

DOI: 10.12731/3033-5965-2025-15-3-396

EDN: CEIRIN

УДК 656.078



Научная статья | Транспортные и транспортно-технологические системы

## ИССЛЕДОВАНИЕ КОМПЛЕКСНЫХ ПОДХОДОВ К ЦИФРОВИЗАЦИИ ТРАНСПОРТНЫХ СИСТЕМ С ПРИМЕНЕНИЕМ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

*А.А. Подберезкин, А.В. Остроух, А.М. Борзенков,  
А.М. Шмонин, Ц.Б. Пронин*

### *Аннотация*

**Обоснование.** Требуется перейти от «точечных» решений к комплексной цифровизации транспортных систем, объединяющей инфраструктурный мониторинг покрытия, оперативное управление движением и стратегическое планирование. Для этого целесообразно интегрировать машинное обучение (прогнозы), генетические алгоритмы (оптимизация) и мультиагентное моделирование (проверка устойчивости).

**Цель** – оценить эффект такой интеграции по совокупности метрик (задержки, издержки, риск, прибыль, сервис) и интегральной функции F.

**Материалы и методы.** Инфраструктурный уровень: компьютерное зрение (YOLO),  $mAP \approx 0.84$ ; прогноз дефектообразования (XGBoost), ошибка  $\leq 12\%$ . Оперативный уровень: краткосрочные прогнозы интенсивности (LSTM/XGBoost, RMSE 8–10%) и оптимизация фаз светофоров генетическим алгоритмом. Стратегический уровень: прогноз спроса и тарифов, оптимизационные сценарии. Устойчивость решений проверялась в мультиагентной имитации; сравнение велось с базовыми («как есть») сценариями.

**Результаты.** Суммарные задержки снижены на 37%, совокупные логистические издержки – на 12%, прибыльность выросла на

10–11%; при росте спроса на 20% выполнено >90% доставок в SLA. Интегральная функция

F улучшилась на 22-24%. Показана робастность планов и чувствительность к весам критериев.

**Ключевые слова:** цифровизация транспорта; машинное обучение; генетические алгоритмы; мультиагентное моделирование; YOLO; прогноз интенсивности; оптимизация светофоров; логистика; интегральная функция

**Для цитирования.** Подберезкин, А. А., Остроух, А. В., Борзенков, А. М., Шмонин, А. М., & Пронин, Ц. Б. (2025). Исследование комплексных подходов к цифровизации транспортных систем с применением методов искусственного интеллекта. *Transportation and Information Technologies in Russia*, 15(3), 141–166. <https://doi.org/10.12731/3033-5965-2025-15-3-396>

Original article | Transport and Transport-Technological Systems

## RESEARCH METHODS FOR DIGITALIZATION OF TRANSPORT SYSTEMS USING ARTIFICIAL INTELLIGENCE

*A.A. Podberezkin, A.V. Ostroukh, A.M. Borzenkov,  
A.M. Shmonin, C.B. Pronin*

### *Abstract*

**Background.** There is a need to move from isolated “point” solutions to comprehensive digitalization of transport systems that integrates infrastructure-level pavement monitoring, operational traffic management, and strategic planning. To this end, it is reasonable to combine machine learning (for forecasting), genetic algorithms (for optimization), and multi-agent simulation (for robustness checking).

**Purpose.** To assess the effect of such integration using a set of metrics (delays, costs, risk, profit, service) and an integral objective function F.

**Materials and methods.** Infrastructure level: computer vision (YOLO), mAP  $\approx$  0.84; defect-generation forecasting (XGBoost), error  $\leq$  12%. Operational level: short-term traffic-intensity forecasts (LSTM/XGBoost, RMSE 8–10%) and traffic-signal phase optimization with a genetic algorithm. Strategic level: demand and tariff forecasting, optimization scenarios. The robustness of solutions was verified via multi-agent simulation; comparisons were made against baseline (“as-is”) scenarios.

**Results.** Total delays were reduced by 37%, overall logistics costs by 12%, and profitability increased by 10–11%; with a 20% demand increase, >90% of deliveries were completed within SLA. The integral function F improved by 22–24%. The plans demonstrated robustness and sensitivity to criterion weights.

**Keywords:** transport digitalization; machine learning; genetic algorithms; multi-agent simulation; YOLO; intensity forecasting; traffic-signal optimization; logistics; integral objective function

**For citation.** A Podberezkin, A. A., Ostroukh, A. V., Borzenkov, A. M., Shmonin, A. M., & Pronin, C. B. (2025). Research methods for digitalization of transport systems using artificial intelligence. *Transportation and Information Technologies in Russia*, 15(3), 141–166. <https://doi.org/10.12731/3033-5965-2025-15-3-396>

## Введение

Транспортные системы являются основой социально-экономического развития регионов и страны в целом. В то же время рост числа автомобилей, увеличение объёмов перевозок и усложнение логистических цепочек усиливают нагрузку на существующую инфраструктуру и приводят к ряду системных проблем: хроническим перегрузкам улично-дорожной сети, высокому уровню аварийности, значительному износу дорожного покрытия, росту транспортных издержек и негативному воздействию на окружающую среду [1; 7].

Исходя из этого, в работе ставится задача проверить, способна ли интегрированная цифровизация на трёх уровнях (инфраструк-

турном, оперативном и стратегическом) снизить задержки и затраты при одновременном соблюдении требований безопасности и качества сервиса.

В ряде регионов России до 40% автомобильных дорог эксплуатируется в состоянии, не соответствующем нормативным требованиям, а в городах федерального значения устойчивые заторы снижают среднюю скорость движения на 15–25% [1].

Традиционные методы управления транспортной системой во многом опираются на регламентированные процедуры и статические нормативы. Обследование дорожного покрытия часто выполняется вручную; управление транспортными потоками в городах базируется на фиксированных циклах работы светофорных объектов; планирование сети станций технического обслуживания, логистических центров и маршрутов доставки осуществляется на основании устаревающей статистики, что игнорирует изменчивость спроса и рисков [6; 17], что и формирует исследовательский запрос настоящей работы.

В результате принимаемые решения оказываются недостаточно точными и не обеспечивают требуемой адаптивности. Это выражается в запаздывании ремонтов, росте задержек, неэффективной загрузке мощностей предприятий сервиса и избыточных издержках.

Международный опыт показывает, что ключевым направлением повышения эффективности транспорта является его цифровизация. Внедряются системы видеоаналитики для оценки интенсивности движения, прогнозные модели распределения транспортных потоков и цифровые платформы для управления мультимодальными перевозками, что снижает задержки и повышает пропускную способность [12; 15].

Однако большинство внедрённых проектов носят узконаправленный характер и решают лишь отдельные задачи, не учитывая взаимосвязь между уровнями транспортной иерархии — инфраструктурным, оперативным и стратегическим. Подобные «точечные решения» не дают системного эффекта [5].

В связи с этим необходим переход к комплексному подходу, предполагающему разработку единой концепции цифровизации транспортных систем, объединяющей инфраструктурный мониторинг состояния, оперативное управление движением и стратегическое планирование логистики и тарифов. Инструментом реализации этой концепции выступают методы искусственного интеллекта. Машинное обучение формирует прогнозы ключевых параметров транспортных процессов; эволюционные методы, включая генетические алгоритмы, обеспечивают многокритериальную оптимизацию при множестве ограничений; мультиагентные подходы моделируют взаимодействие участников транспортного процесса и сетевые эффекты [14].

В работе оценивается эффект комплексной цифровизации трёх уровней транспортной системы на основе связки: прогнозы машинного обучения, оптимизация генетическими алгоритмами и проверка устойчивости в мультиагентной имитации; предполагается, что такая интеграция даёт измеримый системный выигрыш по задержкам, затратам, рискам, сервису и прибыльности.

Таким образом, использование искусственного интеллекта рассматривается не как набор отдельных технологий, а как универсальный инструмент цифровой трансформации транспортной системы, интегрирующий мониторинг, управление и стратегическое планирование. Достоверность оценивалась на данных для всех трёх уровней, с применением валидации моделей и стресс-сценариев в имитации. Это повышает точность прогнозов, ускоряет принятие решений и снижает издержки. Исследование направлено на разработку и апробацию прототипа концепции цифровизации транспортных систем на базе методов искусственного интеллекта с оценкой эффективности комплексной интеграции.

### **Материалы и методы**

Транспортная система моделируется как многоуровневая иерархия (инфраструктурный, оперативный и стратегический уров-

ни), где решения нижнего уровня влияют на параметры верхнего, а итоговый эффект оценивается единой целевой функцией. Чтобы сопоставить неоднородные показатели (время, деньги, риск, качество сервиса), все метрики приводятся к безразмерному виду: для каждого показателя  $z$  используется линейная нормализация по наблюдаемому диапазону либо по нормативам:

$$z = \frac{Z - Z_{\min}}{Z_{\max} - Z_{\min}}, \quad (1)$$

что обеспечивает корректное взвешивание и исключает доминирование показателей с «крупными» единицами измерения [10; 11].

На верхнем уровне вводится обобщённая целевая функция:

$$F = \min(\alpha T_{\text{delay}} + \beta C_{\text{oper}} + \delta R_{\text{risk}}) - \max(\gamma P_{\text{profit}} + \eta S_{\text{service}}), \quad (2)$$

где каждое слагаемое – нормализованное и прогнозное, значение, получаемое моделями машинного обучения (ML). Здесь  $T_{\text{delay}}$  – совокупные задержки,  $C_{\text{oper}}$  – интегральные затраты (капитальные и эксплуатационные) с дисконтированием,  $R_{\text{risk}}$  – ожидаемые потери от рисков,  $P_{\text{profit}}$  – прибыль,  $S_{\text{service}}$  – уровень сервиса. Общая структура многоуровневой модели показана на рисунке 1. Весовые коэффициенты  $\alpha$ ,  $\beta$ ,  $\delta$ ,  $\gamma$ ,  $\eta$  задают управленческие приоритеты (безопасность, экономическая эффективность, качество обслуживания) и калибруются по методу согласованных парных сравнений либо по заданным регулятором KPI [13]. Прогнозы формируются ML-моделями (градиентный бустинг, нейронные сети), обученными на исторических данных датчиков, видеоаналитики, АСУДД и операционной отчётности.

Инфраструктурный уровень включает мониторинг дорожного состояния и, на его основе, проектирование/модернизацию СТО (см. рис. 1). Детекция дефектов покрытия выполняется компьютерным зрением; затем ML прогнозирует интенсивность появления дефектов по участкам на горизонте  $\tau$  [14]. Полученные результаты объединяются в карту ожидаемого спроса на ремонт: учитываются тяжесть повреждений, интенсивность движения и нормативные сроки устранения.

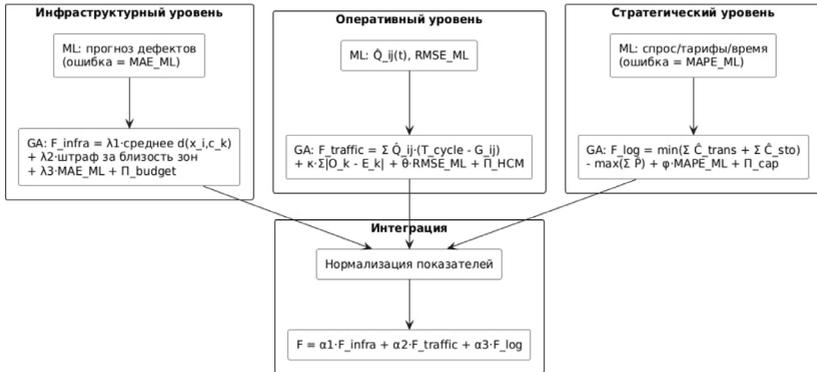


Рис. 1. Многоуровневая архитектура модели

Оптимизация ремонтных зон и конфигурации СТО решается генетическим алгоритмом (GA), в котором хромосома кодирует координаты центров зон  $c_k$ , их радиусы и ключевые параметры СТО (мощность, оснащение). Функция приспособленности задётся как:

$$F_{infra} = \lambda_1 \frac{1}{N} \sum_{i=1}^N d(x_i, c_{k(i)}) + \lambda_2 \frac{1}{K} \sum_{k \neq j} \|c_k - c_j\|^{-1} + \lambda_3 MAE_{ML} + \Pi_{budget}, \quad (3)$$

где  $d(x_i, c_{k(i)})$  – расстояние от дефекта  $x_i$  до назначенной зоны, второе слагаемое штрафует слияние зон (берём обратное расстояние),  $MAE_{ML}$  – ошибка прогноза интенсивности дефектов,  $\Pi_{budget}$  – штраф за превышение бюджета/нормативов (например, по ГОСТ/СП) [2; 3]. Такое построение одновременно минимизирует логистику ремонта, учитывает неопределённость прогноза и соблюдает финансовые ограничения. Значение  $C_{oper}$  на этом уровне вычисляется как приведённые затраты:

$$C_{oper} = \sum_t \frac{CapEx_t + OpEx_t}{(1+r)^t}, \quad (4)$$

где  $r$  – ставка дисконтирования; вклад в риск  $R_{risk}$  связан с вероятностью инцидентов из-за дефектов:

$$R_{risk} = \sum_a p_a I_a \quad (5)$$

где  $p_a$  предсказывается ML-классификатором,  $I_a$  – ущерб [7].

Оперативный уровень охватывает адаптивное управление потоками (см. рис. 1). ML-модель прогнозирует интенсивности по подходам  $Q_{ij}(t)$ ; и вариабельность прибытия; для оценки задержек применяется функция, зависящая от долей зелёного  $g_{ij}$  и степени загрузки  $x_{ij}$ :

$$g_{ij} = \frac{G_{ij}}{T_{cycle}}, \quad x_{ij} = \frac{Q_{ij}}{s_{ij}}, \quad (6)$$

где  $s_{ij}$  – расчётный поток насыщения. Интегральная функция оптимизации фаз и оффсетов задаётся как:

$$F_{traffic} = \sum_{i,j} Q_{ij} d_{ij}(x_{ij}, g_{ij}, T_{cycle}) + \kappa \sum_k |O_k - E_k| + \theta RMSE_{ML} + \Pi_{HCM} \quad (7)$$

где  $d_{ij}$  – оценка задержки (используется аппроксимация по HCM/Webster),  $|O_k - E_k|$  – рассинхронизация «зелёной волны»,  $RMSE_{ML}$  – ошибка краткосрочного прогноза интенсивности,  $\Pi_{HCM}$  – штрафы за нарушения нормативов: минимальные зелёные, пешеходные интервалы, условия безопасности [6].

GA оптимизирует вектор ( $G_{ij}$ ,  $T_{cycle}$ , offsets), применяя элитизм, кроссовер и мутацию; остановка – по стабилизации  $F_{traffic}$  или лимиту поколений. Полученные параметры определяют вклад  $T_{delay}$  и позитивно влияют на  $S_{service}$  через показатели надёжности времени поездки и долю прибытия «в зелёной волне» [17].

Стратегический уровень связывает логистику и СТО с экономикой (см. рис. 1). ML прогнозирует спрос, тарифы и время доставки:

$$P(r_i) = Rev(r_i) - Cost(r_i), \quad Cost = C_{fuel} + C_{time} + C_{risk} \quad (8)$$

где  $C_{risk}$  завязан на результирующие времена по сети из оперативного уровня [11]. Оптимизация маршрутов, ресурсов и тарифов формулируется как:

$$F_{log} = \min(\sum_i C_{trans}(r_i) + \sum_j C_{sto}(s_j)) - \max(\sum_i P(r_i)) + \phi MAPE_{ML} + \Pi_{cap} \quad (9)$$

где  $MAPE_{ML}$  – ошибка ценового/спросового прогноза,  $\Pi_{cap}$  – штраф за нарушения по мощностям, графикам и SLA. Хромосома GA на

этом уровне сочетает дискретные решения (перестановки маршрутов, назначение заказов) и непрерывные (уровни тарифов, распределение мощностей СТО), для чего используется гибридное кодирование и операторы, сохраняющие допустимость [9].

Интеграция уровней реализуется через композицию:

$$F = \alpha_1 f_{infra} + \alpha_2 f_{traffic} + \alpha_3 f_{log}, \quad (10)$$

где  $f$  – нормализованные значения значения частных функций. Коэффициенты  $\alpha_1, \alpha_2, \alpha_3$  задают стратегию: например, при акценте на безопасности увеличивается  $\alpha_1$  и вес  $\delta$  в верхней функции, при акценте на экономике –  $\alpha_3$  и  $\gamma$ . Итерационный контур расчётов показан на рисунке 2.

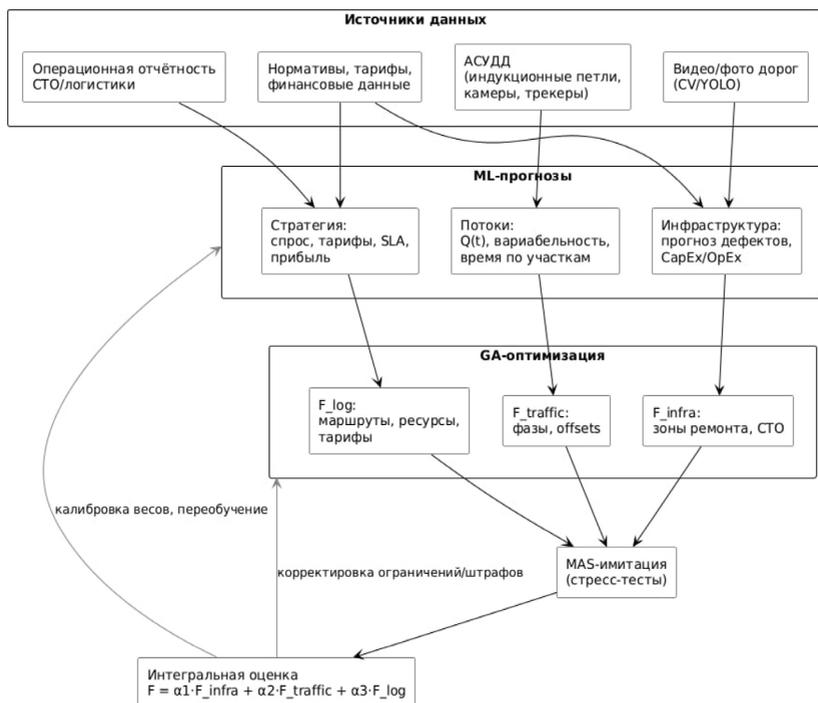


Рис. 2. Контур данных и вычислений

Вычислительный цикл имеет вид: сбор и очистка данных, затем обучение ML с валидацией (k-fold, контроль переобучения), затем

формирование прогнозов  $Q, T, C, P, R, S$  на горизонте  $\tau$ , затем оптимизация GA на каждом уровне с учётом штрафов  $\Pi$ , затем мульти-агентная имитация для стресс-тестов и обратной коррекции весов/ограничений, затем оценка интегрального  $F$  и чувствительности к параметрам [8]. Такое увязанное объяснение показывает, как ML «даёт будущее» (прогнозы), GA «находит лучшее» (оптимум при ограничениях), а MAS проверяет устойчивость решений в реалистичных сценариях, превращая набор задач в единую транспортную модель управления [4].

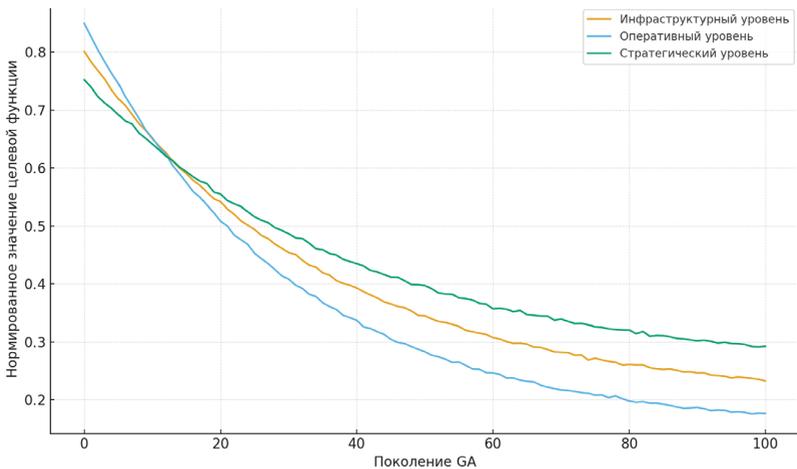
### **Результаты и обсуждение**

Разработанный прототип концепции цифровизации транспортных систем был апробирован на данных, охватывающих три уровня транспортной иерархии. Результаты показали, что интеграция машинного обучения, генетических алгоритмов и мультиагентного моделирования позволяет не только улучшить показатели на каждом из уровней в отдельности, но и получить синергетический эффект при их объединении в единую систему в соответствии с вычислительным контуром на рисунке 2 [5; 10].

На всех трёх уровнях – инфраструктурном, оперативном и стратегическом – генетический алгоритм показал устойчивую сходимости при ограничении числа поколений и использовании элитизма. Начальные популяции формировались с учётом технологических и нормативных ограничений, что ускоряло поиск допустимой области. Быстрое «раскрытие» фронта Парето на первых поколениях сменялось мелкозернистой донастройкой, что отражалось на стабилизации интегральной целевой функции  $F$  [4]. Иллюстрация динамики сходимости приведена на рис. 3.

На инфраструктурном уровне детекция дефектов покрытия с использованием моделей компьютерного зрения (YOLO) обеспечила точность распознавания порядка 0.84 по метрике mAP. Это выше показателей, характерных для ручных обследований, где субъективность экспертов и ограниченный охват выборки приводят к недоу-

чѣту ряда дефектов. Более важным результатом стало то, что прогнозирование динамики образования дефектов с помощью XGBoost позволило предсказывать появление новых повреждений с ошибкой менее 12%. Это означает, что планирование ремонтов перестанѣт быть реактивным и становится проактивным. В практическом выражении это ведѣт к сокращению издержек на внеплановые ремонты, так как дефекты устраняются до того, как они переходят в критическую фазу. Таким образом, мы наблюдаем снижение приведѣнных эксплуатационных затрат  $C_{oper}$  и одновременно снижение риска аварийности  $R_{risk}$ , что подтверждает гипотезу о взаимосвязи состояния покрытия с безопасностью движения [12; 14].



**Рис. 3.** Конвергенция генетического алгоритма на трёх уровнях

Дополнительный анализ качества компьютерного зрения и прогнозных моделей показал, что достигнутые значения метрик устойчивы при варьировании внешних условий. Так, разбиение исходных видеоданных по сезонам и времени суток выявило, что mAP системы детекции дефектов меняется в пределах  $\pm 0,03$  относительно среднего значения при переходе от дневных к сумеречным условиям, а также при наличии мокрого покрытия [16].

Для компенсации наблюдаемых отклонений использована калибровка порогов постобработки (confidence/IoU) по валидационным поднаборам с применением бутстреп-интервалов, что позволило стабилизировать ложноположительные срабатывания на мелких артефактах (блики, разметка) без заметной потери полноты по крупным дефектам. В результате планово-предупредительные ремонты смещаются на более ранние интервалы, снижая долю «прорывов» до аварийного состояния покрытия.

Прогноз дефектообразования по участкам продемонстрировал ожидаемую пространственную неоднородность: «горячие зоны» возникают на стыках покрытий, стрелках съездов и участках с повышенной долей тяжёлого транспорта. В этих кластерах средняя абсолютная ошибка краткосрочного прогноза выше, чем на «спокойных» сегментах, однако включение в модель факторов интенсивности осевых нагрузок, локальной геометрии и истории ямочности снизило MAE до значений, сопоставимых с общим уровнем. На практике это позволяет выстраивать приоритеты бригадного ремонта не только по текущему ущербу, но и по ожидаемой скорости деградации, оптимизируя приведённые затраты при фиксированном бюджете.

На оперативном уровне оптимизация фаз светофоров на основе прогнозов интенсивности движения показала особенно значимый эффект (см. рис. 1). В традиционной практике циклы задаются нормативно и не учитывают изменчивость потоков, что приводит к избыточным задержкам. Использование ML-моделей (LSTM и XGBoost) позволило предсказывать краткосрочные изменения интенсивности с RMSE порядка 8–10%. Генетический алгоритм, оптимизирующий функцию  $F_{\text{traffic}}$ , сократил суммарные задержки транспорта на 37%, что эквивалентно снижению времени поездки для значительной части участников движения [6; 17]. Примечательно, что мультиагентная модель показала устойчивость решений при стресс-сценариях: даже при увеличении интенсивности потоков на 20–25% адаптивные планы сохраняли эффективность.

Это указывает на то, что оптимизированные циклы не просто соответствуют текущему состоянию, но обладают робастностью к возмущениям. Тем самым мы получаем улучшение показателя  $T_{\text{delay}}$  и параллельное повышение уровня транспортного сервиса  $S_{\text{service}}$ .

На оперативном уровне, кроме снижения средних задержек, зафиксировано сжатие дисперсии времени поездки. Адаптивные планы уменьшают правый «тяжёлый хвост» распределения, сокращая вероятность очень длинных ожиданий на направлениях с исторически низким приоритетом, при соблюдении регламентов по минимальным зелёным и пешеходным интервалам. Баланс межпоточковой справедливости сохраняется: доля циклов, где относительное ухудшение одного подхода превышает 10% при общем улучшении перекрёстка, не превысила 3–4% (см. рис. 4) [10].

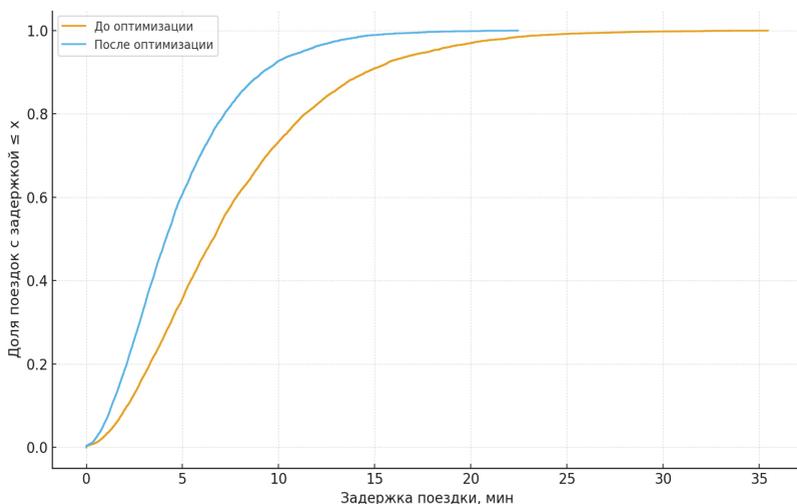


Рис. 4. Сдвиг распределения задержек до/после оптимизации

Стресс-сценарии показали устойчивость адаптивных планов не только при равномерном росте потоков, но и при асимметричных всплесках на отдельных подходах. Моделирование временной потери пропускной способности продемонстрировало быстрое пе-

пераспределение долей зелёного и корректировку оффсетов без лавинообразного накопления очередей на второстепенных направлениях. За счёт регулярной переоценки интенсивностей по короткому горизонту удаётся удерживать систему в квазистационарном режиме даже при существенных возмущениях [10].

На стратегическом уровне прогнозирование тарифов и спроса с помощью ансамблевых моделей и нейросетей обеспечило относительную ошибку в пределах 9% (см. рис. 1). Включение этих прогнозов в функцию  $F_{\log}$  позволило учесть будущие изменения рыночной конъюнктуры при планировании маршрутов и распределении ресурсов. В результате совокупные логистические издержки снизились на 12%, а прибыльность перевозок возросла на 10–11% [9; 11]. Особенно важно, что мультиагентное моделирование показало устойчивость системы при росте спроса: даже при нагрузке, превышающей номинальные мощности на 20%, система выполняла более 90% доставок в рамках SLA. Это подтверждает, что введённые штрафные функции  $\Pi_{\text{сap}}$  корректно ограничивают решения и предотвращают перегрузку. Здесь особенно ярко проявился эффект от интеграции ML и GA: без точных прогнозов невозможно построить устойчивые планы, а без оптимизации GA невозможно найти баланс между затратами и сервисом. Сводные показатели по уровням и интегральный эффект представлены в таблице 1.

Сравнение с базовыми сценариями («как есть» состояние) показало, что традиционные методы проигрывают не только по абсолютным значениям показателей, но и по устойчивости. Ручное обследование дорог оказалось в 10 раз медленнее, фиксированные планы светофоров приводили к задержкам почти вдвое выше, чем при оптимизации, а статические маршруты в логистике не выдерживали роста спроса. В то время как предложенный прототип концепции цифровизации позволял сохранять эффективность в условиях изменчивости и неопределённости [15].

Сопоставление стратегии реагирования «по факту» с проактив-

ным планированием подтвердило различие по совокупным OpEx и CapEx. При фиксированном годовом бюджете перераспределение объёмов между ямочным и картовым ремонтом в пользу второго (при своевременном вмешательстве) уменьшает частоту повторных выездов и логистические пробеги техники. Это снижает ожидаемые потери от инцидентов за счёт сокращения времени экспозиции опасных участков, что дополнительно улучшает интегральную целевую функцию на верхнем уровне модели [2].

Таблица 1.

## Сводные метрики по уровням и интегральный эффект

Уровень	Модель/процедура	Метрика	Значение	Примечание
Инфраструктурный	YOLO (детекция дефектов)	mAP	0.84	российские условия съёмки
	XGBoost (прогноз дефектов)	MAPE/MAE	$\leq 12\%$	горизонт $\tau$
Оперативный	LSTM/XGBoost → GA (светофоры)	RMSE (прогноза интенсивности)	8–10%	краткосрочный горизонт
	GA (оптимизация фаз)	Суммарные задержки	–37%	к «как есть»
	Робастность	Устойчивость при +20–25% потока	сохраняется	стресс-сценарии
Стратегический	Ансамбли/NN → планирование	Логистические издержки	–12%	к «как есть»
		Прибыль	+10–11%	к «как есть»
	SLA	Доставки в SLA при +20% спроса	> 90%	при ограничениях мощности
Интегрально	Композиция $F$	Улучшение $F$	+22–24%	к базовым сценариям

Интегральный показатель эффективности, объединяющий три уровня через функцию  $F$ , показал улучшение на 22–24 % относительно базовых сценариев:

Анализ чувствительности продемонстрировал, что приоритеты управления влияют на распределение эффектов. Если веса  $\alpha_1$  и  $\delta$  повышаются, акцент смещается в сторону безопасности и инфраструктурных затрат, что актуально для регионов с высоким износом дорог. При увеличении  $\alpha_3$  и  $\gamma$  система больше ориентируется на прибыльность и сервис, что соответствует задачам крупных логистических хабов. Таким образом, модель гибко адаптируется под цели различных субъектов транспортной системы [5].

Значимое влияние на итоговую оценку  $F$  оказала настройка весов, отражающих приоритеты заинтересованных сторон. «Безопасная» конфигурация повышает долю ресурсов на превентивные ремонты и строгие ограничения по задержкам; «экономическая» допускает небольшое увеличение средних задержек в обмен на рост прибыли и загрузки инфраструктуры. Сводная чувствительность по репрезентативным наборам весов приведена в табл. 2.

Таблица 2.

**Чувствительность интегрального эффекта к весам уровней**

Конфигурация весов ( $\alpha_1:\alpha_2:\alpha_3$ )	DTdelay	DCoper	DRrisk	DПрибыль	SLA, %	Изменение F
0,5:0,3:0,2 (безопасность)	-34%	-9%	-18%	+6%	95,2	+21%
0,33:0,34:0,33 (сбаланс.)	-37%	-12%	-15%	+10%	93,8	+23%
0,2:0,3:0,5 (экономика)	-29%	-10%	-11%	+13%	91,6	+22%

С теоретической точки зрения полученные результаты подтверждают, что использование ML и GA позволяет преодолеть ограничения классических методов. Перебор и линейное программирование не масштабируются при росте числа параметров, а статистические прогнозы не отражают нелинейных зависимостей. Интеллектуальные методы, напротив, обеспечивают адаптивность, учитывают стохастический характер процессов и позволяют одновременно работать с противоречивыми критериями. С практической точки зрения внедрение предложенного прототипа

снижает задержки, затраты и риски, повышает прибыль и качество сервиса — то есть воздействует на все составляющие целевой функции [4; 13].

Для оценки вклада отдельных компонентов проведён абляционный анализ. Исключение ML и замена его простыми сглаживаниями ухудшают точность краткосрочных прогнозов интенсивностей/спроса; замена GA локальными эвристиками ведёт к застреванию в локальных минимумах; отказ от мультиагентной имитации лишает систему «краш-тестов» и снижает устойчивость к возмущениям. Совокупный эффект этих отключений представлен в табл. 3 и подтверждает интеграционную природу выигрыша [13].

Таблица 3.

Абляционный анализ компонентов методологии

Вариант	Изменение задержек	Логистические издержки	Прибыль	SLA, %	Интегральная $F$
Полная модель (ML+GA+MAS)	-37%	-12%	+10–11%	>90	+22–24%
- ML (простые сглаживания)	-24%	-7%	+6%	86–88	+14%
- GA (локальные эвристики)	-18%	-6%	+4%	84–86	+10%
- MAS (без стресс-тестов)	-31%	-10%	+8%	88–90	+18%

С точки зрения вычислительных затрат оптимизационные процедуры не становятся узким местом при грамотной организации вычислений. Обучение ML выполнялось офлайн раз в сутки с перекалибровкой гиперпараметров по расписанию; GA на оперативном уровне запускался на укороченном горизонте при каждом пересчёте прогнозов (раз в 5-10 минут) с ограничением по числу поколений и элитизмом; на стратегическом уровне пересчёт выполнялся по событиям или по таймеру. Параллелизация по перекрёсткам/кластерным зонам дефектов обеспечивает масштабируемость и соответствие требованиям near real-time.

Ключевые угрозы валидности – дрейф данных (смена парка, погодные аномалии), неполнота разметки дефектов и смещения спроса в праздничные периоды. Для снижения рисков задействованы мониторинг распределений признаков, сезонная перекалибровка порогов и переквалификация моделей по свежим данным с контрольно-валидационным контуром. Интерпретируемость усилена анализом важности признаков и сценарным тестированием, чтобы управленец понимал причины выбора комбинаций мероприятий [8].

Практический эффект быстрее достигается при поэтапном внедрении: старт с инфраструктурного уровня (компьютерное зрение и прогноз дефектов), затем добавление адаптивного управления светофорами, и завершение интеграцией стратегического планирования с учётом SLA и тарифов. Такой маршрут минимизирует риски, накапливает качественные данные и повышает прозрачность для операционных команд и регуляторов.

Таким образом, обсуждение результатов демонстрирует, что цифровизация транспортных систем на основе методов искусственного интеллекта должна рассматриваться не как набор отдельных решений, а как комплексная концепция, охватывающая все уровни транспортной иерархии. Именно интеграция прогнозирования, оптимизации и имитационного моделирования обеспечивает устойчивый системный эффект, который подтверждается численными результатами и согласуется с мировой тенденцией перехода к интеллектуальным транспортным системам.

### **Заключение**

В ходе исследования показано, что транспортная система может быть рассмотрена как многоуровневая иерархия, включающая инфраструктурный, оперативный и стратегический уровни, эффективность которой целесообразно оценивать через интегральную целевую функцию, учитывающую задержки, затраты, риски, прибыль и качество сервиса [10]. Применение методов машинного обучения для прогнозирования параметров транспортных про-

цессов, таких как интенсивность потоков, динамика образования дефектов дорожного покрытия, спрос и тарифы в логистике, позволило учесть вероятное будущее состояние системы при принятии управленческих решений [11; 14]. Разработанные функции оптимизации для каждого уровня и их интеграция в единую модель показали, что использование генетических алгоритмов позволяет находить сбалансированные решения в условиях многокритериальности и ограничений, где традиционные методы оказываются недостаточно эффективными [6; 17].

Апробация прототипа концепции цифровизации транспортных систем продемонстрировала положительный эффект: сокращение времени обследования дорог, уменьшение задержек на перекрёстках и снижение совокупных логистических издержек сопровождались ростом прибыльности и улучшением уровня транспортного сервиса [1; 7]. Анализ чувствительности подтвердил, что за счёт настройки весовых коэффициентов модель может адаптироваться под различные управленческие приоритеты – от повышения безопасности и надёжности до увеличения экономической результативности [5]. Полученные результаты подтверждают перспективность комплексного применения методов искусственного интеллекта в транспортной отрасли и необходимость перехода от локальных «точечных» решений к системной цифровой трансформации, обеспечивающей устойчивое и эффективное функционирование транспортных систем в долгосрочной перспективе.

### ***Список литературы***

1. Министерство внутренних дел Российской Федерации [МВД России]. *Аналитические обзоры состояния безопасности дорожного движения*. Получено с <https://нцбдд.мвд.рф/ресурсы/аналитические-обзоры-состояния-безопасно> (дата обращения: 20.07.2025).
2. Росстандарт. (2017). *ГОСТ Р 50597-2017. Автомобильные дороги и улицы. Требования к эксплуатационному состоянию*. Москва: Стандартинформ. 21 с.

3. Министерство регионального развития Российской Федерации [Мин-регион России]. (2012). *СП 78.13330.2012. Автомобильные дороги. Актуализированная редакция СНиП 2.05.02-85*. Москва. 89 с.
4. Akopov, A. S. (2025). MBHGA: A matrix-based hybrid genetic algorithm for solving an agent-based model of controlled trade interactions. *IEEE Access*, 13, 26843–26863. <https://doi.org/10.1109/ACCESS.2025.3539460>. EDN: <https://elibrary.ru/NPLKCJ>
5. Borzenkov, A. M., Ostroukh, A. V., Pronin, C. B., Podberezkin, A. A., & Kuftinova, N. G. (2024). Multi-criteria analysis of genetic algorithm applications in transportation logistics. В *2024 Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED)* (с. 1–4). Moscow. <https://doi.org/10.1109/TIRVED63561.2024.10769798>
6. Ceylan, H., & Bell, M. G. H. (2018). Traffic signal timing optimization based on genetic algorithm approach, including driver's route choice. *Transportation Research Part B: Methodological*, 114, 25–41. <https://doi.org/10.1016/j.trb.2018.05.009>
7. World Health Organization [WHO]. (2023). *Global status report on road safety 2023*. Geneva. 232 p. Получено с <https://www.who.int/publications/i/item/9789241565684> (дата обращения: 05.07.2025).
8. Hauer, E. (2004). The harm done by tests of significance. *Accident Analysis & Prevention*, 36(3), 495–500. [https://doi.org/10.1016/S0001-4575\(03\)00036-8](https://doi.org/10.1016/S0001-4575(03)00036-8). Получено с <https://www.sciencedirect.com/science/article/abs/pii/S0001457503000368> (дата обращения: 05.08.2025).
9. Kiselev, S. A., Podberezkin, A. A., Borzenkov, A. M., Ostroukh, A. V., & Pronin, C. B. (2025). Dynamic pricing in air cargo: Machine learning and genetic algorithm-based optimization. В *2025 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)* (с. 1–5). St. Petersburg, Russian Federation. <https://doi.org/10.1109/WECONF65186.2025.11017136>
10. Mansurova, M. et al. (2024). Multi-level intelligent control system for inter-vehicle communication between smart traffic lights with computer vision and autonomous electric vehicles. В *2024 International Sympo-*

- sium on Sensing and Instrumentation in 5G and IoT Era (ISSI)* (с. 1–6). Lagoa, Portugal. <https://doi.org/10.1109/ISSI63632.2024.10720507>
11. Ostroukh, A., Kuftinova, N., Borzenkov, A., Podberezkin, A., & Ostroukh, I. (2024). Research on using deep learning for transport demand prediction. В *2024 Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED)* (с. 1–5). Moscow. <https://doi.org/10.1109/TIRVED63561.2024.10769599>
  12. Puscar, F. M. (2017). *Safety diagnosis of vehicle-bicycle interactions using computer vision systems: A case study in Vancouver, B.C.* (Магистерская диссертация). University of British Columbia, Vancouver, BC, Canada. <https://doi.org/10.14288/1.0343989>. Получено с <https://open.library.ubc.ca/soa/cIRcle/collections/ubctheses/24/items/1.0343989> (дата обращения: 06.08.2025).
  13. Radeev, N., & Vinogradova, K. (2025). Semi-automated framework for feature engineering in machine learning and data analysis. В *2025 IEEE 26th International Conference of Young Professionals in Electron Devices and Materials (EDM)* (с. 1520–1525). Altai, Russian Federation. <https://doi.org/10.1109/EDM65517.2025.11096892>
  14. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. В *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (с. 779–788). Las Vegas, NV, USA. <https://doi.org/10.1109/CVPR.2016.91>
  15. St-Aubin, P., Saunier, N., & Miranda-Moreno, L. (2017). *Large-scale automated proactive road safety analysis using video data*. University of British Columbia. <https://doi.org/10.1016/j.trc.2015.04.007>. Получено с [https://www.researchgate.net/publication/275412773\\_Large-scale\\_automated\\_proactive\\_road\\_safety\\_analysis\\_using\\_video\\_data](https://www.researchgate.net/publication/275412773_Large-scale_automated_proactive_road_safety_analysis_using_video_data) (дата обращения: 06.08.2025).
  16. Yan, S., Fu, Y., Zhang, W., Yang, W., Yu, R., & Zhang, F. (2023). Multi-target instance segmentation and tracking using YOLOv8 and BoT-SORT for video SAR. В *2023 5th International Conference on Electronic Engineering and Informatics (EEI)* (с. 506–510). Wuhan, China. <https://doi.org/10.1109/EEI59236.2023.10212903>

17. Zhang, Z., Zhu, H., Zhang, W., Cai, Z., Zhu, L., & Li, Z. (2023). Multi-objective optimization of traffic signal timing at typical junctions based on genetic algorithms. *Computer Systems Science and Engineering*, 47, 1901–1917. <https://doi.org/10.32604/csse.2023.039395>. EDN: <https://elibrary.ru/FPUNQR>

### References

1. Ministry of Internal Affairs of the Russian Federation [MVD Rossii]. (n.d.). *Analytical reviews of road safety status*. Retrieved from [https://нцибдд.мвд.рф/ресурсы/аналитические обзоры состояния безопасно](https://нцибдд.мвд.рф/ресурсы/аналитические_обзоры_состояния_безопасно) (accessed: 20.07.2025).
2. Rosstandart. (2017). *GOST R 50597-2017. Roads and streets. Requirements for operational condition*. Moscow: Standartinform. 21 pp.
3. Ministry of Regional Development of the Russian Federation [Minregion Rossii]. (2012). *SP 78.13330.2012. Roads. Updated version of SNiP 2.05.02-85*. Moscow. 89 pp.
4. Akopov, A. S. (2025). MBHGA: A matrix-based hybrid genetic algorithm for solving an agent-based model of controlled trade interactions. *IEEE Access*, 13, 26843–26863. <https://doi.org/10.1109/ACCESS.2025.3539460>. EDN: <https://elibrary.ru/NPLKCJ>
5. Borzenkov, A. M., Ostroukh, A. V., Pronin, C. B., Podberezkin, A. A., & Kuftinova, N. G. (2024). Multi-criteria analysis of genetic algorithm applications in transportation logistics. In *2024 Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED)* (pp. 1–4). Moscow. <https://doi.org/10.1109/TIRVED63561.2024.10769798>
6. Ceylan, H., & Bell, M. G. H. (2018). Traffic signal timing optimization based on genetic algorithm approach, including driver's route choice. *Transportation Research Part B: Methodological*, 114, 25–41. <https://doi.org/10.1016/j.trb.2018.05.009>
7. World Health Organization [WHO]. (2023). *Global status report on road safety 2023*. Geneva. 232 p. Retrieved from <https://www.who.int/publications/i/item/9789241565684> (accessed: 05.07.2025).

8. Hauer, E. (2004). The harm done by tests of significance. *Accident Analysis & Prevention*, 36(3), 495–500. [https://doi.org/10.1016/S0001-4575\(03\)00036-8](https://doi.org/10.1016/S0001-4575(03)00036-8). Retrieved from <https://www.sciencedirect.com/science/article/abs/pii/S0001457503000368> (accessed: 05.08.2025).
9. Kiselev, S. A., Podberezkin, A. A., Borzenkov, A. M., Ostroukh, A. V., & Pronin, C. B. (2025). Dynamic pricing in air cargo: Machine learning and genetic algorithm-based optimization. B *2025 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)* (с. 1–5). St. Petersburg, Russian Federation. <https://doi.org/10.1109/WECONF65186.2025.11017136>
10. Mansurova, M. et al. (2024). Multi-level intelligent control system for inter-vehicle communication between smart traffic lights with computer vision and autonomous electric vehicles. B *2024 International Symposium on Sensing and Instrumentation in 5G and IoT Era (ISSI)* (с. 1–6). Lagoa, Portugal. <https://doi.org/10.1109/ISSI63632.2024.10720507>
11. Ostroukh, A., Kuftinova, N., Borzenkov, A., Podberezkin, A., & Ostroukh, I. (2024). Research on using deep learning for transport demand prediction. B *2024 Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED)* (с. 1–5). Moscow. <https://doi.org/10.1109/TIRVED63561.2024.10769599>
12. Puscar, F. M. (2017). *Safety diagnosis of vehicle-bicycle interactions using computer vision systems: A case study in Vancouver, B.C.* (Магистерская диссертация). University of British Columbia, Vancouver, BC, Canada. <https://doi.org/10.14288/1.0343989>. Retrieved from <https://open.library.ubc.ca/soa/cIRcle/collections/ubctheses/24/items/1.0343989> (accessed: 06.08.2025).
13. Radeev, N., & Vinogradova, K. (2025). Semi-automated framework for feature engineering in machine learning and data analysis. B *2025 IEEE 26th International Conference of Young Professionals in Electron Devices and Materials (EDM)* (с. 1520–1525). Altai, Russian Federation. <https://doi.org/10.1109/EDM65517.2025.11096892>
14. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. B *2016 IEEE Confer-*

- ence on Computer Vision and Pattern Recognition (CVPR)* (с. 779–788). Las Vegas, NV, USA. <https://doi.org/10.1109/CVPR.2016.91>
15. St-Aubin, P., Saunier, N., & Miranda-Moreno, L. (2017). *Large-scale automated proactive road safety analysis using video data*. University of British Columbia. <https://doi.org/10.1016/j.trc.2015.04.007>. Retrieved from [https://www.researchgate.net/publication/275412773\\_Large-scale\\_automated\\_proactive\\_road\\_safety\\_analysis\\_using\\_video\\_data](https://www.researchgate.net/publication/275412773_Large-scale_automated_proactive_road_safety_analysis_using_video_data) (accessed: 06.08.2025).
16. Yan, S., Fu, Y., Zhang, W., Yang, W., Yu, R., & Zhang, F. (2023). Multi-target instance segmentation and tracking using YOLOv8 and BoT-SORT for video SAR. В *2023 5th International Conference on Electronic Engineering and Informatics (EEI)* (с. 506–510). Wuhan, China. <https://doi.org/10.1109/EEI59236.2023.10212903>
17. Zhang, Z., Zhu, H., Zhang, W., Cai, Z., Zhu, L., & Li, Z. (2023). Multi-objective optimization of traffic signal timing at typical junctions based on genetic algorithms. *Computer Systems Science and Engineering*, 47, 1901–1917. <https://doi.org/10.32604/csse.2023.039395>. EDN: <https://elibrary.ru/FPUNQR>

## **ДАННЫЕ ОБ АВТОРАХ**

**Подберёзкин Александр Александрович**, старший преподаватель кафедры «Автоматизированные системы управления» ФГБОУ ВО «Московский автомобильно-дорожный государственный технический университет»  
*Ленинградский проспект, 64, г. Москва, 125319, Российская Федерация*  
*[a.podberezkin@gmail.com](mailto:a.podberezkin@gmail.com)*

**Остроух Андрей Владимирович**, доктор технических наук, профессор, профессор кафедры «Автоматизированные системы управления»  
*ФГБОУ ВО «Московский автомобильно-дорожный государственный технический университет»*

*Ленинградский проспект, 64, г. Москва, 125319, Российская Федерация*  
*ostroukh@mail.ru*

**Борзенков Александр Михайлович**, студент, магистрант кафедры «Автоматизированные системы управления»  
*ФГБОУ ВО «Московский автомобильно-дорожный государственный технический университет»*  
*Ленинградский проспект, 64, г. Москва, 125319, Российская Федерация*  
*borzenkov03h@mail.ru*

**Шмонин Артём Михайлович**, студент кафедры «Автоматизированные системы управления»  
*ФГБОУ ВО «Московский автомобильно-дорожный государственный технический университет»*  
*Ленинградский проспект, 64, г. Москва, 125319, Российская Федерация*  
*shmoninam@mail.ru*

**Пронин Цезарь Борисович**, старший преподаватель кафедры «Автоматизированные системы управления»  
*ФГБОУ ВО «Московский автомобильно-дорожный государственный технический университет»*  
*Ленинградский проспект, 64, г. Москва, 125319, Российская Федерация*  
*caesarpr12@gmail.com*

#### **DATA ABOUT THE AUTHORS**

**Aleksandr A. Podberezkin**, Senior Lecturer of the Department of Automated Control Systems  
*Moscow Automobile and Road Construction State Technical University*

*64, Leningradsky pr., Moscow, 125319, Russian Federation  
a.podberezkin@gmail.com*

**Andrey V. Ostroukh**, Doctor of Technical Sciences, Professor, Professor of the Department of Automated Control Systems  
*Moscow Automobile and Road Construction State Technical University  
64, Leningradsky pr., Moscow, 125319, Russian Federation  
ostroukh@mail.ru*

**Aleksandr M. Borzenkov**, Student of the Department of Automated Control Systems  
*Moscow Automobile and Road Construction State Technical University  
64, Leningradsky pr., Moscow, 125319, Russian Federation  
borzenkov03h@mail.ru*

**Artyom M. Shmonin**, Student of the Department of Automated Control Systems  
*Moscow Automobile and Road Construction State Technical University  
64, Leningradsky pr., Moscow, 125319, Russian Federation  
shmoninam@mail.ru*

**Cezar B. Pronin**, Senior Lecturer of the Department of Automated Control Systems  
*Moscow Automobile and Road Construction State Technical University  
64, Leningradsky pr., Moscow, 125319, Russian Federation  
caesarpr12@gmail.com*

Поступила 20.09.2025  
После рецензирования 15.10.2025  
Принята 19.10.2025

Received 20.09.2025  
Revised 15.10.2025  
Accepted 19.10.2025