

مسیریابی ترکیبی وسایل نقلیه و پهپادها جهت کاهش مصرف انرژی با استفاده از الگوریتم های یادگیری تقویتی

وحید نجف پور^{۱*}، صالح یوسفی^۲، هادی ویسی^۳

۱. دانشجوی دکتری مهندسی فناوری اطلاعات، گرایش شبکه، دانشگاه ارومیه، ارومیه، ایران.

۲. دانشیار، گروه مهندسی برق و کامپیوتر، دانشگاه ارومیه، ارومیه ایران.

۳. دانشیار، گروه بین رشته ای فناوری، دانشگاه تهران، تهران، ایران.

چکیده

یکی از مباحث مهم که در چند دهه اخیر کاربرد بالایی در هوشمندسازی در شهرهای هوشمند داشته، بحث مسئله مسیریابی سیستم حمل و نقل است. مسئله مسیریابی خودرو و پهپاد درصداست تا با مدل های ریاضی و بهینه سازی به گونه ای عمل کند که مسافت طی شده، زمان کل سفر و در نهایت تابع هزینه حمل حداقل گردد و در نهایت مصرف انرژی به حداقل برسد. در این مسئله، ابتدا یک مدل ریاضی رسمی از تابع هدف مسیریابی بهینه پویا بررسی و معیار بهینه سازی برای سیستم ارائه می شود. رویکردهای برنامه نویسی ریاضی، حداکثر یا به حداقل رساندن یک عملکرد هدف برای بهبود روند، برای اطمینان از کارایی عملیاتی عمل می کند. مسئله حل مسیریابی وسیله نقلیه برای داده های بزرگ با محدودیت هایی روبرو است. برای افزایش کارایی سیستم های مسیریابی وسایل نقلیه، باید مطالعات بیشتری روی همه محدودیت های شبکه همچون بازه زمان خدمت رسانی و محدودیت ظرفیت حمل در مسیریابی انجام شود. در این پژوهش مسئله مسیریابی پهپاد و خودرو به منظور امداد رسانی و با هدف کمینه کردن مجموع زمان خدمت رسانی به گره های تقاضا انجام گرفته است و به محدودیت های عملیاتی پهپادها نظیر ظرفیت و مصرف انرژی توجه شده است. ذات مسئله مدیریت حمل و نقل و نیز مسیریابی پهپادها، مسئله VRP است. روش های فرابتنکاری جهت مسایل کوچک جوابگو هستند. در مسایل بزرگتر از ۱۰۰ تقاضا، نیاز به الگوریتم های یادگیری خودکار ماشینی پیشنهاد می شود. نتایج با یک مدل آموزش دیده روی داده های آزمون بزرگ و خارج از توزیع، مقیاس پذیری و انعطاف پذیری رویکرد پیشنهادی را نسبت به دو الگوریتم فرابتنکاری نشان می دهد.

واژه های کلیدی: مسیریابی پویای وسایل نقلیه، مدیریت حمل و نقل شهری، یادگیری ماشین، مصرف انرژی، مسیریابی پهپاد.

Combined routing of vehicles and drones to reduce energy consumption using reinforcement learning algorithms

Vahid Najafpoor^{1*}, Saleh Yousefi², Hadi Veysi³

1. Ph.D. student of information technology engineering, network orientation, University, Urmia, Iran.

2. Associate Professor, Department of Electrical and Computer Engineering, Urumia University, Urmia, Iran.

3. Associate Professor, Department of Technology, University of Tehran, Tehran, Iran.

Abstract

One of the important topics that has been highly used in smart cities in the last few decades is the issue of transportation system routing. The problem of vehicle and drone routing is trying to work with mathematical models and optimization in such a way that the distance traveled, the total travel time and finally the transportation cost function are minimized and finally the energy consumption is minimized. In this problem, first, a formal mathematical model of the objective function of the dynamic optimal route is investigated and the optimization criterion for the system is presented. Mathematical programming approaches work to maximize or minimize an objective function to improve the process, to ensure operational efficiency. The problem of solving vehicle routing for big data faces some limitations. To increase the efficiency of vehicle routing systems, more studies should be done on all network constraints, problem-related considerations, environment dynamism in routing. In this research, the problem of routing of drones and vehicles for the purpose of providing aid and with the aim of minimizing the total time of service to the demand nodes has been done, and attention has been paid to the operational limitations of drones such as capacity and energy consumption. The essence of the transportation management problem as well as the routing of drones is the VRP problem. Heuristic and meta-heuristic methods are the answer for small problems. In problems larger than 100 requests, the need for automatic machine learning algorithms is suggested. The results with a model trained on large and out-of-distribution test data show the scalability and flexibility of the proposed approach compared to two meta-heuristic algorithms.

Key words: Dynamic routing of vehicle, Urban transportation management, Machine learning, Energy consumption, UAV routing.

سیستم حمل و نقل یکی از مهم ترین حوزه ها در زنجیره تامین است و بهینه سازی آن می تواند موجب کاهش هزینه های عملیاتی و افزایش سودآوری گردد. در این مقاله، در مورد علل و لزوم استفاده از الگوریتم های یادگیری ماشین به عنوان روش *optimization* برای سیستم حمل و نقل خواهد شد و الگوریتم های یادگیری ماشین برای حل مسایل بزرگ با استفاده از یادگیری عمیق مطرح می گردد که طول مسیر را برای مسئله *VRP* پویا ابتدا برای یک وسیله و در صورت امکان برای چند ماشین بهینه کنند و تعداد ماشین کمتری نیز مورد نیاز باشد و یا با تعداد کمتری پرواز، پهپاد بتواند به مکان های مد نظر خدمت رسانی کند و در مجموع انرژی مصرفی کاهش یابد. کارهای زیادی در بحث مدیریت حمل و نقل شهری انجام شده است. معماری های جدیدی نیز برای این کار در نظر گرفته شده است که در زیر به برخی از آنها اشاره می شود. حل مسئله مسیریابی ناوگان شهری به دو صورت استاتیک و دینامیک بررسی می شود. برای حل مسیریابی ناوگان از روش های ریاضی، ابتکاری و فراابتکاری استفاده شده است که در مجموع برای حل مسایل بزرگ کارایی لازم را ندارند و نمی توانند در لحظه پاسخگوی ایجاد راه حل برای اینگونه مسائل باشند. به همین دلیل به حل مسایل مسیریابی با استفاده از یادگیری ماشین پرداخته شده است که باید مدل سیستم حمل و نقل بخوبی شناخته شود و در ادامه راه کارهای ممکن جهت حل مسئله مسیریابی پیشنهاد شود.

۲- مرور کارهای گذشته

پهپادها به سرعت در حال تبدیل شدن به ابزاری قدرتمند برای طیف گسترده ای از کاربردها، از جمله تحویل کالا، جستجو و نجات و نقشه برداری هستند. با این حال، مسیریابی کارآمد و ایمن پهپادها در محیط های پیچیده و پویا، چالش بزرگی را به وجود می آورد. در این مقاله، به بررسی مسئله مسیریابی خودرو برای پهپادها می پردازیم و روش های مختلف حل این مسئله را تشریح می کنیم. سابقه حل مساله مسیریابی خودرو برای پهپادها به عنوان یک مساله پیچیده و جذاب در زمینه هوافضا و رباتیک مطرح است [۱]. این مساله از اهمیت بالایی برخوردار است زیرا پهپادها به عنوان یکی از تکنولوژی های حیاتی در حوزه نظارت، ارتباطات و حمل و نقل استفاده میشوند. سابقه حل مساله مسیریابی خودرو برای پهپادها شامل تلاش های بسیاری از سوی پژوهشگران و صنعتگران در زمینه طراحی الگوریتم های هوش مصنوعی، شبکه های عصبی، الگوریتم های بهینه سازی و سیستم های کنترل خودکار است. این تلاش ها به منظور بهبود کارایی، دقت و سرعت مسیریابی پهپادها برای انجام وظایف مختلف مانند نظارت، جستجو و نجات، تحویل کالا و غیره انجام شده است. با توجه به پیشرفت های اخیر در حوزه هوافضا و رباتیک، انتظار می رود که روش های پیشرفته تر و دقیقتر برای حل مساله مسیریابی خودرو برای پهپادها توسعه یافته و به کار گرفته شود [۲].

مسیریابی خودرو برای پهپادها یک حوزه مهم در تحقیقات و توسعه فناوری پهپادها است که تاکنون به طور گسترده مورد مطالعه قرار گرفته است. ابتدا، پهپادها به عنوان وسیله ای برای انجام ماموریت های نظامی و امنیتی مورد استفاده قرار گرفتند و نیاز به مسیریابی دقیق برای اجرای ماموریت های مختلف داشتند. سابقه مسیریابی خودرو برای پهپادها در دنیا شامل تحقیقات و پروژه های مختلف است که از جمله آنها میتوان به موارد زیر اشاره کرد:

تحقیقات دانشگاهی: دانشگاه ها و مراکز تحقیقاتی در سراسر جهان به بررسی الگوریتم های مسیریابی پهپادها و بهبود عملکرد آنها می پردازند. شرکت های فعال در حوزه فناوری و پهپادها نیز به توسعه الگوریتم های مسیریابی پهپادها و بهبود نظام هدایت آنها اختصاص داده اند. نیروهای نظامی و سازمان های امنیتی در سراسر جهان از پهپادها برای اجرای ماموریت های خطرناک و پیچیده استفاده می کنند و نیاز به مسیریابی دقیق برای این پهپادها دارند. با پیشرفت فناوری و تحقیقات در این زمینه، الگوریتم های مسیریابی خودرو برای پهپادها بهبود یافته و قابلیت اجرای ماموریت های مختلف با دقت و کارآمدی بالاتر را دارا شده اند. یکی از کاربردهایی که می توان برای پهپادها متذکر شد، استفاده از آنها در حوزه های بشردوستانه است که میتواند زنجیره تامین دارو، امدادسانی و موارد مشابه ی را در برداشته باشد. در این پژوهش مسئله مسیریابی پهپاد و وسیله نقلیه به منظور امدادسانی و یا جمع آوری زباله در محیط، با هدف کمینه کردن مجموع زمان خدمت رسانی به گره های تقاضا انجام گرفته است و به محدودیت های عملیاتی پهپادها نظیر ظرفیت و مصرف انرژی توجه شده است. پهپادها مسافت کمتری را طی می کنند و می توانند خدمت رسانی را در زمان کوتاه تر و با سرعت بیشتری انجام دهند، اگرچه محدودیت هایی نیز دارند.

مدیریت حمل و نقل شهری نیز به دلیل رشد سریع مقدار زباله، هزینه های بالای جمع آوری زباله [۳]، ظرفیت های محدود تصفیه [۴] و مشکلات زیست محیطی [۵] به عنوان یک مسئله چالش برانگیز برای شهرهای معاصر در نظر گرفته می شود [۶-۷]. در چنین شرایط پیچیده ای، استفاده از روش های برنامه نویسی و تحقیق عملیاتی می تواند تصمیم گیرندگان را بهره مند کند [۸]. فعالیت های مدیریت حمل و نقل شهری در پنج مرحله از چرخه حیات زباله گروه بندی می شوند: تولید، جمع آوری و حمل و نقل، تحول، تصفیه و دفع نهایی [۹]، هزینه جمع آوری و حمل و نقل زباله ۶۰-۸۰٪ از کل هزینه سیستم مدیریت حمل و نقل را تشکیل می دهد، که عامل مهمی در هزینه های مالی مدیریت حمل و نقل است، پیشرفت در این زمینه نقش بسزایی در صرفه جویی در هزینه های شهرداری خواهد داشت [۱۰-۱۱]. به عنوان یک قاعده، فعالیت جمع آوری و حمل زباله با استفاده از ناوگان وسایل نقلیه با هدف تخلیه سطل های زباله بر اساس برنامه های از پیش تعیین شده انجام می شود [۱۲-۱۵] با این حال، جمع آوری زباله معمولی بر اساس بسیاری از گمانه زنی ها در مورد سطح پرکردن سطل های زباله، پرکردن جزئی تا تخلیه کامل متفاوت است و منجر به مصرف

موجود ایجاد می‌کند. در شکل ۱، بررسی اجمالی مدل سیستم ارائه شده است.



شکل ۱- بررسی اجمالی مدل سیستم حمل و نقل پسماند شهری

نویسندگان در [۲۷] الگوریتم ممتازی را برای انجام مسیریابی اجباری با فرصت زمان و زمینه تضاد معرفی می‌کنند. مدل ترکیبی از جریان را تشکیل داده و فرمولاسیون جزء بندی را برای دستیابی به بهینه‌سازی چندهدفه تنظیم کرده است. راه‌حل تجربی دیگری در [۲۸] ارائه شده است که در آن نویسندگان جمع‌آوری زباله‌ها را به‌عنوان یک مشکل مسیریابی دوره‌ای کامیون با انبارهای زباله میانی بیان می‌کنند. این مدل شامل جستجوی متغیر منطقه‌ای و برنامه‌نویسی دینامیکی به‌منظور دستیابی به راه‌حل بهینه است. در [۲۹] نویسندگان الگوریتم ژنتیکی چند هدفه را برای حل مسئله مسیریابی دینامیکی پیشنهاد می‌دهند. به طور خاص، مدل فرض می‌کند که مسئله جمع‌آوری زباله می‌تواند به‌عنوان یک مسئله فروشنده سیار (*TSP*) بهینه شود. سپس الگوریتم ژنتیک *TSP* را بهینه می‌کند. نویسندگان در [۳۰] یک روش ابتکاری را برای مسیریابی دینامیکی باتوجه به پارامترهای مختلف قابل تنظیم پیشنهاد می‌کنند. سنسورها مسیریابی کنترل موجودی معکوس را در شبکه زباله متراکم فعال می‌کنند. این نظریه ابتکاری با عدم قطعیت اثرات روزانه و فصلی سروکار دارد.

مدل ارائه شده در [۳۱] به حمل و نقل زباله‌های پلاستیکی که از سایر پسماندهای جامد شهری متمایز شده است، تخصص دارد. طراحی مجدد ابتکاری از مسیرهای مجموعه با استفاده از یک معیار سازگار با محیط‌زیست و متعادل کردن تبادل بین هزینه‌ها و مسائل زیست‌محیطی حاصل می‌شود. سرانجام، در [۳۲] نویسندگان یک مدل مسیریابی دینامیکی را برای حمل و نقل زباله در یک شهر هوشمند پیشنهاد می‌دهند. به طور خاص، فقط در [۳۳] مسئله حمل و نقل زباله به‌عنوان مشکلی مطرح می‌شود که می‌توان با گنجاندن شدن زیرساخت *IoT* در شهرهای هوشمند آن را حل کرد.

در این تحقیق تحقیقات ارائه شده در [۱۱] را با معرفی یک مدل سیستم برای جمع‌آوری زباله در یک شهر هوشمند گسترش می‌دهیم. این مدل دارای یک مدل مسیریابی دینامیکی انعطاف‌پذیر است که مدل مسیریابی دینامیکی را اصلاح می‌کند که در [۳۴] گسترش یافته است.

منابع غیرضروری می‌شود [۱۶]. در [۱۷] مدیریت زباله‌های هوشمند در شهرهای هوشمند بررسی شده است. سطح زباله موجود در سطوحی زباله با کمک سیستم سنسورهای اولتراسونیک شناسایی می‌شود و از طریق سیستم *GSM* به اتاق کنترل مجاز منتقل می‌شود. این امر باعث کاهش تعداد سفرهای حمل و نقل زباله شهری می‌شود و از این رو کل هزینه‌های مرتبط با حمل و نقل زباله را کاهش می‌دهد. در نهایت به حفظ پاکیزگی در جامعه کمک می‌کند. بنابراین، سیستم مدیریت زباله هوشمند باعث حمل و نقل بهینه تر زباله‌های شهری می‌شود. نویسندگان در [۱۸] از برنامه‌ریزی مسیریابی دینامیکی بهبودیافته استفاده می‌کنند. آنها یک هدایتگر متغیر منطقه‌ای را که با مسئله حمل و نقل زباله سازگار است، تقویت می‌کنند. در [۱۹] برای دستیابی به مسیریابی دینامیکی، مدل مسیریابی ارائه می‌شود که این مدل از الگوریتم کلونی مورچگان (*ACS*) استفاده می‌کند. آنها محل قرارگیری سطل‌ها را به‌عنوان یک شبکه فاصله‌دار، بهینه‌سازی می‌کنند و برای اینکه بتوانند توزیع سطل‌ها را در مجموعه‌ای از گروه‌ها جمع کنند، از سایر موارد استفاده می‌کنند.

در [۲۰] نویسندگان ترکیب مسیریابی و بهینه‌سازی برنامه‌ریزی را انجام می‌دهند. داده‌های پیشنهادی کاربردی برای سطل‌های منحصر، مدارهای روزانه نقاط جمع‌آوری شده را بازدید می‌کند. برای مدیریت بهتر سیستم از برنامه‌ریزی استفاده می‌شود. نویسندگان در [۲۱] برنامه‌ریزی مسیریابی پهپادها در نظر گرفتن محدودیت زمانی را بررسی کردند. هدف اصلی این روش به‌حداقل رساندن کل هزینه‌های عملیاتی و هزینه‌های ثابت کامیون است. در [۲۲] نویسندگان با فرض مطالبات مشتریان به‌عنوان متغیرهای فازی، مدل مسیریابی دینامیکی را بر اساس خواسته‌های فازی معرفی می‌کنند. مدل رویکرد تجربی مبتنی بر تئوری اعتبار فازی می‌باشد. یک روش فرمول‌بندی ریاضی در [۲۳] برای تدوین برنامه‌ای از مناطق خدمات، تعریف مسیریابی و طراحی برنامه‌ریزی با در نظر گرفتن راه‌حل‌های جایگزین جدید در مدیریت سیستم به‌عنوان یک کل ارائه شده است.

در [۱۱] نویسندگان مسیریابی را با روزه‌های زمانی ارائه می‌دهند که فعالیت منطقی را در یک شهر تحلیل می‌کنند. مدل مسیریابی بهینه برای یافتن کامیون‌ها برای خالی کردن سطل با یک الگوریتم جستجوی منطقه‌ای بزرگ تطبیق پیدا می‌کند. در [۲۴] نویسندگان روش‌های برنامه‌ریزی دینامیکی را که برای حمل و نقل زباله سطل‌های مسیریابی زیرزمینی به کار می‌رود، ارزیابی می‌کنند. با استفاده از مسیریابی دینامیکی، مقادیر دی‌اکسید کربن موجود در محیط از کامیون‌ها کاهش می‌یابد. در [۲۵] نویسندگان شبیه‌سازی رویداد گسسته برای حمل و نقل زباله از سطل برای مسیر زیرزمینی ارائه می‌دهند. مدل از برنامه‌ریزی دینامیکی برای بهره‌برداری از اطلاعات منتقل شده از طریق سنسورهای حرکتی تعبیه شده در سطل‌های زیرزمینی استفاده می‌کند. نویسندگان در [۲۶] مسیریابی را با یک سیستم اندازه‌گیری سیار روی کامیون‌ها توسعه می‌دهند. آنها مسیریابی دینامیکی احتمالی را انجام می‌دهند که اصلاحات را در طول یا بعد از اجرای مسیریابی

۱۳. میانگین زمان جهت تخلیه در ایستگاه و حداکثر کردن ظرفیت خالی جهت سرویس مجدد، مشخص است.

۱۴. در طول زمان در دسترس، کلیه مخازن باید تخلیه شوند. مسیریابی چند هدفه برای پهپادها یک حوزه پیچیده و چالش برانگیز است که به دلیل محدودیت های مختلف مانند محدودیت های انرژی، محدودیت های محیطی و پویایی محیط، نیاز به روش ها و الگوریتم های پیشرفته برای مسیریابی دقیق و کارآمد دارد. برخی از چالش ها، روش ها و جهت های آینده در مسیریابی چند هدفه برای پهپادها عبارتند از:

- محدودیت های انرژی: پهپادها معمولاً دارای محدودیت های انرژی هستند که نیاز به الگوریتم های بهینه برای مسیریابی دارند تا از انرژی بهینه استفاده کنند.
- پویایی محیط: محیط پهپادها پویا و تغییرات زود روز دارد که نیاز به الگوریتم های تطبیقی برای مسیریابی دارد.
- تعامل با سایر پهپادها و اجسام: در صورت وجود چندین پهپاد یا اجسام دیگر در محیط، نیاز به هماهنگی و همکاری بین آنها برای مسیریابی دقیق و امن است.
- الگوریتم های هوش مصنوعی: استفاده از الگوریتم های هوش مصنوعی مانند یادگیری تقویتی، شبکه های عصبی و الگوریتم های تکاملی برای بهبود مسیریابی پهپادها.
- الگوریتم های تطبیقی: استفاده از الگوریتم های تطبیقی برای تطبیق با تغییرات محیط و بهبود عملکرد مسیریابی در شرایط پویا.
- برای استفاده از یادگیری تقویتی عمیق (*DRL*) در حل *VRP* با پهپاد، ابتدا باید این مسئله را به عنوان یک *MDP* فرمول بندی کنیم. در *MDP*، یک عامل هوشمند (پهپاد) در یک محیط پویا عمل می کند و در هر گام زمانی، بر اساس اطلاعات گذشته خود، یک عمل را انتخاب می کند. انتخاب هر عمل منجر به یک حالت جدید در محیط و دریافت پاداش برای عامل می شود. انجام تحقیق با ایجاد شبکه یادگیری تقویتی عمیق با استفاده از *RNN* ها (دو زیر شبکه رمزنگار (*encoder*) و رمزگشا (*decoder*)) با توجه به محدودیت های استخراج شده مسئله حمل و نقل و با ایجاد دیتاست مناسب جهت برآورد و تحلیل طول مسیر خروجی مسئله انجام گرفت. در مرحله اول این تحقیق، نمونه گیری و دیتای تست موقعیت مکانی سطل های زباله و مقدار درخواست آنها و نیز بازه زمانی سرویس به هر درخواست بصورت مصنوعی تولید می شود. در ادامه با استفاده از یک الگوریتم شیب سیاست برای بهینه سازی پارامترهای آن، مدل و شبکه آموزش دیده، راه حل را به عنوان دنباله ای از نقاط توقف مسیر در زمان واقعی تولید می کند. بهینه سازی پارامترها و ابرپارامترهای مسئله جهت ارایه خروجی مسیر مناسب جهت مسایل بزرگ در نظر گرفته شد. در انتها مقایسه رویکرد استفاده شده با یادگیری تقویتی با الگوریتم های اکتشافی کلاسیک و *OR-Tools* گوگل در مقایسه کیفیت راه حل با زمان محاسبات (پس از آموزش) ملاک خوبی برای

تحقیق در مورد روش اکتشافی و روش فرا ابتکاری به طور فزاینده ای رو به گسترش است [۳۵]. همراه با بهینه سازی ازدحام ذرات گسسته (*PSO*)، راول و همکاران [۳۶] یک روش ابتکاری برای بهبود کیفیت حل ذرات *PSO* برای حل یک مسئله چندهدفه ایجاد کرد. در مقاله [۳۷] یک مسئله مسیریابی وسیله نقلیه را با پنجره زمان (*VRPTW*) جمع آوری زباله توسط یک الگوریتم *simulated annealing* حل کرد. ترکولایی و همکاران [۳۸] الگوریتم کلونی مورچگان بهبود یافته برای مدل پیشنهادی مسئله مسیریابی ظرفیت دار (*CVRP*) ارائه کردند. مقاله [۳۹] الگوریتم ترکیبی ژنتیک را برای حل *VRP* برای حمل و نقل زباله های عفونی طراحی کردند. در [۴۰] یک الگوریتم حریصانه یکپارچه همراه با جستجوی محلی متغیر برای یک مسئله مسیریابی چندهدفه برای جمع آوری و حمل و نقل زباله پیشنهاد کرد. به طور خلاصه، تحقیقات زیادی در مورد الگوریتم ها برای حل مسئله جمع آوری زباله انجام شده است. با این وجود، آنها بیشتر الگوریتم های منفردی هستند که جای الگوریتم های ترکیبی که می توانند از هر دو سو بهترین بهره را ببرند. روش حل دقیق برای حل *VRP* متوسط و بزرگ در زندگی واقعی ناکارآمد است [۴۱]. روش های بهینه سازی زیادی در *SWC* استفاده شده است. با این حال، آنها از نظر همگرایی کند، نظریه پیچیده، قابلیت جستجوی ضعیف و تنظیم پارامترهای خسته کننده دارای اشکالاتی هستند. بنابراین، برای دستیابی به نتایج بهتر از نظر هزینه، مسافت سفر و میزان انتشار، توسعه روش های بهینه سازی کارآمد و قوی در *VRP* مورد نیاز است. بخصوص در مورد مسائل واقعی شهرهای بزرگ، با تعداد درخواست بالا، راه حل های فرا ابتکاری فوق سرعت مناسبی ندارند. شرایط کار برداشت به صورت زیر ارائه شده است:

۱. زمان در دسترس محدود است (زمان سفر برای هر وسیله نقلیه و پهپاد نباید از زمان کل در دسترس تجاوز کند).
۲. تعداد مخازن هر پست - ناحیه - منطقه (تعداد گره در شبکه راه) موجود و ظرفیت هر یک مشخص است.
۳. میانگین زمان سرویس برای هر گره (مشتری) مشخص است.
۴. ظرفیت هر نوع از وسایل نقلیه و یا پهپاد مشخص و ثابت است و هزینه برای هر نوع مقداری ثابت است.
۵. مسیرهای مجاز (زیر مجموعه ای از مسیرهای شبکه راهها) موجود است.
۶. تعداد ماشین های در دسترس مشخص است.
۷. فواصل گره ها و محل تخلیه زباله (ایستگاه) مشخص است.
۸. هر گره فقط توسط یک ماشین سرویس دهی می شود.
۹. هر ماشین شروع و پایان مسیریابی از یک ایستگاه است.
۱۰. مجموع تقاضا برای هر ماشین نباید از ظرفیتش تجاوز کند.
۱۱. سرعت برای وسایل نقلیه مقداری ثابت است.
۱۲. هزینه هر واحد زمانی کارکرد (اجازه) از هر نوع ماشین مشخص است.

ارزیابی بهبود عملکرد با استفاده از یادگیری ماشین به نمایش در آمد.

۳- روش و ابزار گردآوری اطلاعات

تولید داده های آموزشی و تست با استفاده از برنامه نویسی پایتون تولید خواهد شد. مسئله مسیریابی برای تعداد نود ۵۰، ۲۰، ۱۰ و در صورت امکان صد نود حل شد و مقایسه طول مسیر بهینه با خروجی کارهای قبلی انجام می گردد. تعداد نمونه جهت یادگیری مساله، یک میلیون نمونه آموزشی و جهت تست ۱۰۰۰ نمونه می باشد. دیتا بصورت تصادفی تولید می شود. در صورت وجود دیتاست واقعی، جهت مقایسه خروجی، با آن هم امکان تست فراهم می شود. بخشی از موقعیت جغرافیایی و مکانی نیز می تواند از دیتای شهری استفاده شود. جامعه آماری نمونه، مخازن زباله منطقه ۱۱ مدیریت پسماند شهر تهران در نظر گرفته می شود. نمونه گیری بصورت تعداد ۱۲۸ و ۲۵۶ نمونه در هر مرحله یادگیری بود. سیستم جمع آوری پسماند خشک (SWC) از تعدادی سطل زباله مجهز به سامانه اینترنت اشیا (smart waste bins) ماشین حمل زباله و اطلاعات ترافیک تشکیل شده است. حالت سیستم به عنوان ورودی به شبکه وارد شده و این دیتای حجیم جهت آموزش و ارزیابی نهایی مدل بکار می رود. این معماری از ترکیب دو بخش تشکیل شده است. ابتدا دنباله ورودی درخواستها رمزگذاری شده و به برداری از اعداد با طول ثابت تبدیل می شود که به آن، بردار زمینه گفته می شود. سپس برای رمزگشایی، بردار به دنباله خروجی یا همان مسیر بهینه تبدیل می شود. در ادامه یک الگوریتم یادگیری تقویتی برای مدیریت هوشمند حمل و نقل طراحی می کنیم که پارامترهای مدل شبکه عصبی را بدون اطلاع از راه حل بهینه برای داده های آموزشی با حداقل زمان محاسباتی تعیین کند. مدل رمزنگار - رمزگشا LSTM یک شبکه عصبی بازگشتی است که یک دنباله ورودی را به دنباله دیگر نگاشت می کند. (یک دنباله که حالت سیستم پسماند شامل درخواستها و موقعیت مخزن و موقعیت فعلی خودرو یا پهپاد است به عنوان ورودی دریافت می کند و خروجی، دنباله دیگری از عملها است که نشان دهنده توالی انتخاب نود بعدی برای سرویس دهی است.) به همین دلیل به آن مدل seq2seq گفته می شود. در این طرح تحقیقاتی نیز به واسطه تحلیل دنباله مسیر خودرو یا پهپاد از همین ساختار پیشنهادی استفاده شد. در این پیشنهاد یک متا الگوریتم حریصانه اتخاذ شده، به موجب آن یک راه حل عملی با افزودن متوالی گره ها ساخته می شود و برای برآورده ساختن محدودیت های مسئله حفظ می شود. این معماری یادگیری عمیق جدید، ویژگی های گره های شبکه را استخراج می کند که به سیاست اجازه می دهد تا سودمندی هر گره را از هم تفکیک کند. برای طراحی شبکه عصبی پیشنهادی در شبیه ساز از شبکه پوینتر استفاده می کنیم. این شبکه از دو زیر شبکه

رمزنگار و رمزگشا تشکیل شده است. شبکه رمزنگار در ابتدا اطلاعات، وضعیت سیستم و مسیر توسعه داده شده را به عنوان ورودی می گیرد تا سیستم را به ویژگی های تعبیه شده برای هر گره مطابق ساختار تبدیل کند.

در این کار ما سیستم مدیریت حمل و نقل را مدل می کنیم. شبکه حمل و نقل در مسئله WLRP^۱ به صورت یک گراف $\Phi(V, E)$ تعریف می شود. به طوری که هر $i \in V$ در گراف یک نقطه مطلوب را نشان می دهد که نشان دهنده مکان خودرو، انبار و مکان دریافت زباله^۲ است. همچنین هر جفت $i, j \in E$ مختصات جغرافیایی جاده هایی است که نقاط $i \in V$ را به هم وصل می کند یک مسیر واحد بین دو مکان با هزینه مرتبط^۳ که طول آن D_{ij} و مدت زمان طی شده تخمینی جاده توسط خودرو یا پهپاد با T_{ij} نشان داده می شود.^۴

$$V = \{v^i = (s^i, d^i), i = 0, 1, \dots, n\} \quad (1)$$

که v^0 نود اولیه یا همان مخزن و بقیه موقعیت جغرافیایی پراکنده مشتریان یا همان درخواست های حمل و نقل^۵ شهری است و n تعداد سطل های زباله در سطح شهر است.^۶ از نماد $Q \in \bigcup_{k \in K} Q_k$ برای نشان دادن کلیه درخواستها^۷ موجود در سیستم که تاکنون بارگیری نشده اند استفاده می شود. برای هر درخواست $q \in Q$ مختصات دو بعدی مکان درخواست بارگیری زباله با $p_q = (x_q, y_q)$ نشان داده می شود. ظرفیت مورد نیاز هر درخواست پر شدن زباله برای بارگیری در هر خودرو برابر d_q است و قبل از زمان نهایی T_q باید به انبار جمع آوری زباله برسد. اگر بازه های زمانی بصورت سخت تنظیم شوند، وسایل نقلیه اجازه ندارند به مشتریان خارج از روزه های زمانی^۸ (TW) خدمت دهند. وقتی که زود هنگام رسیدند، $arr.t_i < t_{ei}$ وسیله نقلیه باید تا زمان شروع خدمت صبر کند. در عین حال، این امکان وجود ندارد که دیرتر از زمان انتهای سرویس، یعنی زمانی که در حال حرکت هستیم، به مقصد برسیم t_{li} . هر ورودی v_i به صورت دوتایی ترتیبی که شامل پنج ویژگی استاتیک (۲ ویژگی موقعیت مکانی^۹ (x_i, y_i) ، زمان شروع سرویس t_{ei} ، زمان پایان سرویس t_{li} ، زمان خدمت دهی t_{si}) و چهار ویژگی دینامیک (مقدار درخواست d_{it} ، ظرفیت وسیله نقلیه q_{it} ، زمان ورود $arr.t_i$ ، زمان خروج $dep.t_i$) درخواستها است، وارد شبکه انکودر که با استفاده از شبکه عصبی بازگشتی (RNN) ساخته شده است، می شود که آن را به یک فضای

⁶ Number of trash bin in town

⁷ Waste-holding capacity of each container

⁸ Time windows

⁹ coordinate

¹ waste location routing problem

² Coordinate of trash bin

³ Distance weights of the road segments

⁴ Road segment between bins

⁵ Waste generation nodes

بردار ترکیبی از جاسازی گره های همه گره های آموخته شده در GCN به عنوان بردار زمینه عمل می کند. اضافه شدن پنجره های زمانی به مسئله VRP باعث افزایش وابستگی گره می شود. امکان سنجی یک مسیر را فقط می توان با در نظر گرفتن توالی گره به عنوان یک کل تعیین کرد و بر اساس π سیاست بهینه خروجی که خروجی توالی مسیر⁹ را نتیجه می دهد، احتمال مقادیر ترتیبی خروجی نقاط توقف بعدی¹⁰ به صورت زیر محاسبه می شود:

$$P(Y | S) = \prod_{t=0}^{T'} p(y_{t+1} | y(t), S) \quad (4)$$

$$\Phi_{t+1} = f(y_{t+1}, \Phi_t) \quad (5)$$

که این احتمال با تابع نشانگر محاسبه می گردد و در آن S حالت سیستم است و y_{t+1} نقطه توقف بعدی است. در معادله ϵ حالت بعدی سیستم از حالت فعلی و انتخاب درخواست بعدی با تابع f به صورت یک زنجیره مارکوف حاصل می شود. بر اساس توزیع احتمال خروجی از شبکه عملگر¹¹، در هر مرحله توالی مشتری ها می تواند رمزگشایی شود. می خواهیم میزان تاثیر هر کدام از گام های زمانی (Time step) ورودی بر گام های خروجی را مشخص کنیم. برای اینکار از تمامی قسمت های شبکه اول (شبکه ای که یک تجسم از چپش نودهای مبدا می ساخت) به یک شبکه LSTM یک طرفه به صورت وزن دار ورودی می دهیم. که وزن یاد شده در واقع همان Attention ما است.

لایه توجه: برای توصیف شباهت بین وضعیت فعلی و هر نقطه مشتری استفاده می شود. در مرحله t ، رمزگشا¹² برای محاسبه حالت پنهان با اطلاعات گراف (s^i, d_i^i) استفاده می شود، که در آن $\tilde{v} = (\tilde{s}^i, \tilde{d}_i^i)$ خروجی رمزگذار¹³ است. مکانیزم توجه به صورت زیر از روی وزن دهی به همسایگان نودها ایجاد می شود که حالت نهفته هر نود را از مجموع وزن دار همسایگان آن نود ایجاد می کند:

$$u_i^t = v_a^T \tanh(W_a [s_i^r; d_{i,t}^r; h^t]),$$

$$a_i = \text{soft max}(u^t)$$

$$c_t = \sum_{i=0}^n a_i \tilde{v}_i \quad (6)$$

که در آن $[0; \cdot]$ عملگر الحاق بین بردارها است¹⁴ و مقادیر v و W وزن های قابل یادگیری هستند. در VRP، شبکه برای تعیین اینکه آیا مشتری بعدی محدودیت های تقاضا و زمان را برآورده می کند یا نه، از ماسک بهره می گیرد. نکته قابل توجه اینجاست که در لایه توجه، بر

برداری ۱۲۸ بعدی نگاشت می کند. برای مخزن $d_0 = 0$ و $t_0 = [a_0, b_0]$ که a_0 و b_0 ، به ترتیب نشان دهنده زودترین خروج ممکن از و آخرین بازگشت به انبار است. خودرو یا پهپاد از انبار خارج می شود، با توجه به محدودیت های ظرفیت و زمان پنجره به مشتریان یا همان سطل زباله هوشمند خدمات ارائه می دهد و در نهایت به انبار باز می گردد. دنباله ای از مشتریانی که وسیله نقلیه سرویس داده، یک مسیر حمل و نقل π است. تابع هدف² ما تلاش می کند تا تعداد درخواست های لجستیکی وارد شده را ماکزیم کند و در عین حال میزان تخطی از زمان و نیز طول مسیر طی شده برای اجابت درخواست ها کمینه باشد. معادلات ریاضی مربوطه در قبل مورد بحث قرار گرفت. نقاط برداشت³ یا همان نقاط توقف به گونه ای انتخاب خواهند شد تا طول مسیر پیمایشی⁴ وسیله نقلیه کمترین و نزدیک به بهینه باشد.

مقدار درخواست⁵ هر مشتری d_{it} یک عدد صحیح است و درخواست مخزن \cdot است. ماکزیم ظرفیت وسیله⁶ C در هر مسئله با توجه به سایز n متغیر است. این نگاشت اطلاعات ورودی و ویژگی های حالت سیستم، از فضای ۹ بعدی به فضای ۱۲۸ بعدی در جزئی نهفته سازی⁷ انجام می شود.

$$v_i = \{(x_i, y_i, t_{ei}, t_{li}, t_{si}), (d_{it}, q_{it}, arr\ time_{it}, dep\ time_{it})\} \in R^9 \text{ to } R^{128} \quad (2)$$

صرفاً در نظر گرفتن ویژگی های یک گره منفرد (موقعیت، مقدار تقاضا و پنجره زمانی) هیچ اطلاعاتی در مورد دنباله مشتری بهینه به دست نمی دهد. بنابراین، این ساختار زیربنایی نمی تواند به طور مستقیم توسط شبکه عصبی مورد استفاده قرار گیرد. در عوض، ویژگی های گره باید ابتدا در فضایی متفاوت در آنچه ما مرحله تعبیه ورودی می نامیم، مجدداً پیش بینی شوند. همانند ما یک تعبیه ورودی ساده را پیشنهاد می کنیم که در آن هر مجموعه از مشتریان با استفاده از یک لایه کانولوشنی یک بعدی تعبیه شده است. بردار زمینه از یک شبکه کانولوشن گراف⁸ (GCN) تولید می شود. با توجه به تغییر ناپذیری تعبیه در اعمال انتخابی، فقط عناصر استاتیک تعبیه شده اند. این بخش به درک تأثیر تعبیه ورودی بر همگرایی و عملکرد مدل RL اختصاص یافته است که مقادیر وزن های این تبدیل به صورت زیر است:

$$h_i^{(0)} = \begin{cases} w [x_i, y_i, t_{ei}, t_{li}, t_{si}] + b & , i \neq 0 \\ w_0 [x_0, y_0, t_{e0}, t_{l0}, t_{s0}] + b_0 & , i = 0 \end{cases} \quad (3)$$

⁹ Waste route

¹⁰ Stop points

¹¹ Actor network

¹² decoder

¹³ encoder

¹⁴ softmax(\cdot) is the softmax function also known as normalized exponential function

¹ Waste collection route

² objective function

³ Pickup locations

⁴ Waste collection route

⁵ Demand

⁶ Waste-holding capacity of vehicle

⁷ embedding component

⁸ graph convolutional network

تخطی برداشت^۳ انتهای سرویس دهی^۴)
 $\delta_i = \max(arr.t_i - t_{li}, 0)$ را بعنوان المان پنالتی در پاداش نهایی برگشتی از مسیر بصورت وزن دار در نظر می‌گیریم. ما سازگاری پرس‌وجو را با همه گره‌ها محاسبه می‌کنیم و گره‌هایی را که نمی‌توان در زمان t بازدید کرد، mask می‌کنیم. برای VRP، این بدان معنی است که ما درخواست‌هایی را که قبلاً بازدید کرده‌ایم و همچنین گره‌هایی مقدار درخواست آنها بیشتر از ظرفیت فعلی وسیله نقلیه است، ماسک می‌کنیم. در هر قدم از انتخاب نود بعدی مسیر ماشین، بایستی مقادیر دینامیک همچون ظرفیت وسیله نقلیه و مقادیر درخواست‌ها و زمان ورود و خروج از نود به روز رسانی شود. عامل ما در مسئله، وسیله نقلیه است که در هر لحظه t حالت را دریافت می‌کند و بر طبق سیاست تعریف شده $\pi(t)$ را بعنوان عمل^۵ بعدی انتخاب می‌نماید.

به روز رسانی پویا: پس از انتخاب مشتری بعدی برای خدمات‌رسانی، حالت سیستم براساس حرکت وسیله نقلیه تغییر می‌کند. وضعیت استاتیکی بدون تغییر باقی می‌ماند، در حالی که وضعیت دینامیکی به هنگام حرکت وسیله نقلیه به جلو به روز رسانی می‌شود. هنگامی که وسیله نقلیه تصمیم می‌گیرد که به مشتری i خدمت کند، متغیر موقعیت برابر با شاخص مشتری انتخابی (idx) است. در همین حال، تقاضای مشتری انتخاب شده صفر می‌شود و بار وسیله نقلیه^۶ با کم کردن مقدار تقاضا به روز می‌شود $C = C - d_i$. علاوه بر این، زمان پایان این سرویس $dep.t_i = arr.t_i + t_{si}$ است که در آن، $arr.t_i$ زمان ورود است. تابع پاداش^۷، هدف یک مسئله یادگیری تقویتی را تعریف می‌کند.

$$J(\theta | s) = \alpha * E_{\pi} [L(\pi | s)] + \beta \sum \delta_{ei} + \gamma \sum \delta_{li} \quad (10)$$

برای بهینه‌سازی پارامترهای شبکه نشانگر نشان‌دهنده، از تقویت‌کننده سیاست مبتنی بر مدل استفاده شود. هدف آموزشی شبکه، ترکیبی است که شامل طول تور مورد انتظار و نیز مقادیر وزن دار از مجموع زمان تخطی از زمان شروع سرویس و مجموع زمان تخطی از زمان پایان سرویس دهی و برداشت زباله است. در حل مسئله برای طول مسیر و دو تخطی پنجره زمانی با وزن $c1 = 0.30$ و $c2 = 0.70$ در محاسبات پاداش تجمعی فرمول شماره ۱۱ لحاظ گردید که مجموع احتمالات سه وزن برابر یک باشد. باتوجه به گراف ورودی، به‌صورت زیر تعریف می‌شود:

$$Reward = c1 * \sum_{i,j \in s \cup 0} c_{ij} + (c2 / 2) (\sum_{i \in \pi} \delta_{ei} + \sum_{i \in \pi} \delta_{li}) \quad (11)$$

خلاف مرحله دیکدر، اطلاعات دینامیک حالت سیستم هم استفاده می‌شود. نودهایی که سرویس داده شده‌اند و نیز نودهایی که اندازه درخواست آنها از ظرفیت فعلی وسیله بیشتر است، ماسک صفر می‌گیرند و به شکل زیر نشان داده می‌شود:

$$Mask_i^t = \begin{cases} 1, & \text{if node is valid at time } t \\ 0, & \text{otherwise} \end{cases} \quad (7)$$

با انتخاب نود بعدی، مقادیر ویژگی‌های دینامیک نود انتخاب شده و دیگر نودها به صورت زیر تغییر می‌کند. مقدار درخواست نود بعدی انتخابی، صفر می‌شود و مقدار درخواست دیگر نودها تغییری نمی‌یابد.

$$d_i^{t+1} = \begin{cases} \max(0, d_i^t - c^t), & \text{if } k = i \\ d_k^t, & \text{for } k \neq i \end{cases} \quad (8)$$

مقدار درخواست نود انتخابی صفر می‌شود و بار فعلی ناوگان هم مقدار درخواست نود از حجم آن طبق فرمول $q_i^{t+1} = \max(0, q_i^t - d_i^t)$ می‌شود. زمان ورود $(arr.time_{it})$ نیز با توجه به سرعت ماشین که یک در نظر گرفته شده است، از جمع زمان خروج از نود قبلی و فاصله دو نود متوالی انتخاب شده حاصل می‌شود. زمان خروج $(dep.time_{it})$ از نود نیز مجموع زمان ورود و زمان سرویس برداشت زباله می‌شود. طول یک تور^۱ را با جایگزینی π به‌صورت زیر تعریف می‌کند:

$$L(\pi | s) = \|x_{\pi(n)} - x_{\pi(1)}\|_2 + \sum_{i=1}^{n-1} \|x_{\pi(i)} - x_{\pi(i+1)}\|_2 \quad (8)$$

که در آن $\| \cdot \|_2$ میانگین و $|\pi|$ طول دنباله است. هدف ما کاهش طول مسیر معادله ۹ با استفاده از یک مدل DRL است که بتواند سمت راست معادله ۵ را محاسبه نماید. معماری شبکه عصبی با استفاده از قانون زنجیره‌ای احتمال تور را به‌صورت زیر فاکتور می‌گیرد. مدل DRL_WLRP پیشنهادی، که به وسیله θ پارامتری شده‌است، نیاز به تعریف استراتژی $p(\pi|G)$ و انتخاب یک توالی π است. این یک سیاست تصادفی است و می‌تواند به صورت زیر فاکتور شود:

$$p_{\theta}(\pi | s) = \prod_{i=1}^n p_{\theta}(\pi(i) | \pi(< i), s) \quad (9)$$

شبکه اشاره‌گر شامل دو ماژول شبکه عصبی بازگشتی (RNN)، رمزنگار و رمزگشا است که هر دو از سلول‌های حافظه کوتاه‌مدت (LSTM) تشکیل شده‌اند. در اینجا مساله را به صورت نرم در نظر گرفته و تخطی از زمان شروع^۲ ($\delta_{ei} = \max(t_{ei} - arr.t_i, 0)$) و

⁵ action

⁶ Collected waste within the truck

⁷ Reward or collection cost

¹bin collection list

² Ready_Violation

³ Pickup delay

⁴Deadlin_Violation

می‌کند. علاوه بر تولید داده، شبیه‌ساز باید با وسیله نقلیه در حین حرکت تعامل داشته باشد. وقتی وسیله نقلیه^۵ نقطه مشتری بعدی را انتخاب می‌کند، شبیه‌ساز دو جنبه اصلی برای به روز رسانی دارد. یکی به روز رسانی حالت دینامیک و دیگری پنهان کردن نقاط غیرقابل دسترس در زمان دیگری است. الگوریتم بعد از آموزش شبکه با یک بار اجرا و با توجه به موقعیت شروع هر وسیله نقلیه که معمولاً از انبار می‌باشد، کلیه نقاط بعدی مسیر وسیله را مشخص می‌کند. شرط پایان اجرا اینست که نقطه درخواست دیگری در سیستم نمانده باشد. ما شبکه را با رویکرد تصادفی^۶ آموزش می‌دهیم و مدل را با استفاده از روش جستجوی حریصانه و پرتو^۷ ارزیابی می‌کنیم. شبکه منتقد^۸ پاداش را برای هر نمونه از یک حالت مشخص با استفاده از دو لایه مترانک تخمین می‌زند.

تولید داده‌های آموزشی و تست با استفاده از برنامه‌نویسی پایتون تولید شد. در مرحله اول این تحقیق، نمونه‌گیری و دیتای تست موقعیت مکانی سطل‌های زباله و مقدار درخواست آنها و نیز بازه زمانی سرویس به هر درخواست بصورت مصنوعی تولید می‌شود. مسئله مسیریابی برای تعداد نود ۱۰،۲۰،۵۰ و صد نود حل شد و مقایسه طول مسیر بهینه با تست ۱۰۰۰ نمونه خروجی کارهای قبلی انجام گردید. Cost ترکیبی نیز محاسبه و با سه الگوریتم مینا مقایسه شد. تعداد نمونه جهت یادگیری مساله، یک میلیون نمونه آموزشی و جهت تست ۱۰۰۰ نمونه می‌باشد. دیتا بصورت تصادفی تولید می‌شود. نمونه‌گیری بصورت تعداد ۱۲۸ و ۲۵۶ نمونه در هر مرحله یادگیری خواهد بود.

دادگان: پارامترهای تولید دیتا به صورت زیر بودند: در یک مثال VRP TW_n، شبیه‌ساز ابتدا n درخواست و یک انبار ایجاد می‌کند. هر درخواست حمل و نقل دارای ۹ ویژگی است که عمدتاً به دو بخش عناصر ایستا و پویا^۹ تقسیم می‌شوند. بخش استاتیک از متغیرهای ثابت در طول زمان شامل مختصات دو بعدی مکان درخواست (x_i, y_i) و مخزن، پنجره‌های زمانی $[t_{ei}, t_{li}]$ و زمان خدمات، t_{si} تشکیل شده‌است. (x_i, y_i) در بازه $[0, 1] \times [0, 1]$ انتخاب شدند. هر دو

زمان سرویس t_{si} و طول پنجره زمانی Δt به طور تصادفی از $[0, 3]$ و $[3, 10]$ تولید می‌شوند. زمان سرویس دهی عدد ثابت ۰.۱ در نظر گرفته شد. کل بازه خدمت به صورت $T=300$ در نظر گرفته می‌شود. و سرعت خودرو یا پهپاد به صورت $v=1$ در نظر گرفته شده‌است. مقدار عددی درخواست d_i به صورت تصادفی در بازه ۱ تا ۹ انتخاب شد. ظرفیت حمل ماشین پسماند^{۱۰} نیز همانند مقاله [22] برای VRP 10، 20، 50، 100 و 100 VRP مختلف در نظر گرفته شد (LOAD_DICT = { 10: 20, 20: 30, 50: 40, 100: 50}).

جهت تخمین مقدار طول مسیر در شبکه کمک کننده^۱، مناسب‌ترین مدل یادگیری ماشینی که توانایی تقریبی حل مسئله را دارد، به‌عنوان یک شبکه عصبی با یک لایه پنهان و یک تابع فعال‌سازی ReLU انتخاب می‌شود. سپس، ویژگی‌های ورودی که باعث بهبود دقت پیش‌بینی می‌شوند، جستجو می‌شوند. برای بهینه‌سازی پارامترها به روش‌های شیب خط‌مشی و نزولی شیب تصادفی متوسل می‌شویم (REINFORCE algorithm). خروجی شبکه کمک کننده $b(S)$ یک عدد اسکالر است که با دادن S بعنوان ورودی شبکه، تخمین زده می‌شود. این خروجی شبیه به مقادیر تابع هدف بهینه در یک الگوی یادگیری نظارت شده عمل می‌کند. با توجه به ماهیت محاسباتی کارآمد انتشار رو به جلو یک شبکه عصبی (به ویژه در CRITNET) چنین روشی زمان محاسبه را تا حد زیادی کاهش می‌دهد.

(۱۲) $\nabla_{\theta} J(\theta | s) = E_{\pi} [(R(\pi | s) - b(s)) \nabla_{\theta} \log p_{\theta}(\pi | s)]$

در عمل، مقدار مورد انتظار با میانگین نمونه‌گیری مونت کارلو در یک اندازه دسته B جایگزین می‌شود.

(۱۳) $\nabla_{\theta} J(\theta | s) \approx \frac{1}{B} \sum_{i=1}^B [(R(\pi_i | s) - b(s)) \nabla_{\theta} \log p_{\theta}(\pi_i | s)]$

میانگین مربعات خطای هدف شبکه کمک کننده توسط ۱۵ محاسبه می‌شود که به صورت شبه کد الگوریتم ۱، آموزش وزن‌های شبکه مدل DRL_VRP انجام می‌شود. در الگوریتم، پارامترهای مدل به طور مکرر به روز می‌شوند. الگوریتم زمانی خاتمه می‌یابد که پارامترها همگرا شوند، یا به حداکثر تعداد تکرار از پیش تعریف شده رسیده باشد.

(۱۴) $\nabla_{\theta_{bl}} J(\theta_{bl} | s) \approx \frac{1}{B} \sum_{i=1}^B \|R(\pi_i | s) - b(s)\|_2^2$

مقاله یک مدل نشانگر پویا را با معماری رمزگذار - رمزگشایی^۲ ارائه می‌دهد که این مدل را قادر می‌سازد ویژگی‌های گره را به طور دینامیکی کشف کند و از اطلاعات ساختار پنهان به طور مؤثر در مراحل مختلف ساخت بهره‌برداری کند. در هر مرحله ساخت، با توجه به بردار زمینه و تعبیه گره (به جز گره‌هایی که محدودیت‌ها را نقض می‌کند)، رمزگشا توزیع بر روی گره‌ها را پیش‌بینی می‌کند و یکی را برای بازدید و بعنوان نقطه توقف بعدی انتخاب می‌کند.

پارامترهای مسئله، بردار تمام متغیرهای آموزش پذیر مورد استفاده در چارچوب رمزگذار و رمزگشا است. هر نمونه^۳ مسئله VRP به عنوان الحاق مکان‌ها، ظرفیت تقاضا^۴ و پنجره‌های زمانی برای هر گره تعریف می‌شود $S = [X, D, T]$ برای آموزش شبکه، از رویکردهای گرادیان خط مشی شناخته شده استفاده می‌کنیم. روش‌های گرادیان خط مشی به طور مکرر از یک گرادیان تخمینی از بازده مورد انتظار برای به روز رسانی پارامترهای خط مشی استفاده می‌کنند. این شبیه‌ساز ابتدا نمونه‌های آزمایشی VRP عظیمی را برای آموزش و اعتبارسنجی تولید

⁷ greedy and beam search

⁸ critic network

⁹ load, demand, arrival, end service

¹⁰ Waste-holding capacity of truck

¹ critic

² encoder-decoder architecture

³ instance

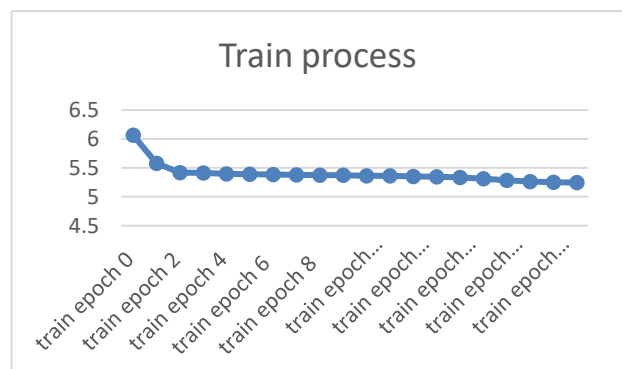
⁴ Waste-holding capacity of each container

⁵ truck

⁶ stochastic approach

۴- محک زدن

در این تحقیق، یک روش جدید بهینه‌سازی ترکیبی بر مبنای شبکه عصبی با یادگیری تقویتی پیشنهاد داده‌ایم به‌گونه‌ای که برنامه مسیریابی خودرو با حداقل زمان محاسباتی برای سرویس‌های حمل‌ونقل آنلاین در شبکه‌های بزرگ انجام می‌شود. برای حل این مسئله برای تعداد ۱۰، ۲۰، ۵۰ و ۱۰۰ درخواست، ما یک شبکه پویتر طراحی کرده‌ایم تا بتوانیم مسیرهای خودرویی را به‌صورت تکراری بسازیم. از آنجایی که پارامترهای آموزشی آفلاین هستند تولید مسیر با کمترین زمان ممکن صورت می‌پذیرد و می‌توانیم با استفاده از آن مسیرهای خودرویی آنلاین در شبکه‌های بزرگ را بسازیم. بدون استفاده از روش پیشنهادی، ساخت یک مجموعه داده آموزشی با هدف بهینه‌سازی مسیر خودرویی برای یک شبکه عصبی آنلاین با حجم زیاد محاسبات غیرعملی است. همچنین ما از مکانیزم توجه یادگیری تقویتی عمیق در مسئله مسیریابی خودرو یا پهپاد استفاده کردیم تا پارامترهای مدل شبکه عصبی به‌خوبی مقداردهی شوند. برای رسیدن به این هدف، ما از یک شبکه عصبی کریٹیک کمک‌کننده^۱ استفاده کردیم تا خروجی مورد انتظار داده آموزشی را تخمین بزنیم. در نهایت، با استفاده از احتمال توزیع خروجی شبکه پویتر یک روش ساختاری چند نمونه‌ای را پیشنهاد می‌دهیم تا مسیرهای خودرویی رمزگشایی شوند. مدل RL زمان بسیار کمتری را برای حل نمونه‌هایی با تعداد ۵۰ یا ۱۰۰ مشتری خرج می‌کند. در انتها نتایج بر روی یک سرور با مشخصات سخت‌افزاری زیر تست گردید و نمودار فرایند آموزش هزینه طول مسیریاب به صورت شکل ۳ بود. آموزش یک مسئله VRP_TW_10 حدوداً ۲۲.۲ ساعت زمان نیاز دارد و با بزرگ شدن مسئله و تعداد نودها، این زمان به ۱۲۰ ساعت برای مسئله با ۱۰۰ درخواست افزایش یافت.



شکل ۳- منحنی طول مسیر در حین آموزش برای هر ۲۰ ایپاک

در شکل ۳ میانگین هزینه راه‌حل‌های پیش‌بینی شده در هر دوره مشاهده می‌کنیم. اگر ما با تنظیم فرآیند آزمایش کنیم، در این مورد، می‌توانیم از نرخ یادگیری رو به زوال استفاده کنیم که فرض می‌کنیم بیشتر تابع هزینه را کاهش می‌دهد. برای بهبود بیشتر نتایج، ما از دو

رویکرد در طول فرآیند تست، جستجوی حریصانه و جستجوی پرتو استفاده می‌کنیم. برای هر مرحله، استراتژی حریصانه بالاترین احتمال نقطه مشتری را به عنوان اقدام انتخاب می‌کند. با این حال، با توجه به عرض پرتو k ، جستجوی پرتو انتخاب‌های بالای k را در یک زمان ذخیره می‌کند و نتایج نهایی را براساس حداکثر احتمال توالی خروجی می‌دهد.

زمان اجرا: مقایسه زمان اجرا سخت‌تر اما مهم است. از آنجا که مدل پایان به پایان است، زمان آموزش در هنگام تجزیه و تحلیل عملکرد کلی روش‌های پیشنهادی در نظر گرفته نمی‌شود. زمان اجرای هر روش با اجرای ۱۰۰۰ نمونه در کل محاسبه می‌شود. تمام زمان محاسبه گزارش شده در عرض چند ثانیه است. که با توجه به زمان ایجاد مسیر بهینه، این خود انگیزه مناسبی برای استفاده از این مدل‌ها در مسایل مسیریابی می‌باشد. این روش به طور مؤثری می‌تواند عملکرد سیستم مدیریت حمل و نقل را در تولید مسیر بهینه (feasible solutions) کامیون‌ها بهبود دهد. زمان اجرا برای روش‌های فرااکتشافی^۲ به طور تصاعدی با تعداد مشتریان افزایش می‌یابد که دلیل آن ماهیت NP-سخت مسئله است.

مدل DRL_WLRP پیشنهادی با الگوریتم‌های مبنای ذکر شده برای VRP_TW و زمان رسیدن به خروجی به ترتیب در جدول ۱ مقایسه شده‌است. ستون اول مبنای اتخاذ شده برای حل گروه‌های مختلف VRP را گزارش می‌کند. ستون دوم نوع و نام الگوریتم را بیان می‌کند که در آن مدل DRL_WLRP پیشنهاد شده در بخش ۳ می‌باشد. ستون‌های دیگر با عناوین "متوسط طول مسیر"، "تخطی از زمان شروع" و "تخطی از زمان پایان سرویس"، "درصد رخداد تخطی زمان شروع" و "درصد رخداد تخطی زمان پایان سرویس" را در گروه‌های مختلف گزارش می‌دهند. برای VRP ، بهترین نتیجه از حل ریاضی با گروبی حاصل می‌شود البته بعلاوه افزایش تعداد پارامترها و متغیرهای محدودیت‌ها حل ریاضی با گروبی نیاز به لایسنس دارد و در حالت عادی جوابگوی حل مسئله نیست. البته در VRP_TW_20 طول مسیر الگوریتم پیشنهادی ما (7.3137) از حل ریاضی نیز بهتر شده است که این موضوع با لحاظ کردن میزان تخطی در هزینه کل قابل توجیه است، چراکه میزان تخطی در حل ریاضی صفر می‌باشد. در جدول 3 مشاهده می‌شود که نتایج بهینه الگوریتم فرابتکاری حتی برای نمونه^۳ ۲۰ نودی نیز زمانبر است. برای هر دو VRP S، مدل DRL_WLRP پیشنهادی می‌تواند به نتایج بهتری نسبت به الگوریتم‌های ساخت مسیر با زمان محاسبه بسیار کوتاه‌تر حتی در اندازه مساله بزرگ دست یابد. روش‌های فرااکتشافی کلاسیک باید هر بار مشکل را از ابتدا حل کنند، درحالی‌که مدل آموزش دیده با توجه به اطلاعات قبلی ذخیره شده در مدل، تلاش کمتری برای محاسبات به خرج می‌دهد.

³ instance

¹ auxiliary critic neural network

² Meta heuristic

جدول ۱- مقایسه پاداش تجمعی و تخطی مدل DRL_WLRP

پیشنهادی با الگوریتم‌های مبنای ذکر شده (Collection Cost: Tour + End Time Violations + Ready Time Violations + Length) *

Instance	1000 instances	Tour Length	Cost *
VRP_10	Proposed DRL_WLRP	5.342	7.4451
	GA	5.4463	8.1094
	PSO	5.818	8.83355
	Exact	4.8124	4.8124
VRP_20	Proposed DRL_WLRP	7.3137	13.3188
	GA	7.3821	21.0585
	PSO	8.74102	32.2614
	Exact	8.4374	8.4374
VRP_50	Proposed DRL_WLRP	14.6873	84.0876
	GA	16.7918	77.8945
	PSO	22.1877	85.9362
	Exact	-	-
VRP_100	Proposed DRL_WLRP	33.0148	107.076
	GA	61.4745	156.857
	PSO	58.728	222.297
	Exact	-	-

عملکرد مدل DRL_WLRP پیشنهادی خود را با روش حل ریاضی Grubi و روش‌های فراابتکاری GA_TW و PSO_TW با روش ذکر شده در بالا مقایسه می‌کنیم. جدول ۲ به ترتیب طول متوسط تور، میزان و درصد تخطی‌های رخ داده، و در انتها کل پاداش تجمعی در روش exact با راه‌حل‌های اولیه مختلف را گزارش می‌کنند. ما می‌توانیم مشاهده کنیم که نتایج بهبود یافته با روش‌های DRL_WLRP، از جمله مدل ما، به طور قابل توجهی بهتر از نتایج کسب شده با الگوریتم‌های فراابتکاری^۱ هم در کیفیت راه‌حل طول مسیر و هم در زمان محاسبه و نیز از لحاظ تخطی‌های صورت گرفته در زمان شروع و پایان سرویس‌دهی است. با در نظر گرفتن VRP_100 به عنوان مثال، نتایج بهبود یافته توسط مدل‌های DRL به میانگین کیفیت جواب طول تور ۳۳۰۱۴۸ با میانگین زمان حل ۱۰۷۰۰۷ ثانیه می‌رسد، در حالی که نتایج بهبود یافته توسط الگوریتم‌های فراابتکاری به بهترین کیفیت جواب با طول تور ۵۸۰۷۲۸ با زمان حل ۲۲۲۰۲۹۷۲ ثانیه می‌رسد. ما بر مقایسه بین PSO با مدل DRL_WLRP خود از نظر کیفیت راه‌حل و زمان محاسبه تمرکز می‌کنیم. با در نظر گرفتن کیفیت راه‌حل با مدل DRL_WLRP برای VRP در تمام ابعاد مساله همچون متوسط طول مسیر یا نیز بصورت پاداش کلی که جمع سه مقدار طول مسیر، تخطی از زمان شروع و پایان در نظر گرفته شود، رقابتی‌تر می‌شود. برای VRP، روش پیشنهادی به نتایج بهتری برای همه گروه‌های تا TW_۱۰۰ دست می‌یابد و همان کیفیت جواب را برای گروه TW_۲۰ و گروه TW_۵۰

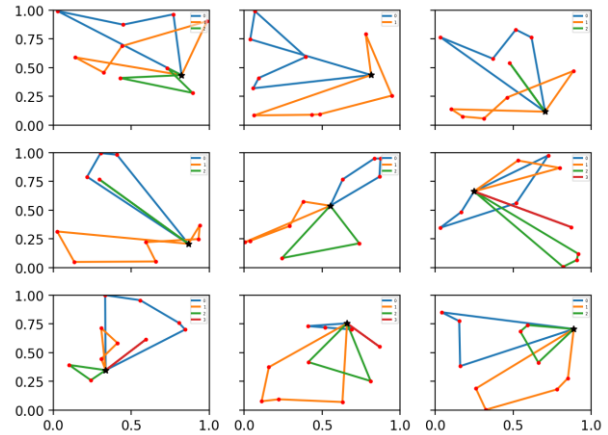
¹Meta heuristic

TW به دست می‌آورد. برای زمان محاسبه، توجه داشته باشید که این دو مدل DRL دارای ویژگی‌های یکسانی از لحاظ سرعت استنتاج می‌باشند. با افزایش تعداد نمونه‌های آموزشی به ۲۰۰۰۰۰۰ نمونه، متوسط طول مسیر خروجی شبکه آموزش دیده بهبود می‌یابد و به عدد ۵۰۲۹۶۶ رسیدیم. ولی تغییر پارامتر مسئله به epoch ۲۰۰، تغییر محسوسی در نتیجه خروجی ندارد. در جدول ۳ مقایسه متوسط زمان محاسباتی و بازه اطمینان ۹۵ درصد برای طول مسیر تور ارائه شده است. مشاهده می‌شود که با افزایش اندازه مسئله به ۱۰۰ نود، متوسط زمان محاسبه طول مسیر برای الگوریتم‌های کلاسیک بطور معناداری افزایش می‌یابد. زمان تولید تور در مدل DRL_WLRP پیشنهادی زیر یک ثانیه می‌باشد و این خود دلیلی بر کاربرد این راه حل در مسایل شهری بزرگ و زمان واقعی است. زمان محاسبات چارچوب ما تقریباً با افزایش اندازه مسئله از ۱۰ نود به ۲۰، ۵۰ و ۱۰۰ نود یکسان باقی می‌ماند، که بسیار سریع‌تر از معیارها است. در مقابل، زمان اجرا برای روش‌های اکتشافی به طور تصاعدی با تعداد مشتریان به دلیل ماهیت NP-hard خود مشکل افزایش می‌یابد. با کاهش اندازه مسئله، روش‌های اکتشافی شروع به نزدیک شدن به نتایج DRL_WLRP می‌کند. این مورد انتظار بود زیرا در بالا دیدیم که OR-Tools در اندازه‌های کوچکتر مسایل از چارچوب DRL بهتر عمل می‌کند.

برای تصور بهتر پیچیدگی و تنوع حل VRP_TW، در شکل ۴ ما یک راه حل تصادفی پیش بینی شده توسط مدل یادگیری عمیق پیشنهادی خود را نشان می‌دهیم. نمونه خروجی شبکه آموزش دیده تست VRP_TW_10 در شکل ۴ نمونه تست در شکل نمایش داده شده است. نود * سیاه رنگ، مخزن و دیگر نقاط قرمز رنگ روی شکل درخواست‌های سرویس از سوی کاربران و یا مخازن هوشمند می‌باشند. در شکل مسیرهای بهینه ایجاد شده که ماشین توسط یادگیری تقویتی آموزش دیده است را نمایش می‌دهیم. برای تمایز بهتر هر مسیر و برگشت ماشین حمل زباله به محل دپو، هر مسیر با یک رنگ نمایش داده شده است. الگوریتم به نحوی شایسته مسیریابی ناوگان را انجام و مسیری بهینه شامل نقاط درخواست را با کمترین طول ارائه می‌نماید. مشاهده می‌شود که الگوریتم به خوبی مسیر نزدیک به بهینه را در زمان کم خروجی می‌دهد. در یک مسئله یادگیری تقویتی با عاملی روبرو هستیم که از طریق سعی و خطا با محیط تعامل کرده و یاد می‌گیرد تا عملی بهینه را برای رسیدن به هدف انتخاب نماید. یادگیری تقویتی از این رو مورد توجه است که راهی برای آموزش عامل‌ها برای انجام یک عمل از طریق دادن پاداش و تنبیه است بدون اینکه لازم باشد نحوه انجام عمل را برای عامل مشخص نماییم. متداول‌ترین روش استفاده از یک شبکه عصبی مکرر (RNN) است زیرا آنها به طور گسترده در توابع یادگیری در مورد توالی‌ها استفاده می‌شوند.

یادگیری تقویتی مدل‌هایی مانند فرایندهای تصمیم‌گیری مارکوف را ارائه می‌دهد که به طور طبیعی تکامل سیستم‌های تصادفی و پویا را به تصویر می‌کشد. فرایندهای تصمیم‌گیری مارکوف چارچوب‌های

ریاضی هستند که برای تشریح محیط در یادگیری تقویتی استفاده می‌شوند و تقریباً همه مسائل این حوزه قابل‌ارائه شدن با MDP ها هستند. بعنوان چالش‌های اصلی مدیریت حمل و نقل به‌عنوان مثال وجود چند انبار و نیز محدودیت پنجره زمانی، در نظر گرفتن خرابی وسیله، اعمال مشکل ترافیک- تصادف و است که بایستی در ارایه مدل مسیریابی داینامیک لحاظ گردد. در انتها ضرورت دارد جهت حل مسایل بزرگ و حل مسئله در زمان سریع، به سمت ارایه الگوریتم‌های یادگیری ماشین و خودکار حرکت کنیم.



شکل ۴- نمایش نمونه راه حل نمونه تصادفی برای اندازه مسئله ۱۰ و مسیر خروجی نمونه تست

۴- خلاصه و نتیجه گیری

فرمول‌بندی VRP با پهپاد به عنوان یک MDP و استفاده از DRL رویکردی نوآورانه برای حل این مسئله پیچیده است. با وجود چالش‌های موجود، این رویکرد پتانسیل بالایی برای بهینه‌سازی مسیرهای پهپاد در سناریوهای مختلف VRP و دستیابی به راه‌حل‌های جدید و کارآمدتر برای مسائل حمل و نقل و لجستیک دارد. مسئله مسیریابی خودرو (VRP) یک مسئله بهینه‌سازی ترکیبی است که به دنبال یافتن بهترین مسیر برای یک یا چند وسیله نقلیه برای بازدید از مجموعه‌ای از نقاط با رعایت محدودیت‌هایی مانند ظرفیت و مسافت است. با ظهور پهپادها، VRP پیچیدگی جدیدی پیدا کرده است، زیرا پهپادها دارای محدودیت‌های خاص مانند برد، ظرفیت حمل و نقل و نیاز به فرود برای شارژ مجدد هستند. در این مقاله پیشنهاد روش جدید بهینه‌سازی با یادگیری تقویتی عمیق جهت مسیریابی ناوگان حمل و نقل با حداقل زمان محاسباتی در شبکه‌های بزرگ با ارایه معماری پویا با توجه به نیاز مسئله حمل و نقل در شهرهای بزرگ و نیز برای پهپادها به همراه ارایه پاداش ترکیبی با توجه به محدودیت‌های مسئله حمل و نقل در مسئله یادگیری تقویتی عمیق و Feasibility rule‌های بهتر و کامل‌تری برای مسئله مورد بررسی که بعنوان چالش‌های اصلی مدیریت حمل و نقل مطرح گردید. (به‌عنوان مثال وجود چند انبار و نیز محدودیت پنجره زمانی، در نظر گرفتن خرابی وسیله، اعمال مشکل ترافیک- تصادف و ...). تلاش برای تحقق خودکارسازی بیشتر در مسیریابی پهپادها با استفاده از الگوریتم‌های هوش مصنوعی، تلاش برای افزایش هماهنگی و همکاری بین پهپادها و سایر اجسام در محیط

برای بهبود عملکرد مسیریابی و استفاده از شبکه‌های سنسور برای جمع‌آوری داده‌های محیط و بهبود دقت مسیریابی پهپادها از اهم موارد و جهت‌گیری‌های آینده هستند. با توجه به پیشرفت فناوری و تحقیقات در این حوزه، انتظار می‌رود که روش‌ها و الگوریتم‌های پیشرفته‌تر برای مسیریابی چند هدفه برای پهپادها توسعه یافته و جهت‌دهنده برای آینده این حوزه باشند. در انتها ارایه مدل شبکه تقویتی عمیق و مکانیزم پاداش و تنبیه با عملکرد بهتر از مسایل ابتکاری و فرابابتکاری مقایسه گردیده و حل ریاضی مسئله نیز با استفاده از حل‌کننده گروبی نیز انجام گرفت. نتایج شبیه‌سازی نشان می‌دهد که مدل DRL_WLRP پیشنهادی نسبت به الگوریتم‌های ریاضی و دیگر مدل‌های DRL عملکرد بهتری داشته و می‌تواند به طور موثری نرخ هم‌گرایی را سرعت بخشیده و کیفیت راه‌حل را بهبود بخشد. ما آزمایش‌ها جامعی را برای ارزیابی عملکرد چارچوب، با استفاده از الگوریتم PSO و GA انجام می‌دهیم. نتایج تجربی نشان می‌دهد که چارچوب پیشنهادی می‌تواند راهبردهای مسیریابی برجسته‌ای را در مقایسه با جستجوی ابتکاری با راه‌حل‌های اولیه تولید شده توسط سایر الگوریتم ایجاد کند. علاوه بر بهبود کیفیت راه‌حل، تولید مسیر چارچوب پیشنهادی زمان محاسباتی کوتاهی را هزینه می‌کند، که این چارچوب را برای مسایلی با اندازه بزرگ امیدوار کننده می‌سازد. در مورد کارهای تحقیقاتی آینده در مورد آموزش شبکه DRL_WLRP با دیتاهای دنیای واقعی، اعمال یادگیری ماشین در مراحل پیش‌بینی درخواست و نیز تعداد ناوگان مورد نیاز و افزودن محدودیت‌هایی همچون مصرف انرژی و نیز خودرو یا پهپادهای الکتریکی زمینه‌های مناسبی خواهد بود. در ادامه، تجزیه و تحلیل عمیق‌تری از ویژگی‌های تعبیه ورودی باید انجام شود و ساختار گرافیکی نمونه‌های مسئله مسیریابی و ارتباط آن با معماری‌های معروف ML مرتبط شود. برخی از راه‌های ممکن برای بهبود عملکرد ترکیب بیشتر الگوریتم‌های کلاسیک با رویکردهای RL باشد.

۵- مراجع

- [1] Aggarwal, S., & Kumar, N. (2020). Path planning techniques for unmanned aerial vehicles: A review, solutions, and challenges. *Computer communications*, 149, 270-299.
- [2] Debnath, S. K., Omar, R., & Latip, N. B. A. (2019). A review on energy efficient path planning algorithms for unmanned air vehicles. *Computational Science and Technology: 5th ICCST 2018*, Kota Kinabalu, Malaysia, 29-30 August 2018, 523-532.
- [3] P. Fernandez-Aracil, A. Ortuno-Padilla and J. Melgarejo-Moreno. (2018). "Factors related to municipal costs of waste collection service in Spain," in *J. Clean. Prod.*, 175, 553-560., 2018.
- [4] Khan, A. H., López-Maldonado, E. A., Khan, N. A., Villarreal-Gómez, L. J., Munshi, F. M., Alsabhan, A. H., & Perveen, K. (2022). Current solid waste management strategies and energy recovery in developing countries- State of art review. *Chemosphere*, 291, 133088.

- [۱۹] بابایی، محسن. (۱۴۰۱). مسیریابی وسایل نقلیه حمل کالا با قابلیت در نظر گرفتن محدودیت ظرفیت و هزینه ثابت بکارگیری ناوگان. فصلنامه مهندسی حمل و نقل.
- [20] Chaudhari, M. S., Patil, B., & Raut, V. (2019, March). Iot based waste collection management system for smart cities: an overview. In 2019 3rd International Conference on Computing Methodologies and Communication (ICCMC) (pp. 802-805). IEEE.
- [21] Kuo, R. J., Lu, S. H., Lai, P. Y., & Mara, S. T. W. (2022). Vehicle routing problem with drones considering time windows. *Expert Systems with Applications*, 191, 116264.
- [22] Phonphoton, N., & Pharino, C. (2019). A system dynamics modeling to evaluate flooding impacts on municipal solid waste management services. *Waste Management*, 87, 525-536.
- [23] Raucq, J., Sørensen, K., & Cattrysse, D. (2019). Solving a real-life roll-on-roll-off waste collection problem with column generation. *Journal on Vehicle Routing Algorithms*, 2(1), 41-54.
- [24] Guo, N., Qian, B., Na, J., Hu, R., & Mao, J. L. (2022). A three-dimensional ant colony optimization algorithm for multi-compartment vehicle routing problem considering carbon emissions. *Applied Soft Computing*, 127, 109326.
- [25] Hemidat, S., Oelgemöller, D., Nassour, A., & Nelles, M. (2017). Evaluation of key indicators of waste collection using GIS techniques as a planning and control tool for route optimization. *Waste and Biomass Valorization*, 8(5), 1533-1554.
- [26] Sulemana, A., Donkor, E. A., Forkuo, E. K., & Oduro-Kwarteng, S. (2018). Optimal routing of solid waste collection trucks: a review of methods. *Journal of Engineering*, 2018.
- [27] A. Nadizadeha and H. H. Nasaba, . (2014). "Solving the Dynamic Capacitated Location-Routing Problem with Fuzzy Demands by Hybrid Heuristic Algorithm", *European Journal of Operational Research*, In Press Available Online, Elsevier.
- [28] Jorge, D., Antunes, A. P., Ramos, T. R. P., & Barbosa-Póvoa, A. P. (2022). A hybrid metaheuristic for smart waste collection problems with workload concerns. *Computers & Operations Research*, 137, 105518.
- [۲۹] کیگانی، محمدحسین، شاهبندرزاده، حمید، حیدری، ابراهیم، & امیری، سید نورالدین. (۱۴۰۱). ارائه مدل چندهدفه فازی - استوار برای مسأله مکان‌یابی - تخصیص - مسیریابی موجودی سبز در بهینه‌سازی فرایند مدیریت پسماند شهری با استفاده از الگوریتم‌های فراابتکاری. فصلنامه مهندسی حمل و نقل، ۴(۱۳)، ۱۹۸۳-۲۰۰۸. doi: 10.22119/jte.2021.282693.2525
- [30] Vu, H. L., Ng, K. T. W., Fallah, B., Richter, A., & Kabir, G. (2020). Interactions of residential waste composition and collection truck compartment design on GIS route optimization. *Waste management*, 102, 613-623.
- [31] Abdallah, M., Adghim, M., Maraqa, M., & Aldahab, E. (2019). Simulation and optimization of dynamic waste collection routes. *Waste Management & Research*, 37(8), 793-802.
- [32] Vasagade, T. S., Tamboli, S. S., & Shinde, A. D. (2017, March). Dynamic solid waste collection and management system based on sensors, elevator and GSM. In 2017 International conference on inventive communication and
- [5] Nanda, S., & Berruti, F. (2021). Municipal solid waste management and landfilling technologies: a review. *Environmental chemistry letters*, 19(2), 1433-1456.
- [6] M. Kharat, S. Murthy, S. Kamble, R. Raut, S. Kamble and M. Kharat. (2019). "Fuzzy multi-criteria decision analysis for environmentally conscious solid waste treatment and disposal technology selection.," in *Technol. Soc.* 57, 20–29 . .
- [7] P. Andrey, I. Valentina and S. Yuri. (2020). "Strategic approaches to management in the field of solid municipal waste management.," in *Talent Dev. Excell.* 12, 700–709 . .
- [8] S. Nesmachnow, D. Rossit and J. Toutouh, . (2018). "Comparison of Multiobjective Evolutionary Algorithms for Prioritized Urban Waste Collection in Montevideo.," in *Uruguay. Electron. Notes Discret. Math.* , 69, 93–100 .
- [9] G. Ghiani, D. Laganà, E. Manni and C. Triki. (2012). ". Capacitated location of collection sites in an urban waste management system.," in *J. Waste Manag.* 32, 1291–1296 .
- [10] E. Tirkolaee, P. Abbasian, M. Soltani and S. Gha arian. (2019). " Developing an applied algorithm for multi-trip vehicle routing problem with time windows in urban waste collection: A case study.," in *Waste Manag. Res.* , 37, 413 .
- [11] Hannan, M. A., Akhtar, M., Begum, R. A., Basri, H., Hussain, A., & Scavino, E. (2018). Capacitated vehicle-routing problem model for scheduled solid waste collection and route optimization using PSO algorithm. *Waste management*, 71, 31-41 .
- [12] M. H. M. A. B. R. A. B. H. & S. E. Akhtar. (2017). "Backtracking search algorithm in CVRP models for efficient solid waste collection and route optimization ",in *Waste Management*, 61, 117-128 .
- [13] A. Expósito-Márquez, C. Expósito-Izquierdo, J. Brito-Santana and J. Moreno-Pérez. (2019). " Greedy randomized adaptive search procedure to design waste collection routes in La Palma.," in *Comput.Ind. Eng.* , 137 .
- [14] Hashemi-Amiri, O., Mohammadi, M., Rahmanifar, G., Hajiaghaci-Keshteli, M., Fusco, G., & Colombaroni, C. (2023). An allocation-routing optimization model for integrated solid waste management. *Expert Systems with Applications*, 227, 120364.
- [15] S. Jaeger, J. Eyckmans, N. Rogge and T. Puyenbroeck. (2011). "Wasteful waste-reducing policies? The impact of waste reduction policy instruments on collection and processing costs of municipal solid waste.," in *Waste Manag.* , 31, 1429–1440 .
- [16] F. Melakessou, P. Kugener, N. Alna_akh, S. Faye and D. Khadraoui. (2020). "Heterogeneous Sensing Data Analysis for Commercial Waste Collection.," in *Sensors (Basel, Switzerland)* , 20, 978.
- [17] Bhor, V., Morajkar, P., Gurav, M., Pandya, D., & Deshpande, A. (2015). Smart garbage management system. *International Journal of Engineering Research & Technology (IJERT)*, 4(03), 2000.
- [18] Nižetić, S., Šolić, P., González-de, D. L. D. I., & Patrono, L. (2020). Internet of Things (IoT): Opportunities, issues and challenges towards a smart and sustainable future. *Journal of Cleaner Production*, 274, 122877.

- [37] İ. İlhan. (2020). "A population based simulated annealing algorithm for capacitated vehicle routing problem ",in Turkish Journal of Electrical Engineering & Computer Sciences, 28(3), 1217-1235.
- [38] E. Tirkolaee, M. Alinaghian, A. Hosseinabadi, M. Sasi and A. Sangaiah. (2019)." An improved ant colony optimization for the multi-trip Capacitated Arc Routing Problem.," in Comput. Electr. Eng. , 77, 457–470.
- [39] N. Wichapa and P. Khokhajaikiat. (2018). "Solving a multi-objective location routing problem for infectious waste disposal using hybrid goal programming and hybrid genetic algorithm.," in Int. J. Ind. Eng. Comput. , 9, 75–98.
- [40] L. Delgado-Antequera, R. Caballero, J. Sánchez-Oro, J. Colmenar and R. Martí. (2020). " Iterated greedy with variable neighborhood search for a multiobjective waste collection problem.," in J. Expert Syst. Appl. , 145, 113101.
- [41] J Liu, M., Song, Q., Zhao, Q., Li, L., Yang, Z., & Zhang, Y. (2022). A hybrid BSO-ACO for dynamic vehicle routing problem on real-world road networks. IEEE Access, 10, 118302-118312..
- computational technologies (ICICCT) (pp. 263-267). IEEE.
- [33] Lavigne, C., Inghels, D., Dullaert, W., & Dewil, R. (2023). A memetic algorithm for solving rich waste collection problems. European Journal of Operational Research, 308(2), 581-604.
- [34] Bhargava, K., Gupta, R., Singhal, A., & Shrinivas, A. (2019). Genetic Algorithm to Optimize Solid Waste Collection. In Proceedings of the 3rd International Conference of Recent Trends in Environmental Science and Engineering (RTESE'19) .
- [35] J. De Armas, B. Melian-Batista, J. Moreno-Perez and J. Brito. (2015). " GVNS for a real-world Rich Vehicle Routing Problem with Time Windows.," in Eng. Appl. Artif. Intell. , 42, 45–56, 2015.
- [36] H. Rau, S. Budiman and G. Widyadana. (2018)."Optimization of the multi-objective green cyclical inventory routing problem using discrete multi-swarm PSO method.," in Transp.Res. Part E-Logist. Transp. Rev. , 120, 51–75 .