



УДК 004.89;004.94

DOI 10.52575/2687-0932-2024-51-3-670-681

Гибридная технология синтеза транспортно-логистических систем на основе машинного обучения и имитационного моделирования

Неупокоева Е.О., Быстров В.В., Шишаев М.Г.

Институт информатики и математического моделирования им. В.А. Путилова КНЦ РАН
Россия, Мурманская обл., 184209, г. Апатиты, ул. Ферсмана, д. 24А
E-mail: neupokoeva@iimm.ru, bystrov@iimm.ru, shishaev@iimm.ru

Аннотация. В настоящее время наблюдается мировой тренд в использовании интеллектуальных технологий в комбинации с компьютерным моделированием для решения сложных прикладных задач. Текущая работа посвящена созданию программных инструментов для информационно-аналитической поддержки управления транспортно-логистическими системами. В статье рассматривается гибридная технологии синтеза транспортно-логистических систем на основе машинного обучения и имитационного моделирования, позволяющая формировать и анализировать конфигурации сложных транспортно-логистических систем с большим количеством компонентов. Приводится краткий обзор нейросетевых методов и технологий, применяемых для решения прикладных задач оперативного управления и планирования в транспортной логистике. Авторы предлагают формализацию задачи планирования конфигурации транспортно-логистической системы в общей постановке и в частном случае. Рассматривается разработанная компьютерная модель имитации сценариев реализации плана движения транспортных средств на заданной конфигурации транспортно-логистической сети.

Ключевые слова: машинное обучение, искусственные нейронные сети, имитационное моделирование, транспортно-логистическая система, железнодорожный транспорт

Для цитирования: Неупокоева Е.О., Быстров В.В., Шишаев М.Г. 2024. Гибридная технология синтеза транспортно-логистических систем на основе машинного обучения и имитационного моделирования. Экономика. Информатика, 51(3): 670–681. DOI 10.52575/2687-0932-2024-51-3-670-681

Hybrid Technology for Synthesis of Transport-Logistics Systems Based on Machine Learning and Simulation

Elena O. Neupokoyeva, Vitaliy V. Bystrov, Maksim G. Shishaev

Putilov Institute for Informatics and Mathematical Modeling of the Federal Research Center
“Kola Science Center”

24A Fersman St, Apatity 184209, Murmansk Region, Russia

E-mail: neupokoeva@iimm.ru, bystrov@iimm.ru, shishaev@iimm.ru

Abstract. The article raises the issues of integration of intelligent information technologies and computer modeling for solving complex applied problems. The authors propose to use the flexible capabilities of modern artificial neural networks and simulation in the tasks of planning transport and logistics systems. In particular, the task of developing software tools for information and analytical support of transport logistics management of a distributed production association is considered. The article focuses on solving the applied problem of planning effective configurations of the railway transport and logistics system. To solve this problem, the authors propose an original hybrid technology for the synthesis of multicomponent transport and logistics systems based on machine learning and simulation modeling. A brief overview of neural network methods and technologies used to solve applied problems of operational management and

planning in transport logistics is provided. The authors propose a formalization of the task of planning the configuration of a transport and logistics system in a general formulation and in a particular case. The developed computer model for simulating scenarios for the implementation of a vehicle traffic plan on a given configuration of a transport and logistics network is considered.

Keywords: machine learning, artificial neural networks, simulation, transport and logistics system, railway transport

For citation: Neupokoyeva E.O., Bystrov V.V., Shishaev M.G. 2024. Hybrid Technology for Synthesis of Transport-Logistics Systems Based on Machine Learning and Simulation. Economics. Information technologies, 51(3): 670–681 (in Russian). DOI 10.52575/2687-0932-2024-51-3-670-681

Введение

Задачи формирования и управления транспортно-логистическими системами (ТЛС) представляют собой весьма обширный класс. Выделяются различные подклассы рассматриваемой задачи – планирования перевозок, маршрутизации в различных постановках и т. п. В общем случае такие задачи обладают высокой размерностью, что усложняет поиск точного оптимального решения и создает предпосылки для применения к их решению «мягких» методов, подразумевающих получение приближенного решения, не гарантирующего строгой оптимальности рассматриваемого критерия. К таким «мягким» подходам следует отнести применение методов машинного обучения (обучения по прецедентам), в частности – искусственных нейронных сетей (ИНС) различных архитектур. Основным фактором, сдерживающим широкое применение машинного обучения для решения задач синтеза и анализа ТЛС, является необходимость в обучающих выборках, требуемый объем которых находится в прямой зависимости от числа переменных в модели исследуемого объекта. В случае крупных ТЛС с большим количеством компонентов и, соответственно, моделируемых параметров, обеспечить достаточное количество наблюдений для формирования обучающей выборки чаще всего невозможно. В этой ситуации эффективным решением может стать комбинированное применение машинного обучения и имитационного моделирования, рассматриваемое далее в данной статье.

Практика применения ИНС в задачах формирования и управления транспортно-логистическими системами

Можно выделить два уровня применения искусственных нейронных сетей (ИНС) в рамках задач формирования и управления транспортно-логистическими системами:

1. решение различных частных задач формирования и управления ТЛС в прикладной постановке: предсказание трафика, управление светофорами, идентификация транспортных средств и т. п. Подобные ТЛС принято называть интеллектуальными транспортными системами (Intelligent Transport Systems, ITS);

2. решение задач в более общей постановке: как правило, это задачи комбинаторной оптимизации (КО) различного вида (задача коммивояжера, задача о ранце, задача о раскраске графа и др.). В рамках данной статьи рассматривается задача планирования конфигурации ТЛС, которую можно отнести к данному направлению.

Прорыв в результативности решения прикладных задач формирования ТЛС с применением ИНС возник с появлением глубоких ИНС [Ketabchi Haghighat at al., 2020; Nguyen at al., 2018]. Практически всё многообразие глубоких архитектур ИНС находит применение в транспортно-логистических системах – многослойные полносвязные сети прямого распространения [Hu, 2020], сверточные сети [Khajeh Hosseini, Talebpour, 2019], рекуррентные ИНС [Liu at al., 2017; Zhang, Kabuka, 2018], автоэнкодеры [Dong at al., 2018; El Natri, Boumhidi, 2018.], генеративно-сопоставительные сети [Sun at al., 2021; Yilun at al.,

2019], трансформеры [Goyal at al., 2023; Liang at al., 2022]. Также широко используется обучение с подкреплением [Genders, Razavi, 2018; Shi at al., 2018].

С помощью ИНС решаются задачи предсказания различных характеристик состояния транспортных линий [Huang at al., 2014; Hu at al., 2020; Sun at al., 2021], распознавания визуальных образов (от идентификации отдельных элементов транспортной инфраструктуры до комплексных систем оценки дорожной ситуации в беспилотных транспортных средствах [Dairi at al., 2017]), управление работой светофоров [Liang at al., 2019] и предсказание спроса (пассажиропотока) в рамках публичных ТЛС.

С другой стороны, задачи формирования (планирования) ТЛС носят более формальный характер и сводятся к тем или иным задачам комбинаторной оптимизации (задача коммивояжера, укладка ранца, раскраска графа и т. п.). Эти задачи относятся к NP-трудным [Bengio at al., 2020]. Существует большое количество алгоритмов решения задач КО в различных постановках, но для их применения в реальной ситуации, как правило, необходима подстройка параметров алгоритма и/или задачи для снижения вычислительной сложности или улучшения качества решения. В результате многократного решения схожих задач, таким образом, накапливается некоторая «коллективная интуиция», что открывает возможность автоматизации процессов генерации упомянутых эвристик с помощью машинного обучения (в частности – с помощью ИНС).

В работе [Bengio at al., 2020] приведен анализ возможных направлений применения методов машинного обучения (МО) для решения задач комбинаторной оптимизации и выделено два основных направления применения методов МО: (а) аппроксимация известного алгоритма с целью уменьшения вычислительной сложности задачи и (б) поиск новых «политик» решения задачи – выбор алгоритма и/или его параметров, обеспечивающих наибольший положительный эффект.

С точки зрения места МО в общем процессе поиска решения комбинаторной задачи выделяются три основных варианта использования моделей машинного обучения:

1. обучение модели непосредственно поиску решения – используется в простых, хорошо формализованных задачах [Bello at al., 2016];
2. модель МО используется для формирования дополнительной информации, используемой затем при решении задачи КО, например, параметризации алгоритма [Bonami at al., 2018; Kruber at al., 2017];
3. модель МО используется параллельно с основным алгоритмом поиска для решения частных подзадач [Lodi, Zarpellon, 2017].

Таким образом, можно заключить, что искусственные нейронные сети находят широкое применение при решении задач формирования и управления ТЛС. При этом основным фактором, ограничивающим возможность широкого применения машинного обучения для решения задач формирования и управления, является отсутствие достаточного объема наблюдений, позволяющего сформировать обучающие выборки для тренировки моделей МО в условиях большого числа параметров модели.

В связи с этим, в рамках данной работы прорабатывался вопрос создания гибридной технологии формирования эффективных ТЛС на основе комбинированного применения генеративно-сопоставительных искусственных нейронных сетей (GAN) и имитационного моделирования. Концепция решения заключается в том, чтобы с помощью GAN, натренированных на упрощенных моделях ТЛС и обучающих прецедентах малого объема, формировать «правдоподобные» (упрощенные) конфигурации ТЛС, которые затем оцениваются по более точной имитационной модели с учетом уже всех значимых ограничений предметной области и взаимосвязей параметров модели, а также по заданным критериям эффективности. Конфигурации, прошедшие проверку на допустимость, предъявляются эксперту для окончательной их оценки с точки зрения заданных критериев эффективности (в общем случае, таковых может быть несколько). Схема предлагаемого подхода представлена на рис. 1.




Рис. 1. Схема комбинированного подхода к формированию ТЛС
 Fig. 1. Combined approach scheme for the formation of a transport and logistics system

Формализация задачи управления транспортной логистикой крупной компании

В самом общем виде задача управления транспортно-логистической системой формулируется следующим образом. Имеется множество элементов транспортно-логистической системы O , в качестве которых могут рассматриваться компоненты подвижного состава, транспортные линии, грузы, планы перевозок и другие элементы, образующие составные части некоторой конфигурации ТЛС s из множества всевозможных конфигураций S :

$$s : B(O) \rightarrow S,$$

где $B(O)$ – булеан множества O .

На множестве конфигураций заданы функции, определяющие критерий качества ТЛС и ограничения на допустимые конфигурации:

$$c : S \rightarrow R,$$

$$r_i : S \rightarrow \{0,1\},$$

где R – множество возможных значений критерия качества (как правило, это вещественные числа, но возможны и иные формулировки критерия, имеющие область значений множества с заданным на них отношением порядка);

$r_i, i = \overline{1, N}$ – множество функций, возвращающих признак допустимости конфигурации – 0 или 1;

N – общее количество ограничений.

Задача формирования ТЛС заключается в том, чтобы найти s , доставляющее экстремум функции c и удовлетворяющее ограничениям r_i .

В зависимости от вида критерия и рассматриваемых в рамках задачи видах объектов O , выделяются различные подклассы данной задачи.

В качестве примера прикладной задачи формирования и управления транспортно-логистическими системами рассматривалась прикладная задача управления железнодорожной логистикой крупной компании. В рассматриваемом случае задачу можно отнести к разновидности задач маршрутизации запасов (Inventory Routing Problem, IRP) [Bertazzi, Speranza, 2012] с неограниченным дополнительным ресурсом. Рассмотрим формальную постановку задачи.

Дано множество подвижных средств (ПС) C , каждый из которых характеризуется текущим местоположением (локацией), состоянием (порожний/тип груза; доступен/движение в направлении локации x , и т. д.), техническими параметрами. При этом компания располагает некоторым множеством собственных подвижных средств и неограниченным количеством арендованных ПС. Дано множество локаций L . Дан план отгрузки (Shipment plan) продукции и сырья из локаций в виде записей, задающих транзакцию перевозки:

$$\langle l^s, l^d, cargo_type, volume, date1, date2, options \rangle,$$

где $l^s, l^d \in L$ – локация отправления (source) и назначения (destination) соответственно; прочие компоненты – тип груза, объем, даты отправки и прибытия, опции. В качестве опций могут быть явно заданы требования к типу ПС, необходимых для перевозки соответствующего груза (например, контейнеровоз).

Каждое ПС может находиться в одном из состояний, описываемых набором свойств:

$$S^1 \text{ – движение с грузом: } S^1(c) = \langle l^s, l^d, t^s, t^d, cargo_type, volume \rangle;$$

$$S^2 \text{ – движение без груза: } S^2(c) = \langle l^s, l^d, t^s, t^d \rangle;$$

$$S^3 \text{ – готовность (ожидание без груза): } S^3(c) = \langle l, t^s, t^f \rangle;$$

$$S^4 \text{ – стоянка с грузом: } S^4(c) = \langle l, t^s, t^f, cargo_type, volume \rangle;$$

$$S^5 \text{ – ремонт: } S^5(c) = \langle l, t^s, t^f \rangle;$$

S^6 – за пределами ТЛС (наемное ПС выведено из аренды; собственное ПС отправлено в утиль и т. п.).

Для удобства введем обозначение: $property(object)$ – значение свойства «property» объекта «object» в момент времени t . Например, $t^s(S(c))$ – начальное время нахождения ПС c в состоянии S .

Необходимо сформировать последовательность ежедневных планов перевозок на временной горизонт T . План перевозок с горизонтом T в момент времени t – это множество последовательностей состояний подвижных средств, задействованных в плане:

$$P^{t,T} = \{p^{t,T}(c_i)\},$$

где

$\{c_i\}$ – множество ПС, задействованных в плане $P^{t,T}$;

$$p^{t,T}(c_i) = \{S_1(c_i), S_2(c_i), \dots, S_N(c_i)\};$$

$$t^s(S_j(c_i)) = t^f(S_{j-1}(c_i)), t^s(S_1(c_i)) \leq t < t^s(S_2(c_i)), t^f(S_N(c_i)) \geq t + T \geq t^s(S_{N+1}(c_i)). \quad (1)$$

Условие (1) определяет «связность» (каждое следующее состояние начинается сразу же по завершении текущего) последовательности состояний i -го ПС, а также положение границ плана на оси времени относительно начального и конечного состояний ПС.

Далее приведена формальная постановка задачи маршрутизации запасов с неограниченным дополнительным ресурсом в виде оптимизационной задачи. При этом сделано упрощение – тип и объем перевозимого груза считается одинаковым для всех состояний ПС.

Параметры размерности задачи:

- int: N – количество ПС, являющихся объектами управления;
- int: K – горизонт планирования, в днях;
- int: L – количество локаций.

Управляемые переменные (decision variables):

- $X = \{x_{ij}\}$ – матрица $N \times K, i = 1, N, j = 1, K$, каждый элемент которой – это структура

вида:

$$x_{ij} = \langle ls, lf \rangle,$$

где

ls – стартовая локация;

lf – конечная локация.

При этом для вагонов, не находящихся в движении, справедливо равенство $ls=lf$.

Запись вида $state(x)$, $ls(x)$, ... или $x.state$, $x.ls$, ... интерпретируется как значение соответствующего поля структуры x .

Элемент матрицы – это состояние вагона i в день j .

- X_0 – начальная матрица X («базовый» план перевозок).

Параметры (general variables):

- const int: $price$ – цена перевозки 1 ПС на «дистанцию» 1 день;

- const int: $rent$ – стоимость аренды 1 ПС в день;

- const int: u – среднее время, требуемое на погрузку/разгрузку ПС;

- int: $T = \{T^{kl}\}$ – симметричная матрица $L \times L$ с нулевой диагональю (альтернативная

запись: $T(l^k, l^l) = T^{kl}$) – матрица «расстояний» между локациями;

- int: $D = \{D_{klj}\}$ – 3-мерная матрица $L \times L \times K$ с нулевой диагональю – потребность в ПС в день j в локациях k , предназначенных к отправке в локацию l ;

- int: $S(X) = \{S_j^k\}$ – матрица $L \times K$ – количество ПС x_{ij} в локациях k в день j (вспомогательная структура, производная от X), где

$$S_j^k = \sum_i [x_{ij}.ls = x_{ij}.lf = k], j = \overline{1, K}, k = \overline{1, L}.$$

Здесь и далее [...] – скобка Айверсона;

- int: $C = \{C^{kl}\}$ – симметричная матрица $L \times L$ с нулевой диагональю (альтернативная запись: $C(l^k, l^l) = C^{kl}$), $C^{kl} = price * T^{kl}$ – матрица стоимости перегона между локациями k и l (предполагаем, что стоимость линейно зависит от расстояния);

- $\hat{S}_j^{kl}(X) = \sum_i [x_{ij}.lf \neq x_{i,j-1}.lf] [x_{ij}.ls = k] [x_{ij}.lf = l] [k \neq l]$ – количество собственных вагонов, стартовавших в день j из локаций k в локацию l ;

- int: $R(X) = \{R_j^{kl}\}$ – 3-мерная матрица $L \times L \times K$ – количество арендованных вагонов, отправленных из локаций k в локацию l в день j , при этом:

$$R_j^{kl} = \begin{cases} D_j^{kl} - \hat{S}_j^{kl}, & \text{если } D_j^{kl} - \hat{S}_j^{kl} \geq 0 \\ 0, & \text{если } D_j^{kl} - \hat{S}_j^{kl} < 0 \end{cases};$$

- $Cost(X) = \sum_{i,j} C(x_{ij}.ls, x_{ij}.lf) [x_{ij}.lf \neq x_{i,j-1}.lf]$ – стоимость реализации транспортного плана;

- $Rent(X, D) = \sum_{j,k,l} 2 * (C^{kl} + rent) * T^{kl} * R_j^{kl}, j = \overline{1, K}; k, l = \overline{1, L}$ – суммарная стоимость аренды ПС при заданном транспортном плане (предполагается, что арендованные ПС всегда возвращаются в станцию отправления).

Ограничения:

- $x_{ij}.lf \neq x_{i,j-1}.lf \rightarrow \bar{x}_{ij} = \bar{x}_{i,j+1} = \dots = \bar{x}_{i,j+m}$, где $m = T(x_{ij}(ls), x_{ij}(lf))$ – если состояние ПС меняется, то оно сохраняется до достижения конечной локации;

- $(x_{ij}.state = 1 \text{ and } x_{i,j-1}.state = 0 \text{ and } x_{ij}.ls = k \text{ and } x_{ij}.lf = l) \rightarrow x_{i,j+C^{kl}}.ls = x_{i,j+C^{kl}+u}.ls = l$ – если ПС стартовал из локаций k в локацию l , то по прибытии в l (через C^{kl} дней) его стартовая локация должна быть равна l и сохраняться таковой еще u дней после финиша (u – время на разгрузку);



- $not \exists x_{ik}^0 : (k < j \wedge x_{ik}^0 \cdot ls = x_{ik}^0 \cdot lf), j = \overline{1, K} \rightarrow x_{ij} \cdot ls = x_{ij}^0 \cdot ls, x_{ij} \cdot lf = x_{ij}^0 \cdot lf$ – правило

генерации «стартовых» ограничений для движущихся ПС.

При этом производится минимизация целевой функции $F_g(X)$ суммарных затрат на реализацию транспортного плана:

$$F_g(X) = Cost(X) + Rent(X) \xrightarrow{x} \min .$$

В качестве подхода к решению такого типа задачи можно использовать парадигму программирования в ограничениях (constraint programming) [Küçük, Topaloglu Yildiz, 2022]. В этом случае условие на минимизацию целевой функции суммарной стоимости реализации транспортного плана можно заменить на ограничение следующего вида:

$$Cost(X) + Rent(X) \leq Cost(X^0) - Benefit ,$$

где

$Cost(X^0)$ – стоимость воплощения базового (текущего) плана;

$Benefit$ – желаемый экономический эффект.

Программирование в ограничениях позволяет решать рассматриваемую задачу не только как поиск оптимального решения, но и нахождение множества допустимых решений, удовлетворяющих сформированным ограничениям. Как показывают вычислительные эксперименты, данный подход демонстрирует хорошие результаты на малоразмерных задачах комбинаторной оптимизации. Но с ростом размерности задачи эффективность программирования в ограничениях резко падает.

Как отмечалось ранее, задача формирования ТЛС имеет высокую комбинаторную сложность, что ограничивает возможность применения прямых методов поиска оптимального или даже допустимого решения. Вместе с тем в ряде случаев прикладная задача заключается не в формировании ТЛС «с чистого листа», а в поиске возможных улучшений в смысле заданного критерия уже существующей системы. Таким образом, на практике обычно имеется сформированный в результате опыта эксплуатации набор наблюдений (прецедентов), что создает предпосылки для использования машинного обучения с целью поиска оптимальных или улучшенных вариантов конфигурации ТЛС.

Имитационное моделирование транспортно-логистических систем (на примере внешней железнодорожной логистики предприятия)

В рамках имитационного блока гибридной технологии синтеза транспортно-логистических систем предполагается использование комбинации нескольких подходов:

1. агентное моделирование (представление структуры модели);
2. системная динамика (для имитации процессов накопления и изменения балансов);
3. дискретно-событийное моделирование (для описания поведения агентов и взаимодействия объектов модели между собой).

В рамках реализации технологии был разработан прототип имитационной модели внешней железнодорожной логистики крупной компании. Для создания модели использовалась инструментальная среда Anylogic 8.7 и ее специализированные библиотеки (ж/д транспорт и управление процессами). На рис. 2 представлена общая схема работы имитационной модели. Внешние данные (план-график, ограничения и пр.) считываются при инициализации модели из внешней базы данных. Работа модели заканчивается, когда все данные о маршрутах обработаны и визуализированы в соответствии с временным распределением или в случае соответствующего выбора пользователя при возникновении ошибки.

В модели используются 8 типов агентов, представляющих различные компоненты ТЛС. Отношение агентов модели представлено в диаграмме классов (рис. 3).



Рис. 2. Общая схема работы имитационной модели
 Fig. 2. General workflow scheme of a simulation model




Рис. 3. Представление диаграммы классов модели
 Fig. 3. Class diagram of a simulation model

Графический интерфейс разработанного прототипа имитационной модели представляет из себя интерактивную схему (рис. 4) расположения транспортных узлов и путей между ними.




Рис. 4. Графический интерфейс модели (агент Main)
Fig. 4. Graphical User Interface of the model (agent Main)

Интерактивный графический интерфейс разработан для агентов *Main*, *Car*, *Station*, *Train*. Для визуального изображения данных используются различные виды графиков и диаграмм. Навигация между элементами интерфейса осуществляется с помощью интерактивных кнопок.

Разработанная имитационная модель позволяет оператору контролировать корректность и качество моделируемой конфигурации ТЛС. Наряду с визуальным контролем обеспечивается проверка ограничений модели на каждом шаге моделирования и, в случае их нарушения, выдается предупреждающее сообщение. На следующих этапах работы над проектом планируется реализовать функцию автоматической локальной оптимизации отдельных параметров моделируемой конфигурации ТЛС с помощью метода Монте-Карло.

Заключение

Искусственные нейронные сети различных архитектур находят широкое применение при решении задач формирования и управления транспортно-логистическими системами. При этом ИНС используются для решения задач как в прикладной (управление отдельными компонентами ТЛС), так и в общей постановке (решение задач комбинаторной оптимизации).

Общей проблемой использования ИНС в задачах формирования и управления ТЛС является высокая сложность задачи при малом количестве наблюдений. Для решения этой проблемы предложена двухэтапная гибридная технология применения генеративно-состязательных сетей для комбинаторной оптимизации на примере задач транспортной логистики.

На первом этапе технологии осуществляется генерация допустимых конфигураций транспортно-логистических систем, представленных в упрощенном виде, с помощью генеративно-состязательной сети, натренированной на имеющихся прецедентах реализации ТЛС в прошлом. На втором этапе осуществляется проверка сгенерированных

вариантов конфигурации на имитационной модели с учетом всего комплекса значимых параметров и ограничений ТЛС.

Сдерживающим фактором для использования МО является малое количество имеющихся прецедентов на фоне большого числа параметров модели. Возможным решением представляется использование многоэтапного подхода: упрощение модели (снижение числа параметров) до уровня, адекватного объему имеющихся наблюдений, генерация на ее основе упрощенных решений и их финальная проверка с помощью имитационного моделирования.

Список источников

- Bello I., Pham H., Le Q., Norouzi M., Bengio S. 2016. Neural Combinatorial Optimization with Reinforcement Learning, Under review as a conference paper at ICLR 2017, arXiv.
- Bengio Y., Lodi A., Prouvost A. 2020. Machine Learning for Combinatorial Optimization: a Methodological Tour d'Horizon, *European Journal of Operational Research*, 290(2): 405–421.
- Bertazzi L., Speranza M.G. 2012. Inventory routing problems: An introduction, *EURO Journal on Transportation and Logistics*, 1: 307–326.
- Bonami P., Lodi A., Zarpellon G. 2018. Learning a Classification of Mixed-Integer Quadratic Programming Problems, *Integration of Constraint Programming, Artificial Intelligence, and Operations Research*: 595–604.
- Dairi A., Harrou F., Mohamed S., Sun Y. 2017. Unsupervised obstacle detection in driving environments using deep-learning-based stereovision, *Robotics and Autonomous Systems*, 100: 287–301.
- Dong C., Shao C., Xiong Z. 2018. An Improved Deep Learning Model for Traffic Crash Prediction, *Journal of Advanced Transportation*, 2018: 1–13.
- El Hatri C., Boumhidi J. 2018. Fuzzy deep learning based urban traffic incident detection, *Cognitive Systems Research*, 50: 206–213.
- Genders W., Razavi S. 2018. Evaluating reinforcement learning state representations for adaptive traffic signal control, *Procedia Computer Science*, 130: 26–33.
- Goyal A., Bhatia A., Yadav A., Sharma D. K. 2023. Misbehavior Detection in Cooperative Intelligent Transportation Systems using Temporal Fusion Transformer, *Proceedings of the 24th International Conference on Distributed Computing and Networking (ICDCN '23)*. Association for Computing Machinery: 431–437.
- Hu W.-C., Wu H.-T., Cho H.-H., Tseng F.-H. 2020. Optimal Route Planning System for Logistics Vehicles Based on Artificial Intelligence, *Journal of Internet Technology*, 21(3): 757–764.
- Huang W., Song G., Hong H., Xie K., 2014, Deep Architecture for Traffic Flow Prediction: Deep Belief Networks With Multitask Learning, *IEEE Transactions on Intelligent Transportation Systems* 15(5): 2191–2201.
- Ketabchi Haghighat A., Ravichandra Mouli V., Chakraborty P., Esfandiari Y., Arabi, S., Sharma A. 2020. Applications of Deep Learning in Intelligent Transportation Systems, *Journal of Big Data Analytics in Transportation*, 2(11): 115–145.
- Khajeh Hosseini M., Talebpour A. 2019. Traffic Prediction using Time-Space Diagram: A Convolutional Neural Network Approach, *Transportation Research Record: Journal of the Transportation Research Board*, 2673(1): 425–435.
- Kruber M., Lübbecke M.E., Parmentier A. 2017. Learning When to Use a Decomposition, *Integration of AI and OR Techniques in Constraint Programming*: 202–210.
- Küçük M., Topaloglu Yildiz S. 2022. Constraint programming-based solution approaches for three-dimensional loading capacitated vehicle routing problems, *Computers & Industrial Engineering*, 171: 108505.
- Liang J., Zhu H., Zhang E., Zhang J. 2022. Stargazer: A Transformer-based Driver Action Detection System for Intelligent Transportation, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*: 3159–3166.
- Liang X., Du X., Wang G., Han Z. 2019. A Deep Reinforcement Learning Network for Traffic Light Cycle Control, *IEEE Transactions on Vehicular Technology*, 68(2): 1243–1253.
- Liu Y., Wang Y., Yang X., Zhang L. 2017. Short-term travel time prediction by deep learning: A comparison of different LSTM-DNN models, *IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*: 1–8.



- Lodi A., Zarpellon G. 2017. On learning and branching: a survey, *TOP*, 25(2): 207–236.
- Nguyen H., Kieu M., Wen T. Cai C. 2018. Deep learning methods in transportation domain: A review, *IET Intelligent Transport Systems*, 12(9): 998–1004.
- Shi D., Ding J., Errapotu S., Yue H., Xu W., Zhou X., Pan M., 2018, Q-Network Based Route Scheduling for Transportation Network Company Vehicles, *IEEE Global Communications Conference (GLOBECOM) 2018 IEEE Global Communications Conference (GLOBECOM)*: 1–7.
- Sun T., Sun B., Jiang Z.-H., Hao R., Xie J. 2021. Traffic Flow Online Prediction Based on a Generative Adversarial Network with Multi-Source Data, *Sustainability*, 13: 12188.
- Yilun L., Dai X., Li L. 2019. Pattern Sensitive Prediction of Traffic Flow Based on Generative Adversarial Framework, *IEEE Transactions on Intelligent Transportation Systems*, 20: 2395–2400.
- Zhang D., Kabuka M. 2018. Combining Weather Condition Data to Predict Traffic Flow: A GRU Based Deep Learning Approach, *IET Intelligent Transport Systems*, 12(7): 578–585.

References

- Bello I., Pham H., Le Q., Norouzi M., Bengio S. 2016. Neural Combinatorial Optimization with Reinforcement Learning, Under review as a conference paper at ICLR 2017, arXiv.
- Bengio Y., Lodi A., Prouvost A. 2020. Machine Learning for Combinatorial Optimization: a Methodological Tour d'Horizon, *European Journal of Operational Research*, 290(2): 405–421.
- Bertazzi L., Speranza M.G. 2012. Inventory routing problems: An introduction, *EURO Journal on Transportation and Logistics*, 1: 307–326.
- Bonami P., Lodi A., Zarpellon G. 2018. Learning a Classification of Mixed-Integer Quadratic Programming Problems, *Integration of Constraint Programming, Artificial Intelligence, and Operations Research*: 595–604.
- Dairi A., Harrou F., Mohamed S., Sun Y. 2017. Unsupervised obstacle detection in driving environments using deep-learning-based stereovision, *Robotics and Autonomous Systems*, 100: 287–301.
- Dong C., Shao C., Xiong Z. 2018. An Improved Deep Learning Model for Traffic Crash Prediction, *Journal of Advanced Transportation*, 2018: 1–13.
- El Hatri C., Boumhidi J. 2018. Fuzzy deep learning based urban traffic incident detection, *Cognitive Systems Research*, 50: 206–213.
- Genders W., Razavi S. 2018. Evaluating reinforcement learning state representations for adaptive traffic signal control, *Procedia Computer Science*, 130: 26–33.
- Goyal A., Bhatia A., Yadav A., Sharma D. K. 2023. Misbehavior Detection in Cooperative Intelligent Transportation Systems using Temporal Fusion Transformer, *Proceedings of the 24th International Conference on Distributed Computing and Networking (ICDCN '23)*. Association for Computing Machinery: 431–437.
- Hu W.-C., Wu H.-T., Cho H.-H., Tseng F.-H. 2020. Optimal Route Planning System for Logistics Vehicles Based on Artificial Intelligence, *Journal of Internet Technology*, 21(3): 757–764.
- Huang W., Song G., Hong H., Xie K., 2014, Deep Architecture for Traffic Flow Prediction: Deep Belief Networks With Multitask Learning, *IEEE Transactions on Intelligent Transportation Systems* 15(5): 2191–2201.
- Ketabchi Haghghat A., Ravichandra Mouli V., Chakraborty P., Esfandiari Y., Arabi, S., Sharma A. 2020. Applications of Deep Learning in Intelligent Transportation Systems, *Journal of Big Data Analytics in Transportation*, 2(11): 115–145.
- Khajeh Hosseini M., Talebpour A. 2019. Traffic Prediction using Time-Space Diagram: A Convolutional Neural Network Approach, *Transportation Research Record: Journal of the Transportation Research Board*, 2673(1): 425–435.
- Kruber M., Lübbecke M.E., Parmentier A. 2017. Learning When to Use a Decomposition, *Integration of AI and OR Techniques in Constraint Programming*: 202–210.
- Küçük M., Topaloglu Yildiz S. 2022. Constraint programming-based solution approaches for three-dimensional loading capacitated vehicle routing problems, *Computers & Industrial Engineering*, 171: 108505.
- Liang J., Zhu H., Zhang E., Zhang J. 2022. Stargazer: A Transformer-based Driver Action Detection System for Intelligent Transportation, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*: 3159–3166.
- Liang X., Du X., Wang G., Han Z. 2019. A Deep Reinforcement Learning Network for Traffic Light Cycle

- Control, *IEEE Transactions on Vehicular Technology*, 68(2): 1243–1253.
- Liu Y., Wang Y., Yang X., Zhang L. 2017. Short-term travel time prediction by deep learning: A comparison of different LSTM-DNN models, *IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*: 1–8.
- Lodi A., Zarpellon G. 2017. On learning and branching: a survey, *TOP*, 25(2): 207–236.
- Nguyen H., Kieu M., Wen T. Cai C. 2018. Deep learning methods in transportation domain: A review, *IET Intelligent Transport Systems*, 12(9): 998–1004.
- Shi D., Ding J., Errapotu S., Yue H., Xu W., Zhou X., Pan M., 2018, Q-Network Based Route Scheduling for Transportation Network Company Vehicles, *IEEE Global Communications Conference (GLOBECOM) 2018 IEEE Global Communications Conference (GLOBECOM)*: 1–7.
- Sun T., Sun B., Jiang Z.-H., Hao R., Xie J. 2021. Traffic Flow Online Prediction Based on a Generative Adversarial Network with Multi-Source Data, *Sustainability*, 13: 12188.
- Yilun L., Dai X., Li L. 2019. Pattern Sensitive Prediction of Traffic Flow Based on Generative Adversarial Framework, *IEEE Transactions on Intelligent Transportation Systems*, 20: 2395–2400.
- Zhang D., Kabuka M. 2018. Combining Weather Condition Data to Predict Traffic Flow: A GRU Based Deep Learning Approach, *IET Intelligent Transport Systems*, 12(7): 578–585.

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Поступила в редакцию 08.07.2024

Поступила после рецензирования 31.08.2024

Принята к публикации 06.09.2024

Received July 08, 2024

Revised August 31, 2024

Accepted September 06, 2024

ИНФОРМАЦИЯ ОБ АВТОРАХ

Неупокоева Елена Олеговна, стажер-исследователь, Институт информатики и математического моделирования им. В.А. Путилова КНЦ РАН., г. Апатиты, Россия

Быстров Виталий Викторович, кандидат технических наук, ведущий научный сотрудник, Институт информатики и математического моделирования им. В.А. Путилова КНЦ РАН., г. Апатиты, Россия

Шишаев Максим Геннадьевич, доктор технических наук, доцент, главный научный сотрудник, Институт информатики и математического моделирования им. В.А. Путилова КНЦ РАН., г. Апатиты, Россия

INFORMATION ABOUT THE AUTHORS

Elena O. Neupokoeva, Intern Researcher, Putilov Institute for Informatics and Mathematical Modeling of the Federal Research Center “Kola Science Center”, Apatity, Russia

Vitaliy V. Bystrov, Candidate of Technical Sciences, Lead Researcher, Putilov Institute for Informatics and Mathematical Modeling of the Federal Research Center “Kola Science Center”, Apatity, Russia

Maxim G. Shishaev, Doctor of Technical Sciences, Associate Professor, Chief Researcher, Putilov Institute for Informatics and Mathematical Modeling of the Federal Research Center “Kola Science Center”, Apatity, Russia