

Гибридный метод распознавания государственных регистрационных знаков транспортных средств на основе конвейерной архитектуры

А. В. Киселев¹, Е. А. Кулешова¹, М. О. Таныгин¹,
Т. Н. Конаныхина¹✉, З. К. Чьямова¹

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: govtn@mail.ru

Резюме

Цель исследования – повышение точности и скорости распознавания государственных регистрационных знаков транспортных средств в режиме реального времени за счет применения гибридного метода, адаптированного к российским стандартам и устойчивого к условиям окружающей среды.

Методы. В статье предложен и апробирован гибридный метод распознавания государственных регистрационных знаков транспортных средств на основе конвейерной архитектуры YOLOv12 – EasyOCR. Был синтезирован уникальный обучающий набор данных, обеспечивающий максимальную вариативность. Проведен сравнительный анализ детекторов (YOLOv10, YOLOv12, RT-DETR), подтверждающий целесообразность использования модели YOLOv12, продемонстрировавшей наилучшие показатели наиболее важных метрик ($Precision = 0,99$, $Recall = 0,98$ и $mAP_{0,5:0,95} = 0,91$). Разработан многовариантный конвейер предобработки изображений для OCR, выполняющий последовательное преобразование вырезанного изображения, включающий адаптивное масштабирование, улучшение контраста, шумоподавление и морфологические операции. Для минимизации типичных ошибок OCR был использован ограниченный набор допустимых символов и реализован алгоритм проверки соответствия российскому формату государственных регистрационных знаков.

Результаты. Оценка эффективности OCR проводилась путем сравнения распознанного текста с эталонным с использованием количественных метрик, таких как CRR (Character Recognition Rate) и PRR (Plate Recognition Rate), являющейся отраслевым аналогом метрики WRR (Word Recognition Rate). Проведен ряд экспериментов на тестовом наборе данных. Экспериментальная валидация предложенного гибридного метода распознавания государственных регистрационных знаков транспортных средств подтвердила его высокую эффективность (получены значения количественных метрик: $mAP_{0,5:0,95} = 0,91$, $CRR = 99,0\%$, $PRR = 98,5\%$), что свидетельствует о способности метода к обеспечению устойчивого распознавания в условиях реальной эксплуатации.

Заключение. Полученные результаты соответствуют верхней границе диапазона показателей современных систем автоматического распознавания, включая коммерческие решения. Это свидетельствует о высокой конкурентоспособности предложенного метода.

Ключевые слова: государственные регистрационные знаки; детектор; многовариантная предобработка изображений.

Конфликт интересов: Таныгин М. О. является членом редакционной коллегии журнала «Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение» с 2022 г., но не имеет никакого отношения к решению опубликовать эту статью. Статья прошла принятую в журнале процедуру рецензирования. Об иных конфликтах интересов авторы не заявляют.

Для цитирования: Гибридный метод распознавания государственных регистрационных знаков транспортных средств на основе конвейерной архитектуры / А. В. Киселев, Е. А. Кулешова, М. О. Таныгин, Т. Н. Конаныхина, З. К. Чьямова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 102–121. <https://doi.org/10.21869/2223-1536-2026-16-2-102-121>.

Поступила в редакцию 29.04.2026

Подписана в печать 28.05.2026

Опубликована 30.06.2026

A hybrid method for recognizing vehicle registration plates based on a pipeline architecture

Alexey V. Kiselev¹, Elena A. Kuleshova¹, Maxim O. Tanygin¹,
Tatyana N. Konanykhina¹✉, Zoya K. Chyamova¹

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: govtn@mail.ru

Abstract

The purpose of the research is improving the accuracy and speed of real-time recognition of vehicle registration plates through the use of a hybrid method adapted to Russian standards and resistant to environmental conditions.

Methods. This paper proposes and tests a hybrid method for recognizing vehicle registration plates based on the YOLOv12 – EasyOCR pipeline architecture. A unique training dataset was synthesized to ensure maximum variability. A comparative analysis of detectors (YOLOv10, YOLOv12, RT-DETR) was conducted, confirming the feasibility of using the YOLOv12 model, which demonstrated the best performance on the most important metrics (Precision = 0,99, Recall = 0,98, and $mAP_{0,5:0,95} = 0,91$). A multivariate image preprocessing pipeline for OCR was developed, performing sequential transformations of the cropped image, including adaptive scaling, contrast enhancement, noise reduction, and morphological operations. To minimize typical OCR errors, a limited set of acceptable characters was used, and an algorithm for checking compliance with the Russian license plate format was implemented.

Results. The OCR performance was assessed by comparing the recognized text with the reference text using quantitative metrics such as Character Recognition Rate (CRR) and Plate Recognition Rate (PRR), which is the industry equivalent of Word Recognition Rate (WRR). A series of experiments were conducted on a test dataset. Experimental validation of the proposed hybrid method for recognizing vehicle license plates confirmed its high efficiency (quantitative metric values of $mAP_{0,5:0,95} = 0,91$, CRR = 99,0 %, PRR = 98,5 %), demonstrating the method's ability to ensure robust recognition under real-world conditions.

Conclusion. The obtained results correspond to the upper limit of the performance range of modern automatic recognition systems, including commercial solutions. This demonstrates the high competitiveness of the proposed method.

Keywords: state registration plates; detector; multi-variant image preprocessing.

Conflict of interest: Tanygin M.O. is a member of the editorial board of the journal "Series: Management, computing, computer science. Medical instrumentation" since 2022, but has nothing to do with the decision to publish this article. The article passed the peer review procedure adopted in the journal. The authors are not for other conflicts of interest.

For citation: Kiselev A.V., Kuleshova E.A., Tanygin M.O., Konanykhina T.N., Chyamova Z.K. A hybrid method for recognizing vehicle registration plates based on a pipeline architecture. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(2):102–121. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-102-121>.

Received 29.04.2026

Accepted 28.05.2026

Published 30.06.2026

Введение

Интенсивное развитие городской среды и связанное с ним увеличение плотности транспортных потоков сформировали ряд проблем в сфере регулирования дорожного движения и управления доступом на территорию различных объектов [1]. Наиболее остро эти проблемы проявляются в зонах с высокими требованиями к безопасности и пропускной способности (промышленных зон, логистических хабов, объектов с охраняемыми периметрами и парковочными комплексами) [2]. Применение методов контроля, основанных на прямом участии оператора, связано не только со значительными временными затратами и снижением общей эффективности, но и с потенциальными рисками, обусловленными человеческим фактором [3].

В данном контексте ключевым технологическим решением выступают системы автоматического распознавания (САР) государственных регистрационных знаков транспортных средств (ГРЗ ТС) [4]. Интеграция таких систем в инфраструктуру «умных» городов и транспортных сетей способствует повышению не только операционной эффективности, но и уровня безопасности, в т. ч. за счет поддержки правоохранительной деятельности по поиску ТС [5].

Однако достижение стабильно высоких показателей точности распознавания в условиях неконтролируемой

внешней среды связано с рядом проблемами [6]. К их числу относятся динамические изменения условий освещения, погодные факторы, наличие механических загрязнений и частичных перекрытий (окклюзий) объектов, приводящие к размытости, снижению контраста и потере части информации [7]. Классические подходы, основанные на последовательности операций предобработки визуальных данных с последующим применением оптического распознавания символов (OCR), часто демонстрируют снижение точности в нестандартных условиях [8].

Современные исследования ориентированы на разработку гибридных и ансамблевых архитектур, в частности, реализованных на основе глубоких нейронных сетей (НС) [9]. Например, в работе [10] авторами рассмотрена проблема снижения точности традиционных систем распознавания ГРЗ ТС в условиях, приближенных к реальным, где качество изображений ухудшается из-за погодных условий, наклона номера или изменения расстояния съёмки. Для решения этой проблемы был предложен метод, объединяющий усовершенствованную архитектуру нейросетевой модели (НМ) YOLOv5 и модель LPRNet. Для повышения устойчивости постобработки применяется модифицированный алгоритм Soft-NMS (мягкого подавления немаксимумов), позволяющий корректно обрабатывать пересека-

ющиеся ограничительные рамки (ОР) и предотвращать ошибки подавления. Для устранения влияния наклона и искажений ГРЗ ТС на качество распознавания авторы включают пространственную трансформирующую НС, выполняющую коррекцию геометрии изображения перед его подачей в LPRNet. Проведённые эксперименты на наборах данных (НД) из открытых источников продемонстрировали существенный рост показателей точности по сравнению с классическими решениями.

В исследовании [11] авторами рассмотрен подход к построению САР ГРЗ ТС, в которой предварительная обработка изображений выполняется средствами библиотеки OpenCV, включая преобразование в оттенки серого, использование двусторонней фильтрации и выделение контуров для локализации области ГРЗ ТС. Извлечение текстовой информации осуществляется при помощи НМ TesseractOCR. Результаты экспериментов показывают, что разработанная система способна работать в режиме реального времени и обеспечивает высокую точность распознавания при различных уровнях освещённости.

Авторы исследования [12] описали подход к распознаванию тайских ГРЗ ТС в видеопотоке. При реализации предложенного подхода авторы использовали НМ SSD MobileNetV2 для детекции ГРЗ ТС на каждом кадре видео и НМ EasyOCR для последующего извлечения текстовой информации. В связи с тем, что движение транспортных средств на видео приводит к размытию кадров и появлению ошибочных или дублирующихся результатов распознавания, для повышения качества распознавания авторами была реализована

процедура постобработки, которая устраняет ошибочные и повторяющиеся результаты.

В работе [13] для решения задачи автоматического распознавания ГРЗ ТС в режиме реального времени на парковочных пространствах авторами была использована НМ YOLOv4. Для извлечения текста был применен алгоритм OCR. Результаты экспериментов показали, что система демонстрирует точность детекции равную 89 %.

Исходя из результатов предшествующих исследований, можно сделать вывод, что распознавание ГРЗ ТС в режиме реального времени на кадрах видеопотока является актуальной задачей, а сравнительный анализ показывает, что гибридные модели, сочетающие одноэтапные НМ в качестве детекторов и глубокие нейросетевые OCR-системы, достигают наилучшего баланса между скоростью обработки видеоряда, точностью детекции и распознавания, а также адаптивностью и устойчивостью к изменениям внешней среды.

Материалы и методы

Большинство НД из открытых источников сформировано на основе изображений ГРЗ ТС иностранных государств, стандарты которых могут существенно отличаться от российских образцов по форме, шрифтовому исполнению, размерности и цветовой гамме. Кроме того, значительная часть из них состоит из изображений, полученных в идеальных условиях, что может отразиться на обобщающей способности НМ. Исходя из того, что существующие НД не удовлетворяют требованиям исследования, для обучения НМ был синтезирован уникальный обу-

чающий НД, сформированный на основе видеоматериалов, полученных с камер наблюдения, установленных на автомобильных дорогах и объектах транспортной инфраструктуры. Для обеспечения максимальной вариативности данных для формирования НД были использованы записи, сделанные при различных условиях освещенности и погоды, включая дождь, снег и туман, которые вносят естественные искажения и шумы. При покадровой разбивке собранных видеофрагментов осуществлялась фильтрация полученных изображений (из общего потока исключались кадры с чрезмерным размытием или полным перекрытием ГРЗ ТС, не несущие полезной информации для обучения модели).

С целью обеспечения высокой обобщающей способности НМ и предотвращения эффекта переобучения применялись методы аугментации данных, заключающиеся в последовательном применении комплекса геометрических и цветовых трансформаций, моделирующих типичные искажения, характерные для камер наружного наблюдения. При аугментации данных были реализованы случайные повороты изображений в диапазоне от -15 до $+15$ градусов, имитирующие неточности установки камер или наклон ТС, операции масштабирования и сдвига, позволяющие моделировать изменение дистанции до объекта и его смещение относительно центра кадра, включены процедуры коррекции яркости и контрастности, которые обеспечивают адаптацию модели к резким перепадам освещения, возникающим в солнечное время суток или при свете фар в ночное время. Для

имитации расфокусировки объектива или воздействия атмосферных осадков применялось добавление гауссовского шума и размытие по методу Гаусса.

Итоговой объем НД после применения процедуры аугментации составил 3000 изображений. Все изображения были проаннотированы. НД был разделен на три независимые выборки – обучающую, валидационную и тестовую в соотношении 70, 20 и 10 % соответственно от общего объема данных.

При выборе оптимального варианта детектора для использования в гибридном методе распознавания ГРЗ ТС был проведен сравнительный анализ различных модификаций одноэтапных архитектур YOLOv10, YOLOv12 и RT-DETR. Процесс обучения каждой из архитектур проводился в соответствии с едиными параметрами обучения на синтезированном ранее НД (количество эпох обучения: 100; размер батча: 32; размер входного изображения: 640×640 пикселей, оптимизатор: AdamW, начальная скорость обучения: 10^{-3} , коэффициент импульса: 0,937). Для автоматического предотвращения избыточного обучения использовался механизм ранней остановки с параметром «терпения», равным 10 эпохам. Использовалось косинусное затухание скорости обучения до финального значения 10^{-5} , применена L2-регуляризация для предотвращения чрезмерного роста абсолютных значений весов.

Была проведена оценка качества обучения НМ. Графики функции потерь Box Loss, рассчитанные на валидационной выборке, представлены ниже (рис. 1).




Рис. 1. Графики функции потерь Box Loss для НМ RT-DETR, YOLOv10 и YOLOv12

Fig. 1. Box Loss function graphs for RT-DETR, YOLOv10 and YOLOv12 models

Функция Box Loss представляет собой компонент общей функции потерь НМ, отвечающий за оптимизацию пространственных параметров, предсказываемых ОР. Box_loss вычисляет пространственное рассогласование, учитывая не только позиционные смещения, но и геометрические аспекты (соотношение сторон, перекрытие) [14]. В архитектурах YOLO и RT-DETR для расчета этого вида потерь используется функция CIoU (Complete Intersection over Union) Loss, которую можно представить с помощью

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(A, B)}{c^2} + \alpha v, \quad (1)$$

где A и B – предсказанная ОР и настоящая ОР соответственно; IoU – это коэффициент пересечения $(A \cap B)$ и объ-

единения $(A \cup B)$ площадей, определяемый по

$$IoU = \frac{S(A \cap B)}{S(A \cup B)}, \quad (2)$$

при этом $IoU = 0$, если A и B не пересекаются; $IoU = 1$ – в случае идеального наложения [15]; $\rho^2(A, B)$ – евклидово расстояние между центрами рамок A и B ; c – диагональ наименьшей охватывающей рамки, которая включает в себя и предсказанную, и истинную рамки; α – положительный весовой коэффициент, определяемый по

$$\alpha = \frac{v}{(1 - IoU) + v}, \quad (3)$$

где v – параметр, измеряющий схожесть соотношения сторон рамок, определяемый по

$$v = \frac{4}{\pi^2} \left(\arctan\left(\frac{w^B}{h^B}\right) - \arctan\left(\frac{w^A}{h^A}\right) \right)^2, \quad (4)$$

где w^B и h^B – ширина и высота истинной рамки; w^A и h^A – ширина и высота предсказанной рамки.

Функция потерь Classification Loss отражает способность модели корректно определять класс обнаруженного

объекта. В случае решения задачи детекции Classification Loss измеряет степень уверенности модели в том, что обнаруженный объект действительно принадлежит целевому классу, а не является фоновым элементом [16]. В рассматриваемых архитектурах детекторов применяется функция потерь BCEWithLogitsLoss (Binary Cross-Entropy with Logits Loss), описываемая по

$$L_{BCE} = -[y \cdot \log(\sigma(x)) + (1 - y) \times \log(1 - \sigma(x))], \quad (5)$$

где y – бинарный индикатор принадлежности к классу при $y \in \{0,1\}$; x – выход модели (логит); $\sigma(x)$ – функция сигмоиды, преобразующая логит в вероятность, определяемая по

$$\sigma(x) = \frac{1}{1 + e^{-x}}. \quad (6)$$

Графики функции потерь Classification Loss для HM RT-DETR, YOLOv10 и YOLOv12, рассчитанные на валидационной выборке, представлены ниже (рис. 2).




Рис. 2. Графики функции потерь Classification Loss для HM RT-DETR, YOLOv10 и YOLOv12

Fig. 2. Graphs of the Classification Loss function for the RT-DETR, YOLOv10 and YOLOv12 models

В контексте задач одноклассовой детекции метрика Precision вычисляется для порогового значения confidence threshold, который определяет минимальную вероятность, при которой детекция считается валидной. Метрика Precision определяется по

$$\text{Precision} = \frac{TP}{TP + FP}, \quad (7)$$

где TP – количество корректно обнаруженных объектов целевого класса; FP –

число ложных срабатываний, т. е. случаев, когда модель ошибочно идентифицировала фоновый элемент как объект интереса [17].

Значение метрики принадлежит интервалу от 0 до 1, где 1 соответствует идеальному сценарию отсутствия ложных детекций. Рассмотрим графики метрики Precision для HM RT-DETR, YOLOv10 и YOLOv12, рассчитанные на валидационной выборке ниже (рис. 3).




Рис. 3. Графики оценки качества классификации Precision для HM RT-DETR, YOLOv10 и YOLOv12

Fig. 3. Graphs of the Precision classification quality assessment for the RT-DETR, YOLOv10 and YOLOv12 models

Метрика оценки качества классификации Recall определяется по

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (8)$$

где FN – число пропущенных объектов, т. е. случаев, когда номерной знак присутствовал на изображении, но модель не смогла его идентифицировать [17].

Значение метрики принадлежит интервалу от 0 до 1, где 1 соответствует идеальному сценарию обнаружения всех объектов без исключения. Графики метрики Recall для HM RT-DETR, YOLOv10 и YOLOv12, рассчитанные на валидационной выборке, представлены ниже (рис. 4).




Рис. 4. Графики оценки качества классификации Recall для HM RT-DETR, YOLOv10 и YOLOv12

Fig. 4. Graphs of the Recall classification quality assessment for the RT-DETR, YOLOv10 and YOLOv12 models

Метрика $mAP_{0,5:0,95}$ (mean Average Precision (AP)) представляет собой среднее арифметическое значений пло-

щадей под кривой Precision-Recall для каждого класса при порогах IoU от 0,5 до 0,95 и рассчитывается по

$$mAP_{0,5:0,95} = \frac{(mAP_{0,5} + mAP_{0,55} + mAP_{0,6} + \dots + mAP_{0,95})}{10}, \quad (9)$$

где $mAP_{0,5}$, $mAP_{0,55}$, $mAP_{0,6}$ и т. д. – это значения mAP, рассчитанные для каждого отдельного порога IoU в диапазоне от 0,5 до 0,95 с шагом 0,05; 10 – количество порогов IoU, по которым производится усреднение.

Графики метрики $mAP_{0,5:0,95}$ для НМ RT-DETR, YOLOv10 и YOLOv12, рассчитанные на валидационной выборке, представлены ниже (рис. 5).




Рис. 5. Графики метрики $mAP_{0,5:0,95}$ для НМ RT-DETR, YOLOv10 и YOLOv12

Fig. 5. Graphs of the $mAP_{0,5:0,95}$ metric for the RT-DETR, YOLOv10, and YOLOv12 models

Проведенный сравнительный анализ метрик качества указывает на целесообразность использования НМ YOLOv12 в качестве детектора ГРЗ ТС в предлагаемом гибридном методе. НМ продемонстрировала лучшие результаты по наиболее важным метрикам ($Precision = 0,99$, $Recall = 0,98$ и $mAP_{0,5:0,95} = 0,91$), что свидетельствует о высокой полноте обнаружения ГРЗ ТС при практически полном отсутствии ложных срабатываний. Для реализации

полного цикла обработки видеопотока, включающего не только обнаружение ГРЗ ТС, но и распознавание символов на них, модель детекции была интегрирована с библиотекой оптического распознавания символов EasyOCR, в основе которой лежат глубокие НС, предобученные в т. ч. на кириллических символах.

Рассмотрим блок-схему алгоритма работы гибридного метода распознавания ГРЗ ТС (рис. 6).




Рис. 6. Блок-схема алгоритма работы гибридного метода распознавания ГРЗ

Fig. 6. Block diagram of the algorithm for the recognition of state registration plates

Предлагаемый гибридный метод можно описать следующим образом:

Этап 1. Загрузка кадра из видеопотока.

Этап 2. Инференс НМ YOLO (первичное обнаружение объектов в кадре, в ходе которого предсказанные ОР с показателем уверенности выше порогового значения рассматриваются как кандидаты для последующей проверки наличия целевого объекта).

Этап 3. Проверка присутствия ГРЗ ТС в кадре. Если ГРЗ ТС отсутствует в кадре, то выводится результат «ГРЗ ТС отсутствует в кадре» и происходит переход к следующему кадру видеопотока, в случае присутствия ГРЗ ТС в кадре – переход к этапу 4.

Этап 4. Выбор ОР с наивысшим значением показателя уверенности.

Этап 5. Обрезка области вокруг ГРЗ ТС с заданным отступом PAD_RATIO (PAD_RATIO = 0,15).

Этап 6. Многовариантная предобработка вырезанной области для OCR. На данном этапе выполняется последовательное конвейерное преобразование вырезанного изображения, результатом которого являются 9 отдельных изображений, полученных на разных этапах конвейера.

Этап 6.1. Преобразование в оттенки серого – процедура, исключаяющая влияние цветовой информации на последующие этапы.

Этап 6.2. Адаптивное масштабирование. Если высота изображения h менее 100 пикселей, то к нему применяется увеличение с коэффициентом $scale$ с использованием бикубической интерполяции по

$$scale = \begin{cases} 1, & \text{если } h \geq 100, \\ \max\left(2, \frac{120}{h}\right), & \text{если } h < 100. \end{cases} \quad (10)$$

При этом порог масштабирования (100 пикселей по высоте) соответствует минимальному разрешению, при котором стандартные шрифты номерных знаков сохраняют распознаваемую структуру.

Этап 6.3. Улучшение контраста методом CLAHE (Contrast Limited Adaptive Histogram Equalization). Для компенсации неравномерного освещения и низкого контраста применяется метод адаптивного выравнивания гистограммы с ограничением контраста. Параметры алгоритма эмпирически оптимизированы: порог ограничения гистограммы clipLimit = 2,5 и размер локальной области tileGridSize = (8,8).

Этап 6.4. Повышение резкости. Применяется для коррекции эффектов расфокусировки и движения с использованием метода нерезкой маски (Unsharp Masking) в комбинации с гауссовым размытием.

Этап 6.5. Подавление шума. Применяется для подавления аддитивного шума, характерного для съемки в условиях низкой освещенности, с использованием алгоритма нелокального среднего (Non-Local Means Denoising), позволяющего корректно сохранять структурные детали (края символов).

Этап 6.6. Адаптивная бинаризация. На данном этапе сегментация текста выполняется с помощью адаптивного порогового преобразования по методу Гаусса с размером окна 15 пикселей и константой сдвига равной 5.

Этап 6.7. Морфологическое закрытие. Для устранения мелких разрывов в символах, которые могут возникать вследствие бинаризации или дефектов поверхности ГРЗ ТС, применяется морфологическое закрытие. Морфологиче-

ское закрытие – это комбинация дилатации и эрозии, применяемая последовательно. Оно используется для того, чтобы закрыть маленькие отверстия и соединить близлежащие объекты. Дилатация – это операция, которая увеличивает область белых пикселей на изображении. При применении этой операции к изображению каждый пиксель обходится структурирующим элементом (ядром). Структурирующий элемент – это небольшая матрица (ядро), которая используется в морфологической обработке изображений для определения способа изменения этих изображений. При попадании пикселя в центр области, определяемой ядром, он заменяется значением максимума в этой области. Эрозия – это обратная операция дилатации, она уменьшает объекты на изображении. При применении эрозии каждый пиксель заменяется минимумом в области, определяемой ядром. Пиксель остается белым только в том случае, если все пиксели в области под ядром также белые¹.

Сначала изображение подвергается дилатации (11), а затем – эрозии (12) с использованием одного и того же значения ядра (размер ядра (kernel) = 2×2 пикселя). Морфологическое закрытие можно описать с помощью (13):

$$D(I) = \max_{\delta \in \text{kernel}} I(x + \delta_x, y + \delta_y), \quad (11)$$

$$E(I) = \min_{\delta \in \text{kernel}} I(x + \delta_x, y + \delta_y), \quad (12)$$

$$C(I) = E(D(I)) = E\left(\max_{\delta \in \text{kernel}} I(x + \delta_x, y + \delta_y)\right), \quad (13)$$

где I – это исходное изображение; (x, y) – координаты центра пикселя; δ – смещение по элементам ядра; kernel – ядро [18].

Этап 6.8. Бинаризация с помощью метода Оцу с предварительным применением фильтра Гаусса (размер ядра (kernel) = 5×5).

Этап 6.9. Инверсия – создание инвертированных версий бинаризованных изображений из этапов 6.6 и 6.8.

Этап 6.10. Гамма-коррекция – коррекция яркости с целью выполнить умеренное осветление изображения без потери информации в светлых участках ($\gamma = 1,3$).

Этап 6.11. Формирование вариантов для обработки. На данном этапе происходит генерация девяти вариантов альтернативных представлений исходного изображения для последующей обработки: *original/upscaled* – базовое изображение в градациях серого; *clahe* – вариант с улучшенным локальным контрастом; *sharpened* – изображение с повышенной резкостью; *denoised* – версия с подавленным шумом; *binary* – адаптивно бинаризованное изображение с морфологической обработкой; *otsu* – бинаризованное изображение по методу Оцу; *inverted* – инвертированный бинаризованный вариант; *otsu_inv* – инвертированное бинаризованное изображение по методу Оцу; *gamma* – изображение с коррекцией яркости.

Этап 7. Применение OCR с ограниченным набором символов для каждого из девяти вариантов предобработки. На данном этапе выполняется распознавание символов на каждом из девяти по-

¹ Киселев А. В., Филист С. А., Шаталова О. В. Методы обработки, анализа и классификации медико-биологических сигналов и данных: учебное пособие. Старый Оскол: Тонкие наукоемкие технологии, 2023. 328 с.

лученных вариантов предобработки с помощью EasyOCR с установленным ограничением набора допустимых для распознавания символов. Для уменьшения вероятности ошибок OCR набор допустимых символов ограничен только теми символами, которые допустимы в российских ГРЗ ТС, а именно цифрами от 0 до 9 и кириллическими буквами А, В, Е, К, М, Н, О, Р, С, Т, У, Х, а также их аналогами в латинском алфавите.

Этап 8. Форматирование распознанного текста, включающее в себя перевод в верхний регистр и замену похожих символов в соответствии с таблицей замен.

Этап 9. Проверка соответствия формату. На данном этапе производится проверка соответствия формата распознанного текста формату российского ГРЗ ТС (буква, три цифры, две буквы, две или три цифры). Также на данном этапе происходит исправление типичных ошибок распознавания, например, если на месте буквы распознана цифра или наоборот (например, «В» и «8»), замена символов в определенных пози-

циях, если это необходимо для соответствия формату. Среди всех вариантов выбирается лучший по значению уверенности результат, который соответствует формату номера, либо, если таких нет, то лучший по значению уверенности результат. Если результат полностью соответствует формату, то он сохраняется как валидный, в случае несоответствия формату – сохраняется резервный вариант с наивысшим значением показателя уверенности.

Этап 10. Визуализация лучшего результата OCR. На данном этапе происходит визуализация предсказанных ОР на исходном изображении, создание коллажа из исходного изображения с предсказанными ОР и лучшего результата OCR, сохранение коллажа и запись данных в CSV-файл.

Результаты и их обсуждение

Рассмотрим пример многовариантной предобработки вырезанной области для генерации девяти вариантов альтернативных представлений исходного изображения (рис. 7).



Рис. 7. Пример многовариантной предобработки вырезанной области для генерации девяти вариантов альтернативных представлений исходного изображения

Fig. 7. An example of multivariate preprocessing of a cut-out area to generate nine alternative representations of the original image

На рисунке 8 представлены результаты тестирования гибридного метода распознавания ГРЗ ТС на тестовом наборе данных. При тестировании ис-

пользовались кадры, сделанные при различных уровнях освещения и различной степени зашумленности.



Рис. 8. Результаты тестирования реализованного гибридного метода распознавания ГРЗ ТС

Fig. 8. Results of testing the implemented hybrid method of license plate recognition

Оценка эффективности OCR-метода оценивалась путем сравнения распознанного текста с эталонным с использованием количественных метрик, таких как CRR (Character Recognition Rate), определяемой по (14) и PRR (Plate Recognition Rate), являющейся отраслевым аналогом метрики WRR (Word Recognition Rate), определяемой по (15).

$$CRR = \frac{\sum N_{total} - (\sum S + \sum D + \sum I)}{\sum N_{total}}, \quad (14)$$

где N_{total} – общее количество символов во всех эталонных номерах тестового набора данных; $\sum S + \sum D + \sum I$ – суммарное количество замен (S), пропусков (D) и лишних символов (I) по всему тестовому набору данных.

$$PRR = \frac{P_{correct}}{P_{total}}, \quad (15)$$

где $P_{correct}$ – общее количество номерных пластин, где каждый символ совпал с эталоном (CRR для этого номера равен 1); P_{total} – общее количество номерных пластин в тестовой выборке.

Значения данных метрик у современных САР ГРЗ ТС, в т. ч. коммерческих, лежат в диапазонах от 96,0 до 100,0 % для CRR и от 92,2 до 99,9 % для PRR [19]. Полученные на тестовом наборе данных значения метрик CRR и PRR для предложенного гибридного метода распознавания ГРЗ ТС равны 99,0 и 98,5 % соответственно. Попадание значений данных метрик в верхние границы представленных выше диапазонов указывает на конкурентоспособность предложенного гибридного метода распознавания ГРЗ ТС.

Выводы

В рамках проведенного исследования предложен и апробирован гибридный метод распознавания ГРЗ ТС на основе конвейерной архитектуры YOLOv12 – EasyOCR. Был синтезирован уникальный обучающий НД, сформированный на основе видеоматериалов, полученных с камер наблюдения, установленных на автомобильных дорогах и объектах транспортной инфраструктуры. Для обеспечения макси-

мальной вариативности данных для формирования НД были использованы записи, сделанные при различных условиях освещенности и погоды, включая дождь, снег и туман, которые вносят естественные искажения и шумы. При покадровой разбивке собранных видеофрагментов осуществлялась фильтрация полученных изображений (из общего потока исключались кадры с чрезмерным размытием или полным перекрытием ГРЗ ТС, не несущие полезной информации для обучения НМ).

Проведен сравнительный анализ детекторов (YOLOv10, YOLOv12, RT-DETR), подтверждающий целесообразность использования модели YOLOv12, продемонстрировавшей наилучшие показатели наиболее важных метрик (Precision = 0,99, Recall = 0,98 и $mAP_{0,5:0,95} = 0,91$).

Разработан многовариантный конвейер предобработки изображений для OCR, выполняющий последовательное преобразование вырезанного изображе-

ния, включающее адаптивное масштабирование, улучшение контраста, шумоподавление и морфологические операции, позволяющий повысить устойчивость распознавания к неконтролируемым условиям внешней среды. Результатом многовариантной предобработки вырезанной области для OCR являются 9 отдельных изображений, полученных на разных этапах конвейера.

Для минимизации типичных ошибок OCR был использован ограниченный набор допустимых символов и реализован алгоритм проверки соответствия российскому формату ГРЗ ТС.

Экспериментальная валидация предложенного гибридного метода распознавания ГРЗ ТС подтвердила его высокую эффективность (получены значения количественных метрик $mAP_{0,5:0,95} = 0,91$, CRR = 99,0 %, PRR = 98,5 %), что свидетельствует о способности метода к обеспечению устойчивого распознавания в условиях реальной эксплуатации.

Список литературы

1. Ma Y., Mészáros F. Review of Urban Access Regulations from the Sustainability Viewpoint // *Urban Science*. 2024. Vol. 8, N 2. P. 29 1–18. <https://doi.org/10.3390/urbansci8020029>.
2. Smart Parking Systems: Reviewing the Literature, Architecture and Ways Forward / C. Biyik, Z. Allam, G. Pieri, D. Moroni, M. Fraifer, E. O'Connell, S. Olariu, M. Khalid // *Smart Cities*. 2021. Vol. 4. P. 623–642. <https://doi.org/10.3390/smartcities4020032>.
3. Human Factor Analysis of the Railway Traffic Operators / A. Janota, R. Pirník, J. Ždánsky, P. Nagy // *Machines*. 2022. Vol. 10, N 9. P. 820. <https://doi.org/10.3390/machines10090820>.
4. Rai R., Shitole S., Sutar P., Kaldhone S., Jadhav J. D. Automatic License Plate Recognition Using YOLOv4 and Tesseract OCR // *International Journal of Innovative Research in Computer and Communication Engineering*. 2022. Vol. 10, N 3. P. 1656. <https://doi.org/10.15680/IJIRCCE.2022.1003089>.

5. Automated License Plate Recognition: A Survey on Methods and Techniques / J. Shashirangana, H. Padmasiri, D. Meedeniya, C. Perera // IEEE Access. 2021. Vol. 9. P. 11203–11225. <https://doi.org/10.1109/ACCESS.2020.3047929>.

6. Брежнев А. В., Томакова Р. А., Брежнева А. Н. Информационная система мониторинга на основе интеллектуальной классификации изображений видеопотоков // Информационное общество. 2023. № 5. С. 134–142. https://doi.org/10.52605/16059921_2023_05_134.

7. Saha U., Saha B., Imran M. A Weather-Adaptive Convolutional Neural Network Framework for Better License Plate Detection // Sensors. 2024. Vol. 24, N 23. P. 7841. <https://doi.org/10.3390/s24237841>.

8. Automated License Plate Recognition for Resource-Constrained Environments / H. Padmasiri, J. Shashirangana, D. Meedeniya, O. Rana, C. Perera // Sensors. 2022. Vol. 22, N 4. P. 1434. <https://doi.org/10.3390/s22041434>.

9. Бобырь М. В., Емельянов С. Г., Милостная Н. А. Разработка программной модели для распознавания символов на номерных знаках автомобиля // Искусственный интеллект и принятие решений. 2025. № 2. С. 142–156. <https://doi.org/10.14357/20718594250212>. EDN KNUYFN.

10. License plate recognition system for complex scenarios based on improved YOLOv5s and LPRNet / X. Wang, M. Wang, H. Guo, J. Li, X. Wang, Y. Zhang // Scientific Reports. 2025. Vol. 15. P. 10052. <https://doi.org/10.1038/s41598-025-18311-4>.

11. Automatic Vehicle License Number Plate Recognition System Using Tesseract OCR & OpenCV / K. N. Chandan, K. Sahana, M. Tharun Gowda, S. M. Darshan, M. Arunkumar // International Advanced Research Journal in Science, Engineering and Technology. 2025. Vol. 12, N 5. <https://doi.org/10.17148/IARJSET.2025.12590>.

12. Sainui J., Thepporn C., Chusuwan P. Thai License Plate Recognition using SSD MobileNet and EasyOCR // Proceedings of the 2024 6th International Conference on Image Processing and Machine Vision (IPMV '24). New York: ACM, 2024. P. 36–41. <https://doi.org/10.1145/3645259.3645266>.

13. License plate detection using YOLO v4 / R. Rathi, A. Sharma, N. Baghel, P. Channe, S. Barve, S. Jain // International Journal of Health Sciences. 2022. Vol. 6, N S2. P. 9456–9462. <https://doi.org/10.53730/ijhs.v6nS2.7475>.

14. Киселев А. В., Брусенцев Н. С., Кулешова Е. А. Анализ эффективности применения двухэтапных нейросетевых моделей для раннего обнаружения лесных пожаров // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 1. С. 8–23. <https://doi.org/10.21869/2223-1536-2024-14-1-8-23>.

15. Stodt J., Reich C., Clarke N. Unified intersection over union for explainable artificial intelligence // Intelligent Systems and Applications. 2024. Vol. 2. P. 758–770. https://doi.org/10.1007/978-3-031-47724-9_50.

16. Generalized Focal Loss: Towards Efficient Representation Learning for Dense Object Detection / X. Li, C. Lv, W. Wang, G. Li, L. Yang, J. Yang // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2023. Vol. 45, N 3. P. 3139–3153. <https://doi.org/10.1109/TPAMI.2022.3180392>.

17. Оценка эффективности модели глубокого обучения на основе EfficientNetB3 для дифференциальной диагностики стадий болезни Альцгеймера / А. В. Киселев, Е. А. Кулешова, М. О. Таныгин, П. М. Свинухов, И. А. Халин // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2025. Т. 15, № 4. С. 192–210. <https://doi.org/10.21869/2223-1536-2025-15-4-192-210>.

18. Метод контроля доступа и мониторинга соблюдения техники безопасности на энергетических хозяйствах предприятий на основе конвейерной нейросетевой модели / А. В. Киселев, Н. С. Брусенцев, Е. А. Кулешова, Д. А. Ермаков // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2024. Т. 14, № 4. С. 28–46. <https://doi.org/10.21869/2223-1536-2024-14-4-28-46>.

19. Advancing Multinational License Plate Recognition Through Synthetic and Real Data Fusion: A Comprehensive Evaluation / R. Laroca, V. Estevam, G. J. P. Moreira, R. Minetto, D. Menotti // *IET Intelligent Transport Systems*. 2025. Vol. 19, N 1. P. e70086. <https://doi.org/10.1049/itr2.70086>.

References

1. Ma Y., Mészáros F. Review of Urban Access Regulations from the Sustainability Viewpoint. *Urban Science*. 2024;8(2):1-18. <https://doi.org/10.3390/urbansci8020029>.

2. Biyik C., Allam Z., Pieri G., Moroni D., Fraifer M., O'Connell E., Olariu S., Khalid M. Smart Parking Systems: Reviewing the Literature, Architecture and Ways Forward. *Smart Cities*. 2021;4:623-642. <https://doi.org/10.3390/smartcities4020032>.

3. Janota A., Pirník R., Ždánsky J., Nagy P. Human Factor Analysis of the Railway Traffic Operators. *Machines*. 2022;10(9):820. <https://doi.org/10.3390/machines10090820>.

4. Rai R., Shitole S., Sutar P., Kaldhone S., Jadhav J.D. Automatic License Plate Recognition Using YOLOv4 and Tesseract OCR. *International Journal of Innovative Research in Computer and Communication Engineering*. 2022;10(3):1656. <https://doi.org/10.15680/IJIRCCCE.2022.1003089>.

5. Shashirangana J., Padmasiri H., Meedeniya D., Perera C. Automated License Plate Recognition: A Survey on Methods and Techniques. *IEEE Access*. 2021;9:11203-11225. <https://doi.org/10.1109/ACCESS.2020.3047929>.

6. Brezhnev A.V., Tomakova R.A., Brezhneva A.N. Information monitoring system based on intelligent classification of video stream images. *Informatsionnoye obshchestvo = Information Society*. 2023;5:134-142. (In Russ.) https://doi.org/10.52605/16059921_2023_05_134.

7. Saha U., Saha B., Imran M.A Weather-Adaptive Convolutional Neural Network Framework for Better License Plate Detection. *Sensors*. 2024;24(23):7841. <https://doi.org/10.3390/s24237841>.

8. Padmasiri H., Shashirangana J., Meedeniya D., Rana O., Perera C. Automated License Plate Recognition for Resource-Constrained Environments. *Sensors*. 2022;22(4):1434. <https://doi.org/10.3390/s22041434>.

9. Bobyr M.V., Emelyanov S.G., Milostnaya N.A. Development of a software model for character recognition on vehicle license plates. *Iskusstvennyy intellekt i prinyatiye resheniy = Artificial Intelligence and Decision Making*. 2025;(2):142-156. (In Russ.) <https://doi.org/10.14357/20718594250212>.

10. Wang X., Wang M., Guo H., Li J., Wang X., Zhang Y. License plate recognition system for complex scenarios based on improved YOLOv5s and LPRNet. *Scientific Reports*. 2025;15:10052. <https://doi.org/10.1038/s41598-025-18311-4>.

11. Chandan K.N., Sahana K., Tharun Gowda M., Darshan S.M., Arunkumar M. Automatic Vehicle License Number Plate Recognition System Using Tesseract OCR & OpenCV. *International Advanced Research Journal in Science, Engineering and Technology*. 2025;12(5). <https://doi.org/10.17148/IARJSET.2025.12590>.

12. Sainui J., Thepporn C., Chusuwan P. Thai License Plate Recognition using SSD MobileNet and EasyOCR. In: *Proceedings of the 2024 6th International Conference on Image Processing and Machine Vision (IPMV '24)*. New York: ACM; 2024. P. 36-41. <https://doi.org/10.1145/3645259.3645266>.

13. Rath R., Sharma A., Baghel N., Channe P., Barve S., Jain S. License plate detection using YOLO v4. *International Journal of Health Sciences*. 2022;6(S2):9456-9462. <https://doi.org/10.53730/ijhs.v6nS2.7475>.

14. Kiselev A.V., Brusentsev N.S., Kuleshova E.A. Analysis of the efficiency of using two-stage neural network models for early detection of forest fires. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravleniye, vychislitel'naya tekhnika, informatika. Meditsinskoye priborostroyeniye = Proceedings of the Southwest State University. Series: Management, Computer Engineering, Computer Science. Medical Instrumentation*. 2024;14(1):8-23. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-1-8-23>.

15. Stodt J., Reich C., Clarke N. Unified intersection over union for explainable artificial intelligence. *Intelligent Systems and Applications*. 2024;2:758-770. https://doi.org/10.1007/978-3-031-47724-9_50.

16. Li X., Lv C., Wang W., Li G., Yang L., Yang J. Generalized Focal Loss: Towards Efficient Representation Learning for Dense Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2023;45(3):3139-3153. <https://doi.org/10.1109/TPAMI.2022.3180392>.

17. Kiselev A.V., Kuleshova E.A., Tanygin M.O., Svinukhov P.M., Khalin I.A. Evaluation of the effectiveness of a deep learning model based on EfficientNetB3 for differential diagnosis of Alzheimer's disease stages. *Izvestiya Yugo-Zapadnogo gosudarstvennogo uni-*

versiteta. *Seriya: Upravleniye, vychislitel'naya tekhnika, informatika. Meditsinskoye priborostroyeniye = Proceedings of the Southwest State University. Series: Management, Computer Engineering, Computer Science. Medical Instrumentation.* 2025;15(4):192-210. (In Russ.) <https://doi.org/10.21869/2223-1536-2025-15-4-192-210>.

18. Kiselev A.V., Brusentsev N.S., Kuleshova E.A., Ermakov D.A. Method of access control and safety monitoring at energy facilities of enterprises based on a conveyor neural network model. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravleniye, vychislitel'naya tekhnika, informatika. Meditsinskoye priborostroyeniye = Proceedings of the South-West State University. Series: Management, Computer Engineering, Computer Science. Medical Instrumentation.* 2024;14(4):28-46. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-4-28-46>.

19. Laroca R., Estevam V., Moreira G.J.P., Minetto R., Menotti D. Advancing Multinational License Plate Recognition Through Synthetic and Real Data Fusion: A Comprehensive Evaluation. *IET Intelligent Transport Systems.* 2025;19(1):e70086. (In Russ.) <https://doi.org/10.1049/itr2.70086>.

Информация об авторах / Information about the Authors

Киселев Алексей Викторович, кандидат технических наук, доцент кафедры вычислительной техники, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: kiselevalexey1990@gmail.com, ORCID: 0000-0001-7228-0281

Alexey V. Kiselev, Cand. Sci. (Engineering), Associate Professor at the Department Computers, Southwest State University, Kursk, Russian Federation, e-mail: kiselevalexey1990@gmail.com, ORCID: 0000-0001-7228-0281.

Кулешова Елена Александровна, кандидат технических наук, доцент кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: lena.kuleshova.94@mail.ru, ORCID: 0000-0002-8270-564X

Elena A. Kuleshova, Cand. Sci. (Engineering), Associate Professor at the Department Information Security, Southwest State University, Kursk, Russian Federation, e-mail: lena.kuleshova.94@mail.ru, ORCID: 0000-0002-8270-564X

Таныгин Максим Олегович, доктор технических наук, доцент, профессор кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: tanygin@yandex.ru, ORCID: 0000-0002-4099-1414

Maxim O. Tanygin, Dr. Sci. (Engineering), Associate Professor, Professor at the Department Information Security, Southwest State University, Kursk, Russian Federation, e-mail: tanygin@yandex.ru, ORCID: 0000-0002-4099-1414

Конаныхина Татьяна Николаевна, кандидат технических наук, доцент, доцент кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: govtn@mail.ru, ORCID: 0000-0002-2755-0163

Tatyana N. Konanykhina, Cand. Sci. (Engineering), Associate Professor, Associate Professor at the Department Software Engineering, Southwest State University, Kursk, Russian Federation, e-mail: govtn@mail.ru, ORCID: 0000-0002-2755-0163

Чьямова Зоя Константиновна, студент кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: zoyachyamova@gmail.com, ORCID: 0009-0000-7734-052X

Zoya K. Chyamova, Student at the Department of Information Security, Southwest State University, Kursk, Russian Federation, e-mail: zoyachyamova@gmail.com, ORCID: 0009-0000-7734-052X