

УДК: 656.13

DOI: 10.48612/NewsKSUAE/75.31

EDN: UNTRBI



Технологии видеоаналитики и анализа больших данных в развитии интеллектуальных транспортных систем

В.В. Мокшин¹, А.А. Ванюшев², Л.Ф. Мавлиев³, Р.В. Николаева³

¹ Казанский национальный исследовательский технический университет
имени А.Н. Туполева, г. Казань, Российская Федерация

² АО «СМП-Нефтегаз», г. Альметьевск, Российская Федерация

³ Казанский государственный архитектурно-строительный университет,
г. Казань, Российская Федерация

Аннотация: *Постановка задачи.* Транспорт играет ключевую роль в экономике и качестве жизни. Для оптимизации транспортной сети применяются интеллектуальные транспортные системы (ИТС), сбор данных в которых осуществляется через видеонаблюдение. Благодаря видеоаналитике и искусственному интеллекту движение становится безопаснее и эффективнее. Цель исследования – обобщение принципов работы ИТС с интеграцией видеоаналитики и Big Data. Задачи: анализ существующих ИТС, использующих эти технологии, и определение технологической основы их построения.

Результаты. Рассмотрены успешные примеры внедрения ИТС в разных странах, подтверждающие эффективность. Интеграция Big Data, машинного обучения и компьютерного зрения качественно улучшает управление дорожной инфраструктурой. В эксперименте сравнены модели детекции Faster R-CNN, YOLOv8s и YOLOv9s по точности, полноте, скорости и ресурсоёмкости. Faster R-CNN точен, но уступает YOLO в скорости и компактности. YOLOv8s показала наилучший баланс качества и быстродействия. YOLOv9s перспективна для устройств с ограниченными ресурсами. Установлена технологическая основа ИТС: видеонаблюдение высокого разрешения, алгоритмы компьютерного зрения, обработка больших данных и в реальном времени, совместимость с другими технологиями, анализ поведения участников, принятие решений, защита конфиденциальности и кибербезопасность.

Выводы. Значимость работы — в оптимизации работы транспортной сети. Результаты подчёркивают важность комплексного подхода, объединяющего технические решения, анализ данных и пользовательские сервисы для создания устойчивой, безопасной и высокоэффективной транспортной сети.

Ключевые слова: транспортная сеть, интеллектуальные транспортные системы, транспортные потоки, видеоаналитика, большие данные, компьютерное зрение, машинное обучение, автомобильные дороги, Big Data.

Для цитирования: Мокшин В.В., Ванюшев А.А., Мавлиев Л.Ф., Николаева Р.В. Технологии видеоаналитики и анализа больших данных в развитии интеллектуальных транспортных систем // Известия КГАСУ, 2026, № 1 (75), с. 376-394, DOI: 10.48612/NewsKSUAE/75.31, EDN: UNTRBI

Video analytics and big data analysis technologies in the development of intelligent transport systems

V.V. Mokshin¹, A.A. Vaniushev², L.F. Mavliev³, R.V. Nikolaeva³

¹ Kazan National Research Technical University named after A.N. Tupolev,
Kazan, Russian Federation

² SMP-Neftegaz JSC, Almetyevsk, Russian Federation

³ Kazan State University of Architecture and Engineering, Kazan, Russian Federation

Abstract: *Problem statement.* Problem Statement. Transportation plays a key role in the economy and quality of life. Intelligent transportation systems (ITS), which collect data through video surveillance, are used to optimize transportation networks. Video analytics and artificial intelligence make transportation safer and more efficient. The goal of this study is to summarize the operating principles of ITS with the integration of video analytics and Big Data. Objectives: analyze existing ITS systems using these technologies and determine the technological basis for their development.

Results. Successful examples of ITS implementation in various countries are considered, confirming their effectiveness. The integration of Big Data, machine learning, and computer vision significantly improves road infrastructure management. The experiment compared the Faster R-CNN, YOLOv8s, and YOLOv9s detection models in terms of accuracy, recall, speed, and resource consumption. Faster R-CNN is accurate but inferior to YOLO in speed and compactness. YOLOv8s demonstrated the best balance of quality and performance. YOLOv9s is promising for devices with limited resources. The technological foundation of the ITS has been established: high-resolution video surveillance, computer vision algorithms, big data and real-time processing, compatibility with other technologies, participant behavior analysis, decision making, privacy protection, and cybersecurity.

Conclusions. The significance of this work lies in optimizing transportation network performance. The results highlight the importance of an integrated approach combining technical solutions, data analysis, and user services to create a resilient, secure, and highly efficient transportation network.

Keywords: transport network, intelligent transport systems, traffic flows, video analytics, big data, computer vision, machine learning, highways, Big Data.

For citation: Mokshin V.V., Vaniushev A.A., Mavliev L.F., Nikolaeva R.V. Video analytics and big data analysis technologies in the development of intelligent transport systems // News of KSUAE, 2026, № 1 (75), p. 376-394, DOI: 10.48612/NewsKSUAE/75.31, EDN: UNTRBI

1. Введение

Транспорт является одной из основных отраслей национальной экономики, определяя социальное и экономическое развитие страны, а также способствуя повышению уровня жизни населения. В то же время стремительный рост уровня автомобилизации создает большую нагрузку на транспортную сеть, увеличивает количество дорожно-транспортных происшествий. Все это способствует снижению эффективности организации дорожного движения, а также тормозит развитие транспортной инфраструктуры, что затрудняет движение населения и делает его не безопасным [1, 2].

Чтобы эффективнее управлять транспортной инфраструктурой, сегодня всё чаще прибегают к внедрению интеллектуальных транспортных систем (ИТС). Такие решения помогают оптимизировать движение, сократить заторы и повысить безопасность на дорогах за счёт использования современных цифровых технологий. Основой данных систем является сбор оперативной информации об условиях дорожного движения для принятия своевременных мер по управлению данным процессом.

Развитие ИТС является одним из ключевых направлений в создании устойчивых и безопасных транспортных сетей. В последние годы растущий объем транспортных потоков, урбанизация и повышение требований к безопасности дорожного движения

привели к активному внедрению технологий больших данных, компьютерного зрения и машинного обучения в транспортную отрасль [3, 4].

В современные ИТС интегрированы сенсоры, видеонаблюдение, прогнозные модели и системы связи для повышения эффективности управления транспортной инфраструктурой и улучшения качества обслуживания участников дорожного движения [5]. Обработка массивов данных, формируемых при анализе видеопотоков, выступает значимым исследовательским направлением. Благодаря алгоритмам распознавания изображений и трекингу объектов удаётся в автоматическом режиме обнаруживать нештатные ситуации, регулировать загруженность дорог и предотвращать опасные сценарии. Такие технологии лежат в основе интеллектуальных решений для контроля трафика и фиксации нарушений ПДД непосредственно в процессе движения [6–8].

Интеллектуальные транспортные системы (ИТС) базируются на непрерывном мониторинге транспортных потоков с привлечением разнородных источников данных: GPS-треков, показаний детекторов трафика, видеофиксации и сведений из социальных медиа [3, 4]. Применение методов анализа больших данных и алгоритмов машинного обучения даёт возможность:

- прогнозировать динамику дорожной обстановки;
- оптимизировать маршрутизацию и снижать уровень заторов;
- планировать перспективное развитие транспортной инфраструктуры;
- оперативно информировать участников движения.

Своевременное оповещение о дорожных происшествиях, метеоусловиях и пробках повышает безопасность и эффективность транспортной сети [9–12]. Дополнительно ИТС интегрируют метеомониторинг, системы весогабаритного контроля и безопасности, а также решения типа «Свободный поток» для автоматизированного взимания платы за проезд.

Развитием и внедрением интеллектуальных систем в транспортный комплекс на основе анализа больших данных сегодня занимаются как российский, так и зарубежные ученые, совместно с организациями в области транспорта [13, 14]. Росавтодор участвует в создании национальной цифровой транспортно-логистической платформы в Российской Федерации, где государственные и ведомственные системы выступают поставщиками данных об автомобильных дорогах. Также в ведомственную программу цифровой трансформации включены мероприятия по внедрению технологий искусственного интеллекта (ИИ) для управления дорожным движением, например, автоматизированный расчет риска возникновения ДТП на участках федеральных дорог.

Поляков А.С. («Транснет») отмечает, что технологии Big Data используются для развития интеллектуальной транспортной системы Москвы, например, для создания Динамической транспортной модели – системы, которая агрегирует данные с датчиков ГЛОНАСС, камер фото- и видеофиксации и транспортных детекторов. С помощью модели можно управлять светофорами, анализировать очаги аварийности, места скопления транспортных средств, выявлять затруднения в движении пассажирского транспорта.

С помощью инструментов Big Data на Алтуфьевском шоссе (г. Москва) специалисты анализировали данные о распределении транспортных потоков, поступающие с камер на перекрестках.

Концерном «Телематика» разработана автоматизированная система управления дорожным движением (АСУДД), которая получает данные с камер, датчиков и прочих устройств, обеспечивает полный доступ к данным о ситуации на дороге и погодных условиях, информирует об аварийных ситуациях и дорожных инцидентах. В системе есть модуль выявления инцидентов, основанный на компьютерном зрении и ИИ, и механизмы определения эффективных сценариев дорожного движения.

Департамент Big Data (Tele2) разработал алгоритм, в котором ИИ анализирует автомобильный трафик по всей России, находит участки дорог и понимает какое количество людей проезжает по ним, сегментируя информацию о них.

Ученые Университет штата Айова (Iowa State University) разработали систему управления дорожно-транспортными происшествиями (TIMELI), которая использует анализ больших данных для раннего обнаружения дорожно-транспортных происшествий

и лучшего управления трафиком. Цель – снизить количество дорожно-транспортных происшествий через проактивный контроль трафика и минимизировать влияние отдельных происшествий через раннее выявление, реакцию и управление трафиком.

Таким образом, в ИТС эффективно объединены передовые информационные технологии, такие как, технологии передачи данных, сенсорные технологии, технологии электронного управления и компьютерные технологии в систему управления транспортом.

Внедрением ИТС можно значительно повысить эффективность использования транспортной инфраструктуры, тем самым сократив государственные инвестиции в объекты инфраструктуры, сократить заторы и снизить частоту дорожно-транспортных происшествий, уменьшить количество выбросов и потребление энергии. Несмотря на то, что преимущества ИТС очевидны, ускорение совершенствования системы входит в число главных приоритетов современных исследований в области транспорта.

Цель исследования: обобщение принципов работы интеллектуальных транспортных систем с интегрированными технологиями видеоаналитики и анализа больших данных.

В рамках исследования решались следующие задачи:

- изучить практику внедрения ИТС, использующих видеоаналитику и анализ больших данных (Big Data), с целью выявления их потенциала в оптимизации транспортных процессов;
- определить ключевые технологические компоненты, необходимые для построения ИТС с поддержкой видеоаналитических алгоритмов и обработки массивов больших данных.

2. Материалы и методы

Данные о транспортных и пешеходных потоках составляют фундаментальную основу для стратегического планирования развития транспортной инфраструктуры и выработки управленческих решений. На основе анализа транспортных потоков специалисты решают целый ряд практических задач [5]:

- выбор оптимального размещения объектов транспортной инфраструктуры;
- определение пропускной способности автомобильных дорог и улиц;
- выявление «узких мест» на автомобильных дорогах и улицах;
- оптимизация скоростного режима на участках дорожной сети.

Методы сбора данных о параметрах транспортного потока имеют принципиальное значение для качества последующей аналитики, при этом выделяют следующие методы:

1. использование стационарных сенсоров, которые включают видеорекамеры и лидары, установленные в фиксированных точках на участках дорожной сети [3]. С их помощью можно определить такие показатели, как: интенсивность транспортного потока и тип транспортного средства, скорость движения транспортных средств;

2. использование мобильных источников данных, к ним смартфоны, GPS-навигаторы, бортовые устройства и датчики, установленные на транспортных средствах [9]. Они могут передавать информацию о местоположении транспортных средств, и траектории движения в режиме реального времени. Это позволяет охватить большую территорию, чем стационарные сенсоры.

Данные полученные при обследовании транспортного потока образуют большой массив «транспортных больших данных», что предъявляет особые требования к инфраструктуре хранения и алгоритмам обработки данных [4]. Для решения данной проблемы активно задействуются инструменты работы с большими данными (Big Data) и алгоритмы машинного обучения, позволяющие автоматизировать процессы распознавания и интерпретации визуальной информации [4].

Анализ больших данных (Big Data), получаемых при мониторинге транспортных потоков, дает возможность понять текущую ситуацию на дорогах, а также спрогнозировать перспективную, таким образом обеспечивая создание эффективной транспортной сети, улучшение качества жизни и снижении негативного воздействия транспорта на окружающую среду [4, 10]. Детализированная картина потоков позволяет оценивать эффективность изменений: например, Big Data рассчитывает и калибрует метрики AADT на всех участках без установки дополнительных датчиков. Анализ ориентации потоков (Origin–Destination) используется при проектировании развязок и парковок [4].

Практические примеры подтверждают, что мониторинг транспортного потока на основе видеоаналитики и Big Data является перспективным направлением развития транспортной сети.

Основные направления, в которых применяются технологии видеоаналитики и Big Data в ИТС:

1. Оптимизация дорожного движения.

Big Data и алгоритмы машинного обучения дают возможность не только описывать текущую ситуацию, но и оптимизировать движение в реальном времени [11]. На основе анализа исторических трендов и онлайн данных строятся модели загрузки транспортной сети, которые позволяют выявлять узкие места и автоматически перенастраивать компоненты ИТС.

Системы адаптивных светофоров, обучающиеся на больших массивах данных, обеспечивают снижение среднего времени ожидания на перекрестках [15]. На рисунке 1 показана система адаптивного управления движением и схематика АУД на перекрестке.




Рис. 1. Система адаптивного управления движением и схематика АУД на перекрестке (иллюстрация авторов)

Fig. 1. Adaptive traffic management system and intersection AUD scheme (illustration by the authors)

Прогностические модели используют разнородные источники: дорожные сенсоры, GPS данные такси и приложений, погодные условия и данные социальных медиа. Гибридные модели CNN+LSTM обеспечивают высокую точность прогноза на 5-30 минут вперед [16].

Практические кейсы демонстрируют эффективность Big Data в управлении трафиком:

- в Лос Анджелесе городской департамент использует платформу ITMS для анализа данных со светофоров, мобильных приложений и камер;
- в Сингапуре система ERP (электронной платы за проезд) динамически изменяет тарифы на основе данных о трафике в реальном времени;
- в Лондоне предиктивная система прогнозирует начало затора с опережением на 5–10 минут благодаря анализу исторических данных;
- в Москве в системе ЦОДД внедрены интеллектуальные алгоритмы управления движением на основе данных сенсоров и видеонаблюдения;
- экспериментально зафиксировано уменьшение длительности пиковых пробок благодаря внедрению адаптивного регулирования.

2. Обеспечение безопасности дорожного движения.

Обеспечение безопасности дорожного движения является одной из ключевых задач которую могут решить ИТС. Безопасность участников дорожного движения обеспечивается за счет применения комплекса технических средств, организационных мероприятий и специализированных цифровых программных платформ.

Сегодня все чаще для решения транспортных проблем прибегают к применению видеоконтроля оснащенного интеллектуальной аналитикой, с его помощью фиксируют нарушения правил дорожного движения [8]. Системы также автоматически выявляют превышение скорости, неадекватные маневры и аномальные скопления пешеходов, что важно для предупреждения чрезвычайных ситуаций [4]. Статистика нарушений, ДТП и технических неисправностей транспортных средств собирается и анализируется с целью

выявления закономерностей и предиктивного прогнозирования опасных участков [4]. Корреляция факторов (погода, время суток, сезонность) позволяет прогнозировать вероятность аварий на конкретных участках транспортной сети. Методы искусственного интеллекта применяются для обнаружения аномалий в режиме реального времени [17].

Практические кейсы демонстрируют эффективность Big Data в области повышения безопасности дорожного движения:

- в Лондоне реализована система прогнозирования аварийных ситуаций на основе анализа ДТП, погодных условий и плотности трафика. Это позволяет заранее усиливать меры контроля и направлять патрули;

- в Сингапуре функционирует централизованная система кибербезопасности ИТС с использованием РКІ-инфраструктуры, что предотвращает несанкционированный доступ и вмешательства в V2X-коммуникации;

- в Москве действует система автоматического выявления нарушений ПДД, включая проезд на красный сигнал, нарушение разметки и превышение скорости. Видеонаблюдение с аналитикой фиксирует более 80% нарушений;

- в Республике Татарстан с 2020 года ведется внедрение Единой платформы управления транспортной системой (ЕПУТС), которая объединяет все подсистемы ИТС, от видеофиксации до модуля прогнозирования и цифрового двойника транспортной сети. В рамках платформы реализован модуль администрирования транспортных правонарушений, обеспечивающий контроль за безопасностью движения, а также модуль инцидент-менеджмента, позволяющий оперативно реагировать на чрезвычайные ситуации. Благодаря ЕПУТС создается комплексная цифровая экосистема, способствующая повышению пропускной способности дорог и безопасности всех участников движения.

3. Информирование участников дорожного движения.

Оповещение водителей и пешеходов, это важная составляющая ИТС. Своевременная информация о дорожной обстановке (наличие пробки, ДТП, погодные условия) позволяет пользователям скорректировать маршрут или стиль вождения, снижая нагрузку на сеть.

Аналитика транспортных потоков предсказывает заторы и аварийные участки, а системы рекомендаций на основе машинного обучения определяют оптимальное время выезда или альтернативные маршруты для водителей [4].

Собранная статистика анализируется алгоритмами, выявляя характерные паттерны, и настраивает информирование с учетом этих знаний. Ключевым элементом является низкая задержка передачи данных, благодаря Big Data и скоростным каналам связь становится почти мгновенной.

Технологии информирования участников дорожного движения используют различные каналы: стационарные динамические информационные табло, радиорекламации (RDS) и мобильные приложения (например: Яндекс.Навигатор, 2GIS).

Динамические информационные табло и мобильные приложения вовлекают участников движения в цепочку обратной связи: благодаря Big Data транспортная система «знает», где скопление, и заранее сообщает об этом пользователю. Такой обмен информацией увеличивает эффективность всей системы: водители могут выбирать альтернативные маршруты, а оперативные службы быстрее реагировать на инциденты.

Технология беспроводной связи V2X (Vehicle to Everything) и облачные платформы позволяют передавать персонализированные предупреждения. Развитие сетей 5G открывает путь к информированию на уровне каждого автомобиля и пешехода: облачные центры собирают данные от тысяч устройств и возвращают их в виде голосовых или графических подсказок водителю [2]. Основные типы V2X-связей представлены на рисунке 2.

Многие города и компании активно используют технологии Big Data и V2X для улучшения информирования участников движения.

4. Метеомониторинг.

Погодные условия существенно влияют на дорожную обстановку: дождь, снег, туман могут снижать скорость движения и пропускную способность дорог. Поэтому современные ИТС включают подсистемы мониторинга погодных условий [18].



Рис. 2. Основные типы V2X-связи и прямая связь транспортных средств (иллюстрация авторов)
Fig. 2. Main types of V2X communication and direct vehicle-to-vehicle communication (illustration by the authors)

Метеостанции, установленные вдоль автомобильных дорог, фиксируют параметры окружающей среды: температуру воздуха и дорожного покрытия, влажность, наличие осадков, видимость и скорость ветра. Эти данные интегрируются с трафиковыми потоками и обрабатываются с помощью технологий Big Data. Например, алгоритмы прогнозирования могут выявлять закономерности, такие как снижение средней скорости движения после начала дождя.

Полученная информация используется для оперативного управления дорожной сетью: данные передаются в диспетчерские центры, транслируются на динамических табло, а также в мобильные приложения водителей. Это позволяет заранее предупреждать участников движения о неблагоприятных погодных условиях и корректировать режимы движения. На рисунке 3 представлена схема мониторинга погодных условий в ИТС, включающая контроль осадков, температуры, влажности и видимости с использованием специализированных сенсоров



Рис. 3. Структура системы мониторинга погодных условий в интеллектуальных транспортных системах (иллюстрация авторов)

Fig. 3. Structure of the weather monitoring system in intelligent transportation systems (illustration by the authors)

Таким образом, метеомониторинг становится неотъемлемой составляющей ИТС, способствующей повышению безопасности и оптимизации дорожного движения в любых погодных условиях.

Практические кейсы демонстрируют эффективность Big Data в системах метеомониторинга:

- в США, в рамках программы Road Weather Management (RWM), активно внедряются системы интеграции погодных данных с управлением движением, что позволяет адаптировать сигнальные планы и выдавать рекомендации водителям в реальном времени;

- в России аналогичные технологии развиваются на магистралях федерального значения, например, на трассе М-12 «Восток», где устанавливаются метеостанции и

датчики состояния дорожного покрытия. Как правило, для мониторинга используются специализированные сенсоры, например, NY RSS11 – для измерения степени обледенения дороги, NY WDS6 – для определения температуры воздуха, влажности и осадков. Если система фиксирует неблагоприятные погодные условия, автоматически включаются предупреждения на электронных табло («Осторожно, гололед!»), корректируются рекомендованные скорости движения и направляются сигналы дорожным службам для проведения противогололедной обработки.

В перспективе развитие ИТС предусматривает все более глубокую интеграцию метеоданных с данными от гидрометцентров и бортовых датчиков автомобилей. Это позволит реализовать проактивное управление движением: например, система заранее снизит лимиты скорости и активирует подготовку дорожной техники в ожидании надвигающегося снегопада.

5. Система весового и габаритного контроля (СВГК).

СВГК предназначена для автоматизированного измерения веса и размеров транспортных средств в движении без их остановки. СВГК применяют технологию Weigh-in-Motion (WIM). На автомобильных дорогах устанавливаются весовые полосы WIM, лазерные и оптические сенсоры [18], а также камеры ANPR для идентификации нарушителей.

СВГК измеряют массу и габариты транспортных средств в движении, и интегрированы с камерами автоматической фиксации. При проезде транспортного средства в зоне работы СВГК, информация о нем передает данные в центр обработки, где система мгновенно определяет превышение допустимых норм и формирует уведомление. Анализ накопленных данных используется для оценки транспортных потоков и предотвращения перегрузки дорожной инфраструктуры.

Практические кейсы демонстрируют эффективность Big Data в системе весового и габаритного контроля:

- в Республике Татарстан на региональных дорогах развернуты автоматические комплексы СВГК, обеспечивающие автоматическое выявление нарушений весовых и габаритных параметров;

- на федеральной трассе М-12 «Восток» функционируют комплексы СВГК. Эксплуатацию и координацию работы таких систем осуществляет «Единый оператор», Государственная компания «Автодор». «Единый оператор» отвечает за сбор, обработку и передачу данных в информационные системы контроля, а также за взаимодействие с административными органами. Внедрение СВГК на М-12 приносит значительные положительные эффекты, включая повышение безопасности, сохранности конструкции дорожной одежды, экономическую выгоду и улучшение экологии.

6. Система взимания платы «Свободный поток» (СВП).

Система взимания платы СВП позволяет осуществлять оплату проезда без остановки или замедления движения транспортных средств, технология реализуется через транспондеры DSRC и камеры ANPR [5].

Интеграция системы взимания платы СВП с аналитикой Big Data делает возможным динамическое ценообразование: повышенные тарифы в часы пик и скидки в периоды низкой загруженности [4]. Аналитические платформы обрабатывают данные о каждом проезде (время, скорость, номер, вес), интегрируя их с погодными условиями, что повышает эффективность управления трафиком.

Одним из первых примеров стала система ERP (Electronic Road Pricing) в Сингапуре, запущенная 1 апреля 1998 года [20]. Позднее подобные решения были внедрены в Лондоне («Congestion Charge») и Нью Йорке («Central Business District Tolling Program») [21]. С 2020 года Сингапур переводит систему на базу GNSS. В каждом автомобиле устанавливается On Board Unit (OBU), который определяет местоположение через спутники и рассчитывает стоимость проезда без арок. Камеры используются лишь для верификации и фиксации нарушений. На рисунке 4 представлена структура и работа систем взимания платы «Свободный поток».

Технология «Свободный поток», например, внедрена на федеральной трассе М-12 «Восток», где используется автоматическая идентификация транспортных средств с

применением камер ANPR и транспондеров DSRC. Платеж взимается без остановки движения, что позволяет существенно увеличить пропускную способность [22]. В основе безбарьерный проезд, цифровая фиксация транспортных средств и интеграция с региональными ИТС.

Управление работой комплексов взимания платы также осуществляется «Единым оператором», обеспечивающим взаимодействие между ИТС, платежной системой и органами надзора. Это позволяет обеспечивать автоматизированный контроль оплаты и оперативную обработку данных о каждом проезде.




Рис. 4. Структура и работа системы сбора платы «Свободный поток» и ERP/E-ZPass (2020) (иллюстрация авторов)

Fig. 4. Structure and operation of the Free Flow Tolling System (illustration by the authors)

3. Результаты и их обсуждение

Рассмотренные ИТС, работающие с технологиями видеоаналитики и Big Data показали свою эффективность при планировании развития транспортной сети и принятия управленческих решений по оптимизации транспортного потока. Исследование реализованных практических кейсов позволило установить технологическую основу построения ИТС с интегрированными технологиями видеоаналитики и Big Data (Табл. 1).

Исследования показали, что наиболее эффективными для обеспечения высокой точности детекции объектов на видео являются нейросетевые модели, такие как, сверточные нейронные сети (CNN). Основным этапом анализа является детекция объектов – выделение транспортных средств, пешеходов, дорожных знаков на каждом кадре. За последние годы получили широкое распространение модели Faster R-CNN и YOLO. Faster R-CNN достигает высокой точности обнаружения благодаря использованию сети, генерирующей кандидатов на объекты, тогда как YOLO обеспечивает сверхбыструю обработку в реальном времени, идентифицируя объекты за один проход. Сравнительные исследования показывают, что Faster R-CNN превосходит YOLO по точности, в то время как YOLO существенно выигрывает в скорости. Таким образом, выбор модели определяется задачами ИТС: высокая точность требуется для детального анализа, а высокая скорость – для оперативного управления трафиком.

Подход YOLO относится к одноступенчатым детекторам и ориентирован на обработку в режиме реального времени за счёт предсказания рамок и классов в одном проходе сети. В математической модели YOLO входное изображение делится на сетку, и каждая ячейка отвечает за детектирование объектов, центр которых попадает в данную ячейку. Для каждой ячейки предсказываются параметры рамок (в YOLOv8 используется anchor-free подход с несколькими уровнями масштабов). Итоговые координаты рамки вычисляются через координаты ячейки и преобразование предсказаний (с использованием сигмоиды и масштабирования «приоритетной рамкой/динамическими якорями» в anchor-free версии). Выбор моделей YOLOv8 и Faster R-CNN обусловлен необходимостью

сопоставления одноступенчатого и двухступенчатого подходов к детекции объектов. В работе более подробно рассматривается математическая основа YOLOv8, поскольку данная модель применяется как базовый вариант для практического анализа и обеспечивает сбалансированное соотношение точности и быстродействия. Faster R-CNN используется преимущественно как сравнительная модель, позволяющая показать особенности двухэтапного подхода к обнаружению объектов.

Таблица 1

Технологическая основа построения ИТС с интегрированными технологиями
видеоаналитики и Big Data

№ п/п	Функциональные элементы	Область применения
1	Видеонаблюдение с высоким разрешением	Использование камер с высоким разрешением позволяет получать четкое изображение, необходимое для точного распознавания объектов и ситуаций.
2	Алгоритмы компьютерного зрения	Применение алгоритмов машинного обучения и глубокого обучения для автоматического обнаружения и классификации объектов (автомобили, пешеходы, велосипедисты).
3	Обработка больших объемов данных	Необходимость обработки огромных потоков видеоданных требует мощных вычислительных ресурсов и эффективных методов сжатия и хранения данных.
4	Обработка в режиме реального времени	Важность быстрого реагирования на изменения дорожной обстановки диктует необходимость обработки данных в режиме реального времени.
5	Совместимость с другими технологиями	Интеграция с GPS, радарами, датчиками скорости и другими источниками данных для комплексного анализа дорожной ситуации.
6	Анализ поведения участников дорожного движения	Оценка интенсивности движения и выявление зон заторов для оперативного принятия решений по управлению транспортом. Распознавание опасных маневров, нарушения правил дорожного движения и предсказание возможных аварийных ситуаций и т.д.
7	Принятие управленческих решений	Автоматическое регулирование сигналов светофоров на основе текущего состояния трафика и плотности потока автомобилей и т.д.
8	Защита конфиденциальности и кибербезопасность	Обеспечение защиты личной информации участников дорожного движения и предотвращение несанкционированного доступа к данным.

Функция потерь YOLOv8 задаётся в виде суммы компонент:

$$\mathcal{L}_{YOLO} = \lambda_1 \mathcal{L}_{loc} + \lambda_2 \mathcal{L}_{cls} + \lambda_{DFL}, \quad (1)$$

где $\lambda_1, \lambda_2, \lambda_{DFL}$ – весовые коэффициенты (задают вклад каждой части в итоговую ошибку);

$\mathcal{L}_{loc}$ – ошибка локализации рамки (насколько точно предсказаны координаты объекта), в том числе с учётом Distribution Focal Loss и CIOU;

$\mathcal{L}_{cls}$ – ошибка классификации (насколько правильно выбран класс объекта), обычно задаётся через Binary Cross-Entropy;

$\mathcal{L}_{DFL}$ – компонент Distribution Focal Loss, который повышает точность регрессии границ рамки за счёт более «точного» обучения положения сторон bounding box.

Для каждого класса используется бинарная кросс-энтропия:

$$\mathcal{L}_{BCE}(y, \hat{y}) = -[y \ln(\hat{y}) + (1 - y) \ln(1 - \hat{y})], \quad (2)$$

где $y \in \{0, 1\}$ – истинная метка, $\hat{y}$ – предсказанная вероятность.

Для оценки качества геометрии предсказанной рамки в документе выделяется метрика CIOU, которая учитывает не только перекрытие рамок, но и расстояние между центрами и согласованность соотношений сторон.

В YOLO вероятностное распределение для классификации объекта внутри anchor box формируется через softmax-функцию или сигмоидальную активацию (в зависимости от реализации). Эта вероятность определяет, к какому классу принадлежит объект в предсказанном bounding box.

Для каждого anchor box модель предсказывает логиты. Вероятность принадлежности объекта к классу вычисляется как:

$$P(class_i) = \sigma(z_i) = \frac{1}{1 + e^{-z_i}}, \quad (3)$$

где z_i – логит (выход сети до функции активации) для i -го класса;

$\sigma(\cdot)$ – сигмоидальная функция, переводящая логит в вероятность 0 ... 1.

Faster R-CNN использует Region Proposal Network (RPN) и относится к двухступенчатым детекторам: сначала формируются возможные области объектов (предложения регионов), затем выполняется классификация и уточнение рамок. При этом модель характеризуется высокими вычислительными затратами, что усложняет применение в сценариях режима реального времени.

Формализация двух этапов записывается следующим образом:

1 этап: извлечение признаков:

$$F = \phi(I), \quad (4)$$

где I – входное изображение (кадр);

$\phi(\cdot)$ – сверточная сеть (backbone), извлекающая признаки;

F – карта признаков (feature map), на которой дальше работают RPN и head.

генерация предложений регионов:

$$\{(r_i, s_i)\}_{i=1}^M = \text{RPN}(F), \quad (5)$$

где $\text{RPN}(\cdot)$ – сеть Region Proposal Network;

r_i – i -й регион-кандидат (proposal, прямоугольная область)

s_i – оценка объектности (objectness score), то есть вероятность того, что регион r_i содержит объект переднего плана, а не фон.

M – число предложенных регионов (обычно их сначала много, затем они фильтруются).

2 этап: классификация и регрессия рамки для каждого региона:

$$(\hat{c}_i, \Delta \hat{b}_i) = \text{Head}(\text{RoI}(F, r_i)), \quad (6)$$

где $\text{RoI}(F, r_i)$ – процедура извлечения характерных признаков для региона r_i из общей карты признаков F (реализуется методами RoI pooling или RoI align);

$\text{Head}(\cdot)$ – вычислительный модуль, выполняющий две задачи: определение категории объекта и корректировку пространственных координат;

$\hat{c}_i$ – итоговый результат классификации (предполагаемый класс или вероятностное распределение по классам) для i -го региона;

$\Delta \hat{b}_i$ – вектор поправок к начальным координатам ограничивающей рамки, позволяющий уточнить фактическое положение и размер объекта относительно исходного региона r_i .

Алгоритм Faster R-CNN реализует двухэтапный процесс обнаружения объектов: на первом этапе генерируются потенциальные области интереса (region proposals), предположительно содержащие объекты, на втором — выполняется их классификация и корректировка границ ограничивающих рамок. В противовес этому, архитектура YOLO осуществляет обнаружение в один этап, одновременно прогнозируя расположение и категории объектов на всём изображении. После этапа детекции следует задача отслеживания движения транспортных средств между последовательными кадрами видеопотока. Для её решения задействуются: фильтр Калмана — для прогнозирования траектории движения; методы анализа оптического потока — для оценки смещения пикселей между кадрами; модели на основе нейросетевых архитектур — для повышения точности трекинга в сложных условиях.

Ключевым параметром анализа является обнаружение аномалий: ДТП, резких маневров, появления неожиданных препятствий. Применение методов глубокого обучения, таких как автоэнкодеры и рекуррентные нейронные сети, позволяет выявлять аномалии с высокой точностью.

Для прогнозирования краткосрочных и долгосрочных изменений трафика применяются методы анализа временных рядов и нейросетевые модели LSTM, GRU. Они учитывают исторические данные о трафике, погодные условия, праздники и события. Такие предсказания помогают эффективно управлять дорожной сетью и планировать

ресурсное обеспечение. На рисунке 5 представлена схема работы системы «детекции» и классификации транспортных средств.

Для детекции транспортных средств в работе применяются модели семейства YOLO. Одним из важных параметров их обучения является batch size, который определяет количество изображений, обрабатываемых моделью за один шаг обновления весовых коэффициентов.

Размер пакета, использованный в эксперименте, представлен на рис. 6. Значение batch = 16 означает, что за один шаг обучения модель обрабатывает 16 изображений, после чего рассчитывается ошибка и выполняется корректировка весов нейронной сети. Выбор данного значения связан с необходимостью обеспечить стабильное обучение и рациональное использование ресурсов графического процессора.




Рис. 5. Схема работы системы детекции и классификации транспортных средств (иллюстрация авторов)

Fig. 5. Scheme of the vehicle detection and classification system (illustration by the authors)

Фиксация параметра **batch** для основных сравниваемых конфигураций позволила сопоставлять модели в одинаковых условиях (Рис. 6). Это дает возможность связывать различия в итоговых метриках прежде всего с особенностями архитектуры и количеством эпох обучения, а не с изменением режима подачи данных. В работе использовалось значение **batch** = 16, поскольку оно обеспечило наиболее устойчивые результаты распознавания.

BATCH (batch size)

Batch - это количество изображений, которое модель обрабатывает за один шаг обучения (один раз обновляет веса).




Рис. 6. Пояснение размера пакета и фиксированного значения batch в эксперименте (иллюстрация авторов)

Fig. 6. Explanation of batch size and fixed batch value in the experiment (illustration by the authors)

Понятие эпохи обучения в контексте данного исследования иллюстрируется на рис. 7. Под эпохой понимается один полный проход модели по всему обучающему набору данных. Следовательно, сравнение режимов обучения на 30 и 50 эпохах позволяет оценить, как увеличение длительности обучения влияет на качество детекции, устойчивость распознавания и итоговые показатели модели.

ЭПОХИ ОБУЧЕНИЯ (epochs)

Эпоха - это один полный проход модели по всему обучающему датасету.




Рис. 7. Пояснение понятия эпохи обучения и длительности обучения в эксперименте (иллюстрация авторов)

Fig. 7. Explanation of the training epoch concept and training duration in the experiment (illustration by the authors)

Для оценки качества моделей использовались метрики $mAP@0.5$, $mAP@0.75$, $mAP@0.5:0.95$, Recall, F1-score, FPS, Size (MB) и Params (M). Показатель $mAP@0.5$ отражает общий уровень обнаружения объектов при мягком критерии совпадения предсказанной и истинной рамки, а $mAP@0.75$ предъявляет более строгие требования к точности локализации транспортного средства в кадре. Метрика $mAP@0.5:0.95$ считается наиболее комплексной для оценки качества работы алгоритмов детекции объектов. Она учитывает результаты при варьируемых порогах совпадения предсказанных и эталонных ограничивающих рамок (в диапазоне от 0,5 до 0,95) и позволяет объективно оценить устойчивость модели к изменениям условий распознавания [3, 4].

Для комплексной оценки алгоритмов детекции объектов применяются следующие метрики: Recall (отражает долю корректно идентифицированных объектов; F1-score (отражает точность и полноту распознавания); FPS (скорость обработки видеопотока); Size (MB) (объем модели в мегабайтах); Params (M) (количество параметров модели). Сравнение переобученных моделей представлено в таблице 2.

Таблица 2

Сравнение переобученных моделей

Модель	Эпохи	Batch size	Params (M)	Size (MB)	FPS	$mAP@0.5$	$mAP@0.75$	$mAP@0.5:0.95$	Recall	F1-score
Faster R-CNN	30	8	44.1	156.3	26.2	0.887	0.824	0.752	0.728	0.800
		16	41.76	159.7	26	0.893	0.830	0.759	0.732	0.805
		25	41.76	155.1	26	0.895	0.832	0.760	0.736	0.809
	50	16	41.76	159.7	26	0.966	0.887	0.820	0.989	0.952
yolov8s	30	9	13.11	21.48	238.9	0.944	0.837	0.746	0.910	0.915
		16	11.13	21.48	224.5	0.949	0.846	0.749	0.889	0.909
		25	14.53	75.8	0.943	0.840	0.741	0.899	0.911	0.794
	50	16	11.13	21.48	172.8	0.950	0.859	0.771	0.911	0.920
yolov9s	30	9	12.4	23.48	221	0.943	0.835	0.739	0.912	0.914
		16	7.17	14.53	89.2	0.943	0.824	0.735	0.907	0.909
		25	14.53	75.8	0.943	0.840	0.741	0.899	0.911	0.794
	50	16	7.17	14.53	86.0	0.949	0.850	0.759	0.911	0.917

Результаты анализа данных, представленных в таблице 2, свидетельствуют о различиях в ключевых характеристиках рассмотренных моделей по параметрам точности, скорости обработки и ресурсоёмкости.

Модель Faster R-CNN показывает высокие показатели качества детекции при конфигурации с 50 эпохами и размером батча 16:

- $mAP@0.5 = 0,966$;
- $mAP@0.75 = 0,887$;
- $mAP@0.5:0.95 = 0,820$;
- $Recall = 0,989$;
- $F1-score = 0,952$.

Полученные значения подтверждают эффективность двухэтапного подхода к обнаружению объектов. Вместе с тем модель характеризуется относительно невысокой скоростью обработки – порядка 26 FPS, а также максимальными показателями объёма (159,7 МБ) и количества параметров (41,76 млн). Это ограничивает её применимость для задач обработки видеопотоков в режиме реального времени. Эксперименты проводились на персональном компьютере с использованием графического ускорителя NVIDIA GeForce RTX 5070 Ti.

Результаты проведенных экспериментов показали, что модель YOLOv8s обеспечивает оптимальный баланс между точностью детекции и скоростью обработки данных. При конфигурации с 50 эпохами и размером батча 16 модель достигает следующих показателей:

- $mAP@0.5 = 0,950$;
- $mAP@0.75 = 0,859$;
- $mAP@0.5:0.95 = 0,771$;
- $Recall = 0,911$;
- $F1-score = 0,920$;
- скорость обработки – 172,8 FPS.

Сокращение числа эпох до 30 при размере батча 9 позволяет повысить скорость до 238,9 FPS, однако сопровождается снижением интегральной точности по сравнению с вариантом 50 эпох. Полученные данные позволяют сделать вывод о целесообразности применения YOLOv8s в составе интеллектуальных транспортных систем, где критически важны как высокая точность распознавания объектов, так и оперативность обработки видеопотока.

Модель YOLOv9s является более компактной: при $batch\ size = 16$ она имеет 7,17 млн параметров и размер 14,53 МБ. При 50 эпохах модель достигает $mAP@0.5 = 0,949$, $mAP@0.75 = 0,850$, $mAP@0.5:0.95 = 0,759$, $Recall = 0,911$, $F1-score = 0,917$. При этом её скорость составляет 86 FPS, что ниже, чем у YOLOv8s, но всё равно значительно выше, чем у Faster R-CNN. Поэтому YOLOv9s можно рассматривать как вариант для устройств с ограниченными вычислительными ресурсами, где важны компактность модели и приемлемое качество детекции.

В целом увеличение числа эпох с 30 до 50 улучшает качество детекции у всех рассмотренных моделей. Наиболее точной по метрикам качества является Faster R-CNN, однако из-за низкой скорости и высокой ресурсоёмкости она менее рациональна для потоковой видеоаналитики. По совокупности метрик наиболее практичной для применения в ИТС является YOLOv8s, так как она обеспечивает лучший баланс между точностью, скоростью обработки и размером модели. Место модуля видеодетекции и распознавания номера в контуре ИТС представлено на рисунке 8.

Следовательно, результатом работы модуля видеодетекции является не только изображение с выделенным объектом, но и структурированные данные, пригодные для дальнейшего использования в мониторинге, аналитике и прикладных сервисах ИТС.

После обнаружения транспортного средства выделяется область номерного знака, которая передается в OCR-модуль. На этом этапе изображение номера преобразуется в текстовое значение, используемое для идентификации автомобиля и последующей записи в базу данных (Рис. 9).

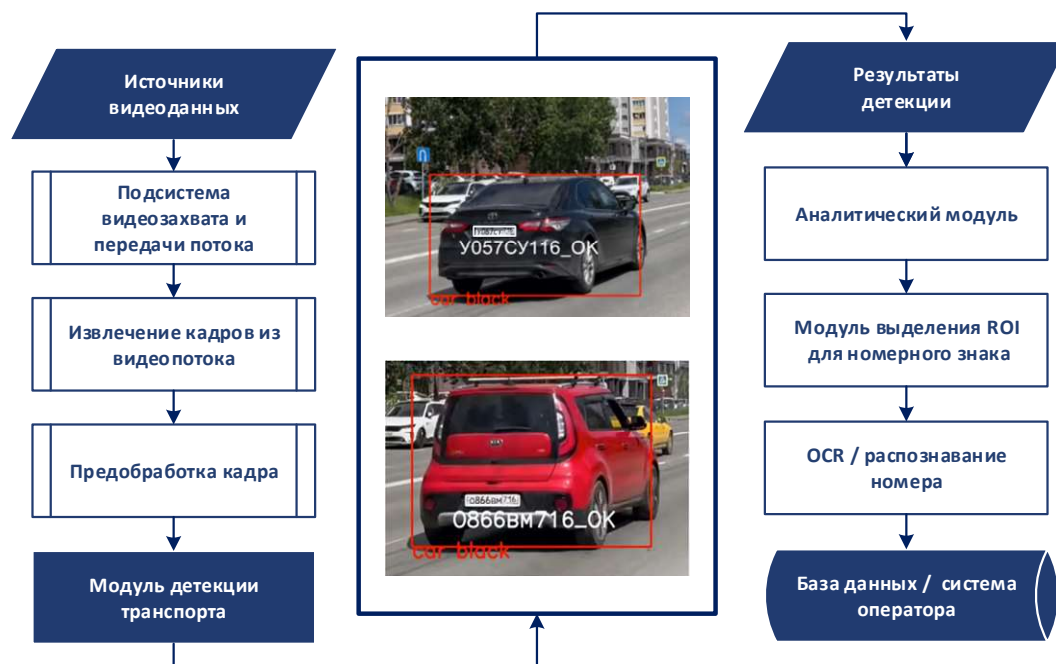


Рис. 8. Место модуля видеодетекции и распознавания номера в контуре ИТС

Fig. 8. The place of the video detection and license plate recognition module in the ITS framework



Рис. 9. Схема распознавания и чтения номерного знака транспортного средства

Fig. 9. Scheme of vehicle license plate recognition and reading

В рассматриваемой реализации процесс включает извлечение кадра, детекцию транспортного средства, выделение области номера, проверку результата, OCR-распознавание и сохранение подтвержденного номера в базе данных. Такая последовательность связывает методы компьютерного зрения с практической задачей учета транспортных средств и фиксации событий.

Практическая задача OCR-распознавания осложняется тем, что качество изображения номера может ухудшаться из-за движения транспортного средства, бликов, загрязнения, погодных условий и перспективных искажений. Поэтому после распознавания требуется дополнительная проверка результата перед передачей его в базу данных и смежные подсистемы ИТС.

Методы видеоаналитики интегрируются в транспортно-управляющие центры через единые платформы данных. Системы обрабатывают информацию о транспортных потоках, номерах автомобилей, выявленных происшествиях и передают ее в режиме реального времени для принятия решений: переключения режимов светофоров, ограничения движения и информирования водителей. На практике интеграция систем позволяет существенно сократить время реагирования на инциденты и улучшить адаптивное управление движением.

По мере развития цифровых технологий интеллектуальные транспортные системы (ИТС) сталкиваются с возрастающими рисками киберугроз. Для минимизации потенциальных угроз реализуется комплекс многоуровневых защитных мер: шифрование данных в каналах обмена информацией между транспортными средствами и элементами инфраструктуры; многоуровневая аутентификация подключённых устройств и авторизованных пользователей; развёртывание межсетевых экранов (файрволов); внедрение систем обнаружения и предотвращения вторжений (IDS/IPS).

Дополнительно применяется анализ сетевого трафика с использованием технологий больших данных (Big Data), что позволяет оперативно выявлять признаки DDoS-атак и иных инцидентов информационной безопасности. Структурная схема системы защиты ИТС представлена на рисунке 10.




Рис. 10. Структура обеспечения безопасности в интеллектуальных транспортных системах (иллюстрация авторов)

Fig. 10. Structure of safety assurance in intelligent transportation systems (illustration by the authors)

Полученные результаты согласуются с выводами исследования Bakırcı, в рамках которого впервые была проведена всесторонняя оценка применимости различных модификаций YOLOv8 в задачах аэромониторинга транспортных потоков [23, 24].

Эти данные подтверждают сделанный в исследовании вывод о сбалансированности модели YOLOv8s.

В результате анализа интеграции технологий больших данных и машинного обучения в ИТС выявлены следующие ключевые эффекты: повышение оперативности мониторинга дорожного движения; оптимизация регулирования транспортных потоков; повышение уровня безопасности дорожного движения; эффективное информирование участников движения; адаптация управления дорожной инфраструктурой к погодным условиям; повышение устойчивости транспортной инфраструктуры.

Интеграция ИТС с инструментами обработки и анализа больших объёмов данных способствует повышению надёжности и безопасности функционирования транспортной инфраструктуры. Ключевыми факторами развития в этой области выступают: совершенствование технологий беспроводной связи типа «транспортное средство — инфраструктура» (V2X), обеспечивающих оперативный обмен данными между участниками движения и элементами дорожной сети; внедрение проактивных подходов к управлению транспортными потоками на основе автоматизированных аналитических систем, позволяющих прогнозировать и предотвращать проблемные ситуации до их возникновения.

4. Заключение

1. Современные транспортные системы стремительно трансформируются. Сегодня их неотъемлемыми элементами стали: анализ видеопотоков, прогнозирование трафика

транспортных потоков, адаптивное управление светофорными объектами, информирование водителей и мониторинг погодных условий.

2. Рассмотренные практические кейсы внедрения ИТС демонстрируют их высокую эффективность в повышении безопасности дорожного движения, снижении заторов и улучшении качества транспортных услуг. Интеграция инструментов обработки больших данных, методов аналитической обработки информации и технологий визуального анализа существенно повышает качество управления транспортной инфраструктурой.

3. Сформирована технологическая база для построения современных ИТС, включающая: системы видеонаблюдения с высоким разрешением; алгоритмы анализа визуальной информации; механизмы обработки больших объёмов данных в режиме реального времени; совместимость с существующими и перспективными технологиями; инструменты анализа поведения участников дорожного движения; модули поддержки принятия управленческих решений; средства защиты персональных данных и обеспечения кибербезопасности.

4. В рамках экспериментального сравнения моделей детекции установлено, что Faster R-CNN обеспечивает высокую точность распознавания, однако уступает моделям семейства YOLO по скорости обработки и компактности. Модель YOLOv8s показала наиболее сбалансированный результат по совокупности метрик точности, быстродействия и размера модели, что делает её рациональным вариантом для задач потоковой видеоаналитики в ИТС. Модель YOLOv9s отличается меньшим числом параметров и может быть использована в условиях ограниченных вычислительных ресурсов.

5. Дальнейшее развитие ИТС связано с расширением применения нейронных сетей, интеграцией данных с мобильных устройств и внедрением полностью автоматизированных решений для адаптивного регулирования движения. Результаты работы подчеркивают важность комплексного подхода, объединяющего технические решения, анализ данных и пользовательские сервисы, для построения устойчивой, безопасной и высокоэффективной транспортной сети.

Благодарности

Работа выполнена за счет гранта, предоставленного Академией наук Республики Татарстан образовательным организациям высшего образования, научным и иным организациям на поддержку планов развития кадрового потенциала в части стимулирования их научных и научно-педагогических работников к защите докторских диссертаций и выполнению научно-исследовательских работ» (Соглашение №15/2025-ПД-КАИ от 22.12.2025).

Список литературы/ References

1. Кутдусов Р.Ф., Гатиятуллин М.Х. Снижение аварийности на объектах дорожного сервиса применением элементов интеллектуальных транспортных систем // Автомобильные дороги и транспортная инфраструктура. 2024. № 1 (5). С. 124-133. EDN: AHJTYT.
Kutdusov R.F., Gatiyatullin M.H. Reducing accidents at road service facilities by using elements of intelligent transport systems // Roads and transport infrastructure. 2024. No. 1 (5). P. 124-133. EDN: AHJTYT.
2. Elassy M., Al-Hattab M., Takruri M., Badawi S. Intelligent transportation systems for sustainable smart cities // Transportation Engineering. 2024. Vol. 16(17). P. 100252. DOI:10.1016/j.treng.2024.100252.
3. Hou W. Applications of Big Data Technology in Intelligent Transportation System // Highlights in Science Engineering and Technology. 2023. Vol. 37. P. 64-71. DOI:10.54097/hset.v37i.6040.
4. Zhu L., Yu F. R., Wang Y., Ning B., Tang T. Big Data Analytics in Intelligent Transportation Systems: A Survey // IEEE Transactions on Intelligent Transportation Systems. 2018. Vol. PP(99). P. 1-16. DOI:10.1109/TITS.2018.2815678.
5. Xu H., Yu W., Lin J. In: Sun Y., Song H. (eds) Secure and Trustworthy Transportation Cyber-Physical Systems. SpringerBriefs in Computer Science. 2017. P. 24-26. DOI:10.1007/978-981-10-3892-1_2.

6. Панкратов А.И. Актуальные вопросы стандартизации в сфере ИТС // Мир дорог. 2021. № 141. С. 70-75. EDN ATNOOU.
Pankratov A.I. Actual issues of standardization in the field of ITS // World of roads. 2021. № 141. P. 70-75. EDN ATNOOU.
7. Tyutyugin K. D., Mokshin V. V. Intersection analysis using computer vision // Vestnik NC BZhd. 2023. No. 4(58). P. 65-72.
8. Daniel M. S., Tiwari S. Advanced Traffic Monitoring and Enforcement Using YOLOv8 // International Journal of Research Publication and Reviews. 2024. Vol. 5(1). P. 2070-2073. DOI:10.55248/gengpi.5.0124.0236.
9. Coghlan C., Dabiri S., Mayer B., Wagner M., Williamson E., Eichler M., Ramakrishnan N. Assigning Bus Delay and Predicting Travel Times using Automated Vehicle Location Data // Transportation Research Record. 2019. P. 1-13. DOI:10.1177/0361198119832866.
10. Филиппченко А.С. Типология алгоритмов больших данных для решения вычислительных задач на транспорте // Информационные технологии. 2024. Т. 30, № 8. С. 411-416. DOI 10.17587/it.30.411-416. EDN FDFNFW.
Filipchenko A.S. Typology of big data algorithms for solving computational problems in transport // Information technologies. 2024. Vol. 30, No. 8. P. 411-416. DOI 10.17587/it.30.411-416. EDN FDFNFW.
11. Azad A.K., Atkison T., Shahen Shah A.F., Review M.A. on Machine Learning in Intelligent Transportation Systems Applications // The Open Transportation Journal. 2024. Vol. 18(1). P. 1-20. DOI:10.2174/012667121233049624082114216.
12. Муртазин Р.Ш., Хузиахметова К.Р. Автоматизация обработки данных при оценке транспортно-эксплуатационного состояния автомобильной дороги : сб. ст. Международного форума – Kazan digital week / Научный центр безопасности жизнедеятельности. Казань, 2024 С. 41-45. EDN TEBLMW.
Murtazin R.Sh., Khuziakhmetova K.R. Automation of data processing in assessing the transport and operational condition of a highway : collection of articles of the International Forum - Kazan digital week / Scientific Center for Life Safety. Kazan, 2024, P. 41-45. EDN TEBLMW.
13. Хузиахметова К.Р., Шияпова Д.М., Мавлиев Л.Ф., Низамов Р.К. Развитие систем взимания платы на автомобильных дорогах // Вестник НЦБЖД. 2025. № 3(65). С. 137-144. EDN FPWUIU.
Khuziakhmetova K.R., Shiyapova D.M., Mavliev L.F., Nizamov R.K. Development of toll collection systems on highways // Bulletin of the National Library of Railways. 2025. № 3(65). P. 137-144. EDN FPWUIU.
14. Минниханов Р.Н., Дагаева М.В., Махмутова А.З. Развитие ИТС: единые цифровые платформы для безопасного управления транспортной системой // Безопасность дорожного движения. 2022. № 3. С. 19-22.
Minnikhanov R.N., Dagayeva M.V., Makhmutova A.Z. Development of ITS: unified digital platforms for safe management of the transport system // Road safety. 2022. No. 3. P. 19-22.
15. Rafique M.T., Hasan A.M., Sajid M. Adaptive Traffic Signal Control Using Reinforcement Learning // arXiv preprint. 2024. arXiv:2408.15751. DOI:10.48550/arXiv.2408.15751.
16. Ma X., Dai Z., He Z., Ma J. Learning Traffic as Images: A Deep Convolutional Neural Network for Large-Scale Transportation Network Speed Prediction // Sensors. 2017. Vol. 17(4). P. 818. DOI:10.3390/s17040818.
17. Hendrawan A., Gernowo R., Nurhayati O. D., Dewi C. A Systematic Review of Deep Learning for Intelligent Transportation Systems with Analysis and Perspectives // Infotel. 2024. Vol. 16(2). P. 370-389. DOI:10.20895/infotel.v16i2.1085.
18. Pisano P.A., Goodwin L.C., Rossetti M.A. Integrated Decision-Support Tool for Winter Road-Maintenance Operations // Transportation Research Record. 2003. No. 1824. P. 98–106. DOI: 10.3141/1824-11.

19. Intelligent Transportation Systems Benefits, Costs, and Lessons Learned. Final Report – March 2018. FHWA-JPO-18-641. URL: www.its.dot.gov/index.htm.
20. Electronic Road Pricing (ERP) Overview // Land Transport Authority of Singapore. URL: <https://onemotoring.lta.gov.sg/content/onemotoring/home/driving/ERP/erp-2-0.html> (reference date: 21.01.2026).
21. ERP (Electronic Road Pricing) // Ministry of Transport Singapore. URL: <https://www.mot.gov.sg/Transport-Matters/TP-Electronic-Road-Pricing/> (reference date: 25.01.2026).
22. Правила проезда и способы оплаты: М-12 «Восток», система «Свободный поток» // Корпоративный сайт ГК «Автодор». – URL: <https://avtodor-tr.ru> (дата обращения: 17.01.2026).
Travel rules and payment methods: M-12 Vostok, Free Flow system // Avtodor Group corporate website. – URL: <https://avtodor-tr.ru> (reference date: 25.01.2026).
23. Bakirci, M. (2024) Enhancing Vehicle Detection in Intelligent Transportation Systems via Autonomous UAV Platform and Yolov8 Integration. Applied Soft Computing, 164, Article 112015. <https://doi.org/10.1016/j.asoc.2024.112015>
24. D. J. Marcelleno and M. P. K. Putra. Performance evaluation of yolov8 in real-time vehicle detection in various environmental conditions. J. Tek. Inform. (JUTIF), vol. 6, no. 1, pp. 269–279, Feb. 2025.
25. Jahangir, Muhammad Talha, (2024) Evaluating FasterR-CNN and YOLOv8 for Traffic Object Detection and Class-Based Counting, International Journal of Innovations in Science & Technology, 6, issue 4, p. 1606-1620.

Информация об авторах

Мокшин Владимир Васильевич, кандидат технических наук, доцент, Казанский национальный исследовательский технический университет им. А.Н. Туполева-КАИ, г. Казань, Российская Федерация;

E-mail: vladimir.mokshin@mail.ru, ORCID: 0000-0002-7650-3419.

Ванюшев Александр Александрович, инженер-программист, АО «СМП-Нефтегаз», г. Альметьевск, Российская Федерация;

E-mail: alex_von1@mail.ru.

Мавлиев Ленар Фидасович, кандидат технических наук, доцент, Казанский государственный архитектурно-строительный университет, г. Казань, Российская Федерация;

E-mail: lenarmavliev@yandex.ru, ORCID: 0000-0001-6301-0941.

Николаева Регина Владимировна, кандидат технических наук, доцент, Казанский государственный архитектурно-строительный университет, г. Казань, Российская Федерация;

E-mail: nikolaeva1@bk.ru, ORCID: 0000-0002-5324-432x.

Information about the authors

Vladimir V. Mokshin, Candidate of Technical Sciences, Associate Professor, Department of Automated Information Processing and Control Systems, Kazan National Research Technical University named after A.N. Tupolev – KAI, Kazan, Russian Federation;

E-mail: vladimir.mokshin@mail.ru, ORCID: 0000-0002-7650-3419.

Alexander A. Vaniushev, Software Engineer, SMP-Neftegaz JSC, Almet'yevsk, Russian Federation;

E-mail: alex_von1@mail.ru.

Lenar F. Mavliev, Candidate of Technical Sciences, Associate Professor, Kazan State University of Architecture and Civil Engineering, Kazan, Russian Federation;

E-mail: lenarmavliev@yandex.ru, ORCID: 0000-0001-6301-0941.

Regina V. Nikolaeva, Candidate of technical sciences, associate professor, Kazan State University of Architecture and Engineering, Kazan, Russian Federation;

E-mail: nikolaeva1@bk.ru, ORCID: 0000-0002-5324-432x.

Дата поступления: 04.02.2026

Дата принятия: 28.04.2026