

МОДЕЛИ ПРИНЯТИЯ РЕШЕНИЙ С ПРИМЕНЕНИЕМ ИНСТРУМЕНТОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ПРИ ПЛАНИРОВАНИИ ИНТЕРМОДАЛЬНЫХ МАРШРУТОВ

Лондарь В.А., Лахметкина Н.Ю.¹

¹ Российский университет транспорта

Аннотация: в настоящее время индустрия контейнерных перевозок активно развивается благодаря внедрению новых технологий и современных информационных систем. Они позволяют оптимизировать процессы управления цепочками поставок и автоматизировать транспортно-логистические процессы, что в свою очередь повышает эффективность управления. При этом, одной из важных задач при планировании интермодальной перевозки является выбор оптимального маршрута, что напрямую влияет на стоимость и скорость доставки груза. Для ее решения необходимо разработать инструмент, с помощью которого будет возможно оперативно анализировать все сценарии перевозки, выбирать оптимальный маршрут и предлагать его клиенту. В статье рассматриваются существующие методы машинного обучения, применяемые для оптимизации маршрута транспортных средств. Основная цель данной статьи заключается в исследовании разработанных решений для их дальнейшего применения в транспортно-логистических процессах. Внедрение изученных инструментов поможет участникам транспортно-логистического рынка эффективно сопоставлять инфраструктурные возможности с возникающим спросом на перевозки.

Ключевые слова: интермодальные перевозки, модели принятия решений, машинное обучение, искусственный интеллект, логистика.

© Лондарь В.А., Лахметкина Н.Ю.

Поступила 25.05.2024, одобрена после рецензирования 18.06.2024, принята к публикации 18.06.2024.

Для цитирования:

Лондарь В.А., Лахметкина Н.Ю. Модели принятия решений с применением инструментов искусственного интеллекта при планировании интермодальных маршрутов // Логистика и управление цепями поставок. - 2024. - Т. 21, №1 (110). - С. 52–61.

Лондарь В.А., аспирант, 751men@gmail.com, Российский университет транспорта (МИИТ), Москва, Россия;

Лахметкина Н.Ю., к.т.н., доцент, naturla@mail.ru, Российский университет транспорта (МИИТ), Москва, Россия, AuthorID: 528739.

Введение

Последние достижения в области информационных технологий и логистических систем привели к значительному увеличению числа транспортно-логистических компаний. Поскольку рынок становится более конкурентным из-за глобализации, быстрого технологического прогресса, короткого жизненного цикла продукции и высоких ожиданий клиентов, компаниям необходимо своевременно предоставлять высококачественную инновационную продукцию по доступным ценам. По мере усложнения сетей поставок увеличивается количество производимых и подлежащих транспортировке грузов, а также количество маршрутов доставки и способов транспортировки. Учитывая такую сложность логистических операций и текущий уровень развития информационных технологий, необходима разработка современных моделей принятия решений, основанных на технологии искусственного интеллекта, в том числе машинного обучения, которые помогут компаниям разумно использовать ресурсы, чтобы оперативно реагировать на спрос клиентов.

В связи с Указом Президента Российской Федерации от 7 мая 2024 г. № 309 «О национальных целях развития Российской Федерации на период до 2030 года и на перспективу до 2036 года»¹, особое значение приобретает

повышение эффективности транспортной логистики, что требует применения передовых технологий и инновационных подходов. В этом контексте, анализ возможностей использования искусственного интеллекта для оптимизации маршрутов представляется актуальной задачей.

Для успешного внедрения машинного обучения в сферу интермодальных перевозок требуется активное участие всех заинтересованных сторон, включая грузоотправителей, перевозчиков, операторов терминалов и государственных органов. Необходимо создать единую базу знаний, которая будет содержать информацию о текущих маршрутах, условиях перевозок, требованиях к грузам и других параметрах. Это позволит алгоритмам программы более точно прогнозировать спрос на перевозки, оптимизировать маршруты и принимать решения в режиме реального времени. Таким образом, совместная работа всех участников транспортного процесса является ключевым фактором для успешного внедрения технологий машинного обучения в сферу интермодальных перевозок.

В следующем разделе будут изучены существующие подходы к анализу данных, основанные на применении методов машинного обучения.

Обзор существующих методов анализа данных с использованием машинного обучения

В современном мире данные играют ключевую роль во всех сферах деятельности человека. Объемы информации растут с каждым днем, и для эффективной работы с ними используются различные методы анализа данных. Одним из наиболее перспективных направлений является машинное обучение.

Машинное обучение – это область искусственного интеллекта, которая занимается созданием алгоритмов, способных обучаться на основе данных и делать прогнозы. Такие алгоритмы могут автоматически выявлять закономерности в больших объемах данных, что

позволяет использовать их для решения широкого спектра задач.

Существует множество методов машинного обучения, каждый из которых имеет свои особенности и применяется в зависимости от конкретной задачи². Некоторые из них основаны на статистике, другие используют нейронные сети или комбинации различных подходов.

В данном разделе рассмотрены 5 основных методов машинного обучения, их преимущества и недостатки, а также примеры ис-

¹ Указ Президента Российской Федерации от 7 мая 2024 г. № 309 «О национальных целях развития Российской Федерации на период до 2030 года и на перспективу до 2036 года»

² Сорокин Денис Методы машинного обучения: [Электронный ресурс] // itglobal URL: <https://itglobal.com/ru-ru/company/blog/metody-mashinnogo-obucheniya/>. (Дата обращения: 10.05.2024).

пользования каждого метода в транспортной логистике.

1. Классификация — это метод машинного обучения, который используется для определения категории объекта на основе его характеристик. В транспортной логистике этот метод может использоваться для определения типа груза или вида транспорта.

Рассмотрим использование классификации. Компания занимается доставкой грузов и хочет оптимизировать процесс выбора транспорта для каждой партии товара. Для этого она собирает данные о предыдущих перевозках (например, вес груза, объем, расстояние до пункта назначения), а затем использует метод классификации для определения наиболее подходящего вида транспорта для каждой партии товара. В этом случае, классификатор будет обучаться на основе данных о выполненных перевозках и выявлять закономерности между характеристиками груза и выбранным видом транспорта. После обучения классификатор сможет автоматически определять наиболее подходящий вид транспорта для новых партий товара, что позволит компании значительно сократить время на принятие решений и повысить эффективность работы.

2. Регрессия — это метод машинного обучения, который используется для предсказания непрерывных значений на основе входных данных. В транспортной логистике регрессия может использоваться для прогнозирования условий перевозки на основе данных о характеристиках подвижного состава, пути следования и количестве груза.

Примером использования регрессии может служить прогнозирование времени доставки груза. Для этого можно использовать такие входные данные, как расстояние перевозки, тип груза, условия транспортировки, тип подвижного состава, количество перегрузок в пути следования и другие. Еще одним примером использования метода регрессии может быть прогнозирование стоимости перевозки. Здесь также можно использовать различные входные данные, такие как расстояние до пункта назначения, тип груза, объем груза, вид транспорта, стоимость тарифа за перевоз-

ку, стоимость погрузо-разгрузочных операций и другие.

Важно отметить, что точность прогнозов зависит от качества входных данных и правильности выбора модели регрессии. Поэтому перед использованием метода важно провести тщательный анализ.

3. Кластеризация — это метод машинного обучения, который используется для группировки объектов в наборы, называемые кластерами, на основе их сходства или близости. В транспортной логистике кластеризация может использоваться для группировки клиентов или грузов по регионам или типам.

Предположим, у нас есть список клиентов, которым нужно доставить товары. Каждый клиент имеет свои координаты (географическое положение). Используя метод кластеризации, мы можем разделить всех клиентов на группы (кластеры), основываясь на их географическом положении. Затем мы можем определить оптимальный маршрут для каждого кластера, чтобы минимизировать затраты на транспортировку.

Для этого мы можем использовать различные алгоритмы кластеризации, такие как K-средних, DBSCAN или HDBSCAN. Эти алгоритмы позволяют нам определить количество кластеров (K) и критерии принадлежности объекта к определенному кластеру.

4. Обучение с подкреплением (Reinforcement Learning, RL) — это метод машинного обучения, который используется для обучения агентов, основанный на принципах поведения живых организмов. В этом методе агент взаимодействует со средой, получает награду или штраф за свои действия и пытается максимизировать общую сумму награды. В транспортной логистике RL может быть использован для решения различных задач, таких как оптимизация маршрутов доставки, управление парком транспортных средств и планирование ресурсов.

Например, транспортная компания хочет оптимизировать маршруты доставки грузов. Она использует обучение с подкреплением для создания агента, который может учиться на основе предыдущего опыта. Агент принимает решения о том, какой маршрут выбрать,

основываясь на таких факторах, как время, стоимость и безопасность. Это позволит компании снизить затраты и повысить качество предоставляемых услуг.

5. Глубокое обучение (Deep Learning) — это метод машинного обучения, который использует нейронные сети для обработки больших объемов данных и обучения сложных моделей. В отличие от традиционных методов машинного обучения, где используются линейные модели, глубокое обучение использует многослойные нейронные сети, способные обрабатывать большие объемы данных и обнаруживать сложные закономерности.

В транспортной логистике глубокое обучение может быть использовано для решения различных задач, таких как прогнозирование спроса на товары, оптимизация маршрутов

доставки, распознавание образов (например, распознавание номерных знаков автомобилей на парковках), анализ данных с датчиков (например, мониторинг состояния транспортных средств) и многое другое.

Предположим, есть большой объем данных о прошлых заказах и их статусах. Необходимо предсказать вероятность успешной доставки товара в определенном регионе. Для этого можно использовать модель глубокого обучения, которая будет анализировать данные и предсказывать вероятность успеха доставки на основе различных факторов, таких как погода, дорожные условия, время года и т.д. Эта информация может быть использована для оптимизации маршрутов доставки и повышения эффективности работы логистических компаний.

Таблица 1


Методы анализа данных

Метод	Пример использования
Классификация	Автоматическое определение оптимального вида транспорта для новых партий товара.
Регрессия	Прогнозирование времени доставки груза и стоимости перевозки.
Кластеризация	Определение оптимального маршрута доставки груза путем объединения клиентов в кластеры (группы).
Обучение с подкреплением	Определение оптимального маршрута доставки груза путем обучения искусственного агента, который принимает решения на основе собственного опыта. Агент прогнозирует маршрут учитывая такие факторы как: безопасность, время доставки, стоимость перевозки.
Глубокое обучение	Определение оптимального маршрута доставки груза на основе данных о текущем состоянии транспортной системы. Сортировка грузов на складе.

Метод обучения с подкреплением (RL) является более предпочтительным, так как он позволяет агенту обучаться в процессе взаимодействия со средой, что особенно полезно в ситуации, при которой условия и требования к перевозкам динамически изменяются. Он позволяет агенту самостоятельно принимать решения и корректировать свое поведение на

основе полученных результатов, что делает его очень эффективным инструментом.

В процессе обучения агент самостоятельно определяет наиболее эффективные действия для достижения максимального вознаграждения. Для этого он запоминает ранее изученные действия, чтобы использовать их в будущем. Общая схема обучения с подкреплением представлена на рисунке 1.

Рисунок 1. Схема обучения с подкреплением³

Основная цель метода обучения с подкреплением заключается в решении марковского процесса принятия решений, где вознаграждение изначально неизвестно. Марковский процесс принятия решений (Markov decision process, MDP) — это математическая модель дискретно-временной динамической системы, которая используется для моделирования принятия решений в контексте частично вывода, а также частично вывода, контролируемого лицом, принимающим решение. Компонентами MDP являются: состояние системы в мо-

мент времени t (S_t), действие, предпринятое в момент времени t (A_t), и вознаграждение в момент времени t (R_t).

Далее в статье рассматриваются методы обучения с подкреплением (RL) и различные их комбинации с глубоким обучением (DL). Данные методы уже успешно применяются для решения задачи оптимизации маршрута транспортного средства [3], из чего следует, что можно рассмотреть их интеграцию в транспортную логистику для создания собственной модели принятия решений.

Обзор методов решения задачи оптимизации маршрута транспортного средства с помощью машинного обучения

Задача оптимизации маршрута транспортного средства (Vehicle Routing Problem, VRP) десятилетиями изучается в прикладной математике и информатике. Она представляет собой сложный вычислительный процесс, и для ее решения были предложены различные точные и эвристические алгоритмы. Однако достижение быстрых и надежных решений остается актуальной проблемой. В базовой форме VRP одно транспортное средство осуществляет доставку товаров в несколько пунктов назначения, при исчерпании товаров транспортное средство возвращается на склад. Основная цель заключается в оптимизации маршрутов, которые начинаются и заканчиваются в определенном узле, известном как депо, с целью максимизации потенциального вознаграждения, которое обычно представляет собой от-

рицательную величину, отражающую общий пробег транспортного средства или среднее время обслуживания.

Перспектива открытия новых алгоритмов без необходимости проведения специфических рассуждений делает нейронные сети и обучение с подкреплением привлекательными методами, которые могут стать значимым шагом на пути к решению данных задач.

На основе уже проведенных исследований Налеп Дж. [5] представил обзор подходов к решению VRP основанных на данных систем умной доставки. Все методы он разделил на три группы:

- использование машинного обучения для решения VRP путем настройки гиперпараметров существующих алгоритмов;

³ Сименс Эдуард Обобщенная схема обучения с подкреплением: [Электронный ресурс] // ResearchGate URL: https://www.researchgate.net/figure/Generalized-Reinforcement-Learning-scheme-15_fig3_329510901. (Дата обращения: 11.05.2024).

- гибридные алгоритмы, использующие машинное обучение для решения VRP;
- использование алгоритмических методов машинного обучения на основе данных для решения VRP.

Кроме того, в своей работе Налепе Дж. дает краткий обзор применений этих алгоритмов.

В работе Мохаммадреза Назари и его коллег [4] предложена сквозная структура, которая включает обучение единой эвристической модели для решения широкого спектра задач идентичного размера. Авторы внесли дополнительный уровень управления в механизм кодирования/декодирования, что способствовало оптимизации логики с использованием RL. Предложенная модель, основанная на RL, не требует вычисления матрицы расстояний и не нуждается в повторном обучении для новых событий, если задачи генерируются на основе обучающего распределения. Это повышает её практическую ценность и масштабируемость при увеличении объема задачи, сохраняя при этом высокую производительность и конкурентоспособность.

Кул, Ван Хуф и Веллинг [6] предложили использовать мощную модель, основанную на внимании и обучить ее с помощью подкрепления (RL) на основе простой, но эффективной базовой программы «жадного» внедрения. Цель метода заключается в использовании гибкого подхода к решению множества не масштабных задач маршрутизации с помощью одного набора гиперпараметров.

Хао совместно с соавторами [7] предложили подход «учись улучшать», который совершенствует решения путем обучения с помощью оператора улучшения, выбранного контроллером на базе RL. Оператор улучшения выбирается из пула мощных операторов, специфичных для RL. Они использовали те же настройки, что и Кул в [6] и сравнили полученные результаты, с целью минимизировать стоимость плана маршрутизации, не нарушая при этом ограничений по пропускной способности транспортного средства.

Ю Дж. Дж. в своей работе [8] преобразовал VRP в задачу создания автомобильных туров и предложил сеть указателей (pointer

network, PN) со встроенным структурированным графом с помощью инструмента Structure2Vec для разработки распределительной системы решения автономных VRP в режиме онлайн, называемой зеленой логистической системой. В тестовом исследовании были использованы данные о транспортной сети и дорожном движении в Кельне, Германия. Картографические данные для города были взяты из OpenStreetMap, а скорость движения на каждой дороге в сети. В качестве примера были использованы характеристики запаса хода электромобилей Tesla Model S, X и Nissan Leaf. При автономном обучении затрачивалось минимальное время на вычисления, что делало стратегию исследования перспективной для онлайн решения VRP. Однако из-за сложности создания контролируемого обучающего набора данных для нейронных сетей был разработан альтернативный метод в виде использования глубокого обучения с подкреплением (Deep reinforcement learning, DRL) для точной настройки параметров модели нейронной сети. Данный подход продемонстрировал выдающиеся возможности предложенной стратегии по сравнению с традиционными методами, основанными на математическом программировании.

В работе [9] Чжао Дж. и его коллеги представили модель глубокого обучения с подкреплением (DRL), которая основана на концепции «актера», использующего механизм внимания для создания стратегий маршрутизации и адаптивной критики, отвечающий за изменение структуры сети и работу с симулятором маршрутизации. Эта модель DRL была объединена с локальным поиском для улучшения качества предлагаемых решений. Эффективность этой модели была проверена на трех различных наборах данных, содержащих 20, 50 и 100 клиентских местоположений соответственно. Применение комбинированного подхода, включающего модель глубокого обучения с алгоритмами локального поиска, обеспечило получение высококачественных решений при сокращении времени генерации. Полученные результаты подтвердили высокую эффективность DRL подхода по сравнению

нию с традиционными алгоритмами построения и другими методами DRL.

В представленном обзоре были рассмотрены особенности разных подходов к решению

задачи оптимизации маршрута транспортного средства. В таблице 2 представлены основные из описанных методов оптимизации.

Таблица 2

Основные методы оптимизации маршрута транспортного средства

Способ обучения	Нововведение	Авторы
Обучение с подкреплением (RL)	Дополнительный уровень управления. Предложенная модель не нуждается в переобучении для новых событий, если задачи генерируются на основе обучающего распределения.	М.Назари, Ороджлой А., Снайдер Л., Такач М.
Обучение с подкреплением (RL)	Модель, основанная на уровнях внимания, вместо сети указателей, обученная с помощью простой базовой линии и программы «жадного» внедрения.	Кул В., Ван Х., Уэллинг М.
Обучение с подкреплением (RL)	Обучение модели с помощью оператора улучшения.	Лу Х., Чжан Х., Ян С.
Глубокое обучение с подкреплением (RL)	Для настройки параметров модели нейронной сети применили обучение с подкреплением.	Ю Дж. Дж., Ю В., Гу Дж.
Глубокое обучение с подкреплением (RL)	DRL модель основанная на концепции «актера». Применили комбинированный подход, включающий объединение модели DRL с алгоритмами локального поиска.	Чжао Дж., Мао М., Чжао Х., Цзоу Дж.

Эвристические методы показывают многообещающие результаты позволяющие снизить затраты на логистику, но для реализации этих идей в реальном мире понадобятся более совершенные модели и подходы к обучению. Кроме того, процесс обучения регулируется разработанными вручную правилами, что ограничивает его эффективность. Что касается глубокого обучения с подкреплением, его

процесс очень трудоемкий, при расчетах объем решения увеличивается экспоненциально с увеличением объема вводимых данных, таким образом, поиск оптимального решения требует больших вычислительных мощностей. Так же некоторые модели требуют переобучения, как только процесс выходит за рамки обучающего распределения, что приводит к неосуществимому подходу к решению задачи.

Заключение

В данной статье представлен анализ подходов, основанных на обучении с подкреплением (RL), которые были предложены для решения задачи оптимизации маршрута транспортных средств (VRP) и ее вариаций.

Исследования показали, что глубокое обучение с подкреплением (DRL) позволяет достичь высокой эффективности и качества

решений, превосходящих традиционные методы, основанные на математическом программировании. Таким образом, данный метод может быть рассмотрен для разработки современных моделей принятия решений в сфере логистики.

Для её разработки необходимы следующие компоненты:

1. База данных о перевозках на полигоне отладки. Это ключевой компонент любой системы машинного обучения. Чем больше данных будет изучено, тем точнее модель сможет делать прогнозы;
2. Алгоритмы глубокого обучения, написанные для полигона отладки;
3. Оптимизационные алгоритмы, для определения наилучшего маршрута, учитывающие ограничения по времени, стоимости и другим факторам на полигоне отладки;
4. Инфраструктура обработки данных, так как глубокое обучение с подкреплением требует больших вычислительных мощностей;

5. Тестовый набор данных, который не использовался при обучении, для оценки эффективности модели. Это позволит определить, насколько хорошо она обобщает полученные знания и посчитать эффективность от использования разработанного алгоритма.

Кроме того, модель, разработанная для полигона отладки и дающая там оптимальный результат может некорректно обрабатывать при ее тиражировании на другие участки. Поэтому масштабируемость остается важной проблемой, которую необходимо решить в будущих исследованиях.

Список источников

1. Транспортная стратегия Российской Федерации на период до 2030 года утвержденная распоряжением Правительства Российской Федерации от 22 ноября 2008 года № 1734-р.
2. Бубнова Г.В. Цифровая логистика – инновационный механизм развития и эффективного функционирования транспортно-логистических систем и комплексов / Г.В. Бубнова, Б.А. Лёвин // International Journal of Open Information Technologies. – 2017. – №3. – С.72–78. EDN XYBPGP.
3. Joe, W., Lau, H.C.: Deep reinforcement learning approach to solve dynamic vehicle routing problem with stochastic customers. In: Proceedings of the International Conference on Automated Planning and Scheduling, vol. 30, pp. 394–402 (2020)
4. Nazari, M. R., Oroojlooy, A., Snyder, L., Takac, M.: Reinforcement learning for solving the vehicle routing problem. In: Advances in Neural Information Processing Systems, pp. 9860–9870 (2018)
5. Nalepa, J.: Where machine learning meets smart delivery systems. In: Smart Delivery Systems. pp. 203–226. Elsevier (2020)
6. Kool, W., Van, H., Welling, M.: Attention, learn to solve routing problems! arXiv:1803.08475 [cs, stat] (2019)
7. Lu, H., Zhang, X., Yang, S.: A learning-based iterative method for solving vehicle routing problems. In: Presented at the International Conference on Learning Representations Sept 25 (2019)
8. Yu, J.J., Yu, W., Gu, J.: Online vehicle routing with neural combinatorial optimization and deep reinforcement learning. In: Presented at the IEEE Transactions on Intelligent Transportation Systems 20, 3806–3817 (2019)
9. Zhao, J., Mao, M., Zhao, X., Zou, J.: A hybrid of deep reinforcement learning and local search for the vehicle routing problems. IEEE Trans. Intell. Transport. Syst. 1–11 (2020)
10. Kalakanti, A.K., Verma, S., Paul, T., Yoshida, T.: RL SolVeR Pro: reinforcement learning for solving vehicle routing problem. In: 2019 1st International Conference on Artificial Intelligence and Data Sciences (AiDAS), pp. 94–99. IEEE, Ipoh, Perak, Malaysia (2019)
11. Lin, B., Ghaddar, B., Nathwani, J.: Deep reinforcement learning for electric vehicle routing problem with time windows arXiv:2010.02068 [cs, math, stat] (2021)
12. Tomljenovic, V., Merzifonluoglu, Y. & Spigler, G. Optimizing inland container shipping through reinforcement learning. Annals of Operations Research (2024) <https://doi.org/10.1007/s10479-024-05927-4>.

DECISION-MAKING MODELS USING ARTIFICIAL INTELLIGENCE TOOLS IN PLANNING INTERMODAL ROUTES

Londar V.A., Lakhmetkina N.Y.¹

¹ Russian University of Transport

Abstract: currently, the container transportation industry is undergoing active development due to the implementation of new technologies and modern information systems. These innovations allow for the optimization of supply chain management processes and the automation of transportation and logistics operations, which in turn enhances management efficiency. One of the crucial aspects in planning intermodal transportation is selecting the optimal route, as it directly impacts the cost and speed of cargo delivery. To address this challenge, it is essential to develop a tool that allows for a swift analysis of all transportation options, selection of the best route, and presentation of it to clients. The article discusses the existing machine learning methods used to optimize the route of vehicles. The main purpose of this article is to study the developed solutions for their further application in transport and logistics processes. The introduction of the studied tools will help participants in the transport and logistics market to effectively compare infrastructure opportunities with the emerging demand for transportation.

Keywords: intermodal transportation, decision-making models, machine learning, artificial intelligence, logistics.

© Londar V.A., Lakhmetkina N.Y.

Received 25.05.2024, approved 18.06.2024, accepted for publication 18.06.2024.

For citation:

Londar V.A., Lakhmetkina N.Y. Decision-making models using artificial intelligence tools in planning intermodal routes. Logistics and Supply Chain Management. 2024. Vol 21, Iss 1 (110). pp. 52-61.

Londar V.A., postgraduate student, 751men@gmail.com, Russian University of Transport (MIIT), Moscow, Russia.

Lakhmetkina N.Y., Candidate of Technical Sciences, Associate Professor, naturla@mail.ru, Russian University of Transport (MIIT), Moscow, Russia, AuthorID: 528739.

References

1. The Transport strategy of the Russian Federation for the period up to 2030 approved by the Decree of the Government of the Russian Federation dated November 22, 2008 No. 1734-R.
2. Bubnova G.V. Digital logistics – an innovative mechanism for the effective development and functioning of transport and logistics systems and complexes / G.V. Bubnova, B.A. Levin // International Journal of Open Information Technologies. - 2017. – No.3. – pp.72-78. EDN XYBPGP.
3. Joe, W., Lau, H.C.: Deep reinforcement learning approach to solve dynamic vehicle routing problem with stochastic customers. In: Proceedings of the International Conference on Automated Planning and Scheduling, vol. 30, pp. 394–402 (2020)
4. Nazari, M. R., Oroojlooy, A., Snyder, L., Takac, M.: Reinforcement learning for solving the vehicle routing problem. In: Advances in Neural Information Processing Systems, pp. 9860–9870 (2018)
5. Nalepa, J.: Wheremachine learning meets smart delivery systems. In: Smart Delivery Systems. pp. 203–226. Elsevier (2020)
6. Kool, W., Van, H., Welling, M.: Attention, learn to solve routing problems! arXiv:1803.08475 [cs, stat] (2019)
7. Lu, H., Zhang, X., Yang, S.: A learning-based iterative method for solving vehicle routing problems. In: Presented at the International Conference on Learning Representations Sept 25 (2019)
8. Yu, J.J., Yu, W., Gu, J.: Online vehicle routing with neural combinatorial optimization and deep reinforcement learning. In: Presented at the IEEE Transactions on Intelligent Transportation Systems 20, 3806–3817 (2019)
9. Zhao, J., Mao, M., Zhao, X., Zou, J.: A hybrid of deep reinforcement learning and local search for the vehicle routing problems. IEEE Trans. Intell. Transport. Syst. 1–11 (2020)
10. Kalakanti, A.K., Verma, S., Paul, T., Yoshida, T.: RL SolVeR Pro: reinforcement learning for solving vehicle routing problem. In: 2019 1st International Conference on Artificial Intelligence and Data Sciences (AiDAS), pp. 94–99. IEEE, Ipoh, Perak, Malaysia (2019)
11. Lin, B., Ghaddar, B., Nathwani, J.: Deep reinforcement learning for electric vehicle routing problem with time windows arXiv:2010.02068 [cs, math, stat] (2021)
12. Tomljenovic, V., Merzifonluoglu, Y. & Spigler, G. Optimizing inland container shipping through reinforcement learning. Annals of Operations Research (2024) <https://doi.org/10.1007/s10479-024-05927-4>.