های پنجره زمانی¹⁶ به طور همزمان بهینه‌سازی می‌کند.

گسترش پیچیدگی‌های عملیاتی در شبکه‌های توزیع، محققان را به سمت الگوریتم‌های پیشرفته‌تر سوق داده است. کرامر و همکاران (۲۰۱۹) با استفاده از الگوریتم Multi-start Iterated Local Search، بهینه‌سازی توزیع در شبکه‌های دارای انبارهای چندگانه و پنجره‌های زمانی انعطاف‌پذیر را مورد ارزیابی قرار دادند. در حوزه‌های تخصصی‌تر مانند توزیع دارویی که نیازمند سطح بالایی از دقت عملیاتی است، کامپلو و همکاران (۲۰۱۹) مدلی جامع برای مدیریت محدودیت‌های زمانی، تاریخ‌های انتشار و تحویل‌های چندباره در طول روز ارائه نمودند. همچنین، رپولهو و همکاران (۲۰۱۹) با ورود به بحث امنیت لجستیک، مدلی برای بهینه‌سازی مسیریابی وزن‌دار با هدف کمینه‌سازی خطرات و ریسک‌های سرقت کالا معرفی کردند. با این وجود، بررسی دقیق این مطالعات نشان می‌دهد که پژوهش‌های پیشین عمدتاً بر کاهش هزینه‌های سازمان تمرکز داشته‌اند و ترجیحات رانندگان ناوگان، به ویژه مسئله نامطلوب بودن پراکندگی مشتریان در یک محدوده توزیع، به عنوان یک عامل کلیدی در رضایت نیروی انسانی و افزایش بهره‌وری، نادیده گرفته شده است.

2.2. کاربرد هوش مصنوعی و یادگیری ماشین در زنجیره تامین

ورود الگوریتم‌های یادگیری ماشین¹⁷ به عرصه زنجیره تامین، افق‌های جدیدی را برای حل مسائل پیچیده مسیریابی گشوده است. هینتیش و ایرنیچ (۲۰۱۸) با توسعه Large Multiple Neighborhood Search¹⁸، راهکاری نوین برای مسئله VRP خوشه‌بندی‌شده ارائه دادند. آن‌ها با استفاده از ساختارهای همسایگی تعمیم‌یافته،

¹³ Dynamic Programming

¹⁴ Particle Swarm Optimisation

¹⁵ Pickup and Delivery

¹⁶ Time Windows

¹⁷ Machine Learning

¹⁸ LMNS

جایگشت‌های بین خوشه‌ها را با موفقیت بهینه‌سازی کردند. این رویکرد در ادامه توسط هینتش (۲۰۲۱) برای مسائل خوشه‌بندی نرم توسعه یافت تا انعطاف‌پذیری شبکه توزیع با صدور مجوز توقف بین خوشه‌ای افزایش یابد. در زمینه لجستیک شهری، حسینی-مطلق و همکاران (۲۰۲۲) یک الگوریتم ترکیبی بر پایه مکانیسم چرخ رولت برای مدیریت تراکم ترافیک و انتخاب عملگرهای تخریب و تعمیر پیشنهاد دادند. اگرچه مطالعاتی نظیر پژوهش کومار و همکاران (۲۰۲۳) و دِوچی (۲۰۲۳) بر پتانسیل بالای یادگیری ماشین در ارتقای توانمندی‌های زنجیره تامین تأکید داشته‌اند، اما بررسی‌های جامع‌تر نظیر پژوهش ریاحی و همکاران (۲۰۲۱) نشان می‌دهد که به دلیل پیچیدگی‌های بالای محاسباتی، استفاده صریح از تکنیک‌های هوش مصنوعی نظیر یادگیری ماشین تنها در ۹ درصد از مقالات زنجیره تامین گزارش شده است. با این حال، شی و همکاران (۲۰۲۰) با معرفی یک چارچوب مبتنی بر یادگیری برای حل مسئله VRP، اثبات کردند که این تکنیک‌ها پتانسیل تحول‌آفرینی در فرآیندهای تصمیم‌گیری لجستیکی دارند.

2.3. هم‌افزایی یادگیری ماشین و الگوریتم‌های فراابتکاری

یکی از پویاترین حوزه‌های مطالعاتی اخیر، یکپارچه‌سازی الگوریتم‌های فراابتکاری با تکنیک‌های یادگیری ماشین است. کریمی-ممقان و همکاران (۲۰۲۲) و بای و همکاران (۲۰۲۳) در پژوهش‌های خود، پتانسیل این هم‌افزایی را در ارتقای کیفیت راه‌حل‌های بهینه‌سازی به اثبات رساندند. اگرچه محققانی مانند چن، یان و همکاران (۲۰۲۳) از تکنیک‌های پیش‌بینی یادگیری ماشین برای برآورد تقاضا در شرایط بحرانی استفاده کردند، اما ورود ابزارهای یادگیری به هسته الگوریتم‌های بهینه‌سازی گام بسیار بزرگ‌تری بود.

ژو و وی (۲۰۲۳) با پیاده‌سازی الگوریتم Q-learning، وزن عملگرها را به صورت پویا در مسائل تخصیص وسایل نقلیه و جابه‌جایی واسطه‌ای تطبیق دادند. کریمی-ممقان و همکاران (۲۰۲۳) نیز با ادغام Q-learning و الگوریتم Iterated Greedy Algorithm، کارایی فرآیند تصمیم‌گیری در انتخاب عملگرها را به شدت افزایش دادند. در حوزه مسائل چندهدفه، چی و همکاران (۲۰۲۲) با توسعه الگوریتم تکاملی مبتنی بر Q-learning، یک استراتژی تقاطع پیشرفته برای مسائل مسیریابی سبز وابسته به زمان ارائه کردند. کاربرد این الگوریتم‌ها توسط شانگ و همکاران (۲۰۲۳) و گوا و همکاران (۲۰۲۲) برای ارزیابی پاداش در سیستم‌های حمل‌ونقل غیرقطعی، و همچنین توسط چن، زونگ و همکاران (۲۰۲۳) در قالب فرآیندهای تصمیم‌گیری مارکوف جهت مسائل دریافت و تحویل مورد بررسی و تأیید قرار گرفته است.

اخيراً محققانی نظیر گوناوان و همکاران (۲۰۱۸) با استفاده از مکانیسم‌های تخصیص اعتبار، روش‌های جستجوی محلی را برای تخصیص بهینه‌تر پالایش کرده‌اند. در مقیاس پیچیده‌تر، لیو و همکاران (۲۰۲۳) با ترکیب شبکه‌های عصبی و الگوریتم Q-learning موفق شدند پارامترهای پیچیده توزیع بار در محیط‌های شهری را با دقت بالایی مدیریت کنند.

3. روش‌شناسی پژوهش و مدل‌سازی ریاضی

برای دستیابی به اهداف این پژوهش و پاسخگویی به چالش‌های پیچیده در شبکه‌های توزیع مویرگی¹⁹، روش‌شناسی این تحقیق بر پایه تلفیق مدل‌سازی ریاضی و توسعه الگوریتم‌های هوش مصنوعی²⁰ بنا شده است.

3.1. تعریف مسئله و ساختار مدل ریاضی

مدل ریاضی پیشنهادی در این پژوهش، چارچوبی یکپارچه برای مدیریت توزیع در یک گراف کامل و جهت‌دار ارائه می‌دهد که به صورت $G = (N, E)$ تعریف می‌گردد. در این ساختار شبکه‌ای، $N = \{d, 1, 2, \dots, n\}$ نشان‌دهنده مجموعه تمامی گره‌ها شامل انبار مرکزی (d) و شبکه مشتریان است و $E = \{(i, j) \in N, i \neq j\}$ مسیرهای ارتباطی میان آن‌ها را شکل می‌دهد. این چارچوب بر مبنای یک زنجیره تامین دو سطحی طراحی شده است که در آن، ناوگانی از وسایل نقلیه ناهمگن با ظرفیت‌های متفاوت وزنی و حجمی، عملیات پخش را بر عهده دارند.

برخلاف رویکردهای کلاسیک VRP که تمرکز خود را صرفاً بر کاهش هزینه‌های سازمان معطوف می‌سازند، نوآوری اصلی این مدل در بازطراحی تابع هدف نهفته است. این تابع به گونه‌ای فرمول‌بندی شده است که یک بده‌بستان منطقی میان ترجیحات مالی مدیران ارشد و نیازمندی‌های رفاهی رانندگان ایجاد کند. مدل ریاضی با استفاده از بردار وزنی $(\lambda_1, \lambda_2, \lambda_3, \lambda_4)$ ، چهار مؤلفه با ابعاد متفاوت را در یک رابطه واحد تجميع و کمینه می‌کند:

$$\text{Min } Z = \lambda_1(\text{Total Distance}) + \lambda_2(\text{Vehicle Cost}) + \lambda_3 \sum_{v \in V} \theta_v + \lambda_4 \sum_{v \in V} \tau_v$$

در این رابطه، دو مؤلفه اول نمایانگر رویکرد سنتی در کاهش مسافت کل و تقلیل هزینه‌های ثابت به‌کارگیری ناوگان هستند. اما دو مؤلفه بعدی مستقیماً برای جلوگیری از پراکندگی مسیرها و ارتقای رضایت رانندگان مدل‌سازی شده‌اند؛ متغیر θ_v میانگین فاصله نسبی بین مشتریان تخصیص‌یافته به وسیله نقلیه v را محاسبه

¹⁹ Capillary Distribution Networks

²⁰ Artificial Intelligence

می‌کند تا مشتریان به صورت متراکم و خوشه‌ای ویزیت شوند، و متغیر τ_v به عنوان مسافت پوششی، حداکثر شعاع پراکندگی هر مسیر را در سطح شهر کنترل می‌نماید.

3.2. رویکرد حل: الگوریتم ALNS مبتنی بر یادگیری

با توجه به ماهیت به شدت پیچیده مسائل مسیریابی چندهدفه، حلگرهای دقیق ریاضی توانایی رسیدن به جواب بهینه در ابعاد واقعی صنعتی را ندارند. برای غلبه بر این چالش، پژوهش حاضر الگوریتم فراابتکاری پیشرفته ALNS را پیشنهاد می‌دهد. ساختار پایه الگوریتم ALNS، که نخستین بار توسط روپکه و پیسینگر (۲۰۰۶) توسعه یافت، بر این منطق استوار است که در هر تکرار، بخش‌هایی از یک راه‌حل توسط عملگرهای تخریب حذف شده و سپس توسط عملگرهای تعمیر با آرایشی بهینه‌تر بازسازی می‌شوند تا الگوریتم از گیر افتادن در نقاط بهینه محلی فرار کند (پیسینگر و روپکه، ۲۰۱۹).

با این حال، نوآوری کلیدی این پژوهش در هوشمندسازی نحوه انتخاب این عملگرهاست. در حالی که الگوریتم‌های سنتی معمولاً از رویکرد تصادفی چرخ رولت برای انتخاب عملگرها استفاده می‌کنند (شی و همکاران، ۲۰۲۳)، این مقاله یک عامل یادگیرنده مبتنی بر Q-learning را به عنوان هسته تصمیم‌گیرنده الگوریتم معرفی می‌کند. در این ساختار، الگوریتم به صورت پیوسته جفت‌های وضعیت-اقدام را تحلیل کرده و ارزش مورد انتظار را برای انتخاب هر عملگر در وضعیت فعلی به‌روزرسانی می‌کند. این فرآیند که در حقیقت مکانیزم درس گرفتن از تجربه را برای الگوریتم شبیه‌سازی می‌کند، با رابطه زیر فرمول‌بندی شده است:

$$Q(s, a) = Q(s, a) + \alpha \left[R(s, a) + \gamma \max_{a'} Q(s', a') - Q(s, a) \right]$$

در این معادله، مؤلفه‌ها به شرح زیر تعریف می‌شوند:

s و a : به ترتیب نمایانگر وضعیت فعلی مسئله و عملگر (تخریب یا تعمیر) انتخاب شده در آن وضعیت هستند.

$Q(s, a)$: امتیازی است که الگوریتم پیش‌بینی می‌کند با انجام اقدام a در وضعیت s به دست خواهد آورد.

$R(s, a)$: پاداش فوری دریافت شده پس از انجام اقدام است.

α : نرخ یادگیری است و مشخص می‌کند که الگوریتم چقدر باید به اطلاعات جدید اعتماد کند و اطلاعات قدیمی را کنار بگذارد.

۷: فاکتور تخفیف است که باعث دوراندیشی الگوریتم می‌شود؛ به این معنا که الگوریتم فقط به پاداش‌های آنی دلخوش نکرده و بهترین شرایط ممکن در آینده ($\max_{a'} Q(s', a')$) را نیز در تصمیم‌گیری فعلی خود لحاظ می‌کند.

منطق پنهان در این فرمول آن است که سیستم، ارزش قبلی یک عملگر را با توجه به نتیجه‌ای که به تازگی کسب کرده و همچنین دورنمایی که از آینده دارد، به صورت مداوم اصلاح می‌کند.

برای اینکه الگوریتم به درستی متوجه شود چه زمانی انتخاب موفق داشته است، یک مکانیسم پاداش‌دهی منصفانه و پویا به صورت زیر طراحی شده است:

$$R(s, a) = V_f + (\ln(z_p^* - z_c))^{1.5}$$

این تابع پاداش به شکلی هوشمندانه از دو بخش تشکیل شده است: بخش اول (V_f) یک مقدار موفقیت ثابت است که صرف‌نظر از میزان بهبود، به عنوان یک پاداش پایه به عملگرهای موفق اختصاص می‌یابد تا انگیزه و پایداری سیستم حفظ شود. بخش دوم، یک مؤلفه پویا است که میزان دقیق بهبود در تابع هدف را می‌سنجد z_p^* بهترین تابع هدف تجربه شده تا کنون، و z_c مقدار تابع هدف در وضعیت فعلی است.

استفاده از تابع لگاریتمی $\ln$ و توان 1.5 در این مؤلفه، یک ترفند ریاضی است تا در صورت بروز یک بهبود ناگهانی و بسیار بزرگ در شبکه توزیع، عدد پاداش بیش از حد بزرگ نشود و تعادل یادگیری سیستم به هم نریزد. این ساختار تضمین می‌کند که الگوریتم هم برای انتخاب عملگرهای موفق و هم برای برداشتن گام‌های بلند بهبودبخش، به شکلی متناسب و منصفانه تشویق شود.

3.3. معرفی عملگرهای نوین تخریب و تعمیر

مهم‌ترین عامل در هوشمندسازی توزیع و جلوگیری از پراکندگی مشتریان که مستقیماً با مفهوم تاب‌آوری شبکه گره خورده است، طراحی عملگرهای تخصصی است. برای ایجاد تنوع، از عملگرهای کلاسیک مانند تعمیر حریصانه (دمیر و همکاران، ۲۰۱۲) و تخریب رشته‌ای (روپکه و پیسینگر، ۲۰۰۶) استفاده شده است؛ اما این پژوهش در کنار آن‌ها، چهار عملگر کاملاً جدید را معرفی می‌کند که توانایی فوق‌العاده‌ای در بهبود کیفیت راه‌حل در مراحل پایانی جستجو (چارک نهایی تکرارها) دارند:

۱. **عملگر Central Gravity Destruction**: این عملگر به صورت هوشمندانه دورترین مشتری نسبت به مرکز ثقل یک مسیر را شناسایی و از آن مسیر حذف می‌کند. این اقدام به طور مؤثری شعاع پوششی مسیر را کاهش داده و از پراکندگی جغرافیایی جلوگیری می‌کند.


۲. **عملگر Nearby Nodes Destruction**: در توزیع مویرگی، یکی از عوامل اتلاف منابع زمانی رخ می‌دهد که دو مشتری بسیار نزدیک به هم، توسط دو ماشین متفاوت و در دو مسیر مجزا سرویس‌دهی شوند. این عملگر گره‌هایی را که با همسایگان فیزیکی خود در یک مسیر نیستند شناسایی کرده و آن‌ها را برای بازتخصیص بهینه، حذف می‌کند.

۳. **عملگر Cluster String Destruction**: تلاقی و تقاطع مسیرهای توزیع یکی از دلایل اصلی افزایش گره‌های ترافیکی و تأخیر در زنجیره تامین است. این عملگر مسیرهای متقاطع را تحلیل کرده و رشته‌ای از گره‌های مجاور را از آن‌ها حذف می‌کند تا در مرحله بعدی، خوشه‌های تمیزتر و بدون تقاطعی شکل گیرند.

۴. **عملگر Cluster Repair**: پس از انجام تخریب‌ها، این عملگر هوشمند وظیفه دارد مشتریان حذف شده را مجدداً در بهینه‌ترین حالت جانمایی کند. این عملگر مشتری را در مسیری درج می‌کند که اکثریت همسایگان جغرافیایی آن مشتری در آن مسیر قرار داشته باشند و همزمان کمترین میزان افزایش مسافت را به سیستم تحمیل کند. ترکیب این عملگرهای نوین با هسته یادگیری ماشین، انعطاف‌پذیری سیستم را در مواجهه با شبکه‌های گسترده و متراکم شهری تضمین می‌نماید.

برای درک ملموس‌تر مکانیزم این عملگرها، روند گام‌به‌گام اصلاح مسیرها در یک شبکه نمونه به تصویر کشیده شده است. همان‌طور که در شکل ۱ مشاهده می‌شود، راه‌حل اولیه (حالت الف) دارای مسیرهای متقاطع و پراکندگی جغرافیایی بالاست. در گام‌های بعدی، مدل با استفاده از عملگر Central Gravity Destruction و Cluster Repair (حالت ب و ج)، گره‌های دورافتاده را حذف و مجدداً تخصیص می‌دهد. در نهایت، با استفاده ترکیبی از عملگرهای Nearby Nodes Destruction و Cluster String Destruction در کنار منطق حریصانه (حالت‌های د تا ز)، گره‌های دارای تداخل به طور کامل تفکیک شده و با تشکیل یک مسیر مستقل و جدید (R_3)، تقاطع‌ها به صفر

رسیده و خوشه‌هایی کاملاً منسجم تشکیل می‌شوند. این همان مکانیزمی است که به صورت در لحظه برای ناوگان شرکت سایه سمن پیاده‌سازی شده است.



شکل 1 روند گام‌به‌گام بهینه‌سازی مسیرها؛ گذار از راه‌حل اولیه متقاطع (الف) به مسیرهای خوشه‌بندی‌شده و بدون هم‌پوشانی (ز) با بهره‌گیری از عملگرهای نوین تخریب و تعمیر.

4. ارزیابی عملکرد و پیاده‌سازی عملیاتی: مطالعه موردی شرکت پخش سایه سمن

به منظور اعتبارسنجی کارایی الگوریتم پیشنهادی و سنجش اثربخشی عملگرهای نوین توسعه‌یافته، ارزیابی‌ها در دو مرحله محاسباتی و عملیاتی انجام پذیرفت. در مرحله نخست، عملکرد الگوریتم بر روی ۳۰ مسئله نمونه در مقیاس‌های کوچک تا بزرگ ارزیابی گردید و نتایج آن با حلگر دقیق GAMS و دو الگوریتم شناخته‌شده VNS و ALNS کلاسیک مورد قیاس قرار گرفت. نتایج آماری نشان داد که مکانیسم Q-learning در انتخاب عملگرها، به طور میانگین ۰.۶۹ درصد نسبت به مکانیزم چرخ رولت و ۰.۶۶ درصد نسبت به انتخاب تصادفی، برتری دارد. در مقیاس کلی نیز، الگوریتم پیشنهادی توانست مقدار تابع هدف را به طور میانگین ۳.۵۱ درصد نسبت به الگوریتم VNS و ۱۹.۳۴ درصد نسبت به ALNS کلاسیک بهبود بخشد. کارایی محاسباتی مدل نیز در سطح بسیار مطلوبی قرار داشت؛ به گونه‌ای که زمان پردازش برای شبکه‌ای با ۱۲۵ گره، تنها ۷.۸۹ ثانیه به طول انجامید که نشان‌دهنده قابلیت بالای این مدل برای تصمیم‌گیری‌های لحظه‌ای²¹ در سیستم‌های توزیع است.


4.1. پیاده‌سازی در شبکه توزیع مویرگی شرکت سایه سمن

برای اثبات کارکرد مدل در محیط واقعی کسب‌وکار و مواجهه با عدم قطعیت‌های لجستیکی، شبکه توزیع شرکت سایه سمن به عنوان بستر اصلی مطالعه موردی انتخاب گردید. شرکت سایه سمن به عنوان یکی از بزرگترین قطب‌های صنعت پخش ایران، وظیفه توزیع سبد گسترده‌ای از محصولات دارویی و غذایی را به بیش از ۹۵,۰۰۰ مشتری در سطح ۳۰ استان کشور بر عهده دارد و برای این منظور از ناوگانی متشکل از ۷۰۰ وسیله نقلیه ناهمگن با ظرفیت‌های ۳.۸ و ۴.۵ تن بهره می‌برد.

با توجه به ساختار غیرمتمرکز سازمان، پیاده‌سازی مدل به صورت استانی انجام پذیرفت. در این پژوهش، شبکه توزیع استان البرز با تمرکز بر ۱۵,۰۰۰ مشتری فعال و میانگین ۷۰۰ تحویل روزانه مورد تحلیل عمیق قرار گرفت. خروجی‌های حاصل از اجرای الگوریتم پیشنهادی بر روی داده‌های یک روز کاری پرفشار شامل ۶۲۸ مشتری تخصیص‌یافته نشان‌دهنده تحولی بنیادین در کیفیت عملیات پخش بود. در حالی که روش‌های کلاسیک VRP با ایجاد مسیرهای طولانی و متقاطع باعث افت رضایت ناوگان می‌شدند، الگوریتم یادگیری‌محور پیشنهادی توانست با استفاده از عملگرهای خوشه‌بندی، پراکندگی مشتریان در مسیرها را به حداقل برساند. نتایج نشان داد که مدل توسعه‌یافته قادر است ۹۰ درصد از هزینه‌های نامرئی ناشی از پراکندگی توزیع را کنترل نموده و در مجموع، مقدار تابع هدف شامل هزینه‌ها و فواصل نسبی را بالغ بر ۱۸.۱۴ درصد در مقایسه با الگوریتم‌های کلاسیک بهبود بخشد.

²¹ Real-time Decision Making

تأثیر این بهبود عملیاتی به وضوح در ساختار جغرافیایی مسیرها قابل مشاهده است. شکل (۲)، نقشه مسیرهای توزیع ناوگان شرکت سایه سمن در استان البرز را قبل و بعد از پیاده‌سازی الگوریتم ALNS مبتنی بر یادگیری نشان می‌دهد؛ خروجی‌ها حاکی از آن است که الگوریتم پیشنهادی به طور چشمگیری تقاطع مسیرها را حذف نموده و خوشه‌بندی کاملاً متراکمی را برای هر راننده ایجاد کرده است.



الف: نتایج با استفاده از الگوریتم کلاسیک ALNS

ب: نتایج با استفاده از مدل پیشنهادی و الگوریتم ALNS مبتنی بر یادگیری

شکل ۲

به منظور اعتبارسنجی دقیق‌تر این بهبودها، جدول (۱) مقایسه جامعی میان سناریوهای مختلف اجرای الگوریتم بر روی داده‌های شرکت سایه سمن ارائه می‌دهد. همان‌طور که در نتایج مشخص است، وجود عملگرهای معرفی شده نقش مستقیمی در کاهش مسافت پوششی و افزایش رضایت ناوگان ایفا می‌کند.

جدول ۱

نام الگوریتم	تعداد وسایل نقلیه (۳۸ تنی)	تعداد وسایل نقلیه (۴۵ تنی)	مجموع وسایل نقلیه	تابع هدف - مسافت کل (متر)	تابع هدف - میانگین مسافت نسبی (متر)	تابع هدف - مسافت پوششی کل (متر)	هزینه وسایل نقلیه استفاده شده	مقدار کل تابع هدف
الگوریتم ALNS مبتنی بر یادگیری (سناریو ۱)	21	3	24	1,433,130	76,581	197,208	7,200,000	8,906,919
الگوریتم ALNS مبتنی بر یادگیری بدون عملگرهای جدید (سناریو ۲)	20	3	23	1,694,382	114,761	334,926	6,900,000	9,044,069
الگوریتم ALNS کلاسیک (سناریو ۳)	20	3	23	1,246,504	852,627	1,881,349	6,900,000	10,880,480
نرخ بهبود سناریو ۱ نسبت به سناریو ۲ (درصد)	-	-	-	15.42	33.23	41.12	-4.35	1.52
نرخ بهبود سناریو ۱ نسبت به سناریو ۳ (درصد)	-	-	-	-13.30	91.02	89.52	-4.35	18.14

4.2. تحلیل حساسیت و دستاوردهای مدیریتی

به منظور استخراج بینش‌های مدیریتی و ارزیابی تاب‌آوری شبکه توزیع سایه سمن در برابر تغییرات محیطی، تحلیل حساسیت بر روی متغیرهای کلیدی عملیات انجام گرفت.

- **بهینه‌سازی ترکیب ناوگان:** تحلیل‌های صورت گرفته بر روی تخصیص وسایل نقلیه نشان داد که با توجه به ویژگی‌های تقاضای مویرگی (تعداد زیاد مشتریان با حجم تقاضای پایین)، محدودیت‌های زمانی ناوگان سایه سمن بسیار سخت‌گیرانه‌تر از محدودیت‌های وزنی و حجمی است. از این رو، استفاده از بیش از یک دستگاه کامیون ۴.۵ تنی توجیه اقتصادی ندارد و بهترین عملکرد توزیع در ترکیب ناوگان (۲۵ دستگاه ۳.۸ تنی و ۱ دستگاه ۴.۵ تنی) به دست می‌آید.

- **ارزیابی ساعات کاری روزانه:** در حال حاضر، سقف ساعات کاری ناوگان سایه سمن ۸:۳۰ ساعت در نظر گرفته شده است. شبیه‌سازی‌ها نشان داد که کاهش این زمان به ۶ ساعت، نیازمند افزودن ۵ دستگاه وسیله نقلیه جدید به شبکه بوده و هزینه‌های کل را ۱۲۰.۷ درصد افزایش می‌دهد. از سوی دیگر، افزایش ساعات کاری به ۱۱ ساعت، تنها به حذف یک وسیله نقلیه (کاهش ۳.۴ درصدی هزینه‌ها) منجر می‌شود که در برابر تحمیل فشار مضاعف و نارضایتی نیروی انسانی، فاقد توجیه است. لذا، حفظ استاندارد ۸:۳۰ ساعت کاری، ضامن تاب‌آوری شبکه خواهد بود.

- **مدیریت زمان خدمت‌رسانی²²:** بررسی‌ها حاکی از آن است که تغییرات زمان توقف در محل مشتری (هم‌اکنون ۴۸۰ ثانیه)، تأثیرات نامتقارنی بر سیستم دارد. کاهش این زمان مستلزم استخدام نیروی کار اضافی برای تخلیه سریع‌تر بار است که صرفه اقتصادی ندارد؛ اما کوچکترین افزایش در زمان خدمت‌رسانی (حتی ۱۰ تا ۲۰ درصد تأخیر)، منجر به افزایش نمایی در هزینه‌های کل و نیاز به توسعه اجباری ناوگان می‌گردد.

- **نوسانات تقاضا:** یکی از مهم‌ترین دستاوردهای این تحلیل، اثبات تاب‌آوری بالای مدل در برابر افت تقاضا است. به دلیل گستردگی جغرافیایی مشتریان، حتی کاهش ۷۰ درصدی حجم تقاضای هر مشتری تأثیر چشمگیری بر کاهش مسافت و هزینه‌ها ندارد، زیرا ناوگان همچنان ملزم به طی مسافت‌های طولانی برای

²² Service Time

رسیدن به نقاط فروش است. در مقابل، در صورت افزایش ۵۰ درصدی تقاضای بازار، ناوگان توزیع سایه سمن نیازمند تصمیم‌گیری استراتژیک برای توسعه ظرفیت لجستیکی خواهد بود.

5. بحث و نتیجه‌گیری

پیچیدگی‌های روزافزون در شبکه‌های توزیع مویرگی و ضرورت ارتقای تاب‌آوری در برابر عدم قطعیت‌های محیطی، گذار از رویکردهای سنتی به سمت چارچوب‌های تصمیم‌گیری هوشمند را گریزناپذیر ساخته است. در این پژوهش، یک مدل ریاضی نوین برای بهینه‌سازی عملیات لجستیک در یک زنجیره تامین دو سطحی توسعه یافت. هدف اصلی این مدل، ایجاد توازن پایدار میان کاهش هزینه‌های سازمان (مسافت و تعداد ناوگان) و ارتقای رضایت منابع انسانی از طریق جلوگیری از پراکندگی جغرافیایی مشتریان بوده است. به منظور غلبه بر پیچیدگی‌های محاسباتی این مسئله در ابعاد صنعتی، یک الگوریتم ALNS توسعه یافت که با بهره‌گیری از مکانیسم Q-learning و Dual Epsilon-Greedy Phases، فرآیند انتخاب عملگرهای جستجو را هوشمندسازی نمود.

اجرای عملیاتی این پلتفرم هوشمند بر روی زیرساخت‌های شبکه توزیع شرکت پخش سایه سمن، به عنوان یکی از رهبران صنعت پخش ایران، نشان داد که پیوند هوش مصنوعی با ابزارهای تحقیق در عملیات، توانایی بالایی در کنترل هزینه‌های پنهان دارد. این چارچوب توانست با استفاده از چهار عملگر نوین خوشه‌بندی، ضمن حذف مسیرهای متقاطع و پراکنده، بهبود ۱۸.۱۴ درصدی در مجموع توابع هدف سیستم ایجاد نماید.

5.1. دستاوردهای مدیریتی برای صنعت پخش ایران

با توجه به رویکردهای نوین صنعت پخش در حوزه تحول دیجیتال و هوشمندسازی لجستیک، یافته‌های پیاده‌سازی شده در شرکت سایه سمن، حاوی پیام‌ها و توصیه‌های استراتژیک مهمی برای مدیران این صنعت است:

- **بهینه‌سازی زمان خدمت‌رسانی:** کنترل زمان توقف ناوگان در محل استقرار مشتریان (که در حال حاضر ۴۸۰ ثانیه برآورد می‌شود) از اهمیتی حیاتی برخوردار است. کوچک‌ترین افزایش در این زمان، باعث رشد نمایی هزینه‌های توزیع می‌گردد. توصیه می‌شود مدیریت توزیع در سایه سمن از تکنیک‌های هوشمند چیدمان بار بهره‌گیرد؛ به گونه‌ای که کالای مشتریانی که در ابتدای مسیر ویزیت می‌شوند، دقیقاً در نزدیک‌ترین فاصله به درب خروجی کامیون چیده شود تا از اتلاف زمان جلوگیری به عمل آید.
- **تاب‌آوری شبکه در برابر شوک‌های تقاضا:** خروجی‌های مدل حاکی از آن است که ساختار توزیع سایه سمن در برابر کاهش شدید تقاضا کاملاً تاب‌آور و مقاوم است و تغییر چشمگیری در هزینه‌های ثابت ناوگان ایجاد نمی‌شود. با این وجود، در صورت مواجهه با پیک‌های فصلی تقاضا (افزایش ۵۰ درصدی و

بیشتر)، محدودیت‌های زمانی رانندگان به یک گلوگاه²³ تبدیل خواهد شد و مدیریت لجستیک باید تصمیمات استراتژیک و پیش‌دستانه‌ای برای تزریق ناوگان استیجاری²⁴ اتخاذ نماید.

5.2. محدودیت‌ها و پیشنهادها برای تحقیقات آتی

همانند تمامی پژوهش‌های آکادمیک، این مطالعه نیز با محدودیت‌هایی مواجه بوده است؛ از جمله آنکه پارامترهای محیطی نظیر زمان سفر میان مشتریان، قطعی و ثابت فرض شده‌اند. با توجه به ماهیت پویای ترافیک شهری، پیشنهاد می‌شود در مطالعات آینده از رویکردهای Robust Optimization جهت کنترل عدم قطعیت‌های ترافیکی استفاده گردد. علاوه بر این، در راستای تحقق عدالت سازمانی و ارتقای رضایت نیروی انسانی، توسعه الگوریتمی که بتواند مسیرها را بر اساس داده‌های تاریخی عملکرد رانندگان و میزان مسافت‌های پیموده‌شده قبلی آنان تخصیص دهد، جذابیت بالایی برای پژوهشگران خواهد داشت. در نهایت، بهره‌گیری از مدل‌های De-Novo Programming در سطوح تصمیم‌گیری استراتژیک، می‌تواند نقشه راه مناسبی برای تعیین دقیق اندازه و ترکیب ناوگان شرکت‌های پخش در افق‌های بلندمدت ارائه دهد.

²³ Bottleneck

²⁴ 3PL

References

1. Arji, G., Ahmadi, H., Avazpoor, P., & Hemmat, M. (2023). Identifying resilience strategies for disruption management in the healthcare supply chain during COVID-19 by digital innovations: A systematic literature review. *Informatics in Medicine Unlocked*, 38, 101199. <https://doi.org/10.1016/j.imu.2023.101199>
2. Bai, R., Chen, X., Chen, Z. L., Cui, T., Gong, S., He, W., & Zhang, H. (2023). Analytics and machine learning in vehicle routing research. *International Journal of Production Research*, 61(1), 4–30. <https://doi.org/10.1080/00207543.2021.2013566>
3. Campelo, P., Neves-Moreira, F., Amorim, P., & Almada-Lobo, B. (2019). Consistent vehicle routing problem with service level agreements: A case study in the pharmaceutical distribution sector. *European Journal of Operational Research*, 273(1), 131–145. <https://doi.org/10.1016/j.ejor.2018.07.030>
4. Chen, X., Yan, H. F., Zheng, Y. J., & Karatas, M. (2023). Integration of machine learning prediction and heuristic optimization for mask delivery in COVID-19. *Swarm and Evolutionary Computation*, 76, 101208. <https://doi.org/10.1016/j.swevo.2022.101208>
5. Chen, J., Zong, Z., Zhuang, Y., Yan, H., Jin, D., & Li, Y. (2023). Reinforcement learning for practical express systems with mixed deliveries and pickups. *ACM Transactions on Knowledge Discovery from Data*, 17(3), 1–19. <https://doi.org/10.1145/3546952>
6. Clarke, G., & Wright, J. W. (1964). Scheduling of vehicles from a central depot to a number of delivery points. *Operations Research*, 12(4), 568–581. <https://doi.org/10.1287/opre.12.4.568>
7. Demir, E., Bektaş, T., & Laporte, G. (2012). An adaptive large neighborhood search heuristic for the pollution-routing problem. *European Journal of Operational Research*, 223(2), 346–359. <https://doi.org/10.1016/j.ejor.2012.06.044>
8. Deveci, M. (2023). Effective use of artificial intelligence in healthcare supply chain resilience using fuzzy decision-making model. *Soft Computing*, 1–14. <https://doi.org/10.1007/s00500-023-08906-2>
9. Gunawan, A., Lau, H. C., & Lu, K. (2018). ADOPT: Combining parameter tuning and adaptive operator ordering for solving a class of orienteering problems. *Computers & Industrial Engineering*, 121, 82–96. <https://doi.org/10.1016/j.cie.2018.05.016>
10. Guo, W., Atasoy, B., & Negenborn, R. R. (2022). Global synchromodal shipment matching problem with dynamic and stochastic travel times: A reinforcement learning approach. *Annals of Operations Research*, 1–32. <https://doi.org/10.1007/s10479-021-04489-z>
11. Hintsch, T. (2021). Large multiple neighborhood search for the soft-clustered vehicle-routing problem. *Computers & Operations Research*, 129, Article 105132. <https://doi.org/10.1016/j.cor.2020.105132>
12. Hintsch, T., & Irnich, S. (2018). Large multiple neighborhood search for the clustered vehicle-routing problem. *European Journal of Operational Research*, 270(1), 118–131. <https://doi.org/10.1016/j.ejor.2018.02.056>
13. Hosseini-Motlagh, S. M., Farahmand, M., & Nouri-Harzvili, M. (2022). A multi-path traffic-covering pollution routing model with simultaneous pickup and delivery. *Computers & Industrial Engineering*, 173, Article 108644. <https://doi.org/10.1016/j.cie.2022.108644>
14. Karimi-Mamaghan, M., Mohammadi, M., Meyer, P., Karimi-Mamaghan, A. M., & Talbi, E. G. (2022). Machine learning at the service of meta-heuristics for solving combinatorial

- optimization problems: A state-of-the-art. *European Journal of Operational Research*, 296(2), 393–422. <https://doi.org/10.1016/j.ejor.2021.04.032>
15. Karimi-Mamaghan, M., Mohammadi, M., Pasdeloup, B., & Meyer, P. (2023). Learning to select operators in meta-heuristics: An integration of Q-learning into the iterated greedy algorithm for the permutation flowshop scheduling problem. *European Journal of Operational Research*, 304(3), 1296–1330. <https://doi.org/10.1016/j.ejor.2022.03.054>
 16. Kilibarda, M., Nikolić, S., & Andrejić, M. (2016). Measurement of logistics service quality in freight forwarding companies: A case study of the Serbian market. *International Journal of Logistics Management*, 27(3), 770–794. <https://doi.org/10.1108/ijlm-04-2014-0063>
 17. Kramer, R., Cordeau, J. F., & Iori, M. (2019). Rich vehicle routing with auxiliary depots and anticipated deliveries: An application to pharmaceutical distribution. *Transportation Research Part E: Logistics and Transportation Review*, 129, 162–174. <https://doi.org/10.1016/j.tre.2019.07.012>
 18. Kumar, A., Mani, V., Jain, V., Gupta, H., & Venkatesh, V. G. (2023). Managing healthcare supply chain through artificial intelligence (AI): A study of critical success factors. *Computers & Industrial Engineering*, 175, Article 108815. <https://doi.org/10.1016/j.cie.2022.108815>
 19. Liu, Y., Ye, Q., Escibano-Macias, J., Feng, Y., Candela, E., & Angeloudis, P. (2023). Route planning for last-mile deliveries using mobile parcel lockers: A hybrid q-learning network approach. *Transportation Research Part E: Logistics and Transportation Review*, 177, Article 103234. <https://doi.org/10.1016/j.tre.2023.103234>
 20. Maheshwari, P., Kamble, S. S., Belhadi, A., Gupta, S., & Mangla, S. K. (2024). Resilient healthcare network for simultaneous product allocations during supply chain disruptions. *Supply Chain Forum: An International Journal*, 25(4), 407–427. <https://doi.org/10.1080/16258312.2023.2238669>
 21. Mara, S. T. W., Norcahyo, R., Jodiawan, P., Lusiantoro, L., & Rifai, A. P. (2022). A survey of adaptive large neighborhood search algorithms and applications. *Computers & Operations Research*, 146, Article 105903. <https://doi.org/10.1016/j.cor.2022.105903>
 22. Pisinger, D., & Ropke, S. (2019). Large neighborhood search. In M. Gendreau & J. Y. Potvin (Eds.), *Handbook of metaheuristics* (pp. 99–127). Springer.
 23. Qi, R., Li, J. Q., Wang, J., Jin, H., & Han, Y. Y. (2022). Qmoea: A q-learning-based multiobjective evolutionary algorithm for solving time-dependent green vehicle routing problems with time windows. *Information Sciences*, 608, 178–201. <https://doi.org/10.1016/j.ins.2022.06.056>
 24. Repolho, H. M., Marchesi, J. F., Júnior, O. S. S., & Bezerra, R. R. (2019). Cargo theft weighted vehicle routing problem: Modeling and application to the pharmaceutical distribution sector. *Soft Computing*, 23(14), 5865–5882. <https://doi.org/10.1007/s00500-018-3250-6>
 25. Riahi, Y., Saikouk, T., Gunasekaran, A., & Badraoui, I. (2021). Artificial intelligence applications in supply chain: A descriptive bibliometric analysis and future research directions. *Expert Systems with Applications*, 173, Article 114702. <https://doi.org/10.1016/j.eswa.2021.114702>
 26. Ropke, S., & Pisinger, D. (2006). An adaptive large neighborhood search heuristic for the pickup and delivery problem with time windows. *Transportation Science*, 40(4), 455–472. <https://doi.org/10.1287/trsc.1050.0135>

27. Shang, C., Ma, L., & Liu, Y. (2023). Green location routing problem with flexible multi-compartment for source-separated waste: A Q-learning and multi-strategy-based hyper-heuristic algorithm. *Engineering Applications of Artificial Intelligence*, 121, Article 105954. <https://doi.org/10.1016/j.engappai.2023.105954>
28. Shi, Y., Liu, W., & Zhou, Y. (2023). An adaptive large neighborhood search based approach for the vehicle routing problem with zone-based pricing. *Engineering Applications of Artificial Intelligence*, 124, Article 106506. <https://doi.org/10.1016/j.engappai.2023.106506>
29. Shi, Y., Zhou, Y., Boudouh, T., & Grunder, O. (2020). A lexicographic-based two-stage algorithm for vehicle routing problem with simultaneous pickup–delivery and time window. *Engineering Applications of Artificial Intelligence*, 95, Article 103901. <https://doi.org/10.1016/j.engappai.2020.103901>
30. Soysal, M., & Çimen, M. (2017). A simulation-based restricted dynamic programming approach for the green time-dependent vehicle routing problem. *Computers & Operations Research*, 88, 297–305. <https://doi.org/10.1016/j.cor.2017.06.023>
31. Xu, X., & Wei, Z. (2023). Dynamic pickup and delivery problem with transshipments and LIFO constraints. *Computers & Industrial Engineering*, 175, Article 108835. <https://doi.org/10.1016/j.cie.2022.108835>
32. Zhu, S. X., & Ursavas, E. (2018). Design and analysis of a satellite network with direct delivery in the pharmaceutical industry. *Transportation Research Part E: Logistics and Transportation Review*, 116, 190–207. <https://doi.org/10.1016/j.tre.2018.06.005>