

УДК 528.854

DOI: [10.26102/2310-6018/2025.51.4.002](https://doi.org/10.26102/2310-6018/2025.51.4.002)

## Повышение качества обучения сверточных нейронных сетей в задачах технического зрения беспилотных поездов

В.А. Федоров, О.М. Огородникова✉

*Уральский федеральный университет имени первого Президента России Б.Н. Ельцина,  
Екатеринбург, Российская Федерация*

**Резюме.** Беспилотные поезда являются ключевым составным элементом следующего уровня автоматизации железных дорог. Запуск локомотивов в беспилотном режиме требует разработки надежных систем технического зрения с применением технологий искусственного интеллекта. В статье представлен метод повышения качества обучения сверточных нейронных сетей в задачах обнаружения объектов железнодорожной инфраструктуры. Достоверность визуального обнаружения объектов системой компьютерного зрения достигается за счет алгоритмического расширения наборов данных для обучения. Предложенный метод учитывает вариативность погодных условий, в которых необходимо обнаружить идентичные объекты, и позволяет генерировать модификации изображений с добавлением эффектов дождя, снега или тумана. В качестве исходного набора данных использовано 21700 аннотированных изображений, содержащих 7 классов объектов. На их основе сформирован расширенный набор из 65100 изображений с использованием разработанного метода. Для оценки эффективности предложенного подхода проведено сравнительное обучение современной модели YOLOv11 на исходном и расширенном наборах данных. Для сравнения результатов использованы метрики F1-меры и mean Average Precision (mAP). Результаты вычислительных экспериментов подтверждают, что применение расширенного набора данных способствует улучшению качества обучения. В частности, F1-мера для модели YOLO, обученной на исходном наборе данных, составила 0,72, тогда как на расширенном наборе данный параметр достиг повышенного значения 0,90. Значение второй использованной метрики mAP (50–95) увеличилось с 0,67 на исходном наборе данных до 0,83 на расширенном. Сравнительные значения метрик были получены при одинаковом пороге достоверности 0,8. Разработанный метод реализован в аппаратно-программном комплексе, который готов к тестовым испытаниям в составе комплексной системы управления и обеспечения безопасности движения грузовых поездов.

**Ключевые слова:** техническое зрение, машинное обучение, сверточные нейронные сети, YOLOv11, автоматизация железнодорожного транспорта, беспилотный транспорт.

**Для цитирования:** Федоров В.А., Огородникова О.М. Повышение качества обучения сверточных нейронных сетей в задачах технического зрения беспилотных поездов. *Моделирование, оптимизация и информационные технологии.* 2025;13(4). URL: <https://moitvivr.ru/ru/journal/pdf?id=2028> DOI: 10.26102/2310-6018/2025.51.4.002

## Improving the quality of convolutional neural networks learning in the tasks of machine vision of unmanned trains

V.A. Fedorov, O.M. Ogorodnikova✉

*Ural Federal University named after the first President of Russia B.N. Yeltsin,  
Yekaterinburg, the Russian Federation*

**Abstract.** Unmanned trains are a key component of the next level of railway automation. Launching locomotives in unmanned mode requires the development of reliable computer vision systems using artificial intelligence technologies. The paper presents a method for improving the quality of learning convolutional neural networks for detecting railway infrastructure objects. The reliability of visual

object detection by a computer vision system can be achieved through algorithmic expansion of training datasets. The proposed method takes into account the variability of weather conditions in which identical objects must be detected, and it allows generating image modifications with added effects of rain, snow or fog. The original dataset included 21700 annotated images and contained 7 classes of objects. Based on them, an extended set of 65100 images was formed using the developed method. To evaluate the effectiveness of the proposed approach, comparative learning of the advanced YOLOv11 model was carried out on the original and extended datasets. The F1-measure and mean average precision (mAP) metrics were used to compare the learning results. The results of the computational experiments confirm that using the extended dataset improves the quality of learning. In particular, the F1-measure for the YOLO model trained on the original dataset was 0.72, while on the extended dataset this parameter reached an increased value of 0.90. The value of the second used metric mAP (50–95) increased from 0.67 on the original dataset to 0.83 on the extended dataset. Comparative values of the metrics were obtained at the same confidence threshold of 0.8. The developed method has been implemented in a hardware and software system, which is ready for testing as part of an integrated control and safety system for freight trains.

**Keywords:** machine vision, machine learning, convolutional neural networks, YOLOv11, rail transport automation, unmanned transport.

**For citation:** Fedorov V.A., Ogorodnikova O.M. Improving the quality of convolutional neural networks learning in the tasks of machine vision of unmanned trains. *Modeling, Optimization and Information Technology*. 2025;13(4). (In Russ.). URL: <https://moitvvt.ru/ru/journal/pdf?id=2028> DOI: 10.26102/2310-6018/2025.51.4.002

## Введение

Актуальность темы исследования определяется быстрым развитием и широким применением систем технического зрения на основе искусственного интеллекта в различных отраслях промышленности, включая железнодорожный транспорт [1]. Интеллектуализация технического зрения активно развивается в связи с проблемой повышения уровня автоматизации и производительности железнодорожных перевозок [2]. Одной из ключевых и нерешенных задач в этой области является достоверное обнаружение объектов железнодорожной инфраструктуры [3]. Быстрая оценка окружающей среды автоматизированной системой управления способствует повышению безопасности движения благодаря снижению рисков, связанных с человеческим фактором. Однако решение обозначенной задачи напрямую связано с преодолением ряда сложностей, таких как визуальное разнообразие инфраструктурных объектов, изменение освещенности и погодных условий, а также с необходимостью организации автоматической оценки в режиме реального времени [4].

Сверточные нейронные сети становятся ведущим инструментом в решении задач обнаружения объектов системами технического зрения благодаря их способности автоматически извлекать признаки и обеспечивать высокую точность [5]. Перспективной одноступенчатой архитектурой обладает модель сверточных нейронных сетей YOLO (You Only Look Once) [6], которая быстро и эффективно решает задачи классификации, детектирования и сегментации разномасштабных изображений [7]. Вместе с тем, достоверность результатов обработки визуальных данных техническим зрением во многом зависит от процедуры обучения сверточной нейронной сети, от качества и разнообразия обучающих данных [8]. В частности, недостаточное количество данных приводит к переобучению и снижению точности модели, ограничивая ее применимость в ответственных автоматизированных системах.

В приложениях беспилотного транспорта качество обучения сверточных нейронных сетей можно повысить за счет расширения наборов данных на этапе препроцессорной подготовки изображений [9].

Таким образом, проблема исследования в данной работе связана с недостаточной надежностью бортовых систем технического зрения в составе автоматизированной системы управления железнодорожным подвижным составом для реализации движения беспилотных поездов (АСУ ЖД ПС). Соответственно, цель исследования заключается в интеллектуализации технического зрения за счет применения сверточных нейронных сетей и их качественного обучения. Достижение поставленной цели требует решения задач исследования:

- 1) обосновать архитектуру сверточной нейронной сети;
- 2) разработать способ расширения обучающего набора данных с использованием фильтров генерации погодных эффектов;
- 3) исследовать влияние расширенного набора на точность обнаружения объектов железнодорожной инфраструктуры системой технического зрения.

### **Материалы и методы**

Объектом исследования в данной работе является система технического зрения собственной сборки для обнаружения объектов на изображениях видеопотока. Поскольку система предназначена для установки на локомотивах с перспективой перехода к беспилотному управлению поездами в рамках предельного уровня автоматизации GOA4 [1], обработка данных и обнаружение объектов ведется в режиме реального времени. Процедура обнаружения включает распознавание объектов и их локализацию в пространстве.

Общая схема исследования включает анализ архитектуры существующих нейронных сетей, разработку и обоснование оптимальной архитектуры с учетом решаемых задач АСУ ЖД ПС, составление обучающих наборов данных с расширенными возможностями глубокого обучения сверточной нейронной сети, апробацию разработанных средств и их анализ по показателям качества.

В работе для решения задач обнаружения объектов железнодорожной инфраструктуры использована исходная модель сверточной нейронной сети YOLOv11 версии n (nano) [10]. Для обучения модели был подготовлен первоначальный набор данных, состоящий из 21700 изображений с аннотированными объектами железнодорожной инфраструктуры. Источником данных послужили видеозаписи реальных поездов с камеры, установленной на локомотиве. Обучение модели производилось на видеокарте с графическим ускорителем NVIDIA RTX A5000, отличительной особенностью которой является большое количество тензорных ядер и достаточный объем видеопамяти (24 Гб).

### **Результаты**

**Анализ, разработка и обоснование архитектуры сверточной нейронной сети.** Архитектура YOLOv11 включает три основные части, получившие бионические названия: позвоночник (backbone), шея (neck) и голова (head). Архитектура YOLOv11 представлена на Рисунке 1, где стрелками показан маршрут передачи данных между слоями и блоками. Позвоночник отвечает за извлечение признаков из входного изображения на нескольких масштабных уровнях с использованием сверточных слоев. Шея объединяет и улучшает представления признаков, полученные на разных масштабах, с помощью специализированных слоев. Голова на выходе формирует окончательные результаты предиктивного анализа изображений, включая локализацию и классификацию объектов на основе уточненных карт признаков.

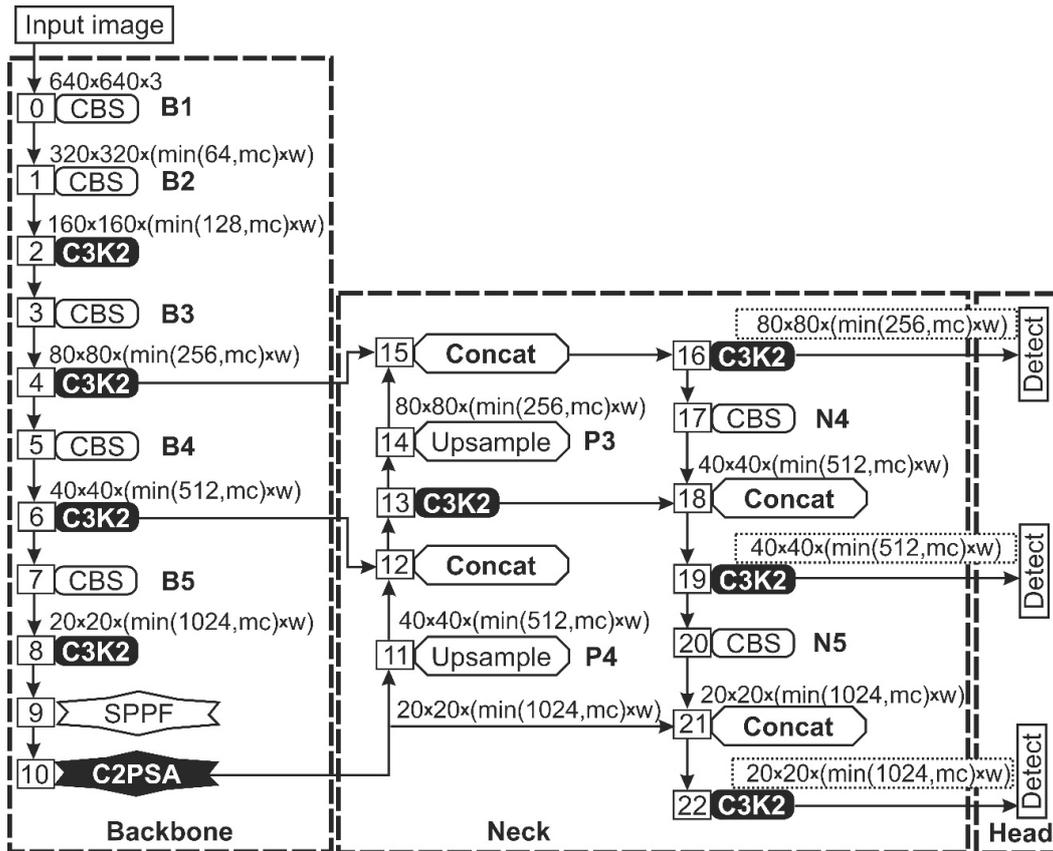


Рисунок 1 – Архитектура исходной модели YOLOv11  
Figure 1 – Architecture of the original YOLOv11 model

Исходная модель подробно изучена и далее подвергнута структурному улучшению с учетом специфики решаемых задач. Следует отметить, что Модель YOLOv11 положительно отличается от использованной нами ранее YOLOv8 [1]; архитектура YOLOv11 усовершенствована заменой блока C2f на блок C3K2 [11]. Новый блок C3K2 улучшает процесс агрегации признаков, обеспечивая более высокую скорость и производительность. В архитектуру также добавлен блок C2PSA, который улучшает пространственное внимание в картах признаков, позволяя модели более эффективно фокусироваться на важных областях изображения.

В данной работе на базе модели YOLOv11 разработана оригинальная облегченная версия нейронной сети, способная решать задачи компьютерного зрения с использованием ограниченных вычислительных ресурсов. Отличие разработанной архитектуры от стандартной заключается в следующем.

1. В блоке агрегации признаков SPPF применена функция активации ReLU, снижающая вычислительную сложность без снижения качества извлечения глобальных признаков. Предварительно блок свертки обрабатывает данные в двухмерном сверточном слое и двухмерном пакетном слое нормализации без вычисления сигмоиды.

2. Блок C2PSA заменен на блок CBAM (Convolutional Block Attention Module), который также снижает вычислительную сложность, но сохраняет фокусировку модели на значительных признаках. Подключенный блок структурно состоит из двух последовательных функций CBAM (Channel Attention Module) и SAM (Spatial Attention Module). Функция CBAM фокусируется на наиболее значимых каналах, выделяя семантически важные признаки. Функция SAM фокусируется на пространственных областях и акцентирует внимание на ключевых объектах изображения.

3. Введены оптимальные параметры масштабирования архитектуры  $d = 0,5$  (множитель глубины сети);  $w = 0,75$  (множитель ширины сети);  $mc = 512$  (максимальное количество каналов), которые не только снижают вычислительную сложность, но и повышают точность сегментации.

**Формирование набора данных для повышения качества обучения сверточных нейронных сетей.** Одним из малозатратных подходов к улучшению качества обучения сверточных нейронных сетей является расширение наборов данных с помощью генерации дополнительных изображений. Дополнительные изображения могут имитировать разнообразие внешних условий, изменяющих визуальное представление объектов. В данной работе к изображениям были применены фильтры с погодными эффектами. Такой подход позволяет модели адаптироваться к изменяющимся условиям наблюдения и повысить устойчивость применяемых алгоритмов к внешним факторам. Пример изображений из первоначального набора представлен на Рисунке 2.

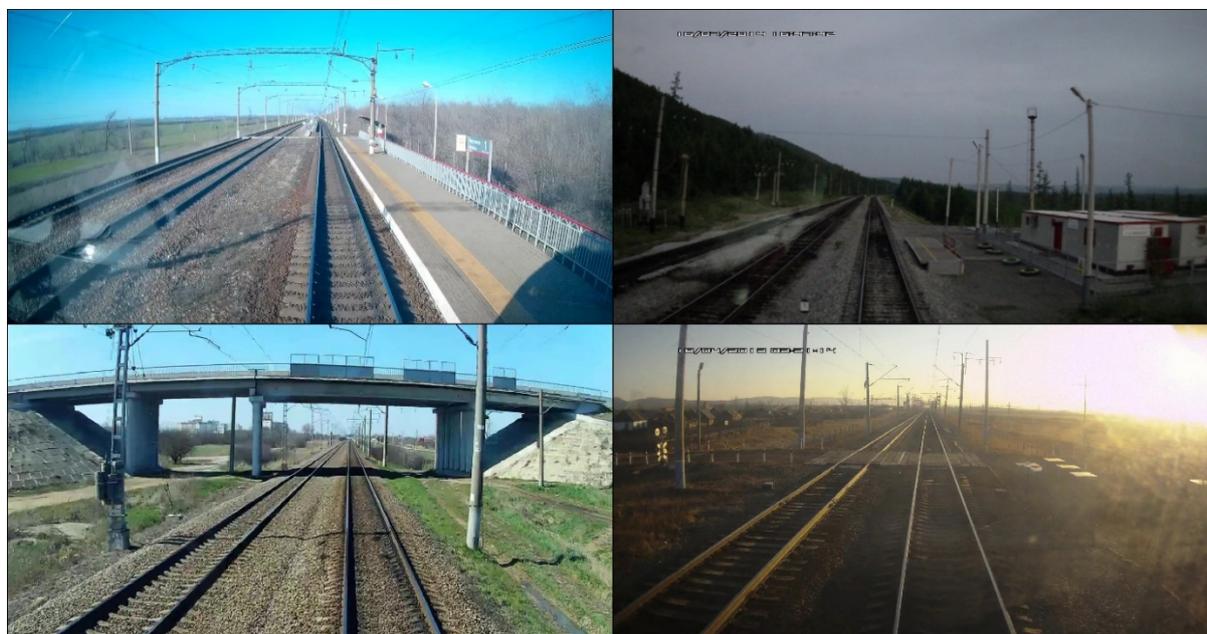


Рисунок 2 – Изображения из первоначального набора данных  
Figure 2 – Images from the original dataset

В наборе данных аннотировано для обнаружения 7 классов объектов: железнодорожная платформа, железнодорожный переезд, мост, путепровод, туннель, внутреннее строение туннеля и мачтовый светофор.

Далее на базе первоначального набора сформирован расширенный набор данных с дополнительными изображениями, в котором содержится 65100 изображений. Дополнительные данные получены путем генерации новых изображений с имитацией трех погодных эффектов (снег, дождь и туман) на основе исходных изображений.

Для моделирования погодных условий разработаны специализированные алгоритмы обработки данных, которые обеспечивают создание реалистичных визуальных эффектов. Каждый алгоритм включает генерацию маски, соответствующую размеру исходного изображения, и применение операций обработки, приближающих вновь полученное изображение к обычной фотографической структуре. Алгоритмы генерации изображений реализованы в виде отдельного программного модуля.

Алгоритм имитации дождя добавляет капли воды в предварительно созданную маску. Для каждой капли задаются случайные координаты центра, случайный размер в пределах некоторого интервала и фиксированный угол наклона, который учитывает влияние ветра на движение капель. Для достижения более высокой степени реализма к маске с каплями применяется гауссово размытие, что позволяет сгладить границы капель и придать им естественный вид. Аналогично работает алгоритм имитации снегопада, который добавляет в маску снежинки и сглаживает их контур операцией размытия.

Алгоритм имитации тумана плавно изменяет видимость объектов на изображении и основан на создании градиентной маски с заполнением в интервале значений от 0 до 255. Градиентная маска отражает постепенное нарастание плотности тумана от края к центру изображения, что придает эффекту большую реалистичность.

Пример сгенерированных изображений с различными погодными эффектами продемонстрирован на Рисунке 3.



Рисунок 3 – Сгенерированные изображения с погодными эффектами  
Figure 3 – Generated images with weather effects

Для дальнейшего сравнительного анализа модель отдельно обучена с использованием двух вариантов наборов данных – первоначального и расширенного. В соответствии с процедурой обучения каждый использованный набор данных был идентично разделен на два раздела – тренировочный набор (85 % от общего числа изображений) и тестовый набор (остальные 15 %).

### Обсуждение

**Анализ количественных показателей качества обучения системы технического зрения.** К основным показателям системы технического зрения, по которым можно количественно характеризовать ее эффективность, относятся точность и скорость обнаружения объектов. Скорость обнаружения объектов разработанной системой технического зрения достигает 17,5 кадров в секунду.

После обучения модели точность и качество обнаружения объектов оценивалось с помощью метрик F1-меры [12] и mAP 50–95 [13] при различных порогах достоверности (доверительной вероятности).

Метрика mAP вычисляется как среднее значение AP (Average Precision) по всем классам объектов по формуле:

$$mAP = \frac{1}{n} \cdot \sum_{i=1}^n AP_i, \quad (1)$$

где  $AP_i$  – средняя точность для каждого класса или объекта,  $n$  – общее количество классов объектов.

Метрика F1-меры вычисляется как гармоническое среднее между точностью (precision) и полнотой (recall) по формуле (2):

$$F_1 = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}}. \quad (2)$$

Для оценки качества обучения и точности обнаружения объектов использовался отдельный оценочный набор данных, состоящий из 5000 размеченных изображений, которые не участвовали в обучении модели.

Результаты метрик F1-меры и mAP 50–95 представлены в Таблице 1.

Таблица 1 – Результаты сравнительной оценки качества обучения модели YOLOv11  
Table 1 – Results of comparative assessment of the learning quality for the YOLOv11 model

Доверительная вероятность	Первоначальный набор		Расширенный набор	
	mAP 50–95	F1-мера	mAP 50–95	F1-мера
0,01	0,738	0,878	0,877	0,987
...	...	...	...	...
0,5	0,738	0,878	0,877	0,987
0,55	0,736	0,874	0,874	0,983
0,6	0,733	0,865	0,873	0,982
0,65	0,728	0,855	0,871	0,980
0,7	0,721	0,834	0,864	0,969
0,75	0,705	0,794	0,857	0,957
0,8	0,674	0,719	0,827	0,906
0,825	0,652	0,665	0,798	0,857
0,85	0,619	0,575	0,759	0,783
0,875	0,582	0,445	0,703	0,666
0,9	0,561	0,346	0,667	0,590
0,925	0,466	0,244	0,635	0,497
0,95	0,312	0,109	0,459	0,339
0,975	0,143	0,001	0,147	0,015

На Рисунках 4 и 5 представлены графики параметров точности обнаружения объектов F1-меры и mAP 50–95 соответственно для первоначального и расширенного наборов данных.

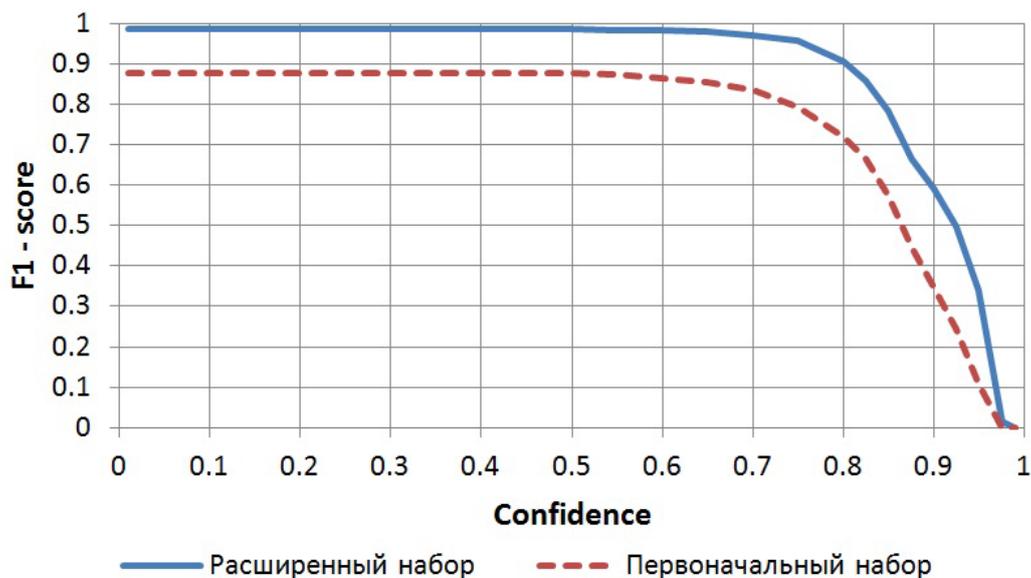


Рисунок 4 – График зависимости параметра F1-мера от доверительной вероятности  
Figure 4 – Dependence of the F1-score parameter on the confidence probability

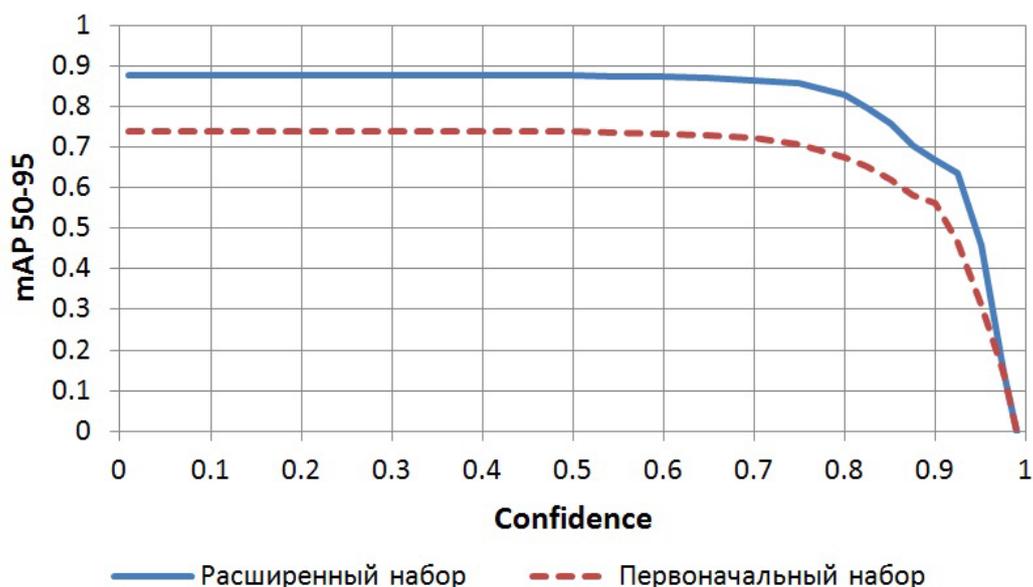


Рисунок 5 – График зависимости параметра mAP 50–95 от доверительной вероятности  
Figure 5 – Dependence of the mAP 50–95 parameter on the confidence probability

Сравнение графиков показывает, что модель, обученная на расширенном наборе данных, демонстрирует более высокую точность обнаружения объектов.

### Заключение

В рамках проекта по разработке системы технического зрения для беспилотных локомотивов в данной работе предложен экономный способ повысить качество обучения сверточной нейронной сети с учетом ограничений по времени и мощности вычислительных ресурсов. Обучающий набор данных увеличен в три раза за счет генерации дополнительных изображений с погодными эффектами снега, дождя и тумана. В натурном эксперименте с помощью камеры, установленной на локомотиве, собран первоначальный набор данных. На базе модели YOLOv11 разработана облегченная версия нейронной сети. В вычислительном эксперименте выполнено

раздельное обучение разработанной модели на двух наборах данных – первоначальном и расширенном. Сравнение результатов обучения подтверждает, что расширенный набор данных повышает точность обнаружения объектов железнодорожной инфраструктуры более, чем на 20 %, по двум использованным показателям качества. Добавление погодных эффектов позволяет модели лучше адаптироваться к изменяющимся условиям и повышает ее устойчивость к внешним факторам.

Разработанная система технического зрения успешно прошла тестовые испытания в производственных условиях и на текущем этапе развития автоматизации железнодорожных перевозок может быть использована в формате интеллектуального помощника машиниста. Предложенный подход может быть применен не только в железнодорожной отрасли, но и других областях, где требуется обнаружение объектов в сложных условиях, включая сельское хозяйство [14] и машиностроение [15], а также внедряются беспилотные транспортные средства.

### СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Федоров В.А., Огородникова О.М. Сверточные нейронные сети как инструмент обнаружения объектов железнодорожной инфраструктуры. *Автоматизация в промышленности*. 2024;(12):20–23.  
Fedorov V.A., Ogorodnikova O.M. Convolutional Neural Networks as a Tool for Detecting Railway Infrastructure Objects. *Avtomatizatsiya v promyshlennosti*. 2024;(12):20–23. (In Russ.).
2. Озеров А.В., Маршова А.С. О некоторых аспектах автоматизации движения поездов на железнодорожном транспорте. *Наука и технологии железных дорог*. 2024;8(3):12–17.  
Ozerov A.V., Marshova A.S. On Some Aspects of Train Automation in Railway Transport. *Nauka i tekhnologii zheleznykh dorog*. 2024;8(3):12–17. (In Russ.).
3. Anagnostopoulos A. High-Speed Railway and Safety: Insights from a Bibliometric Approach. *High-Speed Railway*. 2024;2(3):187–196. <https://doi.org/10.1016/j.hspr.2024.08.004>
4. Fedorov V.A. Recognizing Railway Infrastructure Using CNN and Stereoscopic Vision. In: *2024 International Russian Smart Industry Conference, 25–29 March 2024, Sochi, Russia*. IEEE; 2024. P. 13–18. <https://doi.org/10.1109/SmartIndustryCon61328.2024.10516208>
5. Tang Yo., Qian Yu. High-Speed Railway Track Components Inspection Framework Based on Yolov8 with High-Performance Model Deployment. *High-Speed Railway*. 2024;2(1):42–50. <https://doi.org/10.1016/j.hspr.2024.02.001>
6. Terven Ju., Córdova-Esparza D.-M., Romero-González Ju.-A. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*. 2023;5(4):1680–1716. <https://doi.org/10.3390/make5040083>
7. Попов В.А., Зубков А.В. Применение моделей машинного обучения семейства YOLO для задачи анализа чайного сырья по фотографии. *Моделирование, оптимизация и информационные технологии*. 2025;13(2). <https://doi.org/10.26102/2310-6018/2025.49.2.042>  
Popov V.A., Zubkov A.V. Application of YOLO Family Machine Learning Models for the Task of Analyzing Tea Raw Materials by Photograph. *Modeling, Optimization and Information Technology*. 2025;13(2). (In Russ.). <https://doi.org/10.26102/2310-6018/2025.49.2.042>

8. Гаврилов В.С., Корчагин С.А., Долгов В.И., Андриянов Н.А. Разработка легковесной модели автоматической классификации структурированных и неструктурированных данных в потоковых источниках для оптимизации оптического распознавания символов. *Моделирование, оптимизация и информационные технологии*. 2025;13(3). <https://doi.org/10.26102/2310-6018/2025.50.3.006>  
Gavrilov V.S., Korchagin S.A., Dolgov V.I., Andriyanov N.A. Development of a Lightweight Model for Automatic Classification of Structured and Unstructured Data in Streaming Sources to Optimize Optical Character Recognition. *Modeling, Optimization and Information Technology*. 2025;13(3). (In Russ.). <https://doi.org/10.26102/2310-6018/2025.50.3.006>
9. Castillo-Girones S., Munera S., Martínez-Sober M., Blasco Jo., Cubero S., Gómez-Sanchis Ju. Artificial Neural Networks in Agriculture, the Core of Artificial Intelligence: What, When, and Why. *Computers and Electronics in Agriculture*. 2025;230. <https://doi.org/10.1016/j.compag.2025.109938>
10. Khanam R., Hussain M. YOLOv11: An Overview of the Key Architectural Enhancements. arXiv. URL: <https://doi.org/10.48550/arXiv.2410.17725> [Accessed 31<sup>st</sup> July 2025].
11. He Z., Wang K., Fang T., Su L., Chen R., Fei X. Comprehensive Performance Evaluation of YOLOv11, YOLOv10, YOLOv9, YOLOv8 and YOLOv5 on Object Detection of Power Equipment. arXiv. URL: <https://doi.org/10.48550/arXiv.2411.18871> [Accessed 31<sup>st</sup> July 2025].
12. Yacouby R., Axman D. Probabilistic Extension of Precision, Recall, and F1 Score for More Thorough Evaluation of Classification Models. In: *Proceedings of the First Workshop on Evaluation and Comparison of NLP Systems, 20 November 2020, Virtual Event*. Association for Computational Linguistics; 2020. P. 79–91. <https://doi.org/10.18653/v1/2020.eval4nlp-1.9>
13. Chitraningrum N., Banowati L., Herdiana D., et al. Comparison Study of Corn Leaf Disease Detection Based on Deep Learning YOLO-v5 and YOLO-v8. *Journal of Engineering and Technological Sciences*. 2024;56(1):61–70. <https://doi.org/10.5614/j.eng.technol.sci.2024.56.1.5>
14. Ogorodnikova O.M., Ali W. Method of Ripe Tomato Detecting for a Harvesting Robot. In: *Physics, Technologies and Innovation (PTI-2019): Proceedings of the VI International Young Researchers' Conference, 20–23 May 2019, Ekaterinburg, Russia*. American Institute of Physics; 2019. <https://doi.org/10.1063/1.5134297>
15. Patruno C., Renò V., Nitti M., Mosca N., Di Summa M., Stella E. Vision-Based Omnidirectional Indoor Robots for Autonomous Navigation and Localization in Manufacturing Industry. *Heliyon*. 2024;10(4). <https://doi.org/10.1016/j.heliyon.2024.e26042>

#### ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

**Федоров Владимир Анатольевич**, аспирант кафедры электронного машиностроения, Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, Российская Федерация.  
e-mail: [fedorov.vladimir@urfu.ru](mailto:fedorov.vladimir@urfu.ru)

**Vladimir A. Fedorov**, Postgraduate at the Department of Electronic Engineering, Ural Federal University named after the first President of Russia B.N. Yeltsin, the Russian Federation.

**Огородникова Ольга Михайловна**, доктор технических наук, профессор кафедры электронного машиностроения, Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, Российская Федерация.

*e-mail:* [olga.ogorodnikova@urfu.ru](mailto:olga.ogorodnikova@urfu.ru)

ORCID: [0000-0002-8752-5322](https://orcid.org/0000-0002-8752-5322)

**Olga M. Ogorodnikova**, Doctor of Engineering Sciences, Professor at the Department of Electronic Engineering, Ural Federal University named after the first President of Russia B.N. Yeltsin, the Russian Federation.

*Статья поступила в редакцию 23.07.2025; одобрена после рецензирования 28.08.2025; принята к публикации 19.09.2025.*

*The article was submitted 23.07.2025; approved after reviewing 28.08.2025; accepted for publication 19.09.2025*