

УДК 004.8
DOI 10.17513/snt.40615

ИССЛЕДОВАНИЕ ПРИМЕНЕНИЯ КОМПЬЮТЕРНОГО ЗРЕНИЯ И ГЕНЕТИЧЕСКОГО АЛГОРИТМА КЛАСТЕРИЗАЦИИ ДЛЯ МОНИТОРИНГА СОСТОЯНИЯ ДОРОЖНОГО ПОКРЫТИЯ

Подберёзкин А.А., Борзенков А.М., Остроух А.В., Пронин Ц.Б., Тётченко О.А.

Федеральное государственное бюджетное образовательное учреждение высшего образования
«Московский автомобильно-дорожный государственный технический университет (МАДИ)»,
Москва, Российская Федерация, e-mail: oksanatetcenko@gmail.com

Целью статьи является исследование эффективности применения интеллектуальной системы мониторинга дорожного покрытия на основе компьютерного зрения и генетического алгоритма кластеризации. Исследование направлено на оценку точности детекции дефектов, анализ производительности гибридной архитектуры и проверку соответствия автоматизированных решений требованиям нормативных документов. Для достижения поставленной цели представлена интеллектуальная система мониторинга дорожного покрытия, разработанная для автоматизации выявления дефектов (выбоин, трещин) и формирования ремонтных рекомендаций на основе современных технологий компьютерного зрения и генетических алгоритмов. Система реализована в гибридной архитектуре (микросервисы и монолитный модуль) с использованием Kubernetes, что обеспечивает баланс между производительностью и масштабируемостью. Для детекции дефектов применена модель распознавания объектов, демонстрирующая высокую точность и устойчивость к сложным условиям российских дорог (тени, осадки). Методы фотограмметрии обеспечивают точную геопривязку повреждений, а генетический алгоритм кластеризации объединяет дефекты в ремонтные зоны, учитывая их плотность и пространственное распределение. Внедрение системы позволило сократить время обследования 1 км дороги с 4 ч до 20–25 мин и снизить затраты на 58–62 %. Результаты исследования подтверждают эффективность предложенного подхода для повышения точности мониторинга, объективности оценки состояния дорожного покрытия и оптимизации ремонтных работ. Система готова к интеграции в региональные системы управления дорожной инфраструктурой.

Ключевые слова: мониторинг дорожного покрытия, компьютерное зрение, нормативная оценка, фотограмметрия, гибридная архитектура, генетический алгоритм кластеризации, автоматизация мониторинга

RESEARCH ON METHODS FOR ENHANCING THE ACCURACY OF NEURAL NETWORKS IN ROAD SURFACE ANALYSIS USING GENETIC ALGORITHMS

Podberezkin A.A., Borzenkov A.M., Ostroukh A.V., Pronin Ts.B., Tetchenko O.A.

*Federal State Budgetary Educational Institution of Higher Education
“Moscow Automobile and Road Construction State Technical University (MADI)”,
Moscow, Russian Federation, e-mail: oksanatetcenko@gmail.com*

The main goal of this paper is to study the efficiency of using an intelligent road surface monitoring system based on computer vision and a genetic clustering algorithm. The study is aimed at assessing the accuracy of defect detection, analyzing the performance of the hybrid architecture and checking the compliance of automated solutions with regulatory requirements. To achieve this goal, an intelligent road surface monitoring system is presented, developed to automate the detection of defects (potholes, cracks) and the process of forming repair recommendations based on modern computer vision technologies and genetic algorithms. The system is implemented in a hybrid architecture (microservices + monolithic module) using Kubernetes, which ensures a balance between performance and scalability. To detect defects, an object recognition model is used that demonstrates high accuracy and resistance to the difficult conditions of Russian roads (shadows, precipitation). Photogrammetry methods provide accurate georeferencing of damage, and the genetic clustering algorithm combines defects into repair zones, taking into account their density and spatial distribution. The implementation of the proposed system reduces the time of inspection of 1 km of road from 4 hours to 20-25 minutes and reduces costs by 58-62 %. The results of the study confirm the effectiveness of the proposed approach in increasing the monitoring accuracy, objectivity of road surface condition assessment and optimization of repair work. The system is ready for integration into regional road infrastructure management systems.

Keywords: road surface monitoring, computer vision, hybrid architecture, regulatory assessment, photogrammetry, genetic clustering algorithm, monitoring automation

Введение

В последние годы наблюдается устойчивая тенденция к росту числа дорожно-транспортных происшествий, связанных с неудовлетворительным состоянием дорожного покрытия [1, 2]. По данным официальной статистики МВД за последние 9 лет,

от 12,5 до 19,3 % всех дорожно-транспортных происшествий в Российской Федерации связаны с наличием дефектов проезжей части, таких как выбоины, трещины, пропадки и разрушение кромок, что напрямую угрожает безопасности участников дорожного движения [3, 4] (рис. 1).

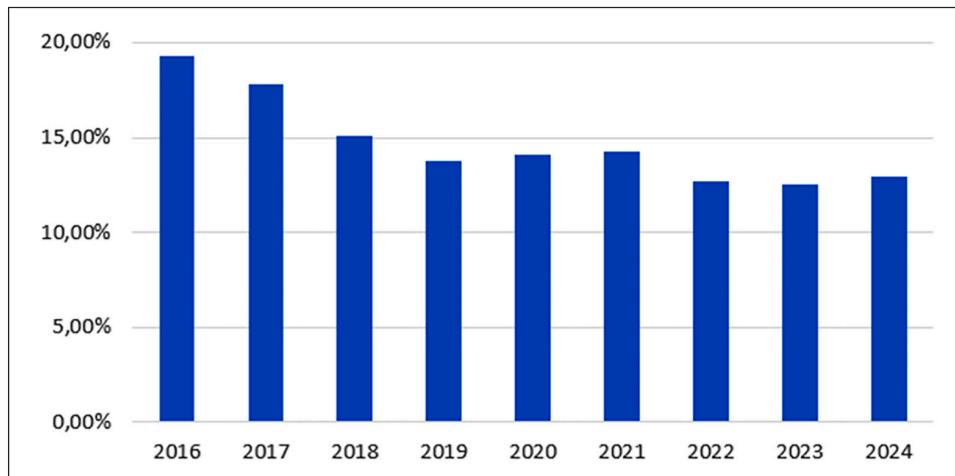


Рис. 1. Статистика ДТП, связанных с наличием дефектов проезжей части, в РФ за 2016–2024 гг.

Примечание: составлен авторами на основе источников [3, 4]

Традиционный ручной мониторинг дорог субъективен, медлителен и лишен точной геопривязки, затрудняя анализ. Зарубежные системы искусственного интеллекта (ИИ) неприменимы в РФ из-за специфики климата, масштабов сети и несовместимости с ГОСТ/СП, что требует отечественного решения для автоматической детекции дефектов, их геопривязки, нормативной оценки и формирования ремонтных рекомендаций с целью повышения эффективности контроля, снижения затрат и улучшения безопасности [1, 2, 5].

Цель исследования – изучение эффективности применения интеллектуальной системы мониторинга дорожного покрытия на основе компьютерного зрения и генетического алгоритма кластеризации. Исследование направлено на оценку точности детекции дефектов, анализ производительности гибридной архитектуры и проверку соответствия автоматизированных решений требованиям нормативных документов (ГОСТ Р 50597-2017, СП 78.13330.2012).

Материал и методы исследования

Архитектура реализована как гибридное решение (микросервисы и монолитный модуль) в Kubernetes для баланса производительности и масштабируемости [6]. Микросервисы на FastAPI (с Apache Kafka) обрабатывают прием изображений, генерацию отчетов и оповещений, обеспечивая независимое масштабирование [7] (рис. 2).

Ключевой монолитный Pod (контейнерная единица в Kubernetes) объединяет ресурсоемкие операции: пространственный пересчет координат, кластеризацию дефектов генетическим алгоритмом и норматив-

ную оценку по ГОСТ, минимизируя сетевые задержки при частом доступе к нейросети и нормативам. Для хранения данных используются: PostgreSQL с PostGIS – для геопривязанных дефектов и пространственных запросов; MinIO (S3-совместимое) – для бинарных объектов (изображения, отчеты) [8]. Kubernetes обеспечивает автоматическое масштабирование и отказоустойчивость, а гибридный подход сочетает гибкость микросервисов с эффективностью централизованной обработки пространственных зависимостей.

YOLOv12 выбрана как ядро компьютерного зрения за оптимальное соотношение точности и скорости. Модель достигла значения точности mAP = 0,912 (mean Average Precision) на валидационном наборе, собранном из изображений российских дорог, при среднем времени инференса около 33 мс на GPU RTX 6000 [9, 10]. Также, благодаря улучшенной архитектуре (PAN (Path Aggregation Network), CSP (Cross Stage Partial connections)), модель устойчива к сложным условиям (тени, мокрый асфальт, снег) [3]. Для снижения ресурсопотребления она оптимизирована через экспорт в ONNX (Open Neural Network Exchange), TensorRT и квантование (Quantization-Aware Training), сократив VRAM (Video Random Access Memory) на ~40% без потери качества [11–13]. Интегрирована как контейнеризированный микросервис FastAPI, принимающий изображения через REST (Representational State Transfer)/Kafka и возвращающий JSON (JavaScript Object Notation) с координатами дефектов (bounding boxes), их классами и confidence для масштабируемости системы.

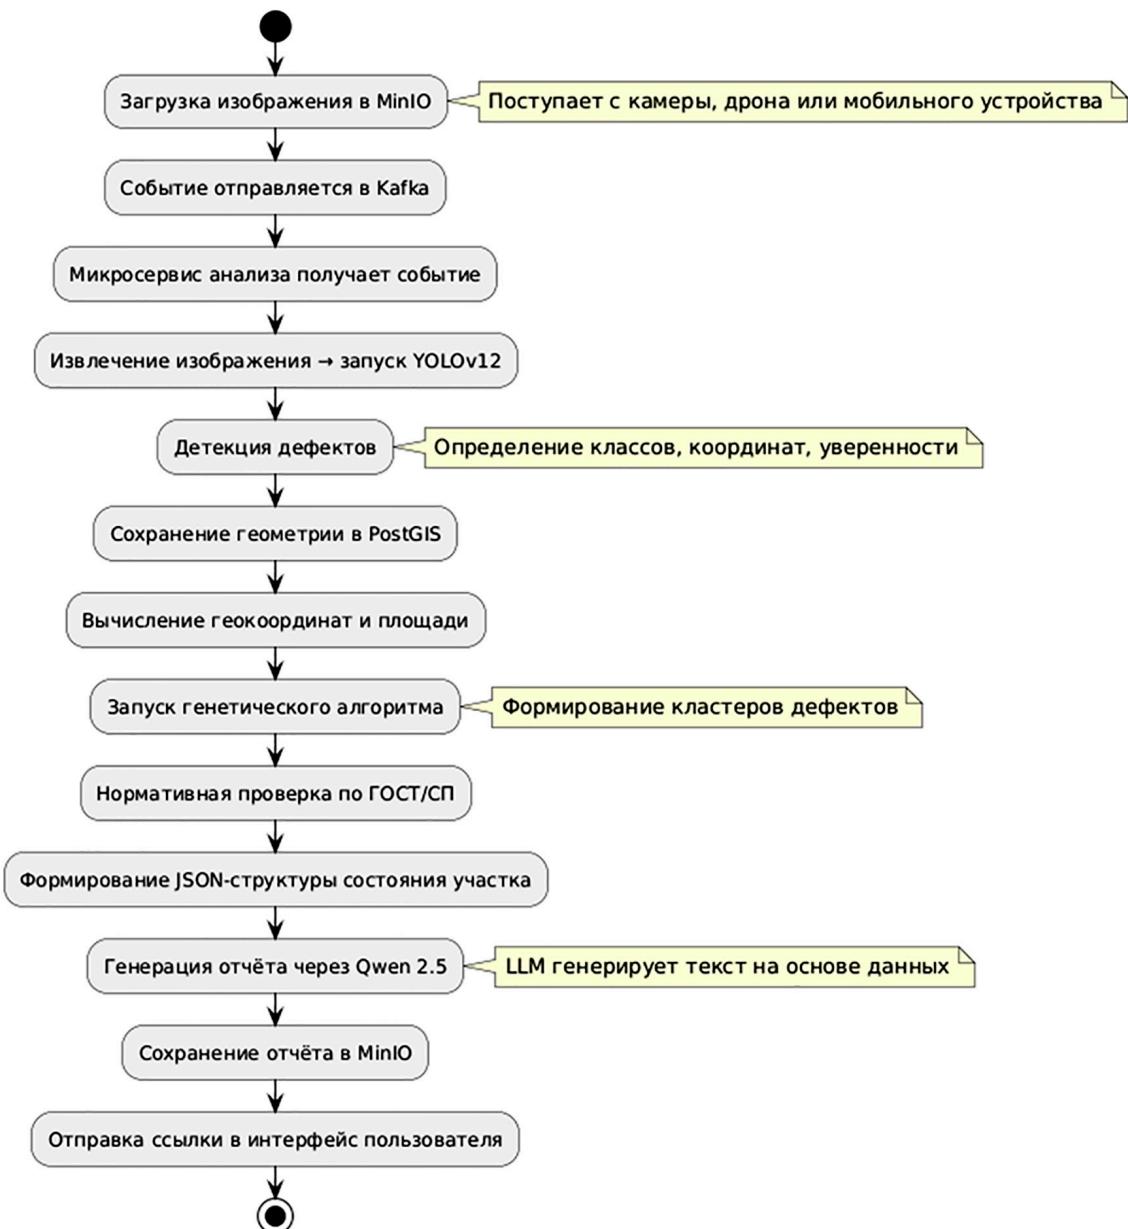


Рис. 2. Полный сценарий потока данных
Примечание: составлен авторами по результатам данного исследования

Поскольку координаты дефектов после детекции представлены в пикселях и непригодны для нормативной оценки, система использует фотограмметрический модуль для пересчета в метрическую систему. На основе параметров съемки (высота, угол наклона камеры, технические характеристики) модуль строит лучевую модель, определяющую пересечение визуального луча с плоскостью дорожного покрытия, что позволяет рассчитать реальные размеры и координаты дефектов. Полученные метрические координаты

в системе WGS-84 (World Geodetic System 1984) сохраняются в PostGIS как пространственные объекты типа *geometry* (Point, 4326), обеспечивая точную геопривязку, пространственный анализ (включая построение буферных зон и расчет расстояний) и сопоставление с нормативами ГОСТ [1].

В рамках задачи пространственно-анализа дефектов дорожного покрытия в системе реализован генетический алгоритм кластеризации, который автоматически объединяет отдельные по-

вреждения в ремонтные зоны [14, 15]. В отличие от традиционных методов, таких как k-means, разработанный подход позволяет учитывать не только расстояния между точками, но и их плотность, а также избегать слишком близкого расположения центров кластеров, что особенно важно при планировании фрагментарного и капитального ремонта [16].

$$F = \frac{1}{K} \sum_{k=1}^K \left(\frac{1}{|C_k|} \sum_{i, j \in C_k, i \neq j} d(p_i, p_j) \right) + \alpha \frac{1}{K(K-1)} \sum_{k=1}^K \sum_{l \neq k} \frac{1}{d(\mu_k, \mu_l)}, \quad (1)$$

где K – количество кластеров (передается из YOLO и PostGIS), C_k – k -й кластер дефектов, $|C_k|$ – количество дефектов в кластере, p_i, p_j – координаты дефектов в кластере C_k , $d(p_i, p_j)$ – евклидово расстояние между дефектами i и j , μ_k – центр тяжести (средняя точка) кластера C_k , α – весовой коэффициент для штрафа за слишком близкие кластеры.

Первая часть функции отвечает за плотность внутри кластеров, вторая – за раздленность между ними. Это позволяет добиться компактных, но не пересекающихся зон повреждений, что критично при последующей нормативной оценке.

Алгоритм работает по классической схеме эволюционного подхода: создается популяция решений, каждая особь кодирует разбиение всех дефектов по K кластерам. На каждом поколении выполняются отбор, скрещивание и мутация, а лучшая особь сохраняется (элитизм). В качестве критерия остановки используется стабилизация значения целевой функции или достижение заданного количества поколений.

Использование данного алгоритма позволило повысить точность объединения дефектов в ремонтные участки, минимизировать ложные объединения и повысить соответствие кластеров нормативной логике ГОСТ Р 50597-2017.

После определения метрических координат и размеров дефектов модуль нормативной оценки сопоставляет их геометрические параметры с критическими порогами, установленными ГОСТ Р 50597-2017 и СП 78.13330.2012 [1, 2]. Система проверяет каждый дефект на соответствие нормативам. Превышение этих значений классифицирует дефект как недопустимый, требующий устранения. Дополнительно, согласно п.5.2 ГОСТ Р 50597-2017, система агрегирует данные на уровне участков: если на 100-метровом отрезке общая площадь дефектов превышает 5% от площади покрытия, это служит основанием для рекомендации капитального или фрагментар-

целевая функция, минимизируемая алгоритмом, учитывает два ключевых аспекта:

– внутрикластерную компактность, то есть средние расстояния между всеми парами дефектов внутри каждого кластера;

– межкластерную разделимость, то есть штраф за слишком близкое расположение центров тяжести различных кластеров.

Формула целевой функции:

ногого ремонта. На основе этого анализа система формирует итоговую оценку состояния покрытия и конкретные рекомендации по ремонту.

Система автоматически генерирует итоговый отчет (DOCX/PDF) на основе данных детекции, геопривязки и нормативной оценки, включая детальную информацию по каждому дефекту (тип, размеры, координаты, соответствие ГОСТ Р 50597-2017) и агрегированные рекомендации по ремонту участков (фрагментарный/капитальный со ссылками на нормативы СП 78.13330.2012) [1, 2]. Отчет дополняется наглядными схемами распределения дефектов и сводными таблицами, обеспечивая совместимость с документооборотом, а его автоматизация гарантирует точность, снижает трудозатраты и исключает субъективные ошибки.

Система мониторинга использует Prometheus и Grafana для сбора метрик (загрузка CPU/GPU, задержки) и визуализации данных в реальном времени. Логи агрегируются через ELK-стек (Elasticsearch, Logstash, Kibana), что позволяет быстро анализировать ошибки и медленные запросы. Alertmanager отправляет алerts (SMS, Telegram, e-mail) при сбоях, например при росте времени обработки или ошибках API. Это сокращает время восстановления (MTTR (mean time to recovery)) до 10 мин и помогает выявлять узкие места (перегрузку GPU, задержки в Kafka). Все это повышает надежность системы и снижает простоту.

Результаты исследования и их обсуждение

Внедрение разработанной системы показало ее преимущество по сравнению с существующими решениями: в отличие от зарубежных ИИМДП (RoadAI, Pavement Condition Index System), она адаптирована к российским климатическим условиям и учитывает требования ГОСТ Р 50597-2017.

Сравнительный анализ разработанной системы с известными решениями ИИМДП

Критерий сравнения	Разработанная система (МАДИ)	Зарубежные аналоги (RoadAI, PCI Systems)	Традиционный ручной метод	Базовые системы CV (YOLO без оптимизации)
Точность детекции (mAP)	0,912	0,82–0,88 (на зарубежных датасетах)	Субъективна, ≈ 0,70 (на основе выборочных проверок)	0,85–0,89 (YOLOv8 на российских данных)
Время обследования 1 км дороги	20–25 мин	30–45 мин (требуется адаптация под условия)	≈ 240 мин (4 часа)	30–35 мин (без интегрированного пайплайна)
Нормативная оценка (ГОСТ/СП)	Полная автоматизация	Отсутствует / требует ручной доработки	Ручная сверка	Отсутствует
Геопривязка дефектов	Автоматическая, точная (фотограмметрия + PostGIS)	Часто приблизительная (GPS-метка)	Визуальная привязка, неточная	Отсутствует / пиксельные координаты
Кластеризация для ремонта	Генетический алгоритм (учет плотности и разделимости)	Простые методы (grid-based, k-means)	Экспертная оценка «на глаз»	Отсутствует
Адаптация к условиям РФ	Полная (тренировка на локальных данных, учет теней, осадков)	Частичная / отсутствует	Естественная	Частичная (зависит от датасета)
Формирование отчета	Автоматическое (DOCX/PDF) с рекомендациями	В основном сырье данные / дашборды	Ручное составление	Сырые данные (JSON, координаты)

Проведен сравнительный анализ разработанной системы с существующими известными решениями в области ИИ-мониторинга дорожного покрытия (ИИМДП). Анализ проводился по ключевым метрикам: точность детекции, время обследования участка дороги, интеграция с нормативной базой и функциональность пространственного анализа. Результаты представлены в таблице.

Повышение точности нейросетевой модели до $mAP = 0,912$ по сравнению с базовыми версиями YOLO ($\approx 0,87$ – $0,89$) было достигнуто за счет комплекса взаимосвязанных нижеперечисленных мер.

Модель YOLOv12 была дообучена на обширном датасете, собранном на дорогах РФ, с применением аугментаций, имитирующих сложные условия: наложение искусственных теней, симуляция мокрого и заснеженного покрытия, изменение контрастности. Это снизило количество ложных срабатываний и пропусков в реальных условиях.

Интеграция фотограмметрического модуля до этапа постобработки предсказаний позволила проводить валидацию размеров объектов не в пикселях, а в метрической системе. Это дало обратную связь для фильтрации заведомо неверных детекций (например, «трещин» физически невозможной

длины или ширины), что напрямую повысило *precision* (точность) модели.

Использование усовершенствованных компонентов PAN (Path Aggregation Network) и CSP (Cross Stage Partial connections) улучшило поток градиентов и контекстуальное понимание сцены, повысив качество детекции мелких и частично скрытых объектов (узких трещин, краев выбоин).

Сокращение времени обследования с 4 ч до 20–25 мин на 1 км достигнуто за счет автоматизации и интеграции всех этапов в единый непрерывный пайплайн, что исключает «ручные» простоя. В процессе работы устранены этапы ручного осмотра дороги, бумажного протоколирования, ручного измерения дефектов и последующего ввода данных в систему.

Процессы детекции (YOLO), геопривязки (фотограмметрия), кластеризации (генетический алгоритм) и нормативной оценки работают как единый автоматизированный конвейер в рамках гибридной архитектуры. Данные передаются между модулями без задержек настыковку.

Заключение

Проведенное исследование подтвердило эффективность разработанного подхода к мониторингу дорожного покрытия. Основной результат – создание интеллек-

туальной системы, которая сочетает современные технологии компьютерного зрения и передовые алгоритмы обработки данных. Ключевое преимущество решения – достижение высокой точности обнаружения дефектов (91,2%) благодаря использованию усовершенствованной модели YOLOv12, специально адаптированной к российским дорожным условиям. Особенность системы – применение гибридной архитектуры, где критически важные вычисления выполняются в оптимизированном монолитном модуле, а остальные задачи распределены между микросервисами. Это обеспечивает как высокую производительность, так и масштабируемость решения. Важным достижением стала разработка специализированного генетического алгоритма для пространственной кластеризации дефектов, который учитывает не только географическое расположение повреждений, но и их плотность, что существенно повышает точность формирования ремонтных зон по сравнению с традиционными методами. Система автоматически анализирует выявленные дефекты по нормативам ГОСТ и формирует обоснованные рекомендации по видам ремонта, что исключает субъективность оценок. Практическая ценность решения подтверждена значительным сокращением времени обследования (с 4 ч до 20–25 мин на 1 км дороги) и снижением затрат на мониторинг на 58–62 %. Полученные результаты демонстрируют готовность системы к интеграции в существующие процессы управления дорожной инфраструктурой и ее потенциал для повышения эффективности обслуживания дорожной сети.

Список литературы

- ГОСТ Р 50597-2017. Автомобильные дороги и улицы. Требования к эксплуатационному состоянию. М.: Стандартинформ, 2017. 21 с.
- СП 78.13330.2012. Автомобильные дороги. Актуализированная редакция СНиП 3.06.03-85. М.: Минрегион России, 2012. 89 с.
- Liling L., Sharad S., Gongzhu H. Analysis of road traffic fatal accidents using data mining techniques // 2017 IEEE 15th International Conference on Software Engineering Research, Management and Applications (SERAM). London. 2017. P. 363–370. DOI: 10.1109/SERAM.2017.7965753.
- Аналитические обзоры состояния безопасности дорожного движения // Официальный сайт Министерства внутренних дел Российской Федерации. [Электронный ресурс]. URL: <https://ицбдд.мвд.рф/ресурсы/аналитические-обзоры-состояния-безопасно> (дата обращения: 20.07.2025).
- Приказ Министерства транспорта Российской Федерации от 07 августа 2020 г. № 288 «О Порядке проведения оценки технического состояния автомобильных дорог» [Электронный ресурс]. URL: <http://www.publication.pravo.gov.ru/Document/View/0001202011200072> (дата обращения: 20.07.2025).
- Wang W. Achieving Business Scalability with Composable Enterprise Architecture // in IEEE Access. 2025. Vol. 13. P. 76464–76472. DOI: 10.1109/ACCESS.2025.3564710.
- Oumoussa I., Saidi R. Evolution of Microservices Identification in Monolith Decomposition: A Systematic Review // in IEEE Access. 2024. Vol. 12. P. 23389–23405. DOI: 10.1109/ACCESS.2024.3365079.
- Makris A., Kontopoulos I., Psomakelis E., Xyalis S.N., Theodoropoulos T., Tserpes K. Performance Analysis of Storage Systems in Edge Computing Infrastructures // Applied Sciences (Switzerland). 2022. Vol. 12. Is. 17. P. 8923. DOI: 10.3390/app12178923.
- Китов В.В. Обнаружение объектов: YOLO // Deep Machine Learning. [Электронный ресурс]. URL: <https://deep-machinelearning.ru/docs/Neural-networks/Object-detection/YOLO> (дата обращения: 05.08.2025).
- Wang C., Bochkovskiy A., Liao H. YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors // 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver, BC, Canada. 2023. P. 7464–7475. DOI: 10.1109/CVPR52729.2023.00721.
- TensorRT Ecosystem Documentation // NVIDIA. Developer. URL: <https://developer.nvidia.com/tensorrt> (дата обращения: 05.08.2025).
- Krishnamoorthi R. Quantizing Deep Convolutional Networks for Efficient Inference: A Whitepaper // arXiv. 2018. P. 36. DOI: 10.48550/arXiv.1806.08342.
- ONNX Runtime. Optimization Techniques // Cross-platform inference and training machine-learning accelerator. URL: <https://onnxruntime.ai/docs/performance> (дата обращения: 20.07.2025).
- Kiselev S.A., Podberezkin A.A., Borzenkov A.M., Ostroukh A.V., Pronin C.B. Dynamic Pricing in Air Cargo: Machine Learning and Genetic Algorithm-Based Optimization // 2025 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF). St. Petersburg. 2025. P. 1–5. DOI: 10.1109/WECONF5186.2025.11017136.
- Borzenkov A.M., Ostroukh A.V., Pronin C.B., Podberezkin A.A., Kuftinova N.G. Multi-Criteria Analysis of Genetic Algorithm Applications in Transportation Logistics // 2024 Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED). Moscow. 2024. P. 1–4. DOI: 10.1109/TIRVED63561.2024.10769798.
- Akopov A.S. MBHGA: A Matrix-Based Hybrid Genetic Algorithm for Solving an Agent-Based Model of Controlled Trade Interactions // in IEEE Access. 2025. Vol. 13. P. 26843–26863. DOI: 10.1109/ACCESS.2025.3539460.

Конфликт интересов: Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest: The authors declare that there is no conflict of interest.