

УДК 004.85

DOI: [10.26102/2310-6018/2024.47.4.042](https://doi.org/10.26102/2310-6018/2024.47.4.042)

Особенности применения глубокого обучения для обнаружения номерных знаков на изображении и их последующая классификация методами компьютерного зрения

В.С. Ревера¹, Е.А. Шельмина^{1,2}✉

¹Томский государственный университет систем управления и радиоэлектроники,
Томск, Российская Федерация

²Национальный исследовательский Томский государственный университет, Томск,
Российская Федерация

Резюме. В статье представлена методика распознавания российских автомобильных номерных знаков с использованием современных технологий глубокого обучения, компьютерного зрения и оптического распознавания символов. Актуальность исследования обусловлена растущей потребностью в автоматизированных системах распознавания автомобильных номерных знаков для улучшения безопасности дорожного движения, оптимизации транспортных потоков и внедрения интеллектуальных транспортных систем. Исследование состоит из двух этапов. На первом этапе обучена нейронная сеть для обнаружения номерных знаков на изображении с использованием соответствующего набора данных автомобильных номеров. На втором этапе, на основе полученных детекций, осуществляется обработка изображений методами компьютерного зрения, выделение отдельных символов путем сегментации, а также их последующая классификация при помощи системы оптического распознавания символов с адаптированным алфавитом. Полученные результаты демонстрируют эффективность предложенного подхода и возможность его применения в реальных условиях. Материалы статьи представляют практическую ценность для специалистов, занимающихся разработкой систем автоматического распознавания номерных знаков, и могут быть использованы в сферах контроля доступа, мониторинга транспорта и обеспечения безопасности на дорогах.

Ключевые слова: YOLO, распознавание номерных знаков, сегментация, детекция объектов, оптическое распознавание символов, нейронные сети, компьютерное зрение, набор данных.

Для цитирования: Ревера В.С., Шельмина Е.А. Особенности применения глубокого обучения для обнаружения номерных знаков на изображении и их последующая классификация методами компьютерного зрения. *Моделирование, оптимизация и информационные технологии.* 2024;12(4). URL: <https://moitvvt.ru/ru/journal/pdf?id=1736> DOI: 10.26102/2310-6018/2024.47.4.042

Features of deep learning application for license plate detection in images and their subsequent classification using computer vision methods

V.S. Revera¹, E.A. Shelmina^{1,2}✉

¹Tomsk State University of Control Systems and Radioelectronics, Tomsk,
the Russian Federation

²National Research Tomsk State University, Tomsk, the Russian Federation

Abstract. The article presents a technique for recognizing Russian car license plates using modern technologies of deep learning, computer vision and optical character recognition. The relevance of the study is due to the growing need for automated license plate recognition systems to improve road safety,

optimize traffic flows and implement intelligent transport systems. The study consists of two stages. At the first stage, a neural network was trained to detect license plates in the image using the appropriate dataset of license plate. At the second stage, based on the received detections, image processing is carried out using computer vision methods, the selection of individual characters by segmentation, as well as their subsequent classification using an optical character recognition system with an adapted alphabet. The results obtained demonstrate the effectiveness of the proposed approach and the possibility of its application in real conditions. The materials of the article are of practical value for specialists involved in the development of automatic license plate recognition systems and can be used in the areas of access control, transport monitoring and road safety.

Keywords: YOLO, license plate recognition, segmentation, object detection, optical character recognition, neural networks, computer vision, dataset.

For citation: Revera V.S., Shelmina E.A. Features of deep learning application for license plate detection in images and their subsequent classification using computer vision methods. *Modeling, Optimization and Information Technology*. 2024;12(4). (In Russ.). URL: <https://moitvvt.ru/ru/journal/pdf?id=1736> DOI: 10.26102/2310-6018/2024.47.4.042

Введение

В современном мире автоматическое распознавание автомобильных номерных знаков является неотъемлемой частью интеллектуальных транспортных систем. Оно находит широкое применение в системах контроля доступа, автоматизации парковок, мониторинге дорожного движения и обеспечении безопасности на дорогах. В условиях растущей урбанизации и увеличения числа транспортных средств, необходимость в эффективных и точных системах распознавания номерных знаков остается актуальной задачей.

Особенность российских автомобильных номеров заключается в использовании кириллических символов и специфического формата, что создает дополнительные сложности при их распознавании с помощью существующих международных систем. Несмотря на намеренное сходство кириллических букв российских номерных знаков с латинскими символами, различия в графических деталях и кодировке (например, между кириллической «У» и латинской «Y») создают существенные проблемы для автоматических систем распознавания, требуя разработки специализированных алгоритмов, способных точно различать и корректно кодировать эти символы. Многие зарубежные решения, ориентированные на распознавание латинских символов, не адаптированы под российские стандарты и не обеспечивают необходимой точности. Преодоление сложностей, связанных с визуальным сходством и различиями в кодировке кириллических и латинских символов на российских номерных знаках, является критически важным для обеспечения высокой точности автоматического распознавания и обработки данных, что подчеркивает необходимость разработки специализированного решения.

Анализируя новые подходы, которые применяются для решения данной проблемы, можно с уверенностью сказать, что методы глубокого обучения и компьютерного зрения показали высокую эффективность при работе с изображениями в задачах обнаружения и распознавания объектов [1]. В частности, модели семейства YOLO [2] зарекомендовали себя как одни из наиболее популярных и широко используемых архитектур для детекции объектов на визуальных данных благодаря своей хорошей скорости и точности.

Технология оптического распознавания символов (OCR) [3] также активно развивается и применяется для распознавания текстовой информации на изображениях. Подобные библиотеки поддерживают множество языков, включая русский, и позволяют эффективно распознавать текстовые символы с изображений. Тем не менее, без

адаптации и специальной предобработки изображений точность распознавания символов на номерных знаках может быть недостаточной из-за специфики шрифтов, освещения, условий съемки и проблем систем OCR при работе с последовательностями букв и цифр.

Целью данного исследования является разработка эффективного алгоритма для автоматического распознавания российских автомобильных номерных знаков с использованием современных подходов глубокого обучения, а также технологий компьютерного зрения и методов оптического распознавания символов.

Материалы и методы

Задача автоматического распознавания автомобильных номерных знаков включает два ключевых этапа: обнаружение номерного знака на изображении и распознавание символов на выделенной области.

Традиционные методы локализации номерных знаков

До появления распространенных глубинных архитектур многие исследования полагались на методы, основанные на ручной настройке признаков и эвристик. Так, широко применялись:

1. Анализ границ и контуров [4]: Ранние решения часто основывались на поиске прямоугольных областей с высокой плотностью границ или контрастных переходов. Использовались такие операции, как фильтрация по градиенту, контурный анализ и морфологическая обработка. Достоинством подобных методов является их сравнительно высокая скорость при низких вычислительных затратах. Однако чувствительность к освещению, ориентации номера и сложному фону зачастую приводила к большому числу ложных срабатываний и снижению общей точности.

2. Цветовые модели и сегментация по цвету [5]: Другим распространенным подходом было использование цветовых характеристик номерных знаков. Переход к цветовым пространствам (например, HSI) позволял фильтровать неподходящие области, выбирая кандидаты с определенным цветом фона или символов. Однако зависимость от стабильных цветовых признаков и неустойчивость при изменениях освещения приводили к тому, что подобные методы были эффективны лишь в ограниченных условиях.

3. Текстурные признаки и традиционные классификаторы: Некоторые решения применяли анализ текстуры или локальных признаков для выделения областей, вероятно содержащих номерные знаки. Могли использоваться SVM или каскадные классификаторы [16]. Хотя такой подход иногда обеспечивал более высокую точность, чем примитивный анализ границ или цвета, он требовал тщательного подбора признаков, а также качественного набора обучающих данных.

Появление глубокого обучения в задачах обнаружения номерных знаков

Распространение сверточных нейронных сетей (CNN) открыло возможности для более точной и устойчивой локализации объектов, включая автомобильные номера. Изначально для обнаружения номерных знаков применяли модели общего назначения, такие как Faster R-CNN [6] или SSD [7], которые показывали хорошую точность, но иногда уступали в скорости. Появление первой версии YOLO [2] стало поворотным моментом: модель выполняла предсказание ограничивающих рамок и классов за один проход, что существенно повысило скорость детекции.

Методы распознавания символов

После успешной локализации номерного знака возникает задача извлечения и распознавания символов. Изначально применялись классические OCR-решения, например, Tesseract [8], требующие тщательной предобработки и ручного выделения

признаков. С появлением глубокого обучения стали доступны модели, непосредственно работающие с изображением номера целиком, такие как CRNN [9] или архитектуры на базе Transformers [10], способные устойчиво распознавать последовательности символов даже при искажениях.

В настоящем исследовании применялся OCR подход, однако в перспективе планируется перейти к обучению специализированной CNN для более точного и адаптивного распознавания кириллических символов на номерных знаках.

Настоящее исследование

Семейство моделей YOLO (You Only Look Once) представляет собой эффективные архитектуры глубокого обучения для задачи детекции объектов на изображениях в режиме реального времени [2]. YOLO основана на сверточных нейронных сетях и способна одновременно выполнять локализацию и классификацию объектов. Принцип работы YOLO заключается в разделении изображения на сетку и предсказании ограничивающих рамок и вероятностей классов для каждой ячейки этой сетки. Такой подход обеспечивает высокую скорость и точность обнаружения объектов.

В стандартной конфигурации модели YOLO обучены на наборе данных COCO [11], содержащем 80 классов объектов. Однако для специфической задачи распознавания номерных знаков требуется адаптация модели под новые данные. В данном исследовании использовалась модель YOLOv9 [12], предварительно обученная на общем датасете, и затем дообученная на специализированном наборе данных номерных знаков. Для этого использовался метод переноса обучения [13], что позволило адаптировать модель к решению необходимой задачи.

Основное достоинство переноса обучения заключается в том, что такие предобученные модели уже освоили базовые признаки изображений, что повышает точность при выполнении новых задач (Рисунок 1).

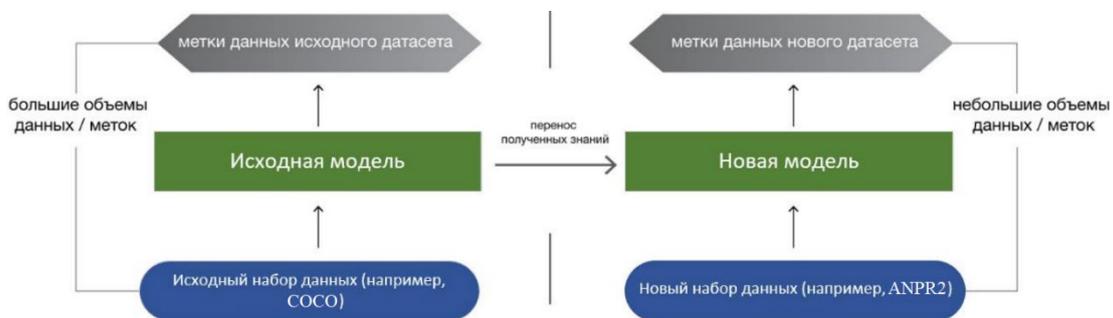


Рисунок 1 – Схема принципа работы переноса обучения
 Figure 1 – The scheme of the principle of transfer learning

Для обучения модели использовался набор данных ANPR2¹. Он включает 307 изображений автомобильных номерных знаков, аннотированных в формате, совместимом с YOLOv9. Данные разделены на следующие части: 91 % изображений предназначен для обучения нейросети, 2 % – для проверки модели в ходе обучения (валидации), и оставшиеся 7 % – для тестирования. Все изображения масштабированы до размера 640×640 пикселей, соответствующего входным требованиям модели.

Переход от традиционных алгоритмов, основанных на границах или цвете, к глубоким моделям детекции, таким как YOLOv9, позволили увеличить точность и устойчивость системы распознавания номерных знаков. Стоит отметить, что важно не

¹ Kumar A. ANPR2 Computer Vision Project. Roboflow. URL: <https://universe.roboflow.com/arvind-kumar-wjygd/anpr2-syxl7> (дата обращения: 01.10.2024).

только выбрать передовую модель для обнаружения объектов, но, в том числе, реализовать алгоритм распознавания символов и адаптировать OCR к национальным условиям, что также было реализовано в данной работе.

Результаты

Для достижения устойчивости разрабатываемой модели использовались специальные техники аугментации [14], что является одной из особенностей применения глубокого обучения. Это позволило повысить разнообразие обучающих данных и улучшить способность модели обобщать информацию. В частности, применялся метод, комбинирующий несколько изображений в одно, позволяя модели видеть объекты в различных масштабах и контекстах (Mosaic). Кроме того, использовались такие техники, как масштабирование (Scaling) и сдвиги по цветовым каналам (Color Jittering). Благодаря интеграции этих техник, модель смогла эффективно обрабатывать изображения с различными искажениями, освещением и фонами.

В процессе обучения отслеживались ключевые метрики, отражающие качество работы модели. Среди них особое внимание уделялось функциям потерь: для координат ограничивающих рамок (box loss) и для классификации объектов (cls loss). Кроме того, оценивались показатели точности (Precision) и полноты (Recall), а также метрики средней точности при различном пороге IoU (mAP@0.5 и mAP@0.5:0.95 соответственно) [15].

Обучение модели YOLOv9 проводилось на протяжении 100 эпох с использованием заранее подготовленных выборок. В качестве оптимизатора был выбран стохастический градиентный спуск (SGD) [16].

Функция потерь для координат рамок (box loss) отражает, насколько точно модель предсказывает положение и размеры ограничивающих рамок объектов по сравнению с истинными значениями. Снижение этого показателя указывает на улучшение способности модели к локализации объектов на изображении (Рисунок 2).

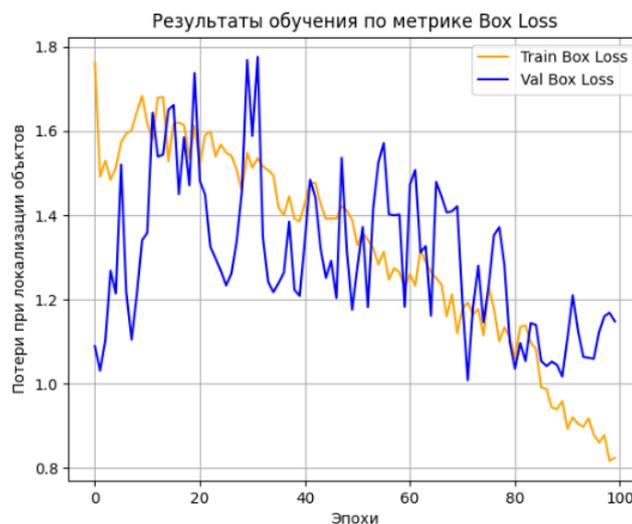


Рисунок 2 – График изменения потерь (box loss) в процессе обучения модели
 Figure 2 – Loss change graph (box loss) during model training

Функция потерь для классификации (cls loss) характеризует разницу между предсказанными и истинными классами объектов. Уменьшение этого показателя свидетельствует о том, что модель становится более точной в распознавании

принадлежности обнаруженных объектов к заданным классам. На Рисунке 3 представлен график изменения функций потерь (cls loss) в процессе обучения модели.



Рисунок 3 – График изменения потерь (cls loss) в процессе обучения модели
 Figure 3 – Loss change graph (cls loss) during model training

Точность (Precision) показывает долю корректно предсказанных положительных результатов среди всех объектов, предсказанных положительным классом. Высокое значение точности означает, что модель делает небольшое количество ложных срабатываний. Полнота (Recall) отражает долю правильно предсказанных положительных результатов среди всех фактических положительных. Высокая полнота свидетельствует о способности модели обнаруживать большинство объектов. На Рисунке 4 представлен график изменения метрик точности (Precision) и полноты (Recall) в процессе обучения.



Рисунок 4 – График изменения метрик Precision и Recall в процессе обучения
 Figure 4 – Graph of metric changes Precision and Recall in the learning process

Средняя точность (mAP@0.5) является интегральной метрикой, которая усредняет точность по различным уровням полноты при пороге пересечения по объединению (Intersection over Union, IoU) равном 0.5. Эта метрика широко используется для оценки моделей обнаружения объектов и позволяет оценить общее качество модели. Средняя точность (mAP@0.5:0.95) является более строгой метрикой, усредняющей значения mAP при порогах IoU от 0.5 до 0.95 с шагом 0.05. Она позволяет оценить

способность модели сохранять высокую точность детекции при различных критериях соответствия предсказанных и истинных рамок. График на Рисунке 5 иллюстрирует изменение средних значений точности $mAP@0.5$ и $mAP@0.5:0.95$ по эпохам обучения.

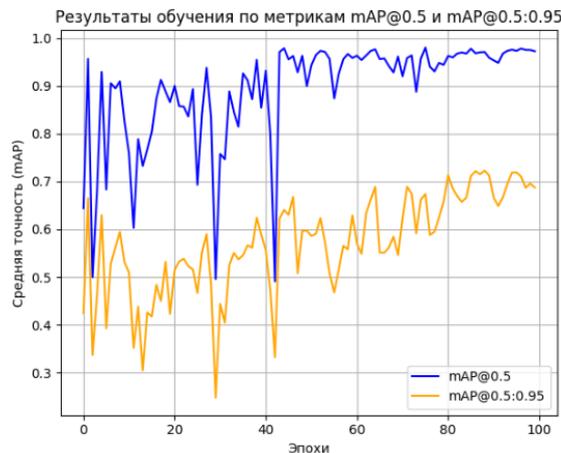


Рисунок 5 – График изменения метрик $mAP@0.5$ и $mAP@0.5:0.95$ в процессе обучения
Figure 5 – Graph of metric changes $mAP@0.5$ and $mAP@0.5:0.95$ in the learning process

По итогам обучения лучшая модель достигла следующих значений метрик на валидационной выборке: Box Loss – 1.045; Cls Loss – 0.604; Precision – 91,5 %; Recall – 100 %; $mAP@0.5$ – 97,1 %; $mAP@0.5:0.95$ – 72,3 %.

Из графиков видно, что по мере увеличения числа эпох, значения функций потерь уменьшаются, что свидетельствует об успешном обучении модели и ее способности к обобщению. Высокие значения метрик Precision и Recall подтверждают способность модели точно обнаруживать номерные знаки на изображениях без значительного числа ложных срабатываний и пропусков. Значение $mAP@0.5$ свидетельствует о высокой средней точности модели при стандартном пороге IoU 0.5. Метрика $mAP@0.5:0.95$ показывает, что модель сохраняет достаточно высокую точность детекции даже при более строгих критериях соответствия рамок.

Таким образом, результаты обучения демонстрируют, что модель успешно обучилась и обладает высокой обобщающей способностью, что позволяет ей эффективно работать на новых данных. Пример работы обученной модели представлен на Рисунке 6.



Рисунок 6 – Пример работы обученной модели YOLO
Figure 6 – An example of how the trained YOLO model works

Разработанный алгоритм распознавания символов включает несколько последовательных этапов. Для работы с визуальной информацией применяются инструменты библиотеки OpenCV [17]. Исходное изображение автомобиля загружается и масштабируется на 150 % с сохранением пропорций для улучшения видимости мелких объектов. На Рисунке 7а представлен пример входного изображения.



Рисунок 7 – Распознавание автомобильного номера: а) пример входного изображения; б) результат обнаружения

Figure 7 – License plate recognition: a) example of an input image; b) detection result

Модель YOLOv9 загружается с предварительно обученными и дообученными весами. После прямого прохода по сети получаются предсказания, содержащие информацию о потенциальных объектах номерных знаков на изображении. На Рисунке 7б представлен результат обнаружения автомобильного номера.

Полученные детекции проходят через процесс фильтрации, отсекаются объекты с вероятностью ниже порога 30 %. После фильтрации детекций применяется алгоритм Non-Maximum Suppression (NMS) [18], который позволяет удалить избыточные ограничивающие рамки, оставляя только одну рамку для каждого номерного знака. Затем, используя координаты ограничивающих рамок, изображение номерного знака вырезается из исходного изображения. Результат удаления избыточных фрагментов изображения представлен на Рисунке 8а.



Рисунок 8 – Обработка изображений: а) результат удаления избыточных фрагментов изображения; б) результат бинаризации изображения

Figure 8 – Image processing: a) the result of removing redundant image fragments; b) the result of image binarization

Вырезанный номерной знак преобразуется в оттенки серого для упрощения последующей обработки. Затем применяется пороговая бинаризация. В результате получается бинарное изображение, где символы представлены белым цветом на черном фоне. Инверсия цветов позволяет улучшить выделение символов при дальнейшей сегментации. Результат бинаризации изображения представлен на Рисунке 8б.

Сегментация начинается с применения морфологических операций дилатации и эрозии к бинарному изображению [19]. Для этих операций используется ядро размером

3×3, которое помогает усилить границы символов и уменьшить шум. Дилатация расширяет белые области (символы), а эрозия позволяет удалить небольшие шумовые элементы на изображении. Этот шаг обеспечивает чёткое выделение символов для дальнейшей обработки. Результат применения морфологических операций приведен на Рисунке 9.

После морфологической обработки выполняется анализ связных компонентов с помощью функции `connectedComponents` [17] из библиотеки `OpenCV`. Эта функция позволяет идентифицировать все отдельные объекты на изображении и присвоить им уникальные метки.



Рисунок 9 – Результат применения морфологических операций
Figure 9 – The result of morphological operations

Для удаления слишком маленьких или слишком больших объектов применяется фильтрация по размеру. В алгоритме устанавливаются нижняя и верхняя границы для фильтрации символов. После этого проводится поиск контуров подходящих объектов. Рамки отобранных символов сортируются по горизонтальной координате, чтобы расположить символы в правильном порядке слева направо. Результат сегментации символов представлен на Рисунке 10.



Рисунок 10 – Результат сегментации символов
Figure 10 – The result of character segmentation

Для распознавания выделенных символов используется библиотека `EasyOCR`², поддерживающая русский язык. Согласно ГОСТ Р 50577-2018³ на регистрационных знаках российских автомобильных номеров разрешены цифры от 0 до 9, а также 12 букв кириллицы: А, В, Е, К, М, Н, О, Р, С, Т, У, Х. Исходя из этого, в процессе распознавания OCR ограничен набор допустимых символов исключительно встречающимися буквами и цифрами, что повысило уверенность алгоритма в предсказаниях. Исключив из допустимого алфавита символы, не используемые в российских номерных знаках, была снижена вероятность ошибочного распознавания, когда алгоритм мог бы интерпретировать схожие по форме символы неверно. Каждый вырезанный символ передается в `EasyOCR` для распознавания и возвращает результат с предсказанием в виде текста. На Рисунке 11 показан пример работы разработанного нами алгоритма.

² JaidedAI/EasyOCR: Ready-to-use OCR with 80+ supported languages and all popular writing scripts including Latin, Chinese, Arabic, Devanagari, Cyrillic and etc. GitHub. URL: <https://github.com/JaidedAI/EasyOCR> (дата обращения: 01.10.2024).

³ Национальный стандарт РФ ГОСТ Р 50577-2018. «Знаки государственные регистрационные транспортных средств. Типы и основные размеры. Технические требования». Москва: Стандартинформ; 2018. 34 с.



Рисунок 11 – Пример работы разработанного алгоритма
Figure 11 – An example of how the developed algorithm works

В конечном итоге, распознанные символы собираются в единую последовательность по горизонтальной координате и определяется средняя степень уверенности предсказания. Полная схема алгоритма распознавания российских автомобильных номеров представлена на Рисунке 12.



Рисунок 12 – Схема алгоритма распознавания российских автомобильных номеров
Figure 12 – The scheme of the algorithm for recognizing Russian car license plates

Для оценки практической эффективности разработанного алгоритма была проведена проверка на 10 контрольных изображениях автомобилей с российскими номерными знаками. Эти изображения не входили в обучающую или валидационную

выборки и были получены из открытых источников. На Рисунке 13 представлены входные изображения.

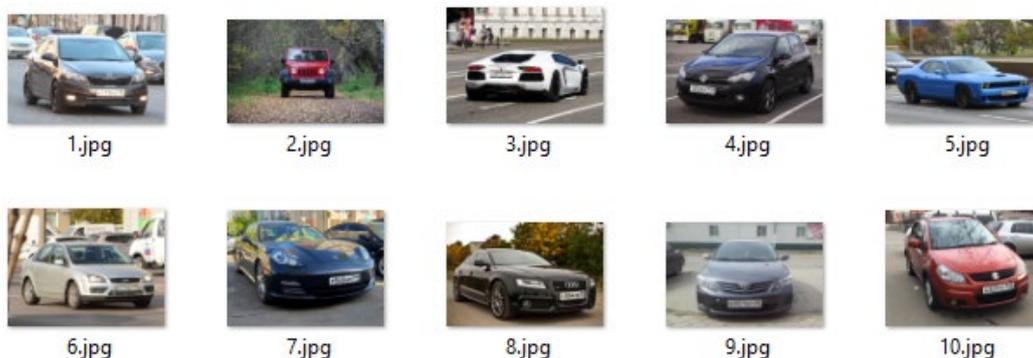


Рисунок 13 – Входные изображения
Figure 13 – Input Images

Использовались разные изображения, которые отличаются по качеству, углу положения номера, освещению. На Рисунке 14 представлены автомобильные номера на входных изображениях.



Рисунок 14 – Автомобильные номера на входных изображениях
Figure 14 – License plates on the input images

При классификации символов использовалась библиотека EasyOCR, которая не предоставляет метрику точности распознавания, но предоставляет значение уверенности (confidence) для каждого распознанного символа. Она отражает степень уверенности системы в правильности распознавания конкретного символа и выражается в процентах.

Наша модель YOLOv9 успешно обнаружила номерные знаки на всех тестовых изображениях со средней точностью 89 %. После детекции номера применялся разработанный алгоритм для распознавания символов. Средняя уверенность распознавания символов на контрольных изображениях составила 76 %. В Таблице 1 представлены результаты распознавания номерных знаков на контрольных изображениях.

Таблица 1 – Результаты распознавания номерных знаков на контрольных изображениях
Table 1 – License plate recognition results in control images

Изображение	Точность детекции (YOLO), %	Номер на картинке	Распознанные символы (алгоритм)	Уверенность согласно алгоритму, %
1	81	y111po178	y11po7	41
2	82	a608cx777	a608cx77	85
3	92	e007ee197	e07ee17	46
4	88	t222kn178	t222kn178	95
5	82	o906om777	o906om77	78

Таблица 1 (продолжение)
Table 1 (continued)

6	83	m777мм777	м7мм	36
7	97	p543нм799	p543нм799	99
8	96	c004мв98	c004мв98	94
9	97	в001ор48	в001ор48	91
10	93	a322pp125	a322pp125	99
Средняя точность	89	Средняя уверенность		76

Для оценки эффективности нашего подхода мы сравнили полученные результаты с данными других исследований в рассматриваемой области. К сожалению, мы не можем объективно оценить точность распознавания символов в OCR, поэтому использовали результаты, полученные в ходе тестового эксперимента. Метрика mAP@0.5 широко используется для оценки качества моделей детекции объектов и позволяет объективно сравнить производительность моделей в части обнаружения номерных знаков.

Следует отметить, что прямое сравнение результатов может быть затруднено из-за различий в используемых наборах данных, условиях экспериментов и методах оценки. Тем не менее, представленное сравнение дает общее представление о производительности нашего подхода относительно других. В Таблице 2 представлены результаты распознавания автомобильных номеров, достигнутые другими авторами.

Таблица 2 – Результаты, достигнутые другими авторами
Table 2 – Results achieved by other authors

Исследование	Метод детекции	Метод распознавания	Точность детекции (mAP@0.5), %	Точность распознавания, %
Md. Saif Hassan Onim и др [20]	YOLOv4	Tesseract	90	52
Yash Shambharkar и др [21]	Своя CNN	OCR	96,2	93,7
Абрамов и Ельцов [22]	YOLOv5s	SCR-Net	95	70
Настоящее исследование	YOLOv9	Адаптированный OCR	97,1	76

Обсуждение

Результаты проведенного исследования демонстрируют хорошую эффективность разработанного алгоритма распознавания российских автомобильных номерных знаков. Модель YOLOv9 показала высокие показатели точности детекции, о чем свидетельствуют значения метрик, полученных по результатам обучения.

Использование методов предобработки изображений, таких как масштабирование, бинаризация и морфологические операции, улучшило качество входных данных для распознавания. Сегментация обеспечила эффективное выделение отдельных символов на номерном знаке, что существенно повысило точность последующей классификации элементов. Ограничение набора допустимых знаков для EasyOCR также исключило возможность ошибочного распознавания недопустимых обозначений. Такой подход снизил количество ошибок и повысил общую точность распознавания.

Анализ ошибок показывает, что алгоритм иногда неверно интерпретирует визуально схожие символы, такие как цифра «0» и буква «О», либо цифра «1» и цифра «7». Эти ошибки могут быть обусловлены ограничениями системы EasyOCR и специфическими шрифтами российских номерных знаков. Кроме того, факторы качества изображения, в особенности, углы съемки, размытие, наличие загрязнений или повреждений на номерных знаках, существенно влияют на точность определения элементов. Плохой свет или тени могут снижать контрастность символов, затрудняя их корректную идентификацию.

Несмотря на эти ограничения, общая эффективность алгоритма остается высокой. Средняя уверенность распознавания символов, полученная в ходе эксперимента, составляет 76 %, на всех проверочных изображениях номерной знак был обнаружен верно. Это подтверждает применимость разработанного алгоритма в практических задачах, хотя и указывает на необходимость его совершенствования. Внедрение более современных моделей OCR, улучшение алгоритма обработки изображений или использование методов глубокого обучения для классификации символов может привести к повышению точности распознавания, особенно в сложных условиях.

Заключение

В рамках проведенного исследования был разработан алгоритм автоматического распознавания российских автомобильных номерных знаков, основанный на применении нейронных сетей и современных технологий компьютерного зрения. Полученные результаты демонстрируют, что предложенный алгоритм достаточно эффективно справляется с поставленной задачей.

Практическая значимость работы заключается в возможности интеграции разработанного алгоритма в системы контроля доступа, анализа транспортного потока, автоматизации парковок и обеспечения безопасности на дорогах. Алгоритм может быть использован специалистами, занимающимися разработкой систем автоматического распознавания номерных знаков, и адаптирован для различных прикладных задач.

Научная новизна исследования состоит в успешности применения интегрированного подхода к распознаванию российских номерных знаков, сочетающего дообучение модели YOLOv9 на специализированном датасете и разработке алгоритма распознавания символов, с использованием современных OCR инструментов, адаптированного под особенности кириллического алфавита и российского стандарта ГОСТ Р 50577-2018. Следует отметить, что представленное исследование является частью более масштабного проекта, направленного на развитие технологий автоматического распознавания автомобильных моделей и знаков. Мы планируем продолжать исследование в этой области и стремиться к более высоким научным результатам в ходе последующей работы над проектом.

Перспективными направлениями дальнейших исследований являются совершенствование методов предобработки и сегментации изображений, включая внедрение адаптивных алгоритмов, способных автоматически подстраиваться под качество входных данных, а также алгоритмов строгого форматирования, что может значительно улучшить результаты классификации символов.

Таким образом, предложенный алгоритм является перспективным решением для автоматического чтения российских автомобильных номеров и обладает широким потенциалом для практического применения в сферах транспорта и безопасности.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Zou Z., Chen K., Shi Z., Guo Y., Ye J. Object Detection in 20 Years: A Survey. *Proceedings of the IEEE*. 2023;111(3):257–276. <https://doi.org/10.1109/JPROC.2023.3238524>
2. Redmon J., Divvala S., Girshick R., Farhadi A. You Only Look Once: Unified, Real-Time Object Detection. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 27–30 June 2016, Las Vegas, NV, USA*. IEEE; 2016. pp. 779–788. <https://doi.org/10.1109/CVPR.2016.91>
3. Sabu A.M., Das A.S. A Survey on Various Optical Character Recognition Techniques. In: *2018 Conference on Emerging Devices and Smart Systems (ICEDSS), 02–03 March 2018, Tiruchengode, India*. IEEE; 2018. pp. 152–155. <https://doi.org/10.1109/ICEDSS.2018.8544323>
4. Anagnostopoulos C.N.E., Anagnostopoulos I.E., Loumos V., Kayafas E. A License Plate-Recognition Algorithm for Intelligent Transportation System Applications. *IEEE Transactions on Intelligent Transportation Systems*. 2006;7(3):377–392. <https://doi.org/10.1109/TITS.2006.880641>
5. Deb K., Le M.H., Woo B.-S., Jo K.-H. Automatic Vehicle Identification by Plate Recognition for Intelligent Transportation System Applications. In: *Modern Approaches in Applied Intelligence: 24th International Conference on Industrial Engineering and Other Applications of Applied Intelligent Systems, IEA/AIE 2011: Proceedings, Part II, 28 June – 01 July 2011, Syracuse, NY, USA*. Berlin, Heidelberg: Springer; 2011. pp. 163–172. https://doi.org/10.1007/978-3-642-21827-9_17
6. Ren S., He K., Girshick R., Sun J. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017;39(6):1137–1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
7. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.-Y., Berg A.C. SSD: Single Shot MultiBox Detector. In: *Computer Vision – ECCV 2016: 14th European Conference: Proceedings, Part I, 08–16 October 2016, Amsterdam, The Netherlands*. Cham: Springer; 2016. pp. 21–37. https://doi.org/10.1007/978-3-319-46448-0_2
8. Smith R. An Overview of the Tesseract OCR Engine. In: *Ninth International Conference on Document Analysis and Recognition (ICDAR 2007), 23–26 September 2007, Curitiba, Brazil*. IEEE; 2007. pp. 629–633. <https://doi.org/10.1109/ICDAR.2007.4376991>
9. Shi B., Bai X., Yao C. An End-to-End Trainable Neural Network for Image-Based Sequence Recognition and Its Application to Scene Text Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017;39(11):2298–2304. <https://doi.org/10.1109/TPAMI.2016.2646371>
10. Baek Y., Lee B., Han D., Yun S., Lee H. Character Region Awareness for Text Detection. In: *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 16–20 June 2019, Long Beach, CA, USA*. IEEE; 2019. pp. 9357–9366. <https://doi.org/10.1109/CVPR.2019.00959>
11. Lin T.-Y., Maire M., Belongie S., Hays J., Perona P., Ramanan D., Dollár P., Zitnick C.L. Microsoft COCO: Common Objects in Context. In: *Computer Vision – ECCV 2014: 13th European Conference: Proceedings, Part V, 06–12 September 2014, Zurich, Switzerland*. Cham: Springer; 2014. pp. 740–755. https://doi.org/10.1007/978-3-319-10602-1_48
12. Wang C.-Y., Yeh I.-H., Liao H.-Y.M. YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information. arXiv. URL: <https://arxiv.org/abs/2402.13616> [Accessed 30th September 2024].

13. Weiss K., Khoshgoftaar T.M., Wang D. A Survey of Transfer Learning. *Journal of Big Data*. 2016;3(1). <https://doi.org/10.1186/s40537-016-0043-6>
14. Shorten C., Khoshgoftaar T.M. A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*. 2019;6(1). <https://doi.org/10.1186/s40537-019-0197-0>
15. Zheng Z., Wang P., Liu W., Li J., Ye R., Ren D. Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression. In: *Proceedings of the AAAI Conference on Artificial Intelligence: Volume 34, No. 07: AAAI-20 Technical Tracks 7, 07–12 February 2020, New York, NY, USA*. Palo Alto: AAAI Press; 2020. pp. 12993–13000. <https://doi.org/10.1609/aaai.v34i07.6999>
16. Шолле Ф. *Глубокое обучение на Python. Второе международное издание*. Санкт-Петербург: Питер; 2023. 576 с.
Chollet F. *Deep Learning with Python. Second Edition*. Saint Petersburg: Piter; 2023. 576 p. (In Russ.).
17. Kaehler A., Bradski G. *Learning OpenCV 3: Computer Vision in C++ with the OpenCV Library*. Sebastopol: O'Reilly Media; 2016. 1024 p.
18. Neubeck A., Van Gool L. Efficient Non-Maximum Suppression. In: *18th International Conference on Pattern Recognition (ICPR'06), 20–24 August 2006, Hong Kong, China*. IEEE; 2006. pp. 850–855. <https://doi.org/10.1109/ICPR.2006.479>
19. Gonzalez R.C., Woods R.E. *Digital Image Processing*. New York: Pearson Education Limited; 2018. 1168 p.
20. Onim M.S.H., Akash M.I., Haque M., Hafiz R.I. Traffic Surveillance using Vehicle License Plate Detection and Recognition in Bangladesh. In: *2020 11th International Conference on Electrical and Computer Engineering (ICECE), 17–19 December 2020, Dhaka, Bangladesh*. IEEE; 2020. pp. 121–124. <https://doi.org/10.1109/ICECE51571.2020.9393109>
21. Shambharkar Y., Salagrama S., Sharma K., Mishra O., Parashar D. An Automatic Framework for Number Plate Detection using OCR and Deep Learning Approach. *International Journal of Advanced Computer Science and Applications*. 2023;14(4). <http://doi.org/10.14569/IJACSA.2023.0140402>
22. Абрамов М.В., Ельцов Д.А. Автоматическое распознавание автомобильных номеров в видеоряде: адаптация алгоритмов для смартфона. *Вестник ВГУ. Серия: Системный анализ и информационные технологии*. 2023;(3):95–106. <https://doi.org/10.17308/sait/1995-5499/2023/3/95-106>
Abramov M.V., Yeltsov D.A. Neural networks with lstm and gru in application to the task of multiclass classification of text posts of social network users. *Proceedings of Voronezh State University. Series: System Analysis and Information Technologies*. 2023;(3):95–106. (In Russ.). <https://doi.org/10.17308/sait/1995-5499/2023/3/95-106>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Ревера Всеволод Сергеевич, магистрант Томского государственного университета систем управления и радиоэлектроники, Томск, Российская Федерация.
e-mail: revera.seva@yandex.ru

Vsevolod S. Revera, Master's student of Tomsk State University of Control Systems and Radioelectronics, Tomsk, the Russian Federation.

Шельмина Елена Александровна, кандидат физико-математических наук, доцент Томского государственного университета систем управления и радиоэлектроники, доцент Национального исследовательского Томского

Elena A. Shelmina, Candidate of Physical and Mathematical Sciences, Associate Professor of Tomsk State University of Control Systems and Radioelectronics, Associate Professor of National

государственного университета, Томск, Research Tomsk State University, Tomsk, the
Российская Федерация. Russian Federation.

e-mail: eashelmina@mail.ru

ORCID: [0000-0002-6278-5961](https://orcid.org/0000-0002-6278-5961)

*Статья поступила в редакцию 08.11.2024; одобрена после рецензирования 16.12.2024;
принята к публикации 26.12.2024.*

*The article was submitted 08.11.2024; approved after reviewing 16.12.2024;
accepted for publication 26.12.2024.*