

**Агафонов Антон Александрович**

**МЕТОДЫ И АЛГОРИТМЫ ОБРАБОТКИ  
ГЕТЕРОГЕННОЙ ИНФОРМАЦИИ И АДАПТИВНОГО УПРАВЛЕНИЯ  
В ИНТЕЛЛЕКТУАЛЬНОЙ ТРАНСПОРТНОЙ СИСТЕМЕ**

2.3.1. Системный анализ, управление и обработка информации, статистика

**АВТОРЕФЕРАТ**

диссертации на соискание ученой степени  
доктора технических наук

Работа выполнена в федеральном государственном автономном образовательном учреждении высшего образования «Самарский национальный исследовательский университет имени академика С.П. Королева» на кафедре геоинформатики и информационной безопасности и в Институте систем обработки изображений РАН – филиале Федерального государственного учреждения "Федеральный научно-исследовательский центр "Кристаллография и фотоника" Российской академии наук" в лаборатории математических методов обработки изображений.

Научный консультант:

доктор физико-математических наук, доцент **Мясников Владислав Валерьевич**.

Официальные оппоненты:

**Гасников Александр Владимирович**, доктор физико-математических наук, федеральное государственное автономное образовательное учреждение высшего образования «Московский физико-технический институт (национальный исследовательский университет)», кафедра математических основ управления, заведующий кафедрой;

**Холодов Ярослав Александрович**, доктор физико-математических наук, автономная некоммерческая организация высшего образования «Университет Иннополис», руководитель лаборатории анализа данных и биоинформатики;

**Чикрин Дмитрий Евгеньевич**, доктор технических наук, федеральное государственное автономное образовательное учреждение высшего образования «Казанский (Приволжский) федеральный университет», директор института вычислительной математики.

Ведущая организация:

Федеральное государственное учреждение «Федеральный исследовательский центр «Информатика и управление» Российской академии наук», г. Москва.

Защита состоится 20 декабря 2023 г. в 10.00 часов на заседании диссертационного совета 24.2.379.09, созданного на базе федерального государственного автономного образовательного учреждения высшего образования «Самарский национальный исследовательский университет имени академика С.П. Королева», по адресу: 443086, г. Самара, Московское шоссе, д. 34.

С диссертацией можно ознакомиться в библиотеке федерального государственного автономного образовательного учреждения высшего образования «Самарский национальный исследовательский университет имени академика С. П. Королева» и на официальном сайте по электронному адресу:

[https://ssau.ru/files/resources/dis\\_protection/Agafonov\\_A\\_A\\_Metody\\_i\\_algoritmy\\_obrabotki.pdf](https://ssau.ru/files/resources/dis_protection/Agafonov_A_A_Metody_i_algoritmy_obrabotki.pdf)

Автореферат разослан «\_\_\_» \_\_\_\_\_ 2023 г.

Ученый секретарь  
диссертационного совета,  
д.т.н., доцент

С.В. Востокин

## Общая характеристика работы

Диссертация посвящена разработке методов, алгоритмов и программных средств, направленных на решение проблемы повышения эффективности использования транспортной инфраструктуры путем управления транспортным потоком с гетерогенным составом транспортных средств, а также движением отдельных транспортных средств в кооперативных интеллектуальных транспортных системах.

Под **интеллектуальной транспортной системой (ИТС)** понимается система управления, интегрирующая современные информационные и телематические технологии и предназначенная для автоматизированного поиска и принятия к реализации максимально эффективных сценариев управления транспортно-дорожным комплексом региона, конкретным транспортным средством (ТС) или группой транспортных средств с целью обеспечения заданной мобильности населения, максимизации показателей использования дорожной сети, повышения безопасности и эффективности транспортного процесса, комфортности для водителей и пользователей транспорта<sup>1</sup>.

**Актуальность темы.** В настоящее время транспортные системы являются неотъемлемой частью человеческой деятельности. Постоянный рост дорожного трафика, особенно в крупных городах, приводит к значительному увеличению затрат (времени, стоимости) на осуществление корреспонденций участниками дорожного движения, а также к увеличению вредных выбросов в атмосферу и ухудшению экологической обстановки. Для улучшения ситуации во многих странах используются различные стратегии: замена классических транспортных средств на гибриды и электромобили, территориальное и временное зонирование доступных территорий передвижения, развитие альтернативных средств передвижения, развитие средств совместного использования транспортных средств, оптимизация существующей транспортной инфраструктуры с целью повышения эффективности ее использования.

Одной из современных тенденций является развитие информационно-коммуникационных технологий и их проникновение в различные сферы жизни человека. Развитие интернета вещей, автомобильных самоорганизующихся сетей (VANET), подключенных и автономных транспортных средств привело к увеличению числа источников данных, которые могут использоваться для повышения эффективности решения задач анализа, прогнозирования и управления транспортным потоком: данные с камер видеонаблюдения на перекрестках и детекторов транспортного потока, траектории движения транспортных средств из навигационных приложений, информация о маршруте, положении и скорости движения подключенных и автономных транспортных средств и т.д. Одновременно с ростом числа источников, лавинообразно растет и объем доступных для анализа данных, что позволяет использовать методы машинного обучения и подходы к обработке «больших данных» для решения транспортных задач.

В настоящее время разработка и внедрение ИТС является ключевым способом повышения эффективности использования дорожно-транспортной инфраструктуры. Существующие решения задач анализа и моделирования транспортного потока (Гасников А.В., Швецов В.И., Яшина М.В., Чехович Ю.В.), прогнозирования (Duan Z., Zhang S.), директивного и косвенного управления транспортным потоком (Холодов Я.А., Михеева Т.И., Якимов М.Р., Varaiya P., Wei H.), задач информирования участников дорожного движения (Li Y., Samaranyake S.), как правило, основываются на традиционных источниках данных: датчиках, детекторах транспортного потока, видеокамерах. В то же время, согласно аналитическому отчету НТИ «Автонет», по прогнозам, к 2025 году в эксплуатации будет более 400 миллионов подключенных автомобилей. Также, по мнению аналитиков, к 2030 году доля новых транспортных средств со встроенной связью достигнет 96%. Как следствие,

---

<sup>1</sup> ГОСТ Р 56829-2015 Интеллектуальные транспортные системы. Термины и определения.

ожидаемый переход к транспортному потоку с гетерогенной структурой, включающему подключенные и управляемые водителями транспортные средства, увеличение числа источников данных и их объема, а также развитие методов машинного обучения и искусственного интеллекта, требует как разработки математических методов и алгоритмов решения отдельных задач в транспортных сетях, так и реализации ИТС, объединяющей эти решения для повышения эффективности использования транспортной инфраструктуры.

Разработка кооперативной ИТС, решающей задачи анализа, прогнозирования и управления транспортным потоком с гетерогенным (смешанным) составом транспортных средств позволит:

- повысить эффективность решения задач анализа и прогнозирования параметров транспортного потока за счет использования гетерогенной информации об усредненных характеристиках потока и данных о маршрутах движения подключенных транспортных средств, их положении и скорости движения;

- повысить эффективность решения задач директивного управления дорожным движением в транспортных сетях с гетерогенным составом транспортных средств за счет адаптивного управления транспортным потоком на регулируемых перекрестках и/или совместного управления сигналами светофорных объектов и движением подключенных и/или автономных подключенных транспортных средств, что позволит уменьшить общую загруженность дорожной сети, потребление топлива и выбросы продуктов сгорания, особенно в городских районах;

- повысить эффективность решения задач косвенного управления и информирования, таких как прогнозирование времени движения подключенных или общественных транспортных средств, построение маршрутов движения отдельных транспортных средств или перераспределение транспортных потоков путем маршрутизации всех транспортных средств или их отдельной части.

Учитывая все изложенные выше тезисы, можно говорить о безусловной актуальности как темы диссертационной работы в целом, так и отдельных выбранных направлений исследований в частности.

**Цель и задачи исследования.** Целью исследования является повышение эффективности использования транспортной инфраструктуры путем управления транспортным потоком с гетерогенным составом транспортных средств, а также движением отдельных транспортных средств в кооперативной интеллектуальной транспортной системе.

Для достижения поставленной цели в диссертации решаются следующие задачи:

- 1) проведение системного анализа задачи управления транспортным потоком с гетерогенным составом транспортных средств;

- 2) разработка алгоритмических средств решения задачи краткосрочного прогнозирования параметров гетерогенного транспортного потока в транспортной сети с использованием методов машинного обучения и подходов к обработке больших данных на основе гетерогенной информации (актуальных и статистических данных) о состоянии транспортного потока и движении отдельных транспортных средств;

- 3) разработка алгоритмических средств решения задачи директивного управления транспортным потоком на регулируемых перекрестках путем независимого и/или координированного адаптивного управления сигналами светофоров и движением подключенных автономных транспортных средств в транспортной сети;

- 4) разработка алгоритмических средств решения задач косвенного управления транспортным потоком и информирования в ИТС:

- разработка алгоритмов решения задачи прогнозирования движения отдельных транспортных средств с использованием методов машинного обучения;

- разработка алгоритмов решения навигационной задачи нахождения надежного пути в стохастической зависящей от времени транспортной сети;
- разработка алгоритмов маршрутизации подключенных транспортных средств в транспортной сети в кооперативной ИТС на основе численного метода резервирования маршрутов, позволяющего достичь транспортного равновесия в сети;

5) разработка и реализация программного комплекса кооперативной ИТС, решающей задачи анализа, прогнозирования и управления транспортным потоком с гетерогенным составом транспортных средств с использованием подходов к обработке больших данных;

б) проведение экспериментальных исследований разработанных методов и алгоритмов на натуральных и модельных данных, анализ результатов и сравнение с существующими решениями.

**Объект исследования** – кооперативные интеллектуальные транспортные системы.

**Предмет исследования** – методы управления транспортным потоком и движением отдельных транспортных средств, направленные на повышение эффективности использования существующей транспортной инфраструктуры.

**Методы исследования.** В диссертационной работе используются методы машинного обучения и искусственного интеллекта, теории вероятностей и статистического анализа, теории графов, методы оптимизации.

**Научная новизна:**

1) предложен комплекс алгоритмических средств (математический метод и алгоритмы) решения задачи краткосрочного прогнозирования параметров транспортного потока в транспортной сети с использованием графовых сверточных нейронных сетей и подходов к обработке больших данных на основе гетерогенной информации о состоянии транспортного потока и движении отдельных транспортных средств.

2) предложен комплекс алгоритмических средств решения задачи директивного управления транспортным потоком, включая:

- метод адаптивного светофорного управления транспортным потоком на основе максимизации взвешенного потока транспортных средств с использованием алгоритмов оценки транспортного потока на основе детерминированной модели прогнозирования движения транспортных средств (не требующей настройки/обучения) и на основе обучаемой модели глубокой нейронной сети регрессионного вида;
- алгоритм адаптивного светофорного управления транспортным потоком с использованием подхода на основе машинного обучения с подкреплением, учитывающий как наблюдаемые, так и прогнозные параметры, описывающие состояние транспортного потока;
- метод адаптивного управления транспортным потоком на регулируемых перекрестках путем координированного управления сигналами светофоров и траекториями движения подключенных автономных транспортных средств в транспортной сети;

3) предложен комплекс алгоритмических средств решения задачи косвенного управления транспортным потоком и информирования в ИТС:

- алгоритм определения надёжного пути в зависящей от времени стохастической (транспортной) сети, учитывающий информацию о пространственной и временной корреляции сегментов дорожной сети, текущую и прогнозную информацию о состоянии транспортного потока; ускоренная модификация алгоритма с использованием распределения Леви;

- алгоритмы краткосрочного прогнозирования времени движения отдельных транспортных средств, учитывающие гетерогенную информацию о транспортной ситуации, прямо или косвенно влияющую на прогнозируемое время движения;
- алгоритм маршрутизации подключенных транспортных средств в транспортной сети на основе численного метода резервирования маршрутов, учитывающий стохастические свойства транспортной сети; модификация алгоритма для его применения в гетерогенном транспортном потоке;

4) разработана архитектура и реализован программный комплекс кооперативной ИТС, решающей задачи анализа, прогнозирования и управления транспортным потоком с гетерогенным составом транспортных средств с использованием подходов к обработке больших данных.

**Практическая значимость работы.** Разработанные решения могут быть использованы в составе кооперативной ИТС и позволяют повысить точность прогнозирования параметров транспортного потока, снизить временные затраты на совершение транспортных корреспонденций, потребление топлива и выбросы продуктов сгорания, т.е. в целом повысить эффективность использования транспортной инфраструктуры. Разработанный программный модуль, входящий в состав программного комплекса, позволяет решать задачу анализа движения общественного транспорта и используется для информирования пассажиров о времени прибытия общественных транспортных средств на остановочные пункты в г. Самара, что подтверждается актом внедрения АО «Самара-Информспутник». Прогнозная информация, предоставляемая разработанным программным комплексом, доступна для пассажиров на сайте транспортного оператора г. Самара ([tosamara.ru](http://tosamara.ru)) или с использованием мобильного приложения «Прибывалка-63».

**Реализация результатов работы.** Результаты диссертации использованы при выполнении ряда госбюджетных и хоздоговорных НИР в АО «Самара-Информспутник», в т.ч. работ по созданию информационно-справочной системы городского округа Самара в части разработки интернет-портала Транспортного оператора Самары ([www.tosamara.ru](http://www.tosamara.ru)), проекта РФФИ № 13-07-12103-офи-м «Анализ и прогнозирование транспортных потоков на основе комплексного использования космической навигационной информации, данных дистанционного зондирования Земли и систем видеонаблюдения», программы фундаментальных исследований Президиума РАН «Фундаментальные проблемы информатики и информационных технологий» (проект 2.12), проекта РФФИ № 16-37-00055 мол-а «Адаптивные методы краткосрочного прогнозирования параметров транспортных потоков», проекта РФФИ № 18-29-03135-мк «Быстрые алгоритмы и высокопроизводительные вычисления в задачах обработки больших данных для анализа, предсказания и управления движением в интеллектуальных транспортных системах», проекта РФФИ № 18-07-00605-а «Методы и алгоритмы централизованного управления автономными транспортными средствами в интеллектуальных транспортных системах», проекта ФЦП «Исследования и разработки по приоритетным направлениям развития научно-технического комплекса России на 2014-2020 годы» по теме «Персональный цифровой автотранспортный помощник» (соглашение № 075-15-2019-062), проекта РНФ № 21-11-00321 «Методы и алгоритмы совместного и координированного управления сигналами светофоров и подключенными автономными транспортными средствами в транспортной сети».

**Апробация работы.** Основные результаты диссертации были представлены на международных научных конференциях: 18<sup>th</sup> IEEE International Conference on Intelligent Transportation Systems (Лас-Пальмас-де-гран-Канария, Испания, 2015, CORE B), 2016 IEEE Intelligent Vehicle Symposium (Гетеборг, Швеция, 2016, CORE B), 15<sup>th</sup>-16<sup>th</sup> Conference on Computer Science and Intelligence Systems (Болгария, виртуальный формат, 2020-2021, CORE

B), 19<sup>th</sup> International Conference on Intelligent Data Engineering and Automated Learning (Мадрид, Испания, 2018, CORE C), 16<sup>th</sup> International Symposium on Neural Networks (Москва, Россия, 2019, CORE C), 5<sup>th</sup> International Conference on Analysis of Images, Social networks, and Texts (Екатеринбург, Россия, 2016), 21<sup>st</sup> IEEE International Conference on Computational Science and Engineering (Бухарест, Румыния, 2018), 2018 The 2<sup>nd</sup> International Conference on Mechanical, System and Control Engineering (Самара, Россия, 2018), 4<sup>th</sup> International Conference on Intelligent Transportation Engineering (Сингапур, 2019), международная научная конференция «Проблемы управления и моделирования в сложных системах» (Самара, Россия, 2019), , 3<sup>rd</sup> International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (Россия, виртуальный формат, 2021), 2022 IEEE International Multi-Conference on Engineering, Computer and Information Sciences (Россия, виртуальный формат, 2022), 4<sup>th</sup> International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (Липецк, Россия, 2022), научная конференция «Транспортные потоки на сетях» (Россия, виртуальный формат, 2023), Международная конференция и молодежная школа «Информационные технологии и нанотехнологии» (Самара, Россия, 2015-2023).

**Публикации.** По теме диссертационной работы автором опубликовано 75 работ, в т.ч. 57 работ в изданиях, индексируемых в базах данных Scopus и Web of Science (WoS), получено 8 свидетельств о государственной регистрации программы для ЭВМ.

**Соответствие паспорту специальности 2.3.1. Системный анализ, управление и обработка информации, статистика.** Область исследования соответствует пунктам паспорта: 4 – Разработка методов и алгоритмов решения задач системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта; 9 – Разработка проблемно-ориентированных систем управления, принятия решений и оптимизации технических объектов; 10 – Методы и алгоритмы интеллектуальной поддержки при принятии управленческих решений в технических системах.

**Структура диссертации.** Диссертация состоит из введения, пяти глав, заключения, списка литературы (427 наименований). Работа изложена на 397 страницах, содержит 179 рисунков, 44 таблицы.

**На защиту выносятся:**

1) комплекс алгоритмических средств (математический метод и алгоритмы) решения задачи краткосрочного прогнозирования параметров транспортного потока в транспортной сети с использованием графовых сверточных нейронных сетей и подходов к обработке больших данных на основе гетерогенной информации о состоянии транспортного потока и движении отдельных транспортных средств, отличающийся от известных повышенной точностью;

2) комплекс алгоритмических средств решения задачи директивного управления транспортным потоком, позволяющий снизить среднее время транспортных корреспонденций и средний расход топлива по сравнению с известными методами:

- метод адаптивного светофорного управления транспортным потоком на основе максимизации взвешенного потока транспортных средств с использованием алгоритмов оценки транспортного потока на основе детерминированной модели прогнозирования движения транспортных средств (не требующей настройки/обучения) и на основе обучаемой модели глубокой нейронной сети регрессионного вида;
- алгоритм адаптивного светофорного управления транспортным потоком с использованием подхода на основе машинного обучения с подкреплением, учитывающий как наблюдаемые, так и прогнозные параметры, описывающие состояние транспортного потока;

- метод адаптивного управления транспортным потоком на регулируемых перекрестках путем координированного управления сигналами светофоров и траекториями движения подключенных автономных транспортных средств в транспортной сети;
- 3) комплекс алгоритмических средств решения задачи косвенного управления транспортным потоком и информирования в интеллектуальных транспортных системах:
- алгоритм определения надёжного пути в зависящей от времени стохастической (транспортной) сети, учитывающий информацию о пространственной и временной корреляции сегментов дорожной сети, текущую и прогнозную информацию о состоянии транспортного потока; ускоренная модификация алгоритма с использованием распределения Леви, отличающаяся от известных алгоритмов повышенной производительностью;
  - алгоритмы краткосрочного прогнозирования времени движения отдельных транспортных средств, учитывающие гетерогенную информацию о транспортной ситуации, прямо или косвенно влияющую на прогнозируемое время движения, отличающиеся от известных алгоритмов повышенной точностью;
  - алгоритм маршрутизации подключенных транспортных средств в транспортной сети на основе численного метода резервирования маршрутов, учитывающий стохастические свойства транспортной сети; модификация алгоритма для его применения в гетерогенном транспортном потоке;
- 4) программный комплекс кооперативной ИТС, решающей задачи анализа, прогнозирования и управления транспортным потоком с гетерогенным составом транспортных средств с использованием подходов к обработке больших данных;
- 5) результаты экспериментальных исследований, подтвердившие эффективность разработанных методов, алгоритмов и реализованного программного комплекса.

### Краткое содержание диссертации

**Кооперативная интеллектуальная транспортная система** – ИТС, основанная на технологиях V2X (cooperative intelligent transport system, C-ITS)<sup>2</sup>.

**Vehicle-to-Everything (V2X)** – процесс взаимодействия ТС с любыми объектами, которые могут повлиять на транспортное средство, для взаимного обмена информацией посредством беспроводной связи<sup>2</sup>.

**Подключенное транспортное средство** – транспортное средство, которое обменивается данными с другими транспортными средствами и устройствами, сетями и сервисами, охватывающими дорожную инфраструктуру<sup>2</sup>. **Беспилотное транспортное средство** – высоко- или полностью автоматизированное транспортное средство, функционирующее без вмешательства человека<sup>2</sup>.

В первом разделе диссертации представлен анализ современного состояния области исследования, рассмотрены современные методы решения задач анализа и прогнозирования транспортного потока (Гасников А.В., Швецов В.И., Яшина М.В., Чехович Ю.В., Duan Z., Zhang S.) задач директивного и косвенного управления транспортным потоком и движением отдельных транспортных средств в кооперативных ИТС (Холодов Я.А., Якимов М.Р., Софронова Е.А., Varaiya P., Wei H.), методы решения задач информирования участников движения (Li Y., Samaranyake S.), а также представлены современные тенденции развития ИТС (Михеева Т.И., Sumalee A.). Проведенный обзор подтвердил актуальность рассматриваемой задачи построения кооперативной ИТС, решающей задачи анализа,

---

<sup>2</sup> Распоряжение Правительства РФ от 25.03.2020 N 724-р «Об утверждении Концепции обеспечения безопасности дорожного движения с участием беспилотных транспортных средств на автомобильных дорогах общего пользования».



прогнозирования и управления транспортным потоком с гетерогенным составом транспортных средств.

Центральным результатом проведённого в первом разделе анализа является конкретизация цели и задач исследования, проводимого в диссертационной работе.

Во втором разделе диссертации предложен комплекс алгоритмических средств (математический метод и алгоритмы) решения задачи краткосрочного прогнозирования параметров гетерогенного транспортного потока в транспортной сети с использованием графовых сверточных нейронных сетей и подходов к обработке больших данных.

Примем в качестве математической модели улично-дорожной сети (УДС) ориентированный граф  $G = (V, E, W)$ , ребра  $e \in E$  которого соответствуют сегментам УДС, вершины  $v \in V$ ,  $N = |V|$  представляют собой разделяющие участки дорог узлы,  $W \in R^{N \times N}$  – взвешенная матрица смежности.

Обозначим  $x_t^i \in R$  – наблюдаемый параметр транспортного потока (ТП) на ребре  $i \in E$  в момент времени  $t$ ,  $x^i = (x_{t_{cur}-T}^i, \dots, x_{t_{cur}}^i)$  – набор наблюдаемых параметров ТП на ребре  $i \in E$  в момент времени  $t_{cur}$  за  $T$  временных интервалов,  $X_t$  – набор наблюдаемых параметров для всех ребер графа в момент времени  $t$ ,  $X$  – набор наблюдаемых параметров за  $T$  временных интервалов.

Формальная постановка задачи краткосрочного прогнозирования транспортного потока может быть выполнена следующим образом: имея граф  $G = (V, E, W)$  и последовательность  $X$  наблюдаемых значений параметров транспортного потока, рассчитать оценку параметров транспортного потока  $\hat{X}_t$  через  $T_{ph}$  временных интервалов:  $\hat{X}_{t+1}, \hat{X}_{t+2}, \dots, \hat{X}_{t+T_{ph}} = f(X; G)$ .

Предложенные в диссертации алгоритмические средства прогнозирования включают:

- 1) базовый алгоритм прогнозирования для УДС малого размера при недостаточном объеме статистических данных, описывающих состояние транспортных потоков;
- 2) алгоритм прогнозирования на основе обработки больших данных для его применения при увеличении объемов данных и возможности использования инфраструктуры обработки больших данных;
- 3) алгоритм прогнозирования на основе графовой нейронной сети для его применения при наличии больших объемов данных, необходимых для обучения нейронных сетей, и неизменности топологии УДС;
- 4) метод прогнозирования гетерогенного транспортного потока для его применения в среде, состоящей из подключенных и управляемых водителями транспортных средств.

Базовый алгоритм прогнозирования был предложен в кандидатской диссертации автора и не выносится на защиту. Модификация алгоритма для его применения с использованием инфраструктуры больших данных основывается на методе  $k$  ближайших соседей. Для описания транспортных потоков предлагается формировать вектор признаков с учётом характеристик ТП в пространственно-компактном подграфе графа дорожной сети следующим образом:

1) граф улично-дорожной сети разбивается на пространственно компактные непересекающиеся подграфы  $\{G_j\}_{j=1, \overline{K}}$ . Набор ребер конкретного подграфа  $G_j$  зависит от выбранного алгоритма разбиения графа. Для каждого подграфа  $j$  формируется вектор признаков  $X^j$  из параметров ТП:  $X^j = (x^i)_{i \in G_j}$ ;

2) выполняется снижение размерности исходного вектора признаков  $X^j$  путём устранения пространственно-временной зависимости значений параметров потоков и формируется итоговый вектор признаков  $y^j$  подграфа  $j$ , состоящий из  $M_j$  компонент:  $y^j = (y_0^j, \dots, y_{M_j-1}^j)$ ,  $M_j < |G_j|$ .

3) результирующий вектор признаков  $S_i$  для каждого сегмента  $i \in E$  формируется из исходного вектора признаков  $x^i$  для сегмента  $i$  и вектора признаков  $y^j$  для подграфа  $j$ , которому принадлежит сегмент:  $S_i = (x^i, y^j)$ ,  $i \in E$ .

Для определения близости между векторами признаков используется взвешенное евклидово расстояние с учётом тренда (Xia D, 2016):

$$d(S_i, \bar{S}_i) = d^{link}(x^i, \bar{x}^i) + \gamma d^{pca}(y^j, \bar{y}^j),$$

$$d^{link}(x, \bar{x}) = \alpha \sqrt{\sum_{t=1}^T \beta^{T-t+1} (x_t - \bar{x}_t)^2} + (1 - \alpha) \sqrt{\sum_{t=2}^T \sum_{\delta=1}^{t-1} ((x_t - x_\delta) - (\bar{x}_t - \bar{x}_\delta))^2},$$

$$d^{pca}(y, \bar{y}) = \sqrt{\sum_{n=1}^M (y_n - \bar{y}_n)^2},$$

где  $0 \leq \alpha \leq 1$ ,  $0 < \beta \leq 1$ ,  $0 \leq \gamma \leq 1$  – коэффициенты.

В качестве функции прогнозирования используется функция, учитывающая средневзвешенное значение векторов признаков и тренд прогноза:

$$\hat{X}_{T+1} = \theta \sum_{k=1}^K \frac{d_k^{-1}}{\sum_{k=1}^K d_k^{-1}} X_{T+1}^k + (1 - \theta) (X_T + \frac{1}{KT} \sum_{k=1}^K \sum_{t=1}^T (X_{T+1}^k - X_t^k)),$$

где  $\hat{X}_{T+1}$  – прогнозное значение параметра ТП в момент времени  $T + 1$ ,  $X_{T+1}^k$  – значение параметра ТП  $k$ -го ближайшего соседа в соответствующий момент времени,  $d_k$  – расстояние между вектором признаков, описывающим текущее состояние ТП, и  $k$ -м ближайшим соседом,  $0 \leq \theta \leq 1$  – коэффициент,  $K$  – количество ближайших соседей.

Данный алгоритм был реализован с использованием модели распределенных вычислений MapReduce (рисунок 1).

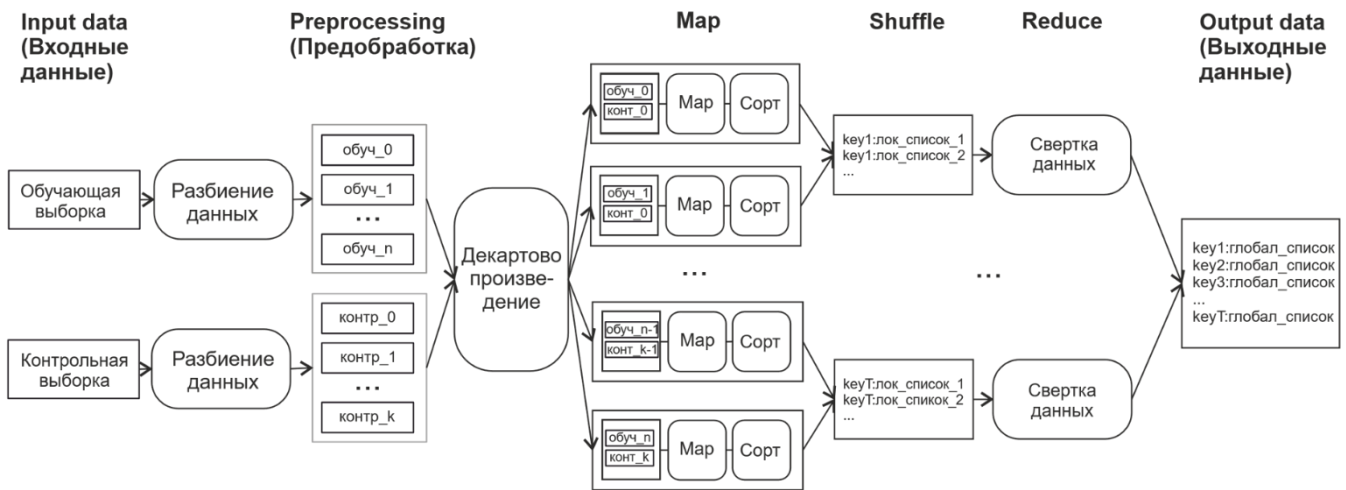


Рисунок 1 – Схема работы предлагаемой модели на основе MapReduce

В рамках модели обработка данных происходит параллельно на нескольких вычислительных узлах. На первом шаге осуществляется подготовка входных данных, происходит разбиение данных на разделы. Затем формируются упорядоченные пары разделов. Далее на шаге Map формируется локальный список  $k$  ближайших соседей для каждого вектора признаков. На заключительном шаге Reduce для каждого элемента тестовых данных множество списков локальных ближайших соседей преобразуется в результирующий (глобальный) список. Полученные списки  $k$  ближайших соседей используются для нахождения прогнозируемой величины транспортного потока.

Предложенный алгоритм на основе обработки больших данных был модифицирован для повышения точности прогнозирования параметров ТП в пространственно-компактной области с использованием методов машинного обучения, и, в частности, аппарата графовых сверточных нейронных сетей (ГНС). Традиционные сверточные нейронные сети способны эффективно извлекать локальные паттерны, но могут применяться только для структур

данных, представляющих собой регулярные сетки. Свертка на графах обобщает традиционную свертку и может использоваться для обработки данных на графовых структурах.

Общий подход к определению сверточного оператора для графовых данных, основанный на матрице смежности  $W$ , состоит из следующих шагов:

- 1) вычисление матрицы Лапласа графа  $L$ :  $L = I - D^{-\frac{1}{2}}WD^{\frac{1}{2}}$ ,  $D_{ii} = \sum_j W_{ij}$ ;
- 2) разложение матрицы Лапласа по собственным значениям:  $L = U\Lambda U^T$ , где  $\Lambda$  – диагональная матрица,  $U$  – Фурье-базис.

Используя эту нотацию, сверточный оператор для графовых данных определяется как результат умножения сигнала  $x \in \mathbb{R}^N$  на графе с ядром  $g_\theta$  (Hammond D., 2011):

$$g_\theta * x = g_\theta(L)x = g_\theta(U\Lambda U^T)x = U g_\theta(\Lambda)U^T x.$$

Для локализации фильтра  $g_\theta$  и уменьшения количества параметров используется обобщенная свертка на графе с помощью полиномов Чебышева (Hammond D., 2011).

Предложенный алгоритм краткосрочного прогнозирования на основе ГНС представляет собой гибридную модель глубокого обучения, которая объединяет слои пространственно-временной свертки на графах с операторами долгой краткосрочной памяти (LSTM). Архитектура нейронной сети представлена на рисунке 2.

Используемый вектор признаков  $X^{fv}$  объединяет текущий временной ряд из наблюдаемых значений параметров ТП, а также временные ряды, учитывающие дневные и недельные паттерны изменения транспортного потока.

Разработанный алгоритм прогнозирования был обобщен для его применения в смешанном транспортном потоке с учетом гетерогенной информации о состоянии транспортного потока и движении отдельных транспортных средств. В этом случае дополнительно вводится в рассмотрение множество подключенных ТС  $U$ . Для каждого ТС  $u_k \in U$  считается известной следующая информация:

$$I_k = (o_k, d_k, \tau_k, R_k),$$

где  $o_k \in V$  – исходная вершина (вершина отправления),  $d_k \in V$  – конечная вершина (вершина прибытия),  $\tau_k$  – время начала движения,  $R_k$  – маршрут транспортного средства.

Предложенный метод краткосрочного прогнозирования гетерогенного ТП состоит из двух основных частей: прогнозирование ТП по текущим и архивным статистическим значениям параметров ТП (без информации от подключенных транспортных средств) (Алгоритм 1) и оценка загрузки транспортной сети подключенными транспортными средствами (Алгоритм 2). В Алгоритме 1 величина  $\tau^{cur}$  – текущее время,  $X^{hist}$  – архивные значения параметров ТП,  $\{n_e\}_{e \in E}$  – накопленное количество подключенных ТС, которые зарезервировали временной интервал на сегменте  $e \in E$ . Функция *PredictFlow* реализует один из описанных ранее алгоритмов прогнозирования параметров ТП. В Алгоритме 2 величина  $c_e(\tau^{in})$  – оценка времени движения,  $\tau^{in}$  и  $\tau^{out}$  – время въезда и выезда с сегмента

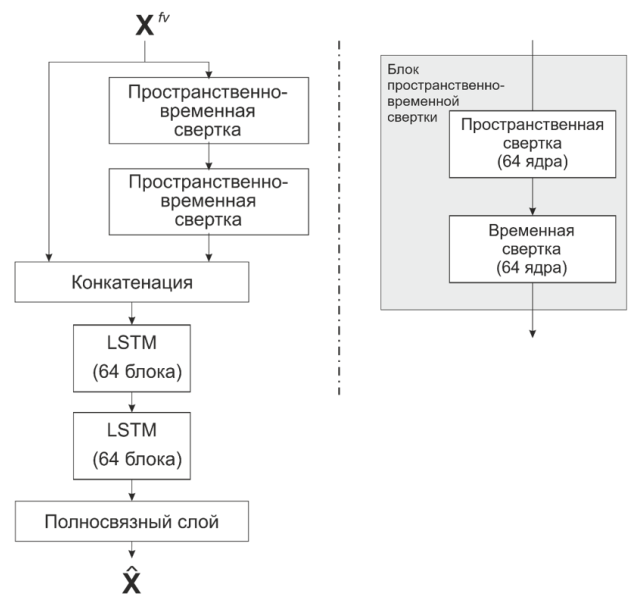


Рисунок 2 – Архитектура нейронной сети прогнозирования параметров ТП

сети. Чтобы вычислить скорость движения (функция *CalcTravelSpeed*), используется пяти-параметрическая модель скорости-плотности следующего вида (MacNicholas M., 2008):

$$s^{5PL}(p) = s_b + \frac{s_f - s_b}{(1 + \exp((p - p_b)/\theta_1))^{\theta_2}},$$

где  $p$  – плотность ТП,  $s_f$  – средняя скорость прохождения сегмента в свободном потоке,  $s_b$  – средняя скорость прохождения сегмента в условиях дорожного затора,  $p_b$  – значение плотности потока, соответствующей переходу из свободного движения к затрудненному движению,  $\theta_1, \theta_2$  – параметры, определяющие форму кривой.

---

#### Алгоритм 1: Метод прогнозирования гетерогенного транспортного потока

---

```

1: Входные данные:  $\tau^{cur}, X^{hist}, \{n_e\}_{e \in E}$ 
2: Выходные данные:  $\hat{X}$ 
3:  $X^{cur} = \{\}$ ;
4: for  $e \in E$  do
5:    $x_e(\tau^{cur}) = ObserveDensity(\tau^{cur})$ ;
6:    $x_e^{cv}(\tau^{cur}) = \frac{n_e(\tau^{cur})}{\lambda_e L_e}$ ;
7:    $x_e^{flow}(\tau^{cur}) = x_e(\tau^{cur}) - x_e^{cv}(\tau^{cur})$ ;
8:    $X^{cur}.append(x_e^{flow}(\tau^{cur}))$ ;
9: end
10:  $X^{FV} = (X^{hist}, X^{cur})$ ;
11:  $\hat{X}^{flow} = PredictFlow(X^{FV})$ ;
12: for  $e \in E$  do
13:   for  $t = 0$  to  $T^{ph}$  do
14:      $\hat{x}_e^{cv}(t) = \frac{n_e(t)}{\lambda_e L_e}$ ;
15:      $\hat{X}.append(\hat{x}_e^{flow}(t) + \hat{x}_e^{cv}(t))$ ;
16:   end
17: end

```

---



---

#### Алгоритм 2: Алгоритм оценки транспортной нагрузки

---

```

1: Входные данные:  $R_k, \hat{X}^{flow}, \{n_e\}_{e \in E}$ 
2: Выходные данные: обновленный  $\{n_e\}_{e \in E}$ 
3:  $\tau^{in} = \tau^{cur}$ ;
4: for  $e \in R_k$  do
5:    $\hat{x}_e^{cv}(\tau^{in}) = \frac{n_e(\tau^{in})}{\lambda_e L_e}$ ;
6:    $\hat{x}_e(\tau^{in}) = \hat{x}_e^{flow}(\tau^{in}) + \hat{x}_e^{cv}(\tau^{in})$ ;
7:    $c_e(\tau^{in}) = \frac{L_e}{CalcTravelSpeed(\hat{x}_e(\tau^{in}))}$ ;
8:    $\tau^{out} = \tau^{in} + c_e(\tau^{in})$ ;
9:   for  $t = [\tau^{in}]$  to  $[\tau^{in}] + 1$  do
10:      $n_e(t) = n_e(t) + 1$ ;
11:   end
12:    $\tau^{in} = \tau^{out}$ ;
13: end

```

---

Для оценки эффективности и определения границ применимости были проведены экспериментальные исследования разработанных алгоритмических средств. На первом этапе экспериментального анализа были проведены исследования *алгоритма на основе обработки больших данных*. В качестве исходных данных для проведения исследований использовались значения средней скорости движения транспортного потока (в км/ч) для всей транспортной сети г. Самары, полученные за 50 дней.

Было произведено сравнение предложенной модели при использовании различных алгоритмов разбиения графа (обозначены ниже как  $G^{box}, G^{dist}, G^{flow} / NCut$ ), сезонной модели временных рядов SARIMA (Williams B., 2007) и модели TDUD-KNN (Xia D., 2016). Результаты экспериментов представлены в таблице 1 и на рисунке 3. Разработанный алгоритм со способом разбиения графа на подграфы с учетом транспортных потоков ( $G^{flow} / NCut$ ) показал лучшие результаты по сравнению с базовыми алгоритмами прогнозирования по критериям средней абсолютной (MAE, км/ч) и средней относительной ошибки (MAPE, %).

Таблица 1 – Сравнение алгоритмов

Алгоритм	MAE	MAPE
$G^{box}$	2,654	11,45
$G^{dist}$	2,653	11,42
$G^{flow}$ (NCut)	<b>2,646</b>	<b>11,4</b>
TDUD-KNN	2,732	11,76
SARIMA	2,677	11,64




Рисунок 3 – Сравнение алгоритмов по критерию MAE

Исследования алгоритма на основе графовой нейронной сети было проведено на наборе данных, описывающих параметры ТП в области УДС г. Самары, а также на двух общедоступных наборах данных о дорожном движении PeMSD4 и PeMSD7 (Chen C., 2001). Результаты исследований для УДС г. Самары представлены в таблице 2 и на рисунке 4. Сравнение ГНС было проведено с двумя базовыми моделями: линейная регрессия, полносвязная нейронная сеть с двумя скрытыми слоями, 24 нейрона в каждом слое (MLP).

Таблица 2 – Сравнение алгоритмов

Алгоритм	MAE	MAPE
Линейная регрессия	2,16	10,46
MLP	1,89	9,04
GCNN, K=1	1,7295	8,352
<b>GCNN, K=2</b>	<b>1,7315</b>	<b>8,336</b>
GCNN, K=3	1,821	8,773




Рисунок 4 – Сравнение алгоритмов по критерию MAE

Анализ результатов показывает, что предложенный алгоритм на основе модели ГНС дает более качественный результат прогноза, чем базовые алгоритмы прогнозирования. Лучший результат по совокупному критерию был показан моделью, использующей полиномы Чебышева второго порядка ( $K = 2$ ). Кроме того, использование ГНС позволяет повысить точность прогноза по сравнению с алгоритмом на основе обработки больших данных, однако графовая сеть требует большого объема данных для обучения. Кроме того, при изменении топологии дорожной сети может потребоваться переобучение модели.

На втором этапе проводилась оценка эффективности разработанной модели (GCNN) на наборах данных PeMSD4 и PeMSD7 со state-of-the-art методами прогнозирования:

- 1) LSTM: нейронная LSTM-сеть, GRU: нейронная GRU-сеть (Fu R., 2016);
- 2) STGCN: нейронная сеть, использующая пространственно-временную свертку на графе с механизмом активации GRU (Yu B., 2018);
- 3) ASTGC: нейронная сеть, использующая пространственно-временную свертку на графе на основе механизма внимания (Guo S., 2019).

Предложенная модель показывает лучшие результаты по выбранным критериям практически для всех значений горизонта прогноза (таблица 3). При прогнозе на час вперед разница между предложенной моделью и другими базовыми моделями более значительна.

Прогнозная информация о параметрах транспортного потока является ключевой информацией для решения задач директивного и косвенного управления транспортным потоком и движением транспортных средств с целью повышения эффективности использования транспортной инфраструктуры.

Таблица 3 – Сравнение эффективности моделей на наборах данных PEMS7 и PEMS4

Модель	PEMS7 (15 / 30 / 60 мин)		PEMS4 (15 / 30 / 60 мин)	
	MAE	MAPE	MAE	MAPE
GRU	2,384/3,124/3,868	5,559/7,563/9,67	1,516/1,911/2,336	3,069/4,117/5,293
LSTM	2,329/3,035/3,803	5,446/7,385/9,604	1,536/1,905/2,336	3,084/4,096/5,292
STGCN	<b>2,258/3,065/4,061</b>	<b>5,293/7,483/10,293</b>	<b>1,452/1,923/2,565</b>	<b>2,899/4,108/5,652</b>
ASTGCN	2,469/3,186/4,017	5,793/7,764/10,136	1,744/2,122/2,664	3,634/4,698/6,052
<b>GCNN</b>	<b>2,261/2,917/3,546</b>	<b>5,305/7,13/8,938</b>	<b>1,468/1,825/2,228</b>	<b>2,95 /3,915/5,054</b>

В третьем разделе диссертации предложен комплекс алгоритмических средств (математические методы и алгоритмы) решения задачи директивного управления в ИТС. Задача повышения эффективности использования транспортной инфраструктуры путем адаптивного управления транспортным потоком является ключевой задачей, решаемой в рамках ИТС. Управление дорожным движением выполняется посредством адаптивного светофорного регулирования транспортного потока. Предложенные методы и алгоритмы управления включают в себя:

1) алгоритм адаптивного управления с использованием подхода на основе машинного обучения с подкреплением (англ.: Reinforcement Learning, RL), применимый при наличии большого объема данных для обучения нейронных сетей, возможности моделирования движения;

2) метод адаптивного управления на основе максимизации взвешенного потока транспортных средств с использованием алгоритмов оценки транспортного потока на основе детерминированной модели прогнозирования движения транспортных средств (не требующей настройки/обучения) и на основе обучаемой модели глубокой нейронной сети регрессионного вида, применимый при наличии информации о транспортном потоке на перекрестке;

3) метод адаптивного управления на регулируемых перекрестках путем координированного управления сигналами светофоров и траекториями движениям подключенных автономных транспортных средств в транспортной сети, применимый в среде, состоящей из подключенных и управляемых водителями транспортных средств.

Система управления сигналами светофоров называется *адаптивной*, если выбор фазы светофорного регулирования происходит на основании данных движения транспортных средств.

Задача обучения с подкреплением обычно представляется как Марковский процесс принятия решений. В диссертации рассматривается транспортная сеть, в которой каждый перекресток контролируется независимым RL-агентом, который в данный момент времени  $t$  выбирает действие  $a_t \in A$  на основе наблюдаемого состояния  $s_t \in S$  на перекрестке. Для описания дорожной ситуации в зоне перекрестка (т.е. пространства состояний  $S$ ), используются следующие факторы:

- 1) количество движущихся транспортных средств на каждой входящей полосе;
- 2) длина очереди на каждой входящей полосе;
- 3) общее время ожидания –последовательное время, в течение которого транспортное средство находится без движения;
- 4) суммарная скорость транспортных средств на каждой встречной полосе;
- 5) прогнозируемое количество транспортных средств, которые пересекут перекресток в течение заданного интервала времени  $\Delta t$ .

После того, как агент  $i$  получил текущее состояние системы, он выбирает действие  $a_t^i \in A$  для следующего временного интервала  $\Delta t$ . Выбранный набор действий  $a^t$  всех агентов отправляется в систему, которая переходит в новое состояние  $s_{t+1} \in S$  в соответствии с вероятностью перехода. На финальном этапе определяется награда

$R_{a_t}(s_t, s_{t+1})$ . В работе награда для агента  $i$  рассчитывается как взвешенная линейная комбинация нескольких факторов, косвенно описывающих состояние ТП:

$$r_t^i = \alpha_0 \sum_{l \in L^i} q_t^l + \alpha_1 \sum_{l \in L^i} v_t^l + \alpha_2 p^i,$$

где  $\alpha_j, j = \overline{0,2}$  – весовые коэффициенты,  $L^i$  – множество входящих полос на перекрестке  $i$ ,  $q_t^l$  – длина очереди (количество) транспортных средств на полосе  $l$  в момент времени  $t$ ,  $v_t^l$  – средняя скорость движения на полосе  $l$  в момент времени  $t$ ,  $p^i$  – «давление», то есть разница между количеством въезжающих и выезжающих транспортных средств на перекрестке  $i$  (Varaiya P., 2013).

Рассмотрим Q-функцию полезности пары  $(s, a)$  в соответствии со стратегией  $\pi$ :  $Q^\pi(s, a) = E\{R|s_t = s, a_t = a, \pi\}$ . Одним из возможных решений нахождения оптимальной стратегии  $\pi^*$  является нахождение оптимальной Q-функции:  $Q^*(s, a) = \max_{\pi} Q^\pi(s, a)$ . В диссертации применяется подход двойного Q-обучения (van Hasselt H., 2010), в котором используются две Q-функции  $Q^A, Q^B$  в качестве двойной оценки:

$$Q_{t+1}^A(s_t, a_t) = (1 - \alpha)Q_t^A(s_t, a_t) + \alpha \left( r_t + \gamma Q_t^B \left( s_{t+1}, \arg \max_a Q_t^A(s_{t+1}, a) \right) \right),$$

$$Q_{t+1}^B(s_t, a_t) = (1 - \alpha)Q_t^B(s_t, a_t) + \alpha \left( r_t + \gamma Q_t^A \left( s_{t+1}, \arg \max_a Q_t^B(s_{t+1}, a) \right) \right).$$

В качестве аппроксиматоров Q-функции предлагается использовать две нейронные сети с одинаковой архитектурой, представленной на рисунке 5.

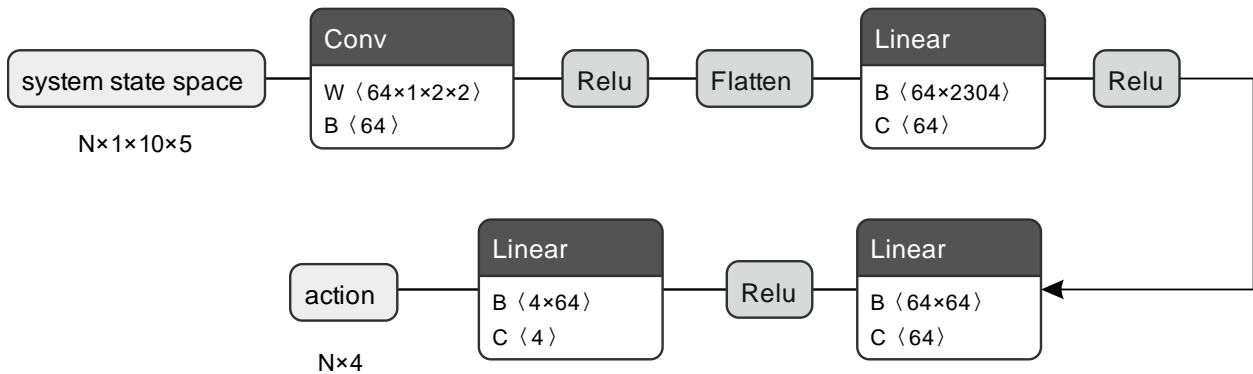


Рисунок 5 – Архитектура нейронной сети с двойным Q-обучением

Таким образом, предлагаемый алгоритм на основе **обучения с подкреплением** состоит из следующих шагов:

- 1) каждый RL-агент наблюдает текущее состояние транспортного потока и прогнозирует количество ТС, которые проедут перекресток в течение заданного интервала времени, формирует вектор признаков, описывающий дорожную ситуацию;
- 2) каждый RL-агент выбирает действие на следующий временной интервал, используя подход с двойным Q-обучением на основе созданного вектора признаков;
- 3) выбранный набор действий всех агентов отправляется в систему, которая переходит в новое состояние.

Несмотря на активное развитие методов управления сигналами светофоров на основе обучения с подкреплением, остаются открытыми вопросы обучения моделей и сходимости к глобальному максимуму, стабильности их работы на сложных сценариях управления. Для решения указанных проблем в диссертационной работе был разработан метод адаптивного управления, основанный на подходе **модельно-предикативного управления**. Задача адаптивного управления заключается в максимизации прогнозируемого потока

транспортных средств, проходящих через перекресток за рассматриваемый временной интервал.

Предлагаемый метод управления тривиален – он выбирает ту фазу, прогнозируемый поток для которой оказывается максимален (Алгоритм 3). Ключевым моментом метода является способ расчета потока ТС за рассматриваемый интервал, то есть вид функции  $PWFlow$ . Предлагается следующий вид функции, в которой выполняется подсчет количества ТС, которые проедут перекресток за выбранный интервал времени, взвешенных с использованием коэффициента, учитывающего время ожидания на перекрестке.

**Алгоритм 3: Метод максимального взвешенного потока MaxPWFlow**

1: **Входные данные:**  $\tau_{min}, t_{cur}, p_{cur}, P$   
 2: **Выходные данные:**  $p_{out}$   
 3: **if**  $t_{cur} < \tau_{min}$  **then**  
 4:    $p_{out} = p_{cur}$   
 5:    $t_{cur} = t_{cur} + 1$   
 6: **else**  
 7:    $p_{out} = \text{argmax}(\{PWFlow(p) \text{ for } p \text{ in } P\})$   
 8:    $t_{cur} = 0$   
 9: **end if**

$$PWFlow(p) = \sum_{l \in L_p^{in}} \sum_{c \in C_l} \eta(c, l) I(t(c) < \tau_{min}),$$

где  $L_p^{in}$  – множество входящих полос движения, для которых допустимо движение при фазе  $p$ ,  $C_l$  – множество ТС на полосе движения  $l$ ,  $I(val)$  – индикатор, принимающий значение «1» при  $val = True$ , и значение «0» – иначе,  $\eta(c, l)$  – весовой коэффициент, учитывающий время ожидания ТС  $c$  на полосе  $l$ .

В Алгоритме 3 величина  $P$  – множество фаз светофорного объекта,  $\tau_{min}$  – допустимый минимальный временной интервал переключения фаз,  $t_{cur}$  – время активности текущей действующей фазы светофора  $p_{cur} \in P$ ,  $p_{out} \in P$  – следующая выбранная фаза светофорного объекта.

В диссертации предложены два алгоритма оценки интервала времени  $t(c)$ , необходимого для достижения перекрестка. Набор предложенных в *детерминированной прогнозной модели* аналитических закономерностей базируется на простейших принципах механики, связывающих возможное перемещение транспортного средства с его возможным ускорением и физическими ограничениями среды. В модели рассматриваются закономерности, описывающие три составляющие оценки времени – время равноускоренного движения  $t_1(c)$ , прямолинейного движения  $t_2(c)$  и время задержки отправления  $d(c)$ :

$$t(c) = t_1(c) + t_2(c) + d(c).$$

Алгоритм оценки интервала времени  $t(c)$  на основе *модели глубокой нейронной сети* использует нейронную сеть, архитектура которой показана на рисунке 6. В качестве входных параметров модели используется гетерогенная информация, прямо или косвенно описывающая транспортную ситуацию на текущем и смежном дорожных сегментах, а также движение рассматриваемого ТС  $c$ :

- 1) положение ТС  $S = S(c)$  (расстояние от текущей позиции ТС до перекрестка);
- 2) скорость движения ТС  $v = v(c)$ ;
- 3) ускорение ТС  $a = a(c)$ ;
- 4) максимально разрешенная скорость движения  $v_{max}$ ;
- 5) число ТС перед рассматриваемым ТС  $c$  до перекрестка  $n = n(c)$ ;
- 6) тип  $k$  ожидаемого перестроения на перекрестке;
- 7) скорость  $v_0$  и положение  $S_0$  ближайшего ТС на полосе выезда.



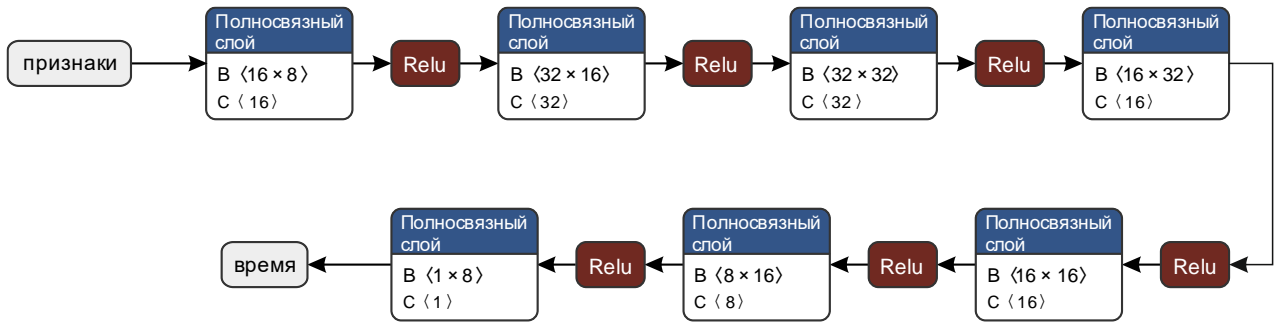


Рисунок 6 – Архитектура нейронной сети для оценки времени прохождения перекрестка

В среде с гетерогенным транспортным потоком выделим три типа ТС, которые можно различить в транспортном потоке:

1) подключенные ТС: для этого типа ТС предполагается, что маршрут, положение, скорость и другая информация о ТС известны в реальном времени;

2) наблюдаемые ТС: ТС, управляемые водителями, которые движутся в пределах досягаемости датчиков подключенных ТС (камер, лидаров) впереди или позади подключенных ТС. В эту группу также входят ТС, находящиеся в зоне действия камер видеонаблюдения на перекрестках. Предполагается, что для этого типа ТС известны положение и скорость ТС;

3) ненаблюдаемые ТС: ТС, которые движутся вне диапазонов датчиков подключенных ТС / камер видеонаблюдения. В результате информация об этих транспортных средствах не используется для оценки прогнозируемого транспортного потока на перекрестках.

Модификация метода заключается в использовании в оценке транспортного потока только данных от подключенных и наблюдаемых транспортных средств:

$$PWFlow(p) = \sum_{l \in L_p^{income}} \sum_{c \in C_l^{obs}} \eta(c, l) I(t(c) < \tau_{min}),$$

где  $C_l^{obs}$  – множество ТС, которое содержит подключенные и наблюдаемые ТС.

Разработанные алгоритмические средства адаптивного управления сигналами светофорных объектов используют информацию от подключенных ТС для эффективного контроля транспортного потока путем светофорного регулирования. В то же время, возможность управлять траекторией движения ТС на перекрестке позволяет рассматривать задачу управления транспортным потоком как задачу совместного управления сигналами светофоров и траекториями движения транспортных средств на перекрестке.

Ключевой задачей является минимизация времени движения ТС, в т.ч. за счет сокращения времени ожидания на перекрестках, поскольку это уменьшает дорожные заторы и повышает мобильность водителей. Вторым важным критерием является снижение расхода топлива, так как это может способствовать сокращению выбросов и повышению энергоэффективности транспортной системы. С учетом сказанного, задача, решаемая разработанным методом управления транспортным потоком на регулируемом перекрестке, формулируется следующим образом:

$$\lambda \cdot TravelT_{\Sigma}(A_{TS}, A_{Tr}) + \eta \cdot WaitingT_{\Sigma}(A_{TS}, A_{Tr}) + \delta \cdot FuelC_{\Sigma}(A_{TS}, A_{Tr}) \rightarrow \min_{A_{TS}, A_{Tr}},$$

где  $TravelT_{\Sigma}(A_{TS}, A_{Tr})$  – длительность совершения всех корреспонденций ТС на перекрестке,  $WaitingT_{\Sigma}(A_{TS}, A_{Tr})$  – длительность ожидания всех ТС на перекрестке,  $FuelC_{\Sigma}(A_{TS}, A_{Tr})$  – объем общего потребления топлива,  $A_{TS}, A_{Tr}$  – используемые алгоритмы управления сигналами светофоров и построения траектории движения (включая их

параметры),  $\lambda, \eta, \delta$  – вещественные безразмерные весовые коэффициенты, совместно характеризующие относительную важность того или иного фактора.

В качестве алгоритма управления сигналами светофоров  $A_{TS}$  используется предложенный метод максимального взвешенного потока. Рассмотрим алгоритм построения траектории движения  $A_{Tr}$ . Пусть контролируемое ТС въезжает на смежную с перекрестком полосу движения в момент времени  $t_0$  со скоростью  $v_0$  в позицию  $l_0$ ;  $L$  – длина полосы движения;  $v_{max}$  – максимальная допустимая скорость движения на рассматриваемой полосе движения;  $\bar{a}$  – максимальное ускорение, с которым может двигаться рассматриваемое ТС;  $\underline{a}$  – максимальное торможение, достижимое рассматриваемым ТС. Требуется построить физически достижимую и безопасную траекторию движения ТС до перекрестка  $tr$  с учетом следующих ограничений:

$$\begin{aligned} tr(t_0) &= l_0, \\ 0 \leq tr'(t) &\leq v_{max}, \quad \underline{a} \leq tr''(t) \leq \bar{a}, \quad \forall t \in (-\infty, +\infty), \\ G(T(tr, L)) &= T(tr, L), \end{aligned}$$

где  $T(tr, L)$  – время, при котором ТС достигнет позиции  $L$ , двигаясь по траектории  $tr$ ,  $G(t)$  – функция, которая возвращает ближайшее к  $t$  время зеленой фазы светофора:

$$G(t) = \min\{t': t' > t \wedge t' \in [T_0 + nT_c, T_0 + nT_c + T_g], n \in \mathbb{Z}^+\},$$

где  $T_0$  – время начала светофорного цикла,  $T_c = T_g + T_y + T_r$  – длительности полного рабочего цикла светофора, которое включает в себя длительности зеленой фазы  $T_g$ , желтой фазы  $T_y$  и красной фазы  $T_r$ .

Для управления движением ТС на перекрестке в работе используется модифицированный вариант Shooting Heuristic алгоритма (Zhou F, 2017). На первом этапе алгоритма последовательно формируются два сегмента траектории (рисунок 7а).

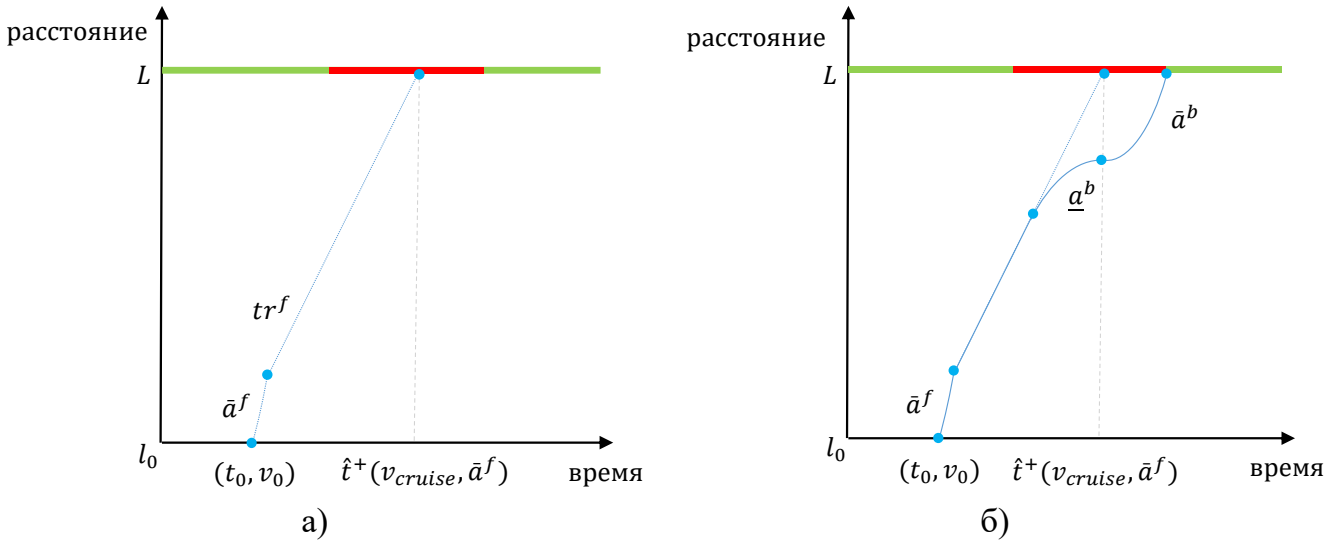


Рисунок 7 – Этапы построения траектории

Первый сегмент соответствует равноускоренному движению из начального состояния до достижения крейсерской скорости. Второй сегмент траектории соответствует равномерному прямолинейному движению до момента въезда на перекресток. Полученная траектория является результирующей, если в момент въезда на перекресток горит зеленый сигнал светофора. В противном случае начинается второй этап алгоритма (рисунок 7б). Последний сегмент траектории сдвигается вправо по оси времени до начала зеленой фазы светофора. Затем из этого исходного сегмента формируются сегменты траектории с ускорением и торможением, благодаря которым траектория плавно соединяется с исходной траекторией в результирующую.

Полученную траекторию можно оценить по различным показателям эффективности дорожного движения. В рамках предложенного в данной работе метода была использована взвешенная сумма нескольких критериев оценки траектории:

$$M(tr) = \lambda \cdot R_T(TravelT(tr)) + \eta \cdot R_T(WaitingT(tr)) + \delta \cdot R_F(FuelC(tr)).$$

Для подбора оптимальных параметров траектории  $(\bar{a}^f, \bar{a}^b, \underline{a}^b, v_{cruise})$  использовался субградиентный метод.

Обозначим  $c(p, l) \in \{green, yellow, red\}$  – сигнал светофора фазы  $p$  для полосы движения  $l$ . Предложенный метод совместного управления траекториями движения ТС и сигналами светофоров можно описать следующим образом:

1) построить траектории для всех ведущих транспортных средств на каждой полосе  $l$ , предполагая, что для всех полос  $c(p_{next}, l) = green$  (т.е. для всех транспортных средств движение разрешено);

2) рассчитать оценку времени прохождения перекрестка  $t(c)$ : для транспортных средств с известной траекторией движения  $t(c)$  рассчитывается на основе построенной траектории, для остальных транспортных средств  $t(c)$  рассчитывается с использованием алгоритма прогнозирования на основе глубокой нейронной сети;

3) выбрать следующую фазу  $p_{next}$ , используя алгоритм адаптивного управления светофором *MaxPWF*low (Алгоритм 3);

4) учитывая прогнозируемую следующую фазу  $p_{next}$ , перестроить траектории для всех транспортных средств, для которых предположение  $c(p_{next}, l) = green$  не выполняется.

Целью экспериментального исследования является оценка эффективности предлагаемых методов и алгоритмов в реальных сценариях моделирования. В качестве платформы для моделирования использовался пакет микроскопического моделирования движения транспортных средств SUMO. Для оценки эффективности использовались три сценария моделирования движения: движение по магистрали (Cologne-3, рисунок 8а), движение в области транспортной сети малого размера (Cologne-8, рисунок 8б) и в крупномасштабной сети (Cologne-316, рисунок 8в).

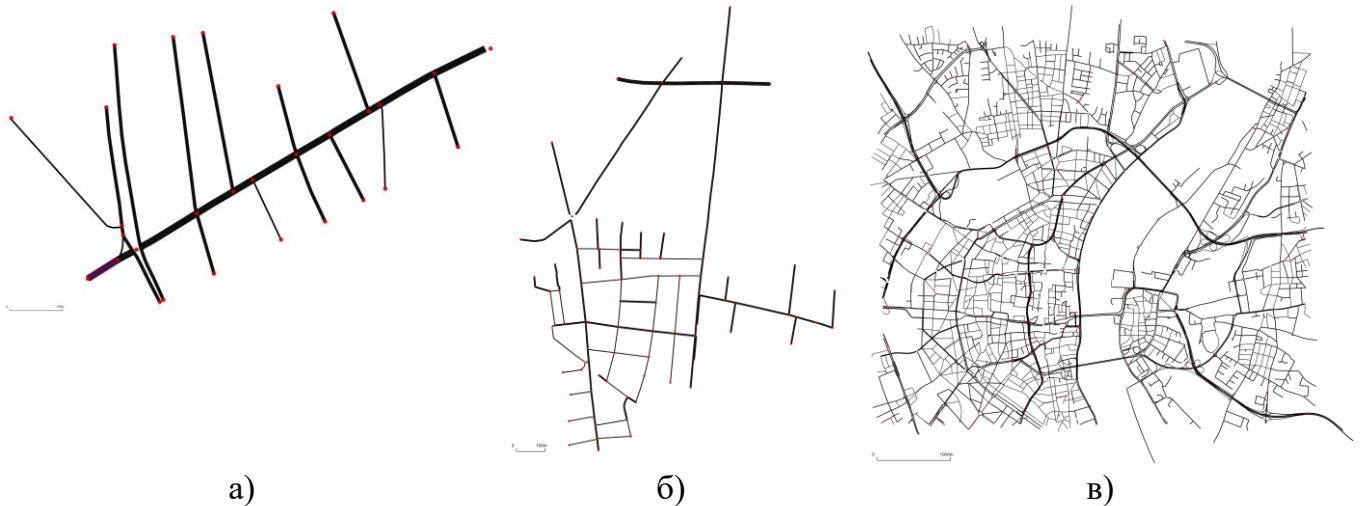


Рисунок 8 – Сценарии моделирования

В экспериментальном исследовании проводилось сравнение метода совместного управления с несовместными стратегиями адаптивного управления светофором, в том числе на основе state-of-the-art RL-алгоритмов:

- 1) IDQN: RL-алгоритм на основе оптимизации Q-функции полезности (Ault J., 2021);
- 2) IPPO: RL-алгоритм на основе оптимизации стратегии (Ault J., 2021);
- 3) A2C: RL-алгоритм advantage actor-critic (Wu Y., 2017);
- 4) *MaxPWF*low: предложенный метод на основе максимизации взвешенного потока;

5) *Trajectory Control*: предложенный алгоритм управления траекториями с учетом адаптивного управления светофорами методом MaxPWFlow;

6) *Trajectory Control + RL*: предложенный алгоритм управления траекториями с учетом адаптивного управления светофорами алгоритмом IDQN;

7) *Совместное управление*: предложенный метод совместного управления траекториями движения и сигналами светофоров.

На первом этапе экспериментального исследования оценивалась сходимость процесса обучения RL-алгоритмов. На рисунке 9 показаны кривые обучения для каждого алгоритма в двух сценариях. Согласно графикам, алгоритму IDQN требуется больше эпизодов для достижения стабильного значения среднего времени ожидания.




Рисунок 9 – Кривые обучения: а) сценарий Cologne-8, б) сценарий Cologne-316

Для оценки эффективности разработанного решения и сопоставления результатов с наилучшими существующими решениями было проведено исследование описанных методов по критериям среднего расхода топлива (таблица 4), среднего времени движения (таблица 5) и среднего времени ожидания для каждого сценария. Таблицы показывают среднее значение и стандартное отклонение, усредненное по десяти эпизодам моделирования движения транспортных средств.

Таблица 4 – Средний расход топлива (мл) для различных сценариев моделирования

Модель \ Сценарий	«Cologne-3»	«Cologne-8»	«Cologne-316»
IDQN	64,24 ± 0,84	88,51 ± 1,76	334,74 ± 3,37
IPPO	64,42 ± 0,88	88,52 ± 1,74	416,93 ± 8,85
A2C	66 ± 0,6	93,68 ± 1,75	355,62 ± 9,36
<i>MaxPWFlow</i>	62,15 ± 0,4	86,48 ± 1,77	328,62 ± 1,81
<i>Trajectory Control</i>	60,55 ± 0,46	84,42 ± 1,58	331,76 ± 1,75
<i>Trajectory Control + RL</i>	61,76 ± 0,43	86,52 ± 1,6	333,82 ± 1,7
<b><i>Совместное управление</i></b>	<b>59,57 ± 0,43</b>	<b>83,41 ± 1,5</b>	<b>325,25 ± 1,71</b>

Таблица 5 – Среднее время движения (с) для различных сценариев моделирования

Модель \ Сценарий	«Cologne-3»	«Cologne-8»	«Cologne-316»
IDQN	57,9 ± 1,08	89,89 ± 2,07	332,15 ± 3,19
IPPO	58,25 ± 1,01	89,51 ± 1,98	406,94 ± 7,92
A2C	60,57 ± 0,9	95,15 ± 2,09	350,28 ± 8,32
<i>MaxPWFlow</i>	55,01 ± 0,57	87,69 ± 2,03	327,08 ± 1,85
<i>Trajectory Control</i>	53,48 ± 0,7	85,57 ± 1,88	328,68 ± 1,72
<i>Trajectory Control + RL</i>	54,5 ± 0,52	88,11 ± 1,83	331,83 ± 1,85
<b><i>Совместное управление</i></b>	<b>52,12 ± 0,44</b>	<b>84,32 ± 1,89</b>	<b>323,96 ± 1,95</b>

Лучшие результаты были показаны предложенным методом совместного управления. Полученные результаты также позволяют сделать вывод, что наилучший результат среди

RL-алгоритмов показал алгоритм на основе Q-обучения. Однако, RL-алгоритмы имеют более высокую дисперсию значения критерия по сравнению с предложенным методом на основе модельно-предикативного управления (MaxPWFlow). Эффективность управления повышается с применением последовательно метода адаптивного управления только сигналами светофорных объектов и метода совместного управления траекториями движения и сигналами светофоров. Экспериментальные исследования в среде моделирования показывают, что предложенный метод совместного управления позволяет снизить расход топлива, время движения и время ожидания по сравнению с базовыми методами в каждом сценарии. Среднее снижение расхода топлива составило от 1% для сценария «Cologne-316» до 4,2% для сценария «Cologne-3» по сравнению с адаптивным управлением сигналами светофоров, среднее время движения снизилось до 5.3% для сценария «Cologne-3», среднее время ожидания – до 27% в крупномасштабном сценарии «Cologne-316».

В четвертом разделе диссертации предложен комплекс алгоритмических средств решения задач косвенного управления транспортным потоком и информирования в ИТС. В данном разделе рассмотрены задачи прогнозирования движения отдельных транспортных средств, навигационная задача нахождения надежного пути, задача маршрутизации транспортных средств в сети и задача обеспечения информационной безопасности коммуникаций.

Задача прогнозирования времени движения отдельных транспортных средств является одной из наиболее востребованных задач для участников дорожного движения. Одна из возможных постановок, актуальная и сейчас – прогнозирование времени прибытия общественного транспортного средства (ОТС) на остановочные пункты.

Для оценки времени прохождения сегмента  $T_{ij}^{travel}$  между остановками  $i$  и  $j$  могут быть использованы различные факторы, которые прямо или косвенно влияют на целевое значение оценки прогноза. В диссертации предлагается использовать следующую гетерогенную информацию, описывающую транспортную ситуацию:

$$X_{i,j} = (day, time, v_{i-1,i}, h^r, T_{ij}^{m,r}, \hat{T}_{ij}^r, h^{any}, T_{ij}^{m,any}, \hat{T}_{ij}^{any}, T_{ij}^{hist}, T^{flow}, c_{ij}),$$

где  $day$  – день недели,  $time$  – время суток в минутах с полуночи,  $v_{i-1,i}$  – скорость прохождения предыдущего сегмента,  $h^r$  – интервал времени между предыдущим ОТС того же маршрута  $r$  и рассматриваемым ОТС,  $T_{ij}^{m,r}$  – время прохождения сегмента предыдущим ОТС  $m$  того же маршрута  $r$ ,  $\hat{T}_{ij}^r$  – взвешенное время прохождения сегмента предыдущими ОТС того же маршрута  $r$ ,  $h^{any}$  – интервал времени между предыдущим ОТС любого маршрута и рассматриваемым ОТС,  $T_{ij}^{m,any}$  – время прохождения сегмента предыдущим автобусом  $m$  любого маршрута,  $\hat{T}_{ij}^{any}$  – взвешенное время прохождения сегмента предыдущими автобусами любого маршрута,  $T_{ij}^{hist}(t)$  – среднее время прохождения дорожного сегмента автобусами любых маршрутов по статистическим данным в момент времени  $t$ ,  $T_{ij}^{flow}(t)$  – среднее время прохождения дорожного сегмента транспортным потоком по статистическим данным в момент времени  $t$ ;  $c_{ij}$  – количество автобусов на заданном дорожном сегменте.

Для решения задачи прогнозирования времени прибытия ОТС в работе предлагается использовать нейронную сеть на основе LSTM.

Экспериментальные исследования проводились на основе данных о движении транспортных средств пассажирских автобусных маршрутов в городе Самара, Россия. Для экспериментального анализа было выбрано 5 произвольных автобусных маршрутов, содержащих от 22 до 39 остановок. Было проведено сравнение предложенного алгоритма на основе LSTM-сети с базовой моделью искусственной нейронной сети (ИНС, один скрытый

слоем, состоящий из 32 нейронов) и моделью линейной регрессии. Результаты экспериментальных исследований показывают, что разработанный алгоритм обеспечивает лучший результат для каждого маршрута по сравнению с базовыми подходами (рисунок 10а), причем при увеличении суммарного времени движения относительная ошибка уменьшается (рисунок 10б).




Рисунок 10 – Экспериментальные исследования алгоритма прогнозирования движения ОТС

Следующая задача – задача *нахождения надежного пути* в стохастической транспортной сети с учетом информации о пространственной и временной корреляции сегментов дорожной сети, текущей и прогнозной информации о состоянии сети.

В задаче зависящая от времени стохастическая улично-дорожная сеть рассматривается в виде ориентированного графа  $G = (N, A, P)$ , где  $N$  – множество вершин графа,  $|N|$  – количество вершин,  $A$  – множество ребер,  $|A|$  – количество ребер,  $P$  – вероятностное описание времени прохождения ребер графа (т.е. сегментов улично-дорожной сети). В зависящих от времени стохастических сетях вес каждого сегмента  $(i, j) \in A$  обычно представляется как случайная величина  $T_{ij}(\tau)$  с зависящей от времени плотностью вероятности  $p_{ij}^\tau(t)$ . Обозначим  $u_i(t)$  – вероятность прибытия в конечную вершину  $d$  из вершины  $i$  за время, не превышающее  $t$ .

Оптимальная стратегия навигации определяется как стратегия максимизации вероятности прибытия в конечную вершину  $d \in N$  из начальной (текущей) вершины  $o \in N$  при наличии временного бюджета  $T$ :

$$u_i^\tau(t) = \max_{j \in N \wedge (i,j) \in A} \int_0^t p_{ij}^\tau(\theta) u_j^{\tau+\theta}(t - \theta), \forall i \in N \setminus \{d\}, t \in [0, T], \tau \geq 0$$

$$u_d^\tau(t) = 1, t \in [0, T], \tau \geq 0.$$

На практике решение этой проблемы производится с использованием численного алгоритма, заменяющего операции свёртки реализацией с использованием быстрого алгоритма Фурье. Представленный в (Samaranayake S., 2012) алгоритм решения задачи нахождения надежного пути учитывает только текущую информацию о загрузке транспортной сети для определения веса каждого сегмента. В диссертации предложен модифицированный алгоритм, учитывающий актуальную и прогнозную информацию  $I(\tau)$  для решения задачи навигации:

$$u_i^\tau(t|I(\tau)) = \max_{j \in N \wedge (i,j) \in A} \int_0^t p_{ij}^\tau(\theta|I(\tau)) u_j^{\tau+\theta}(t - \theta|I(\tau + \theta)) d\theta, \forall i \in N \setminus \{d\}, t \in [0, T], \tau \geq \tau_0,$$

$$u_d^\tau(t|I(\tau)) = 1, t \in [0, T], \tau \geq \tau_0.$$

Прогноз оценки функции плотности, то есть получение выражений  $p_{ij}^r(t|I(\tau_0))$  ( $\tau > \tau_0$ ), осуществляется через прогноз моментов распределений. Поскольку суть данной задачи – это прогноз параметров транспортного потока, для её решения используется подход, описанный во втором разделе диссертации.

Наиболее вычислительно сложным этапом работы алгоритма нахождения надежного пути является вычисление свертки. Для решения этой проблемы было предложено использовать устойчивое распределение Леви в качестве описания времени прохождения сегмента. В диссертации:

- 1) представлено устойчивое распределение Леви для описания времени прохождения сегментов дорожной сети;
- 2) показано, что операция свертки в базовом алгоритме может быть заменена пересчетом параметров функции распределения Леви;
- 3) предложен алгоритм аппроксимации функции нахождения максимума в базовом алгоритме с помощью функции распределения Леви;
- 4) представлен новый алгоритм решения задачи определения надежного пути;
- 5) предложен способ ускорения работы алгоритма путем предварительного вычисления аппроксимаций.

Для сравнения разработанного и базового алгоритмов решалась задача навигация на графе улично-дорожной сети Самары. Гистограммы распределения разности времени движения, полученного предложенным алгоритмом и базовым алгоритмом, показаны на рисунке 11а. На рисунке 11б оценивалось, насколько предложенный маршрут движения укладывался в требуемый бюджет поездки. В таблице 6 показано среднее время вычисления.




Рисунок 11 – Сравнение алгоритмов по затраченному временному ресурсу

Из полученных результатов можно сделать вывод, что предложенный алгоритм на основе распределения Леви ведет к нахождению маршрута движения вне выбранного бюджета чаще базового алгоритма на основе вычисления свертки примерно на 9%, однако позволяет примерно в 40 раз сократить время вычислений.

Таблица 6 – Сравнение времени работы алгоритмов

	Леви	Вычисление свертки
Время работы, мс	606	23625

Следующая задача – *маршрутизация транспортных средств в сети*. Постепенное развитие автономных и подключенных транспортных средств позволяет решать задачу минимизации времени движения с точки зрения эффективного распределения транспортных средств в сети. Для решения этой задачи в работе предложена модификация алгоритма резервирования маршрутов (Алгоритм 4), учитывающая стохастические свойства транспортной сети.

---

**Алгоритм 4: Алгоритм резервирования маршрутов (RRA)**

---

```
1: Входные данные:  $O, D, \tau, k$ 
2: if  $p_k = \emptyset$  then // Очистить трафик
3:   for  $(v_i, v_j) \in p_k$  do
4:      $\tau_{in} = \left\lfloor \frac{d(v_i)}{T_{discr}} \right\rfloor$ ;
5:      $\tau_{out} = \left\lfloor \frac{d(v_j)}{T_{discr}} \right\rfloor$ ;
6:     for  $t = \tau_{in}, \tau_{out}$  do
7:        $n_{v_i, v_j}(t) = n_{v_i, v_j}(t) - 1$ ;
8:     end for
9:   end for
10: end if
11:  $p_k = A * (O, D, n)$ ; // Обновить маршрут
12: for  $(v_i, v_j) \in p_k$  do // Обновить трафик
13:    $\tau_{in} = \left\lfloor \frac{d(v_i)}{T_{discr}} \right\rfloor$ ;
14:    $\tau_{out} = \left\lfloor \frac{d(v_j)}{T_{discr}} \right\rfloor$ ;
15:   for  $t = \tau_{in}, \tau_{out}$  do
16:      $n_{v_i, v_j}(t) = n_{v_i, v_j}(t) + 1$ ;
17:   end for
18: end for
```

---

**Алгоритм 5: Алгоритм обнаружения аномалий**

---

```
Входные данные:  $x_j(t), v_j(t), a_j(t), \tau_{ij}(t)$ 
 $\forall j = 0, N - 1$ 
Выходные данные: Вход управления  $u_j(t)$ 
1:  $d_{ij}(t) = [x_i(t - \tau_j) - x_i(t) - (i - j)s + v_0(t - \tau_0)\tau_j]$ ;
2:  $v_{ij}(t) = [v(t - \tau_j) - v_i(t)]$ ;
3:  $a_{ij}(t) = [a_i(t - \tau_j) - a_i(t)]$ ;
// Расчет средних ошибок
4:  $\bar{d}_i = \frac{1}{\Delta_i} \sum_{j=0}^{N-1} \alpha_{ij} d_{ij}(t)$ ;
5:  $\bar{v}_i = \frac{1}{\Delta_i} \sum_{j=0}^{N-1} \alpha_{ij} v_{ij}(t)$ ;
6:  $\bar{a}_i = \frac{1}{\Delta_i} \sum_{j=0}^{N-1} \alpha_{ij} a_{ij}(t)$ ;
// Проверка данных
7: for  $j = 0, 1, \dots, N - 1$  do
8:    $\epsilon = \|\bar{d}_i(t) - d_{ij}(t)\| + \|\bar{v}_i(t) - v_{ij}(t)\| + \|\bar{a}_i(t) - a_{ij}(t)\|$ ;
9:   if  $\epsilon > \sigma$  then
10:      $M = M \cup \{i\}$ ;
11:   end if
12: end for
13:  $u_i(t) = \dots$  // Расчет управляющего входа
```

---

Предполагается, что каждое транспортное средство взаимодействует с единой системой построения маршрутов. Построение нового маршрута с одной стороны, учитывает текущее состояние резервирования для расчета скорости движения по сегменту, с другой стороны, обновляет состояние резервирования для всех сегментов, входящих в новый маршрут. Для решения проблемы применения алгоритма резервирования в среде с гетерогенным транспортным потоком была предложена его модификация, в которой учитываются не только прогнозные значения параметров транспортного потока, но и фазы светофоров, управляемых рассмотренным адаптивным методом. Разработанный алгоритм состоит из следующих этапов:

- 1) сбор и предварительная обработка данных о состоянии потоков, сигналах светофоров и движении транспортных средств;
- 2) обнаружение загруженных участков дорожной сети;
- 3) выбор транспортных средств для перестроения маршрутов исходя из текущей загрузки транспортной сети;
- 4) построение нового маршрута движения для выбранных транспортных средств.

Заключительная задача косвенного управления, рассматриваемая в диссертации – это *обеспечение информационной безопасности коммуникаций*. Рассмотрим одну из постановок задачи для защиты от внутренних угроз при движении транспортных средств в колонне. Для управления транспортными средствами в колонне и поддержания оптимальной дистанции необходим обмен информацией между транспортными средствами. Стратегия управления движением состоит в том, чтобы поддерживать скорость и требуемое расстояние между транспортными средствами.

Динамика  $i$ -го транспортного средства описывается классическими уравнениями движения:



$$\dot{x}_i(t) = v_i(t), \dot{v}_i(t) = a_i(t), \dot{a}_i(t) = \frac{1}{T_i} [u_i(t)],$$

где  $u_i$  – управляющее воздействие:

$$u_i(t) = \frac{1}{\Delta_i} \sum_{j=0, j \notin M}^{N-1} \beta_1 \alpha_{ij} [x_i(t - \tau_j) - x_i(t) - (i - j)s + v_0(t - \tau_0)\tau_j] + \frac{1}{\Delta_i} \sum_{j=0, j \notin M}^{N-1} \beta_2 \alpha_{ij} [v_j(t - \tau_j) - v_i(t)] + \frac{1}{\Delta_i} \sum_{j=0, j \notin M}^{N-1} \beta_3 \alpha_{ij} a_j(t - \tau_j)$$

Предложен алгоритм обнаружения аномалий (Алгоритм 5) на основе вычислений ошибки положения относительно желаемого расстояния между транспортными средствами, ошибки скорости и желаемых значений ускорения. Предложенный алгоритм позволяет обнаружить вредоносные транспортные средства и вычислить управляющее воздействие  $u_i$ , используя только доверенные данные. Управляющее воздействие используется в стратегии управления движением ТС в колонне для поддержания скорости и требуемого расстояния между ТС.

**Пятый раздел** диссертации посвящен разработке архитектуры и реализации программного комплекса кооперативной ИТС. Программный комплекс обеспечивает выполнение следующих функций:

1) анализ и прогнозирование скорости движения с использованием гетерогенной информации (статических и актуальных данных) о состоянии ТП, в т.ч. данных от подключенных транспортных средств;

2) адаптивное управление транспортным потоком путем светофорного регулирования с учетом данных от подключенных и автономных подключенных транспортных средств, в т.ч. совместное управление сигналами светофорных объектов и траекториями движения подключенных и/или автономных подключенных транспортных средств;

3) расчет времени прибытия общественных транспортных средств на остановочные пункты и расчет оптимального маршрута движения на общественном транспорте с использованием информации о времени прибытия транспортных средств;

4) расчет оптимального пути на индивидуальном транспорте в стохастической сети с учетом информации о прогнозном распределении транспортных потоков.

В диссертации разработана и реализована модульная архитектура исследовательского программного комплекса с использованием подходов к обработке больших данных в составе высокопроизводительного горизонтально масштабируемого вычислительного кластера. Для реализации выбрана лямбда-архитектура, которая состоит из трёх взаимодополняющих уровней: уровень пакетной обработки, выполняющий обработку пакетов данных по расписанию, уровень скоростной обработки, выполняющий потоковую обработку данных в реальном времени, и уровень обслуживания, которые объединяет результаты пакетной и потоковой обработки для предоставления агрегированных данных пользователю по запросу.

В качестве источника данных используется система моделирования движения транспортных средств SUMO. Данные о параметрах движения поступают в брокер сообщений Apache Kafka. Далее, на уровне скоростной обработки используется инструмент Spark Streaming для чтения сообщений из Apache Kafka, сохранения в распределенную систему HDFS и в базу данных Cassandra. Hadoop используется для распределенного хранения файлов и их пакетной обработки. БД Cassandra используется для хранения большого массива разнородных данных. Для пакетной обработки используется инструмент

Apache Spark, который выполняет задачи прогнозирования параметров транспортного потока и скорости движения отдельных (общественных и подключенных) транспортных средств. Apache Spark использует файловое хранилище HDFS для чтения исходных данных и сохраняет результат аналитической обработки в БД PostgreSQL. На уровне обслуживания было разработано веб-приложение на языке Java с использованием библиотеки Spring Boot. Приложение реализует программно-прикладной интерфейс (API), принимает запросы пользователей и возвращает результат аналитической обработки.

В рамках программного комплекса были разработаны программные модули, решающие задачи анализа, прогнозирования и управления транспортным потоком и движением отдельных транспортных средств.

*Программный модуль краткосрочного прогнозирования параметров транспортного потока* предназначен для анализа и краткосрочного прогнозирования параметров ТП на основе технологии «больших данных», методов машинного обучения с использованием гетерогенной информации о состоянии транспортных потоков.

*Программный модуль адаптивного управления транспортным потоком* предназначен для решения задач расчета фазы светофорного объекта с использованием выбранного метода адаптивного управления: на основе обучения с подкреплением или на основе модельно-предикативного подхода, расчета траектории движения транспортных средств, согласованной с фазами светофорных объектов, позволяющей достичь координированного управления сигналами светофорных объектов и движением автономных подключенных транспортных средств.

*Программный модуль расчета оптимального пути на индивидуальном транспорте* предназначен для расчета надежного пути на индивидуальном транспорте в стохастической сети, максимизирующего вероятность достижения пункта назначения в течение определенного промежутка времени, с учетом информации о прогнозном распределении транспортных потоков.

*Программный модуль расчета оптимального пути на общественном транспорте* предназначен для решения задач анализа и краткосрочного прогнозирования времени прибытия общественного транспорта на остановочные пункты, расчета оптимального пути на общественном транспорте в стохастической сети с учетом прогнозной информации о времени прибытия транспортных средств. Данный модуль используется как часть программного комплекса транспортного оператора Самары для анализа движения общественного транспорта и отображения результатов анализа посредством сайта (рисунок 12а), мобильных приложений (рисунок 12б) и картографического сервиса (рисунок 12в).

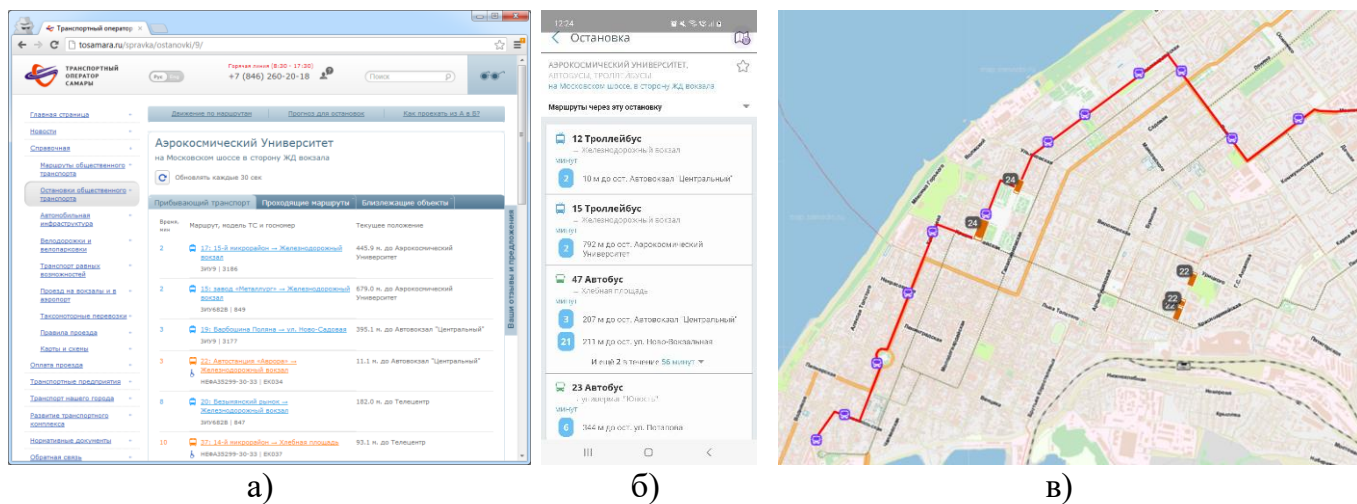


Рисунок 12 – Способы информирования участников дорожного движения

Разработанный программный комплекс позволил получить результаты исследований математических методов и алгоритмов решения задач анализа, прогнозирования и управления транспортным потоком с гетерогенным составом транспортных средств, а также движением отдельных транспортных средств в кооперативных ИТС.

### **Заключение**

В диссертационной работе разработаны методы и алгоритмы обработки гетерогенной информации и адаптивного управления в интеллектуальной транспортной системе, позволяющие повысить эффективности использования транспортной инфраструктуры путем директивного и косвенного управления транспортным потоком с гетерогенным составом транспортных средств, а также движением отдельных транспортных средств. В работе были получены следующие основные результаты:

1) проведена формализация задачи директивного управления транспортным потоком с гетерогенным составом транспортных средств, определены информационные потоки и состав гетерогенной информации, используемой для решения задачи управления;

2) разработан комплекс алгоритмических средств (математический метод и алгоритмы) решения задачи краткосрочного прогнозирования параметров транспортного потока в транспортной сети с использованием графовых сверточных нейронных сетей и подходов к обработке больших данных на основе гетерогенной информации о состоянии транспортного потока и движении отдельных транспортных средств, позволяющий снизить ошибку прогнозирования транспортного потока до 6% по сравнению с современными (state-of-the-art) решениями задачи прогнозирования на открытых наборах данных;

3) разработан комплекс алгоритмических средств решения задачи директивного управления транспортным потоком, включая методы независимого и/или координированного адаптивного управления сигналами светофоров и движением подключенных автономных транспортных средств в транспортной сети. Экспериментальные исследования в среде моделирования показывают, что предложенные методы позволяют снизить средний расход топлива (до 4,2%), среднее время движения (до 5.3%) и среднее время ожидания (до 27%) по сравнению с современными методами решения задачи адаптивного управления светофорными объектами;

4) разработан комплекс алгоритмических средств решения задачи косвенного управления транспортным потоком и информирования в ИТС:

- алгоритм определения надёжного пути в зависящей от времени стохастической (транспортной) сети, учитывающий информацию о пространственной и временной корреляции сегментов дорожной сети, текущую и прогнозную информацию о состоянии транспортного потока; ускоренная модификация алгоритма с использованием распределения Леви, позволяющая повысить скорость вычислений в среднем в 40 раз при ухудшении качественных показателей в среднем на 9%;
- алгоритмы краткосрочного прогнозирования времени движения отдельных транспортных средств, учитывающие гетерогенную информацию о транспортной ситуации, прямо или косвенно влияющую на прогнозируемое время движения;
- алгоритм маршрутизации подключенных транспортных средств в транспортной сети на основе численного метода резервирования маршрутов, учитывающий стохастические свойства транспортной сети; модификация алгоритма для применения в гетерогенном транспортном потоке;

5) разработан и реализован программный комплекс кооперативной интеллектуальной транспортной системы, решающей задачи анализа, прогнозирования и управления транспортным потоком с гетерогенным составом транспортных средств с использованием подходов к обработке больших данных;

б) проведены экспериментальные исследования разработанных алгоритмических средств на натуральных и модельных данных, подтвердившие эффективность разработанных методов, алгоритмов и реализованного программного комплекса.

### Основные публикации по теме диссертации

*Статьи в изданиях, индексируемых реферативными базами данных Web of Science / Scopus:*

1. Agafonov, A. Cooperative Control for Signalized Intersections in Intelligent Connected Vehicle Environments / A. Agafonov, A. Yumaganov, V. Myasnikov // *Mathematics*. – 2023. – Vol. 11(6). – P. 1540. (Q1 JCR/WoS)
2. Агафонов, А.А. Совместное управление сигналами светофоров и траекториями движения транспортных средств / А.А. Агафонов, А.С. Юмаганов // *Информатика и автоматизация*. – 2023. – Т. 22(1). – С. 5–32. (K1 ВАК)
3. Агафонов, А.А. Метод определения надежного кратчайшего пути в стохастической сети с использованием параметрически заданных устойчивых распределений вероятностей / А.А. Агафонов, В.В. Мясников // *Труды СПИИРАН*. – 2019. – Т. 18(3). – С. 558–582. (K1 ВАК)
4. Мясников, В.В. Детерминированная прогнозная модель управления сигналами светофоров в интеллектуальных транспортных и геоинформационных системах / В.В. Мясников, А.А. Агафонов, А.С. Юмаганов // *Компьютерная оптика*. – 2021. – Т. 45(6). – С. 917–925. (Q2 SJR)
5. Agafonov, A. Bus Arrival Time Prediction with LSTM Neural Network / A. Agafonov, A. Yumaganov // *Advances in Neural Networks – ISNN 2019: Lecture Notes in Computer Science*. – 2019. – Vol. 11554. – P. 11–18. (Q2 SJR)
6. Agafonov, A.A. Bus Arrival Time Prediction Using Recurrent Neural Network with LSTM Architecture / A.A. Agafonov, A.S. Yumaganov // *Optical Memory and Neural Networks*. – 2019. – Vol. 28(3). – P. 222–230. (Q2 SJR)
7. Агафонов, А.А. Анализ больших данных в геоинформационной задаче краткосрочного прогнозирования параметров транспортного потока на базе метода k ближайших соседей / А.А. Агафонов, А.С. Юмаганов, В.В. Мясников // *Компьютерная оптика*. – 2018. – Т. 42(6). – С. 1101–1111. (Q2 SJR)
8. Агафонов, А.А. Исследование численного метода резервирования маршрутов в геоинформационной задаче маршрутизации автономных транспортных средств / А.А. Агафонов, В.В. Мясников // *Компьютерная оптика*. – 2018. – Т. 42(5). – С. 912–920. (Q2 SJR)
9. Agafonov, A. Spatial-Temporal K Nearest Neighbors Model on MapReduce for Traffic Flow Prediction / A. Agafonov, A. Yumaganov // *Intelligent Data Engineering and Automated Learning, LNCS: Lecture Notes in Computer Science*. – 2018. – Vol. 11314. – P. 253–260. (Q2 SJR)
10. Агафонов, А.А. Метод определения надёжного кратчайшего пути в зависящей от времени стохастической сети и его применение в геоинформационных задачах управления транспортом / А.А. Агафонов, В.В. Мясников // *Компьютерная Оптика*. – 2016. – Т. 40(2). – С. 275–283. (Q2)
11. Агафонов, А.А. Оценка и прогнозирование параметров транспортных потоков с использованием композиции методов машинного обучения и моделей прогнозирования временных рядов / А.А. Агафонов, В.В. Мясников // *Компьютерная оптика*. – 2014. – Т. 38(3). – С. 356–369. (Q2 SJR)
12. Агафонов, А.А. Алгоритм оценки времени прибытия общественного транспорта с использованием адаптивной композиции элементарных прогнозов / А.А. Агафонов, В.В. Мясников // *Компьютерная оптика*. – 2014. – Т. 38(2). – С. 356–368. (Q2 SJR)
13. Agafonov, A.A. Adaptive Traffic Signal Control Based on Neural Network Prediction of Weighted Traffic Flow / A.A. Agafonov, A.S. Yumaganov, V.V. Myasnikov // *Optoelectronics, Instrumentation and Data Processing*. – 2022. – Vol. 58(5). – P. 503–513. (Q3 SJR)
14. Agafonov, A.A. Hybrid Prediction-Based Approach for Traffic Signal Control Problem / A.A. Agafonov, V.V. Myasnikov // *Optical Memory and Neural Networks*. – 2022. – Vol. 31(3). – P. 11. (Q3)
15. Agafonov, A.A. Short-Term Traffic Data Forecasting: A Deep Learning Approach / A.A. Agafonov // *Optical Memory and Neural Networks*. – 2021. – Vol. 30(1). – P. 1–10. (Q3 SJR)
16. Yumaganov, A. An Improved Map Matching Algorithm Based on Dynamic Programming Approach / A. Yumaganov, A. Agafonov, V. Myasnikov // *Information Technology for Management: Towards*

- Business Excellence: Lecture Notes in Business Information Processing. – 2021. – Vol. 413. – P. 87–102. (Q3 SJR)
17. Agafonov, A.A. Using satellite monitoring and statistical data to predict arrival time of city public transport / A.A. Agafonov, A.V. Chernov, A.V. Sergeev // Pattern Recognition and Image Analysis. – 2015. – Vol. 25(3). – P. 385–388. (Q3 SJR)
  18. Agafonov, A. Traffic flow forecasting algorithm based on combination of adaptive elementary predictors / A. Agafonov, V. Myasnikov // Communications in Computer and Information Science. – 2015. – Vol. 542. – P. 163–174. (Q3 SJR)
  19. Агафонов, А.А. Прогнозирование параметров движения городского пассажирского транспорта по данным спутникового мониторинга / А.А. Агафонов, А.В. Сергеев, А.В. Чернов // Компьютерная оптика. – 2012. – Т. 36(3). – С. 453–458. (Q3 SJR)
  20. Агафонов, А.А. Адаптивное управление дорожными сигналами на основе нейросетевого прогноза максимального взвешенного потока / А.А. Агафонов, А.С. Юмаганов, В.В. Мясников // Автометрия. – 2022. – Т. 58(5). – С. 85–97.
  21. Agafonov, A. Traffic Flow Prediction Using Graph Convolution Neural Networks / A. Agafonov // 2020 10th International Conference on Information Science and Technology. – 2020. – P. 91–95.
  22. Agafonov, A.A. A public transport departure time prediction algorithm based on operation strategies and real-time monitoring data / A.A. Agafonov // CEUR Workshop Proceedings. – 2018. – Vol. 2210. – P. 75–81.
  23. Borodinov, A. A Method of Preference and Utility Elicitation By Pairwise Comparisons and its Application to Intelligent Transportation Recommendation Systems / A. Borodinov, A. Agafonov, V. Myasnikov // 2020 10th International Conference on Information Science and Technology (ICIST). – 2020. – P. 77–85.
  24. Agafonov, A. GPU implementation of the stochastic on-time arrival routing algorithm / A. Agafonov, A. Maksimov, A. Borodinov // CEUR Workshop Proceedings. – 2020. – Vol. 2665. – P. 164–167.
  25. Borodinov, A.A. Public transport route planning in the stochastic network based on the user individual preferences / A.A. Borodinov, A.S. Yumaganov, A.A. Agafonov // CEUR Workshop Proceedings. – 2019. – Vol. 2391. – P. 66–71.
  26. Agafonov, A.A. Approximation of the road segments travel time using Levy distributions in the reliable shortest path problem / A.A. Agafonov, V.V. Myasnikov, A.I. Maksimov // Journal of Physics: Conference Series. – 2019. – Vol. 1368. – P. 032008.
  27. Agafonov, A.A. Performance comparison of machine learning methods in the bus arrival time prediction problem / A.A. Agafonov, A.S. Yumaganov // CEUR Workshop Proceedings. – 2019. – Vol. 2416. – P. 57–62.
  28. Agafonov, A. A Route Reservation Approach for an Autonomous Vehicles Routing Problem / A. Agafonov, A. Borodinov // MATEC Web of Conferences. – 2018. – Vol. 220. – P. 02004.
  29. Agafonov, A.A. Vehicle routing algorithms based on a route reservation approach / A.A. Agafonov, V.V. Myasnikov // Journal of Physics: Conference Series. – 2018. – Vol. 1096(1). – P. 012029.
  30. Agafonov, A.A. Short-term traffic flow forecasting using a distributed spatial-temporal model / A.A. Agafonov, A.S. Yumaganov // CEUR Workshop Proceedings. – 2018. – Vol. 2210. – P. 402–409.
  31. Agafonov, A. Efficiency comparison of the routing algorithms used in centralized traffic management systems / A. Agafonov, V. Myasnikov // Procedia Engineering. – 2017. – Vol. 201. – P. 265–270.
  32. Abdulganiev, I. Acceleration of the reliable shortest path algorithm in a time-dependent stochastic transport network / I. Abdulganiev, A. Agafonov // CEUR Workshop Proceedings. – 2017. – Vol. 1901. – P. 1–5.
  33. Agafonov, A. Structural optimization of the travel time prediction model based on hierarchical regression / A. Agafonov, V. Myasnikov // CEUR Workshop Proceedings. – 2016. – Vol. 1710. – P. 1–9.
  34. Abdulganiev, I. Automatic checking of road network models / I. Abdulganiev, A. Agafonov // CEUR Workshop Proceedings. – 2016. – Vol. 1638. – P. 249–255.
  35. Agafonov, A. An Adaptive Algorithm for Public Transport Arrival Time Prediction Based on Hierarchical Regression / A. Agafonov, V. Myasnikov // IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC. – 2015. – Vol. 2015. – P. 2776–2781.

36. Agafonov, A. Adaptive Traffic Light Control Using a Distributed Processing Approach / A. Agafonov // 2022 IEEE International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON). – 2022. – P. 186–189.
37. Yumaganov, A. Cooperative Application of Vehicular Traffic Rerouting Method and Adaptive Traffic Signal Control Method / A. Yumaganov, A. Agafonov, V. Myasnikov // 2023 IX International Conference on Information Technology and Nanotechnology (ITNT) – 2023. – P. 1-5.
38. Agafonov, A. Efficiency of Adaptive Traffic Signal Control in a Partially Connected Vehicle Environment / A. Agafonov, A. Yumaganov, V. Myasnikov // 2023 IX International Conference on Information Technology and Nanotechnology (ITNT). – 2023. – P. 1-4.
39. Agafonov, A. Connected Vehicles Travel Time Prediction in a Scenario with Adaptive Traffic Light Control / A. Agafonov, E. Efimenko // 2023 IX International Conference on Information Technology and Nanotechnology (ITNT). – 2023.
40. Yumaganov, A. Vehicle Trajectory Planning in the Problem of Traffic Flow Control at Signalized Intersections / A. Yumaganov, A. Agafonov // 2022 VIII International Conference on Information Technology and Nanotechnology (ITNT). – 2022.
41. Agafonov, A. An Algorithm for Cooperative Control of Traffic Signals and Vehicle Trajectories / A. Agafonov, A. Yumaganov, V. Myasnikov // 2022 4th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA). – 2022. – P. 675–680.
42. Agafonov, A. Adaptive Traffic Signal Control Based on Maximum Weighted Traffic Flow / A. Agafonov, A. Yumaganov, V. Myasnikov // 2022 VIII International Conference on Information Technology and Nanotechnology (ITNT). – 2022.
43. Agafonov, A. Comparison of Traffic Signal Control Algorithms in a Large-Scale Traffic Simulation Environment / A. Agafonov, E. Efimenko // 2022 VIII International Conference on Information Technology and Nanotechnology (ITNT). – 2022.
44. Petrenkov, D. Anomaly Detection in Vehicle Platoon with Third-Order Consensus Control / D. Petrenkov, A. Agafonov // 2021 Ural Symposium on Biomedical Engineering, Radioelectronics and Information Technology (USBREIT). – 2021. – P. 0463–0466.
45. Kovalev, K. Authentication Scheme in Vehicular Ad Hoc Networks Based on Road Side Unit Infrastructure / K. Kovalev, A. Agafonov // 2021 International Conference on Information Technology and Nanotechnology (ITNT). – 2021.
46. Agafonov, A. Determining the Optimal Number of Features for User Preference Elicitation in Recommender Systems / A. Agafonov, A. Yumaganov, V. Myasnikov // 2021 International Conference on Information Technology and Nanotechnology (ITNT). – 2021.
47. Agafonov, A. Agent-Based Traffic Signal Control Using a Reinforcement Learning Approach / A. Agafonov, A. Yumaganov // 2021 International Conference on Information Technology and Nanotechnology (ITNT). – 2021.
48. Agafonov, A. Short-term Traffic Flow Prediction in a Partially Connected Vehicle Environment / A. Agafonov, V. Myasnikov // 2021 3rd International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA). – 2021. – P. 968–972.
49. Agafonov, A. Reconstruction of User Trips on Public Transport Using Indirect Information / A. Agafonov, V. Myasnikov // 2021 International Conference on Information Technology and Nanotechnology (ITNT). – 2021.
50. Agafonov, A. Traffic Signal Control: A Double Q-learning Approach / A. Agafonov, V. Myasnikov // Proceedings of the 16th Conference on Computer Science and Intelligence Systems, FedCSIS 2021. – 2021. – P. 365–369.
51. Yumaganov, A. Map Matching Algorithm Based on Dynamic Programming Approach / A. Yumaganov, A. Agafonov, V. Myasnikov // 2020 15th Conference on Computer Science and Information Systems (FedCSIS) – 2020. – P. 563–566.
52. Agafonov, A. Spatio-Temporal Graph Convolutional Networks for Short-Term Traffic Forecasting / A. Agafonov, A. Yumaganov // 2020 International Conference on Information Technology and Nanotechnology (ITNT). – 2020.

53. Agafonov, A. 3D Objects Detection in an Autonomous Car Driving Problem / A. Agafonov, A. Yumaganov // 2020 International Conference on Information Technology and Nanotechnology (ITNT). – 2020.
54. Agafonov, A. Anticipatory Vehicle Routing in Stochastic Networks Using Multi-Agent System / A. Agafonov, V. Myasnikov, A. Borodinov // 2019 XXI International Conference Complex Systems: Control and Modeling Problems (CSCMP). – 2019. – P. 91–95.
55. Agafonov, A. Stochastic On-time Arrival Problem with Levy Stable Distributions / A. Agafonov, V. Myasnikov // 2019 4th International Conference on Intelligent Transportation Engineering (ICITE). – 2019. – P. 227–231.
56. Agafonov, A. Short-Term Traffic Flow Forecasting Using a Distributed Spatial-Temporal k Nearest Neighbors Model / A. Agafonov, A. Yumaganov // 2018 IEEE International Conference on Computational Science and Engineering (CSE). – 2018. – P. 91–98.
57. Agafonov, A. Reliable routing in stochastic time-dependent network with the use of actual and forecast information of the traffic flows / A. Agafonov, V. Myasnikov // IEEE Intelligent Vehicles Symposium, Proceedings. – 2016. – Vol. 2016-August. – P. 1168–1172.

*Свидетельства о государственной регистрации программы для ЭВМ:*

58. Свидетельство о государственной регистрации программы для ЭВМ № 2016616120 Российская Федерация. Прогнозирование параметров транспортных потоков: № 2016613312: заявлено 08.04.2016: опубликовано 06.06.2016 / Мясников В.В., Агафонов А.А.
59. Свидетельство о государственной регистрации программы для ЭВМ № 2019610695 Российская Федерация. Программный модуль краткосрочного прогнозирования параметров транспортных потоков на основе технологии «Больших данных» с использованием данных реального времени и архивных данных о состоянии транспортных потоков: № 2018665023: заявлено 24.12.2018: опубликовано 15.01.2019 / Агафонов, А.А., Юмаганов А.С., Мясников В.В., Бородинов А.А.
60. Свидетельство о государственной регистрации программы для ЭВМ № 2021666358 Российская Федерация. Программный модуль краткосрочного прогнозирования параметров смешанных транспортных потоков: № 2021665497: заявлено 04.10.2021: опубликовано 13.10.2021 / Агафонов А.А., Мясников В.В., Юмаганов А.С., Юзькив Р.Р.
61. Свидетельство о государственной регистрации программы для ЭВМ № 2021666359 Российская Федерация. Программный модуль управления сигналами светофора на основе детерминированной прогнозной модели: № 2021665500: заявлено 04.10.2021: опубликовано 13.10.2021 / Агафонов А.А., Мясников В.В., Юмаганов А.С., Юзькив Р.Р.
62. Свидетельство о государственной регистрации программы для ЭВМ № 2022663558 Российская Федерация. Программный модуль управления сигналами светофора с использованием модели глубокой нейронной сети: № 2022662536: заявлено 29.06.2022: опубликовано 15.07.2022 / Агафонов А.А., Мясников В.В., Юмаганов А.С., Ефименко Е.Ю., Ганеева Ю.Х.
63. Свидетельство о государственной регистрации программы для ЭВМ № 2022663570 Российская Федерация. Программный модуль нахождения рекомендованной траектории движения автономных транспортных средств с учетом информации о светофорном цикле: № 2022662537: заявлено 29.06.2022: опубликовано 15.07.2022 / Агафонов А.А., Мясников В.В., Юмаганов А.С., Козлов Д.А., Ганеева Ю.Х.
64. Свидетельство о государственной регистрации программы для ЭВМ № 2020612379 Российская Федерация. Программный модуль расчета оптимального надежного пути на индивидуальном транспорте в стохастической сети с использованием параметрически заданных устойчивых распределений вероятностей: № 2020611546: заявлено 14.02.2020: опубликовано 20.02.2020 / Агафонов А.А., Мясников В.В.
65. Свидетельство о государственной регистрации программы для ЭВМ № 2019660218 Российская Федерация. Программный модуль прогнозирования времени прибытия общественного транспорта с использованием рекуррентной нейронной сети: № 2019618913: заявлено 19.07.2019: опубликовано 02.08.2019 / Агафонов А.А., Юмаганов А.С., Бородинов А.А.