

## СОЗДАНИЕ СИСТЕМЫ ИДЕНТИФИКАЦИИ ТРАНСПОРТНЫХ СРЕДСТВ В РЕЖИМЕ РЕАЛЬНОГО ВРЕМЕНИ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

**Низамова Зарина Файзиддиновна**

*Бухарский государственный технический университет, магистрант 1-го курса специальности «Программный инжиниринг»*

**Аннотация.** В данной статье рассматриваются вопросы проектирования и создания системы идентификации транспортных средств в режиме реального времени на основе методов искусственного интеллекта. Исследуются современные подходы к распознаванию автомобилей, включая свёрточные нейронные сети (CNN), архитектуры YOLO и SSD для обнаружения объектов, а также методы оптического распознавания символов (OCR) для считывания государственных регистрационных номеров. Предлагается архитектура комплексной системы, способной в реальном времени обнаруживать, классифицировать и идентифицировать транспортные средства по видеопотоку с камер наблюдения. Проведены экспериментальные исследования, подтверждающие высокую точность и производительность предлагаемого решения.

**Ключевые слова:** идентификация транспортных средств, искусственный интеллект, компьютерное зрение, свёрточные нейронные сети, YOLO, распознавание номерных знаков, OCR, обработка видеопотока, глубокое обучение, система реального времени, обнаружение объектов, интеллектуальная транспортная система.

### **Введение**

В условиях стремительной урбанизации и роста автомобильного парка задача автоматической идентификации транспортных средств приобретает всё большую актуальность. По данным Международной организации производителей автомобилей (OICA), мировой автопарк превысил 1,4 миллиарда единиц, что создаёт значительные нагрузки на транспортную инфраструктуру и системы безопасности. Традиционные методы контроля дорожного движения, основанные на ручном наблюдении и простых датчиках, уже не способны обеспечить необходимый уровень эффективности и оперативности.

Развитие технологий искусственного интеллекта, в особенности глубокого обучения и компьютерного зрения, открывает принципиально новые возможности для решения данной проблемы. Современные нейросетевые архитектуры позволяют с высокой точностью обнаруживать, классифицировать и идентифицировать транспортные средства по видеопотоку в режиме реального

времени. Такие системы находят применение в различных областях: от управления дорожным движением и контроля парковок до обеспечения общественной безопасности и автоматизации платных дорог.

В Республике Узбекистан вопросы интеллектуализации транспортной инфраструктуры получили особое внимание в рамках государственных программ цифровой трансформации. Указ Президента Республики Узбекистан «О стратегии «Цифровой Узбекистан — 2030»» определяет развитие интеллектуальных транспортных систем как одно из приоритетных направлений. Внедрение систем автоматической идентификации транспортных средств является важным компонентом данной стратегии, способствующим повышению безопасности дорожного движения и эффективности управления транспортными потоками.

Целью настоящей работы является разработка архитектуры и программной реализации системы идентификации транспортных средств в режиме реального времени с использованием современных методов искусственного интеллекта. Для достижения данной цели были поставлены следующие задачи: анализ существующих подходов к идентификации транспортных средств, разработка архитектуры комплексной системы, выбор и адаптация нейросетевых моделей, проведение экспериментальных исследований и оценка эффективности предлагаемого решения.

### **Обзор существующих подходов к идентификации транспортных средств**

Задача идентификации транспортных средств имеет многолетнюю историю исследований. Ранние подходы основывались на классических методах компьютерного зрения, таких как извлечение признаков Хаара, гистограммы направленных градиентов (HOG) и метод опорных векторов (SVM). Несмотря на определённые успехи, данные методы характеризовались недостаточной устойчивостью к изменениям освещения, ракурса и частичным перекрытиям объектов.

Революционным прорывом стало появление глубоких свёрточных нейронных сетей (CNN). Архитектуры AlexNet, VGGNet и ResNet продемонстрировали выдающиеся результаты в задачах классификации изображений, значительно превзойдя традиционные методы. Для задач обнаружения объектов были разработаны специализированные архитектуры двух основных типов: двухстадийные детекторы, такие как R-CNN, Fast R-CNN и Faster R-CNN, обеспечивающие высокую точность, но требующие значительных вычислительных ресурсов, и одностадийные детекторы, такие как YOLO (You Only Look Once) и SSD (Single Shot MultiBox Detector), обеспечивающие обработку в режиме реального времени при незначительном снижении точности.

Семейство моделей YOLO представляет особый интерес для систем реального времени. Начиная с первой версии, предложенной Дж. Редмоном в 2016 году,

архитектура YOLO прошла значительную эволюцию. Версия YOLOv5, разработанная компанией Ultralytics, стала стандартом де-факто для многих практических применений благодаря оптимальному соотношению точности и скорости. Последующие версии YOLOv7 и YOLOv8 продолжили тенденцию к повышению производительности, достигая точности mAP@0.5 более 50 процентов на наборе данных COCO при скорости обработки свыше 100 кадров в секунду на современных графических процессорах.

Параллельно с развитием методов обнаружения объектов активно совершенствовались технологии распознавания государственных регистрационных номеров (ANPR/ALPR). Современные системы ANPR используют многоэтапный подход: локализация номерной пластины на изображении, сегментация символов и их распознавание. Для распознавания символов широко применяются рекуррентные нейронные сети (RNN) в сочетании с механизмом коннекционистской временной классификации (CTC), а также модели на основе архитектуры Transformer. Исследования показывают, что точность распознавания номерных знаков достигает 95–99 процентов в благоприятных условиях и 85–92 процентов в сложных сценариях, включающих ночное освещение, неблагоприятные погодные условия и нестандартные углы обзора.

Помимо распознавания номерных знаков, существуют методы идентификации транспортных средств по их визуальным характеристикам: марке, модели, цвету и типу кузова. Такие системы особенно полезны в случаях, когда номерной знак не виден или повреждён. Для решения данной задачи используются архитектуры глубоких нейронных сетей, предварительно обученные на больших наборах данных, таких как CompCars и Stanford Cars Dataset. Точность классификации марки и модели автомобиля в современных работах достигает 93–97 процентов.

#### **Архитектура предлагаемой системы**

Предлагаемая система идентификации транспортных средств представляет собой многомодульную программную платформу, объединяющую несколько взаимосвязанных компонентов. Архитектура системы построена по принципу конвейерной обработки данных, что обеспечивает высокую производительность и масштабируемость.

Первый модуль системы отвечает за захват и предварительную обработку видеопотока. Данный модуль осуществляет подключение к камерам видеонаблюдения по протоколам RTSP или HTTP, декодирование видеопотока, коррекцию геометрических искажений, адаптивную нормализацию яркости и контраста, а также формирование пакетов кадров для подачи на вход нейросетевых моделей. Для повышения производительности используется многопоточная обработка с разделением задач захвата и анализа между различными потоками исполнения.

Второй модуль реализует функцию обнаружения и классификации транспортных средств. В качестве базовой модели используется архитектура YOLOv8, доработанная для специфики задачи. Модель обнаруживает транспортные средства на кадре, определяет их тип (легковой автомобиль, грузовик, автобус, мотоцикл, специальный транспорт) и формирует ограничивающие прямоугольники (bounding boxes) для каждого обнаруженного объекта. Для повышения точности отслеживания объектов между кадрами используется алгоритм DeepSORT, объединяющий фильтр Калмана с глубокими метриками внешнего вида.

Третий модуль осуществляет распознавание государственных регистрационных номеров. Процесс включает три последовательных этапа: детекция области номерного знака с использованием специализированной модели YOLO, выравнивание и нормализация изображения номерной пластины с применением перспективного преобразования, распознавание символов на основе модели CRNN (Convolutional Recurrent Neural Network) с механизмом CTC-декодирования. Данный модуль адаптирован для распознавания номерных знаков стандартов различных стран, включая стандарты Республики Узбекистан.

Четвёртый модуль реализует классификацию транспортных средств по визуальным признакам: марке, модели и цвету. Для определения марки и модели используется свёрточная нейронная сеть на базе архитектуры EfficientNet-B4, дообученная на расширенном наборе данных, включающем более 200 марок и 1500 моделей автомобилей. Определение цвета осуществляется на основе анализа цветовых гистограмм в пространстве HSV с применением кластеризации методом k-средних.

Пятый модуль представляет собой центральную подсистему управления данными и принятия решений. Данный модуль объединяет результаты работы всех предыдущих модулей, осуществляет поиск идентифицированных транспортных средств по базе данных, формирует итоговую карточку транспортного средства, включающую все собранные параметры, обеспечивает хранение данных и формирование отчётов, реализует интерфейс взаимодействия с оператором и интеграцию с внешними информационными системами.

Для обеспечения работы в режиме реального времени архитектура системы предусматривает использование графических процессоров (GPU) для ускорения нейросетевых вычислений. Применяется фреймворк NVIDIA TensorRT для оптимизации моделей, что позволяет достичь скорости обработки не менее 25 кадров в секунду при разрешении 1920 на 1080 пикселей на одном графическом процессоре NVIDIA RTX 3080.

#### **Методы и алгоритмы идентификации**

Ключевым элементом предлагаемой системы является нейросетевая модель обнаружения объектов на основе архитектуры YOLOv8. Данная архитектура

представляет собой одностадийный детектор, который обрабатывает входное изображение за один проход через сеть, что обеспечивает высокую скорость работы. Архитектура YOLOv8 включает три основных компонента: магистральную сеть (backbone) на основе CSPDarknet для извлечения иерархических признаков, шею (neck) на основе модуля PANet для агрегации признаков различных масштабов и голову (head), формирующую предсказания ограничивающих прямоугольников и классов объектов.

Для обучения модели обнаружения транспортных средств был подготовлен специализированный набор данных, включающий более 50 000 аннотированных изображений транспортных средств, снятых в различных условиях: дневное и ночное время, различные погодные условия (ясно, дождь, снег, туман), различные углы обзора камер, городские и загородные дороги. Аугментация данных включала геометрические преобразования (поворот, масштабирование, сдвиг), фотометрические преобразования (изменение яркости, контраста, насыщенности), мозаичную аугментацию и случайное стирание.

Распознавание государственных регистрационных номеров реализовано на основе архитектуры CRNN, объединяющей свёрточные слои для извлечения визуальных признаков и рекуррентные слои на базе двунаправленных LSTM для моделирования последовательных зависимостей между символами. Функция потерь CTC (Connectionist Temporal Classification) позволяет обучать модель без необходимости точной сегментации отдельных символов, что значительно упрощает подготовку обучающих данных.

Алгоритм отслеживания DeepSORT обеспечивает непрерывное отслеживание транспортных средств между последовательными кадрами видеопотока. Алгоритм использует фильтр Калмана для предсказания положения объекта на следующем кадре и метрику глубокого внешнего вида для ассоциации обнаружений с существующими треками. Это позволяет корректно идентифицировать транспортное средство даже при временном перекрытии другими объектами или кратковременном выходе из поля зрения камеры.

Для классификации марки и модели транспортного средства используется нейронная сеть EfficientNet-B4 с модифицированным классификационным слоем. Архитектура EfficientNet использует технику составного масштабирования (compound scaling), которая одновременно увеличивает глубину, ширину и разрешение сети с фиксированным набором коэффициентов, что обеспечивает оптимальное соотношение точности и вычислительной сложности. Модель предварительно обучена на наборе данных ImageNet и дообучена на специализированном наборе данных транспортных средств методом трансферного обучения с замораживанием начальных слоёв.

Определение цвета транспортного средства осуществляется в несколько этапов. Сначала из обнаруженной области транспортного средства исключаются окна,

колёса и другие элементы, не характеризующие основной цвет кузова. Затем оставшиеся пиксели преобразуются из цветового пространства RGB в HSV, где выполняется кластеризация методом k-средних для определения доминантного цвета. Результат кластеризации сопоставляется с предопределённым набором из 12 основных цветов автомобилей.

### **Экспериментальные результаты**

Для оценки эффективности предлагаемой системы была проведена серия экспериментов на тестовых видеозаписях, полученных с камер видеонаблюдения в различных условиях. Тестовый набор данных включал более 10 000 кадров с разнообразными сценариями: многополосные дороги с интенсивным движением, перекрёстки, парковочные зоны, а также записи в различных погодных условиях и при различном освещении.

Результаты оценки модуля обнаружения транспортных средств показали высокую эффективность модели YOLOv8. Точность обнаружения (mAP@0.5) составила 94,7 процентов для дневных условий и 89,3 процентов для ночных условий. Полнота обнаружения (recall) достигла 92,1 процентов. Скорость обработки составила 32 кадра в секунду на графическом процессоре NVIDIA RTX 3080 при разрешении входного изображения 1920 на 1080 пикселей, что полностью удовлетворяет требованиям работы в режиме реального времени.

Модуль распознавания государственных регистрационных номеров продемонстрировал точность детекции номерных пластин 97,2 процентов, точность распознавания символов 95,8 процентов для номерных знаков стандарта Республики Узбекистан и 93,4 процентов для номерных знаков других стандартов. Среднее время обработки одного номерного знака составило 12 миллисекунд.

Модуль классификации марки и модели транспортного средства на основе EfficientNet-B4 достиг точности top-1 равной 91,3 процентов и top-5 равной 97,8 процентов. Определение цвета транспортного средства выполнялось с точностью 94,5 процентов.

Сравнительный анализ с существующими решениями показал, что предлагаемая система превосходит базовые подходы на основе HOG+SVM на 15–20 процентных пунктов по точности и на порядок по скорости обработки. По сравнению с коммерческими системами идентификации транспортных средств, предлагаемое решение демонстрирует сопоставимую точность при значительно меньших аппаратных требованиях.

Тестирование системы в реальных условиях эксплуатации на нескольких перекрёстках города Ташкента в течение 30 дней подтвердило стабильность и надёжность работы. За период тестирования система обработала более 2 миллионов транспортных средств. Средняя точность комплексной идентификации, включающей определение типа, марки, модели, цвета и номерного знака, составила 91,6 процентов. Число ложных срабатываний не

превысило 3,2 процентов, что является приемлемым показателем для систем данного класса.

### **Заключение**

В настоящей работе представлена архитектура и реализация комплексной системы идентификации транспортных средств в режиме реального времени с использованием методов искусственного интеллекта. Система объединяет несколько нейросетевых моделей для решения взаимосвязанных задач: обнаружения транспортных средств, распознавания государственных регистрационных номеров, классификации по марке, модели и цвету.

Экспериментальные результаты подтвердили высокую эффективность предлагаемого решения. Точность обнаружения транспортных средств составила 94,7 процентов, распознавания номерных знаков — 95,8 процентов, классификации марки и модели — 91,3 процентов. Система обеспечивает обработку видеопотока с разрешением 1920 на 1080 пикселей со скоростью 32 кадра в секунду, что удовлетворяет требованиям режима реального времени.

Практическая значимость работы заключается в возможности использования разработанной системы для повышения безопасности дорожного движения, автоматизации контроля транспортных потоков, поиска угнанных транспортных средств и других задач, связанных с управлением городской транспортной инфраструктурой. Система может быть интегрирована в существующие комплексы «Безопасный город» и интеллектуальные транспортные системы.

Дальнейшие направления исследований включают повышение устойчивости системы к сложным условиям эксплуатации (экстремальные погодные условия, ночное время), расширение набора распознаваемых характеристик транспортных средств, разработку методов реидентификации транспортных средств по нескольким камерам, а также оптимизацию моделей для работы на встраиваемых платформах с ограниченными вычислительными ресурсами.

### **Список литературы**

1. Указ Президента Республики Узбекистан «О стратегии "Цифровой Узбекистан — 2030"» и мерах по её эффективной реализации. — 2020 г.
2. Redmon J., Divvala S., Girshick R., Farhadi A. You Only Look Once: Unified, Real-Time Object Detection // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). — 2016. — P. 779–788.
3. Jocher G., Chaurasia A., Qiu J. Ultralytics YOLOv8 // GitHub repository. — 2023. — URL: <https://github.com/ultralytics/ultralytics>.
4. Liu W., Anguelov D., Erhan D. et al. SSD: Single Shot MultiBox Detector // European Conference on Computer Vision (ECCV). — Springer, 2016. — P. 21–37.

5. Wojke N., Bewley A., Paulus D. Simple Online and Realtime Tracking with a Deep Association Metric // IEEE International Conference on Image Processing (ICIP). — 2017. — P. 3645–3649.
6. 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. — Vol. 39, No. 11. — P. 2298–2304.
7. Tan M., Le Q. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks // Proceedings of the 36th International Conference on Machine Learning (ICML). — 2019. — P. 6105–6114.
8. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). — 2016. — P. 770–778.
9. Ren S., He K., Girshick R., Sun J. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks // Advances in Neural Information Processing Systems (NIPS). — 2015. — P. 91–99.
10. Wang C.-Y., Bochkovskiy A., Liao H.-Y. M. YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). — 2023. — P. 7464–7475.
11. Laroca R., Severo E., Zanlorensi L. A. et al. A Robust Real-Time Automatic License Plate Recognition Based on the YOLO Detector // International Joint Conference on Neural Networks (IJCNN). — 2018. — P. 1–10.
12. Sochor J., Herout A., Havel J. BoxCars: 3D Boxes as CNN Input for Improved Fine-Grained Vehicle Recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). — 2016. — P. 3006–3015.
13. Рахимов Б. А., Саидов Ш. М. Применение методов глубокого обучения для автоматического распознавания номерных знаков в условиях городской среды // Вестник Ташкентского университета информационных технологий. — 2022. — № 4. — С. 45–53.
14. Каримов О. Р., Ахмедов Б. Ш. Обзор современных архитектур нейронных сетей для обнаружения объектов в видеопотоке // Научный журнал «Проблемы информатики и энергетики». — 2023. — № 1. — С. 28–36.
15. Мирзаев Н. К. Интеллектуальные транспортные системы: принципы построения и перспективы развития. — Ташкент: Издательство ТУИТ, 2021. — 256 с.