

УДК 004.89

DOI: [10.26102/2310-6018/2026.55.4.011](https://doi.org/10.26102/2310-6018/2026.55.4.011)

Алгоритм автоматической идентификации транспорта экстренных служб

Т.Э. Шульга, А.И. Либерман, А.А. Фадеева✉, Т.А. Костюкевич

*Саратовский государственный технический университет имени Гагарина Ю.А.,
Саратов, Российская Федерация*

Резюме. Актуальность исследования обусловлена необходимостью обеспечения оперативного доступа транспортных средств экстренных служб на территорию охраняемых объектов, доступ к которым в условиях современной городской среды часто ограничен шлагбаумами и другими физическими барьерами, управляемыми автоматически. Данная проблема может быть решена за счет внедрения интеллектуальных систем идентификации транспорта экстренных служб. В связи с этим, данная статья направлена на разработку алгоритма автоматической идентификации транспорта экстренных служб по изображению. Идея предлагаемого алгоритма основывается на совместном использовании искусственной нейронной сети и онтологической модели знаний о транспорте экстренных служб. Онтология разработана с использованием редактора Protégé и языка OWL на основе анализа открытых данных о классификации и оснащении экстренных служб. В качестве основы искусственной нейронной сети выбрана архитектура YOLOv8, обученная на расширенном наборе данных Roboflow. Результаты экспериментального исследования подтвердили высокую эффективность предложенной модели, достигшую точности 89 %, что свидетельствует о ее практической применимости для решения целевой задачи. Разработанный алгоритм может быть интегрирован в интеллектуальные системы управления доступом на территориях жилых комплексов и коммерческих объектов, способствуя тем самым повышению уровня безопасности и оптимизации сервисного обслуживания.

Ключевые слова: OWL-онтология, семантическая модель, искусственная нейронная сеть, алгоритм распознавания изображений, транспорт экстренных служб.

Для цитирования: Шульга Т.Э., Либерман А.И., Фадеева А.А., Костюкевич Т.А. Алгоритм автоматической идентификации транспорта экстренных служб. *Моделирование, оптимизация и информационные технологии*. 2026;14(4). URL: <https://moitvvt.ru/ru/journal/article?id=2234> DOI: 10.26102/2310-6018/2026.55.4.011

Algorithm for automatic identification of emergency service vehicles

T.E. Shulga, A.I. Liberman, A.A. Fadeeva✉, T.A. Kostyukevich

Yuri Gagarin State Technical University of Saratov, Saratov, the Russian Federation

Abstract. The relevance of this research is determined by the need to ensure rapid access for emergency service vehicles to the territory of secured facilities, whose access in the modern urban environment is often restricted by automatically controlled barriers and other physical obstacles. This issue can be addressed by implementing intelligent identification systems for emergency service vehicles. Consequently, this paper aims to develop an algorithm for the automatic identification of emergency service vehicles based on images. The core idea of the proposed algorithm relies on the combined use of an artificial neural network and an ontological knowledge model of emergency service vehicles. The ontology was developed using the Protégé editor and the OWL language, based on an analysis of open data concerning the classification and equipment of emergency services. The YOLOv8 architecture, trained on an extended Roboflow dataset, was chosen as the foundation for the an artificial neural network. The results of the experimental study confirmed the high efficiency of the proposed model,

achieving an accuracy of 89 %, which indicates its practical applicability for solving the target task. The developed algorithm can be integrated into intelligent access control systems for residential complexes and commercial facilities, thereby contributing to an increased level of safety and optimized service delivery.

Keywords: OWL ontology, semantic model, artificial neural network, image recognition algorithm, emergency service vehicles.

For citation: Shulga T.E., Liberman A.I., Fadeeva A.A., Kostyukevich T.A. Algorithm for automatic identification of emergency service vehicles. *Modeling, Optimization and Information Technology*. 2026;14(4). (In Russ.). URL: <https://moitvivr.ru/ru/journal/article?id=2234> DOI: 10.26102/2310-6018/2026.55.4.011

Введение

Контроль и ограничение доступа транспортных средств на территорию охраняемых объектов является актуальной задачей [1]. Широко применяемые в городской инфраструктуре шлагбаумы и иные физические барьеры могут приводить к задержкам автомобилей экстренных служб, прибывающих на место происшествия. В связи с этим требуется разработка интеллектуальных методов классификации, способных оперативно распознавать такой специальный транспорт и обеспечивать ему приоритетный проезд.

В качестве решения данной проблемы могут быть предложены системы идентификации автотранспорта по государственному регистрационному знаку (например, [2]). Настоящая статья развивает этот подход и посвящена разработке алгоритма распознавания автомобилей экстренных служб по изображению. Работа алгоритма основана на совместном использовании искусственных нейронных сетей (ИНС), активно применяемых для решения задач распознавания, в том числе в области безопасности [3, 4], и онтологий, служащих для моделирования знаний в различных предметных областях [5, 6], включая классификацию наземных транспортных средств [7].

Предложенная в работе онтологическая модель знаний о транспорте экстренных служб разработана с использованием редактора Protégé и языка OWL на основе анализа открытых данных о классификации и оснащении экстренных служб. В качестве основы ИНС выбрана архитектура YOLOv8, обученная на расширенном наборе данных Roboflow.

Предлагаемый алгоритм применим для управления доступом в жилых массивах и на объектах коммерческой инфраструктуры, что способствует повышению уровня безопасности и качества предоставляемых услуг.

Материалы и методы

Разработка алгоритма автоматической идентификации транспорта экстренных служб потребовала анализа методов, способных объединить высокую точность распознавания образов с семантической интерпретацией результатов. Перспективным направлением был признан гибридный подход, интегрирующий искусственные нейронные сети и онтологии. Этот симбиоз позволяет преодолеть ограничения «черного ящика», свойственные ИНС, за счет использования онтологий в качестве формализованных словарей понятий и их взаимосвязей. Такие словари наделяют систему способностью «понимать» контекст и смысл распознанных объектов, что повышает точность и обоснованность обработки информации [8].

Согласно анализу литературы, использование онтологий в архитектуре интеллектуальных систем на основе ИНС дает ряд следующих методологических преимуществ [8, 9]:

- структурирование знаний: возможность создания, унификации и многократного использования логически организованных баз знаний;
- логический вывод: способность системы к рассуждению на основе формальных правил для принятия обоснованных решений и извлечения неявной информации;
- семантический поиск: обеспечение быстрого и содержательного поиска информации в данных и документах;
- интероперабельность: применение общей, четко определенной терминологии для интеграции разрозненных данных и модулей системы;
- интерпретируемость: наглядное представление сложных взаимосвязей и предоставление результатов в форме, пригодной для машинной и человеческой интерпретации;
- актуальность данных: поддержка оперативного обновления знаний в режиме, близком к реальному времени.

Таким образом, онтологии формируют смысловой каркас, который не только обогащает нейросетевые модели, но и приближает их к парадигме объяснимого искусственного интеллекта – ключевому требованию для ответственных приложений в медицине, безопасности и образовании [10, 11].

Следовательно, несмотря на необходимость тщательного проектирования онтологической модели, ее интеграция с ИНС открывает путь к созданию более робастных и гибких интеллектуальных систем распознавания, что и легло в основу предлагаемого в данной работе алгоритма.

Для выбора онтологии для решения задачи распознавания транспорта экстренных служб был проведен сравнительный анализ открытых онтологий наземного транспорта [12]. В результате установлено, что существующие онтологии не содержат знаний о структуре и характеристиках транспорта экстренных служб. Было принято решение о разработке специальной онтологии транспорта экстренных служб на базе OWL-онтологии наземного транспорта технологического института Toyota за счет добавления в нее классов, свойств и аксиом. Разработка проводилась в редакторе Protégé.

Для реализации модуля распознавания транспорта экстренных служб была выбрана архитектура искусственной нейронной сети YOLO, доказавшая свою эффективность в задачах детектирования объектов в реальном времени благодаря высокой скорости работы и точности [13].

На основе сравнительного анализа, проведенного в исследовании [14], была выбрана версия YOLOv8. Эта модель включает такие инновационные архитектурные решения, как anchor-free механизм и decoupled head, что повышает надежность и точность детектирования. Указанные усовершенствования способствуют более точной локализации объектов различных размеров и форм, повышая общую производительность модели при снижении вычислительных затрат.

Входное изображение поступает в модель, где оно нормализуется и масштабируется до требуемого разрешения, что обеспечивает стандартизацию данных для последующей обработки. Затем изображение разбивается на сетку фиксированного размера, где каждая ячейка отвечает за детектирование объектов в соответствующей области. Размер сетки определяется архитектурой модели и разрешением входного изображения.

Для каждой ячейки сетки модель прогнозирует наличие объектов, вычисляя вероятность их присутствия и параметры ограничивающей рамки (bounding box). К этим параметрам относятся координаты центра рамки, ее ширина и высота, а также оценка уверенности (confidence score) в обнаружении объекта.

После выделения областей с потенциальными объектами модель выполняет их классификацию, присваивая каждому объекту один из заданных классов. В рассматриваемой задаче такими классами могут быть, например, «Транспорт принадлежит службам экстренной помощи» (y1) и «Транспорт не принадлежит службам экстренной помощи» (y2). Процесс классификации осуществляется с помощью сверточных и полносвязных слоев, которые анализируют признаки объекта и сопоставляют их с признаками, извлеченными в процессе обучения.

Результаты

Разработка онтологии транспорта экстренных служб. Предлагаемая онтологическая модель (Рисунок 1) включает два базовых концепта: EmergencyServiceType (Тип экстренной службы) и EmergencyEquipment (Оборудование экстренной службы). Для установления семантических связей между ними определены объектные свойства: hasEmergencyEquipment (имеет оборудование) и hasEmergencyServiceType (относится к типу службы).

Иерархия класса EmergencyServiceType состоит из следующих подклассов: Ambulance (Скорая помощь), FireTruck (Пожарная машина), PoliceCar (Полицейский автомобиль), OtherEmergencyServiceTransport (Прочий транспорт экстренных служб).

Класс EmergencyEquipment содержит подклассы, описывающие специализированное оснащение: Cistern (Цистерна), Hose (Рукав), FlashingLight (Проблесковый маячок), ExternalLogo (Внешний логотип), Nozzle (Сопло/брандспойт), Ladder (Лестница).

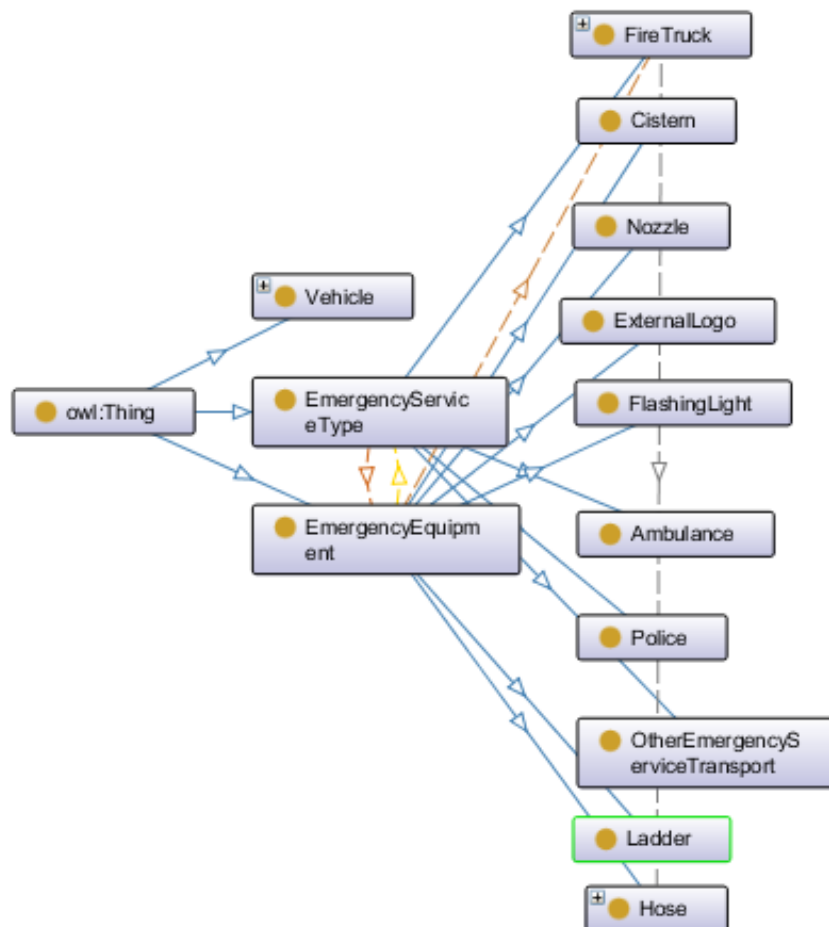


Рисунок 1 – Схема разработанной онтологии
 Figure 1 – Scheme of the developed ontology

В Таблице 1 представлено описание введенных объектных свойств.

Таблица 1 – Объектные свойства онтологии
Table 1 – Object properties of the ontology

Объектное свойство	Описание свойства объекта	Область определения свойств (domain)	Область значения свойств (range)
hasEmergencyEquipment (имеет оборудование)	Связывает тип службы с типичным для неё оборудованием	EmergencyServiceType	EmergencyEquipment
hasEmergencyServiceType (относится к экстренной службе)	Указывает, для транспорта какой службы предназначено оборудование (обратное свойство)	EmergencyEquipment	EmergencyServiceType

Семантика свойств позволяет осуществлять логический вывод. Например, если установлено, что транспортное средство обладает оборудованием Hose (Рукав), система может вывести его принадлежность к классу FireTruck (Пожарная машина).

Подготовка набора данных и обучение модели. В качестве исходного набора данных использовался датасет Roboflow¹, как наиболее релевантный, поскольку он содержит множество классов транспорта экстренных служб и их оборудования, включает аннотации в формате ограничивающих рамок (bounding boxes) и, что особенно важно, представлены изображения российских служб. Для повышения полноты данных набор был дополнен фотографиями автомобилей аварийной газовой службы и МЧС, а оборудование на изображениях размечено с помощью инструмента LabelImg. Итоговый набор данных содержал 2500 изображений.

В рамках подготовки к обучению исходный набор данных был разделен на три независимые части в стандартной для машинного обучения пропорции: обучающая выборка (70 %), валидационная выборка (15 %) и тестовая выборка (15 %). Процесс оптимизации длился 500 эпох. Для финальной оценки была выбрана модель с весами, показавшими наилучшую эффективность на валидационном наборе.

Динамика ключевых показателей в ходе обучения представлена на Рисунке 2. Для наглядности по оси абсцисс отложены эпохи, что дает возможность наблюдать траекторию изменения параметров, а по оси ординат – абсолютные значения соответствующих функций потерь (loss) и метрик качества.

Использовалась следующая интерпретация функций потерь.

Box Loss служит мерой ошибки регрессии координат ограничивающих рамок, отражая расхождение между предсказанным и истинным положением объектов. Монотонное убывание этой кривой указывает на улучшение точности локализации детектируемых объектов.

Classification Loss (cls_loss) количественно оценивает ошибку в определении принадлежности объекта к классу. Снижение данного показателя свидетельствует о повышении качества классификации внутри обнаруженных областей.

¹ Computer Vision Datasets. Roboflow. URL: <https://public.roboflow.com/> (дата обращения: 06.02.2026).




Рисунок 2 – Динамика метрик в процессе обучения модели
 Figure 2 – Training metrics dynamics

Distribution Focal Loss (df_loss) представляет собой специализированный тип потерь, сконструированный для компенсации дисбаланса классов в данных. Его механизм направлен на перераспределение внимания модели с простых примеров на сложные, что повышает устойчивость обучения, особенно для редких категорий.

Использовалась следующая интерпретация метрик качества.

Точность (Precision) определяется как доля истинно обнаруженных объектов среди всех случаев, классифицированных моделью как целевой класс. Высокое значение этой метрики минимизирует количество ложноположительных срабатываний.

Полнота (Recall) характеризует способность модели детектировать все экземпляры целевого класса в наборе данных. Высокая полнота является индикатором низкого уровня ложноотрицательных результатов.

Анализ кривых на Рисунке 2 показывает стабильный и сходящийся процесс обучения. Все графики демонстрируют плавную монотонную динамику: функции потерь устойчиво снижаются, а ключевые метрики качества последовательно растут, не проявляя признаков значительных колебаний. Такое поведение является надежным индикатором корректной настройки гиперпараметров и отсутствия нестабильности.

Более того, наблюдаемая картина – последовательное снижение потерь при одновременном росте и стабилизации precision и recall на валидационной выборке – позволяет сделать вывод об эффективном обучении модели без симптомов переобучения или недообучения. Переобучение, как правило, проявляется в расхождении кривых на обучающей и валидационной выборках, когда потери на обучении продолжают падать, а обобщающая способность (метрики на валидации) ухудшается. Недообучение характеризуется высокими значениями функции потерь и низкими показателями метрик на обеих выборках, что указывает на недостаточную емкость модели или неоптимальный процесс оптимизации. В данном случае данные признаки отсутствуют.

На основе анализа представленных графиков можно сделать вывод об успешном обучении модели.

Для визуализации и анализа результатов были использованы тестовые изображения, на которых выполнено сравнение предсказанных и реальных ограничивающих рамок объектов (Рисунок 3). Это позволило наглядно оценить точность распознавания и локализации объектов моделью, что важно для понимания ее эффективности в реальных условиях. В результате работы на тестовых данных модель достигла значения метрики precision (точность), равного 89 %.



Рисунок 3 – Оценка точности обученной модели
 Figure 3 – Accuracy evaluation of the trained model

Алгоритм идентификации транспорта экстренной службы. Предлагаемый алгоритм реализует гибридный подход, объединяя детектирование объектов с помощью обученной модели YOLOv8 и их семантическую верификацию на основе разработанной онтологии. Алгоритм работы системы представлен на Рисунке 4.

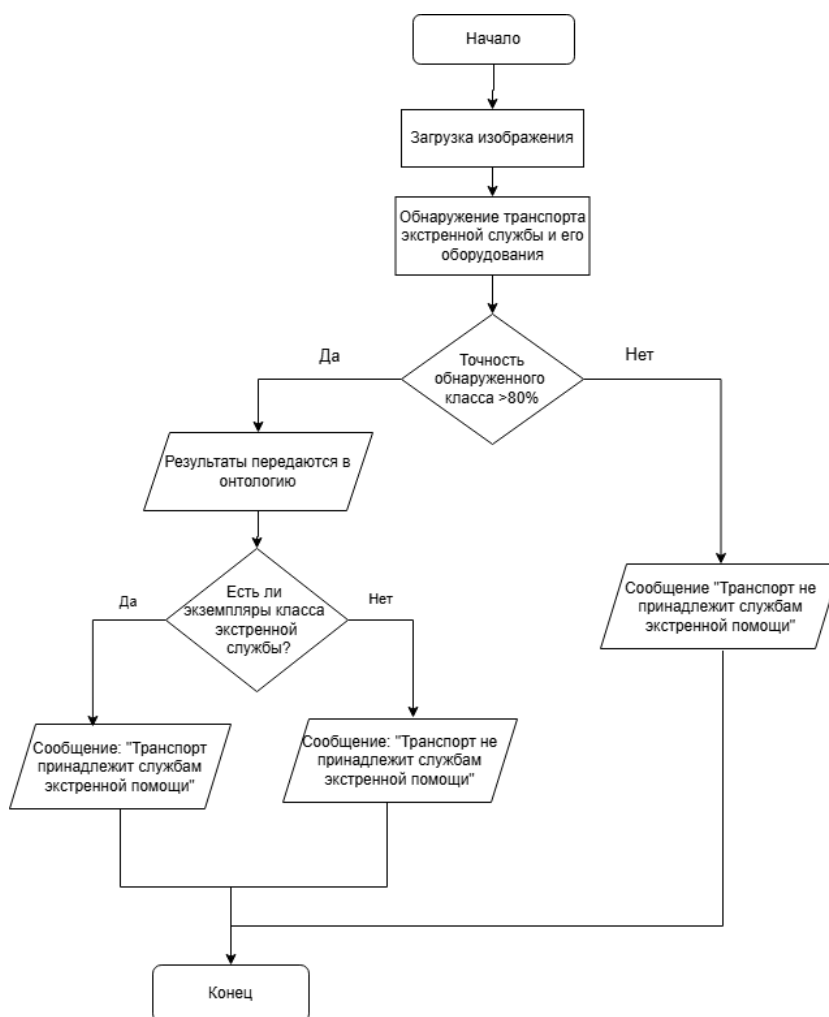


Рисунок 4 – Алгоритм классификации транспорта
 Figure 4 – Vehicle classification algorithm

Алгоритм включает следующие шаги.

1. *Ввод данных.* На вход системы поступают изображения с камер видеонаблюдения или других источников в цифровом формате.

2. *Детектирование объектов.* Модель YOLOv8 выполняет первичную идентификацию транспортного средства и его видимого оборудования (проблескового маячка, брандспойта, рукава и т. д.).

3. *Фильтрация по уверенности.* Для каждого обнаруженного класса (транспорт, оборудование) проверяется, превышает ли уверенность модели заданный порог (например, 80 %). Если уверенность для основного класса (типа транспорта) ниже порога, транспортное средство считается не относящимся к экстренным службам, и обработка прекращается.

4. *Интеграция с онтологией.* При успешном прохождении фильтрации в онтологической модели создается экземпляр транспортного средства. На основе предсказанных классов оборудования с помощью объектных свойств (таких как `hasEmergencyEquipment`) он связывается с соответствующим классом службы (например, `FireTruck`).

5. *Логический вывод.* Запускается процедура логического вывода (`reasoning`) на основе правил и свойств, заложенных в онтологии. Это позволяет проверить семантическую согласованность данных (например, соответствует ли обнаруженное оборудование заявленному типу службы) и сделать дополнительные выводы.

6. *Принятие решения.* На основании результатов логического вывода система принимает финальное решение. Если семантические проверки пройдены, доступ для транспортного средства разрешается. В противном случае оно классифицируется как постороннее.

Таким образом, система последовательно комбинирует скоростное детектирование средствами нейронной сети и содержательную проверку с использованием онтологии, что повышает надежность идентификации.

Заключение

В данной работе разработана OWL-онтология, систематизирующая знания о транспортных средствах экстренных служб и их специализированном оснащении. Онтология формирует семантический каркас, определяющий связи между классами объектов и их свойствами, что обеспечивает основу для логического вывода.

Параллельно была выбрана и обучена модель детектирования объектов YOLOv8. Экспериментальные результаты продемонстрировали высокую точность модели 89 %, что подтверждает ее практическую пригодность для решения поставленной задачи.

Интеграция онтологического подхода с нейросетевой моделью позволила разработать гибридный алгоритм идентификации. Реализация данного алгоритма в интеллектуальной системе идентификации транспорта будет способствовать минимизации задержек для спецтранспорта, обеспечивая его приоритетный проезд и тем самым повышая оперативность реагирования в чрезвычайных ситуациях и общий уровень дорожной безопасности.

Перспективным направлением дальнейших исследований является интеграция разработанного модуля визуальной идентификации с системами распознавания по государственному регистрационному знаку для создания комплексной системы контроля доступа.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Колоденкова А.Е. Автоматизация процесса контроля и управления доступом транспортных средств на территорию образовательной организации. *Вестник Ростовского государственного университета путей сообщения*. 2025;(2):28–34. Kolodenkova A.E. Automation of the process of control and management of vehicle access to the territory of an educational organization. *Vestnik Rostovskogo Gosudarstvennogo Universiteta Putej Soobshcheniya*. 2025;(2):28–34. (In Russ.).
2. Мещеряков Е.В., Филатова М.В. Автоматизированная система подбора парковочных мест. *Научный аспект*. 2024;50(6):6443–6448.
3. Ключев С.Г., Трунов Е.Е. Проблемы обучения глубоких нейронных сетей для обнаружения угроз нарушения безопасности в сетях с динамической топологией. *Моделирование, оптимизация и информационные технологии*. 2021;9(1). <https://doi.org/10.26102/2310-6018/2021.32.1.012>
Klyuev S.G., Trunov E.E. Deep neural networks training problems of detecting security threats in networks with dynamic topology. *Modeling, Optimization and Information Technology*. 2021;9(1). (In Russ.). <https://doi.org/10.26102/2310-6018/2021.32.1.012>
4. Соболевская Е.Ю., Шевченко И.Д., Алексеев С.Е. Алгоритм формирования базы уязвимостей и выбор архитектуры нейронной сети для их обработки. *Моделирование, оптимизация и информационные технологии*. 2022;10(3). <https://doi.org/10.26102/2310-6018/2022.38.3.025>
Sobolevskaya E.Y., Shevchenko I.D., Alekseev S.E. Vulnerability base formation algorithm and neural network architecture selection for its processing. *Modeling, Optimization and Information Technology*. 2022;10(3). (In Russ.). <https://doi.org/10.26102/2310-6018/2022.38.3.025>
5. Клименко А.Б., Баринов А.А. Метод управления вычислительными ресурсами распределенных систем на основе «жадной» стратегии и онтологии эффективных алгоритмов. *Моделирование, оптимизация и информационные технологии*. 2024;12(1). <https://doi.org/10.26102/2310-6018/2024.44.1.018>
Klimenko A.B., Barinov A.A. Distributed computing resource management method based on greedy strategy and efficient algorithms ontology. *Modeling, Optimization and Information Technology*. 2024;12(1). (In Russ.). <https://doi.org/10.26102/2310-6018/2024.44.1.018>
6. Потравнова А.А., Солопекин Д.А. Разработка и наполнение прототипа онтологии дорожных знаков РФ. В сборнике: *Проблемы управления в социально-экономических и технических системах: Материалы XIX Международной научно-практической конференции, 13–14 апреля 2023 года, Саратов, Россия*. Саратов: Наука; 2023. С. 415–418.
7. Либерман А.И., Шульга Т.Э. Онтологическая модель «военная наземная техника». *Известия высших учебных заведений. Поволжский регион. Технические науки*. 2023;(1):64–74. <https://doi.org/10.21685/2072-3059-2023-1-5>
Liberman A.I., Shul'ga T.E. "Military ground equipment" ontological model. *University proceedings. Volga region. Engineering sciences*. 2023;(1):64–74. (In Russ.). <https://doi.org/10.21685/2072-3059-2023-1-5>
8. Еркимбаев А.О., Зицерман В.Ю., Кобзев Г.А. Современные возможности совместного применения онтологий и методов машинного обучения для работы с данными. *Научно-техническая информация. Серия 1: Организация и методика информационной работы*. 2025;(10):10–27.

- Erkimbaev A.O., Zitserman V.Yu., Kobzev G.A. Modern possibilities of joint application of ontologies and machine learning for working with data. *Scientific and Technical Information Processing*. 2025;(10):10–27. (In Russ.).
9. Шилов Н.Г., Пономарев А.В., Смирнов А.В. Анализ методов онтолого-ориентированного нейро-символического интеллекта при коллаборативной поддержке принятия решений. *Информатика и автоматизация*. 2023;22(3):576–615. <https://doi.org/10.15622/ia.22.3.4>
Shilov N., Ponomarev A., Smirnov A. The Analysis of Ontology-Based Neuro-Symbolic Intelligence Methods for Collaborative Decision Support. *Informatics and Automation*. 2023;22(3):576–615. (In Russ.). <https://doi.org/10.15622/ia.22.3.4>
10. Карпов О.Э., Андриков Д.А., Максименко В.А., Храмов А.Е. Прозрачный искусственный интеллект для медицины. *Врач и информационные технологии*. 2022;(2):4–11. https://doi.org/10.25881/18110193_2022_2_4
Karpov O.E., Andrikov D.A., Maksimenko V.A., Hramov A.E. Explainable artificial intelligence for medicine. *Medical doctor and IT*. 2022;(2):4–11. (In Russ.). https://doi.org/10.25881/18110193_2022_2_4
11. Захарова И.Г., Воробьева М.С., Боганюк Ю.В. Сопровождение индивидуальных образовательных траекторий на основе концепции объяснимого искусственного интеллекта. *Образование и наука*. 2022;24(1):163–190. <https://doi.org/10.17853/1994-5639-2022-1-163-190>
Zakharova I.G., Vorobeva M.S., Boganyuk Yu.V. Support of individual educational trajectories based on the concept of explainable artificial intelligence. *The Education and science journal*. 2022;24(1):163–190. (In Russ.). <https://doi.org/10.17853/1994-5639-2022-1-163-190>
12. Костюкевич Т.А., Либерман А.И. Сравнительный анализ онтологий наземного транспорта. В сборнике: *Проблемы управления в социально-экономических и технических системах: Материалы XX Международной научно-практической конференции, 17–18 апреля 2024 года, Саратов, Россия*. Саратов: Наука; 2024. С. 65–67.
13. Бобырь М.В., Храпова Н.И. Информационно-аналитическая система детектирования движения объектов на пешеходном переходе. *Онтология проектирования*. 2024;14(4):531–541. <https://doi.org/10.18287/2223-9537-2024-14-4-531-541>
Bobyry M.V., Khrapova N.I. Information and analytical system for detecting the movement of objects on a pedestrian crossing. *Ontology of Designing*. 2024;14(4):531–541. (In Russ.). <https://doi.org/10.18287/2223-9537-2024-14-4-531-541>
14. Terven J.R., Cordova-Esparaza D.M. *A comprehensive review of YOLO: From YOLOv1 to YOLOv8 and beyond*. arXiv. URL: <https://arxiv.org/pdf/2304.00501v1> [Accessed 6th February 2026].

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Шульга Татьяна Эриковна, доктор физико-математических наук, профессор, Саратовский государственный технический университет имени Гагарина Ю.А., Саратов, Российская Федерация.
e-mail: taiss@yandex.ru
ORCID: [0000-0002-5521-5960](https://orcid.org/0000-0002-5521-5960)

Tatiana E. Shulga, Doctor of Physical and Mathematical Sciences, Professor, Yuri Gagarin State Technical University of Saratov, Saratov, the Russian Federation.

Либерман Алена Ивановна, старший преподаватель, Саратовский государственный технический университет имени Гагарина Ю.А., Саратов, Российская Федерация.

e-mail: libermanai@ro.ru

ORCID: [0009-0002-9887-9473](https://orcid.org/0009-0002-9887-9473)

Alena I. Liberman, Senior Lecturer, Yuri Gagarin State Technical University of Saratov, Saratov, the Russian Federation.

Фадеева Анна Александровна, аспирант, Саратовский государственный технический университет имени Гагарина Ю.А., Саратов, Российская Федерация.

e-mail: haninaa@mail.ru

ORCID: [0009-0006-7646-9122](https://orcid.org/0009-0006-7646-9122)

Anna A. Fadeeva, Postgraduate, Yuri Gagarin State Technical University of Saratov, Saratov, the Russian Federation.

Костюкевич Татьяна Алексеевна, студент, Саратовский государственный технический университет имени Гагарина Ю.А., Саратов, Российская Федерация.

e-mail: tanya.kostyukevich.02@mail.ru

ORCID: [0009-0009-5624-8754](https://orcid.org/0009-0009-5624-8754)

Tatiana A. Kostyukevich, Student, Yuri Gagarin State Technical University of Saratov, Saratov, the Russian Federation.

Статья поступила в редакцию 27.02.2026; одобрена после рецензирования 13.04.2026; принята к публикации 21.04.2026.

The article was submitted 27.02.2026; approved after reviewing 13.04.2026; accepted for publication 21.04.2026.