

УДК 004.93'12

DOI:10.25729/ESI.2026.42.2.005

## Разработка метода идентификации транспортного средства

Горский Максим Сергеевич, Мосева Марина Сергеевна

Московский технический университет связи и информатики,  
Россия, Москва, *m.s.gorskiy@edu.mtu.ru*

**Аннотация.** Целью статьи является описание разработки и обучения модели, способной классифицировать автомобили по маркам и моделям на основе изображений, а также интерфейса для удобного взаимодействия с моделью. Новизна работы подтверждается использованием современных методов идентификации транспортных средств для их тонкой классификации. В статье представлены три раздела, каждый из которых охватывает ключевые аспекты исследования. В рамках первого раздела выполнен анализ предметной области, в котором рассмотрены существующие методы идентификации транспортных средств, включая технологии на основе лидарных данных, а также методы, использующие изображения и видео. Особое внимание уделено анализу современных подходов к классификации транспортных средств по маркам, моделям и другим атрибутам. Этот анализ позволил выявить сильные и слабые стороны различных подходов и обосновать выбор архитектур глубокого обучения для дальнейшего исследования. Во втором разделе описан собранный набор данных с детальной маркировкой по маркам и моделям, использованный для исследования. Проведено сравнение трех моделей машинного обучения по различным метрикам, таким, как точность, полнота, f1-мера. В результате анализа была выбрана модель, которая продемонстрировала наилучшие результаты в задачах классификации транспортных средств. Так же была проведена количественная оценка детектора, используемого в дальнейшем, которая подтвердила эффективность выбранной модели. Третий раздел описывает практическую часть работы, в которой были проведены аугментация и дополнение набора данных. После дообучения модели на улучшенных данных была выполнена интеграция классификатора с детектором YOLOv11. Реализован веб-интерфейс, который обеспечивает удобное взаимодействие с системой, позволяя загружать видео, просматривать результаты детекции и классификации в реальном времени, а также анализировать статистические данные. Тестирование системы на реальных данных видеонаблюдения подтвердило эффективность подхода, хотя и выявило необходимость дальнейшей оптимизации для сложных ракурсов и условий освещенности.

**Ключевые слова:** идентификация транспортных средств, машинное обучение, YOLO, компьютерное зрение, аугментация данных

**Цитирование:** Горский М.С. Разработка метода идентификации транспортного средства / М.С. Горский, М.С. Мосева // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 55-69. – DOI:10.25729/ESI.2026.42.2.005.

**Введение.** Современные методы машинного обучения открывают новые возможности для автоматической идентификации транспортных средств. В условиях роста автомобильного парка задача классификации марок и моделей приобретает особую актуальность для систем мониторинга дорожного движения, автоматизации парковок и повышения безопасности.

Целью статьи является описание разработанного авторами метода классификации автомобилей на основе изображений с использованием сверточных нейронных сетей. Создаваемая модель должна выделять ключевые характеристики транспортных средств для их точной идентификации.

Практическая значимость исследования заключается в возможности применения результатов в транспортной логистике, системах видеонаблюдения и других областях, требующих автоматизированного распознавания автомобилей. Реализация проекта будет способствовать совершенствованию управления дорожным движением и снижению зависимости от человеческого фактора.

В статье будет выполнен анализ существующих методов, из которых выбираются наиболее подходящие, проведено сравнение выбранных методов и моделей, определены наиболее успешные, собраны и подготовлены наборы данных для обучения, а также разработан метод идентификации транспортных средств.

**1. Обзор подходов к идентификации транспортных средств.** В сфере дорожного транспорта простого обнаружения транспортных средств недостаточно – необходима их детальная классификация по марке, модели и другим признакам. Эта задача актуальна для таких приложений, как дифференцированная оплата проезда, криминалистика и сбор статистики.

Практическая значимость подчеркивается исследованием [1], где показана связь между типом автомобиля, его скоростью и объемом вредных выбросов. Автоматическая идентификация транспортных средств позволила бы оптимизировать скоростные режимы для разных категорий транспорта, снизив тем самым загрязнение окружающей среды.

Для изучения видов транспортных средств и потоков транспортных средств существуют различные их характеристики. Описать транспортное средство можно с помощью следующих данных: тип кузова, количество осей, назначении, габариты, масса, марка и т.д. [2]. Важным критерием классификации является назначение транспортного средства. В исследованиях [3, 4] служебный транспорт (скорая помощь, полиция) выделяется в отдельный класс для приоритизации проезда и моделирования дорожного движения. Также существуют способы описания транспортных потоков. Исходя из документа [5], можно выделить такие характеристики транспортных потоков, как интенсивность движения, состав движения, пропускная способность, плотность движения.

Задачу классификации транспортных средств можно решить разными способами. Один из способов – использование датчиков для получения информации об автомобиле. В статье [6] авторы используют сканирование автомобиля при помощи датчиков, преобразование получившихся данных в формат изображения, преобразование получившегося изображения и передача этого изображения в сверточную нейронную сеть (рис. 1). В качестве конечной модели использовалась модель EfficientNet.



**Рис. 1.** Преобразование данных LiDAR в изображение для EfficientNet

Решение схожей задачи можно найти в [7]. В ней авторы предлагают подход, который улучшает распознавание объектов в трудных световых условиях. Основной моделью стал REDFormer, который использует в своем алгоритме карты BEV, а также способен настраиваться в зависимости от условий окружающей среды. В статье [8] авторы предложили подход, объединяющий работу модели YOLOv3 и данные, полученные от нейронной сети, использующей данные радара. Для модели, обрабатывающей данные радара, была использована полносвязная сверточная нейронная сеть FCN-8 (рис. 2). В статье [9] для обработки данных радара используется модель, названная RPR. Помимо данных от датчиков, модель принимает на вход данные из сверточной нейронной сети, которая, в свою очередь, принимала входное изображение. Параллельно, на результатах сверточной нейронной сети, работает сеть региональных предложений (RPN). Результаты обеих моделей объединяются и проходят через Fast R-CNN.




Рис. 2. Принцип работы алгоритма YOdar

Актуальность метода использования датчиков в распознавании автомобилей на изображении подчеркнута в статье [10]. В статье объединяются подходы из других статей, предлагается общий алгоритм слияния моделей, работающих с изображением и с сенсорами. Выполняется сравнение существующих подходов, выявляются как схожие черты, так и различия между ними.

Городские камеры наблюдения требуют не только детектирования, но и классификации транспорта по типу, марке и цвету. В исследовании [11] для классификации иранских автомобилей использовалась связка StrongSORT (YOLOv5, OSNet, ResNet). Для статьи был собран свой датасет иранских автомобилей [12] из 29 классов, лучший результат показала ResNet50. В работе [13] распознавание номеров решается через предварительную классификацию ТС. По итогу лучшей по всем параметрам оказалась TinyYOLOv4.

Исследование [14] посвящено устойчивости классификации к шумам изображения. Предложены фреймворки PMAL для обучения с очисткой от шумов и PMD для компрессии модели, что позволяет сохранить точность при уменьшении вычислительных затрат. В статье [15] проблема идентификации решается внедрением двух модулей в нейронную сеть: LTRA и HFCA. Первый предназначен для оптимизации входных данных, а второй для поиска более точных классификационных признаков (рис. 3)

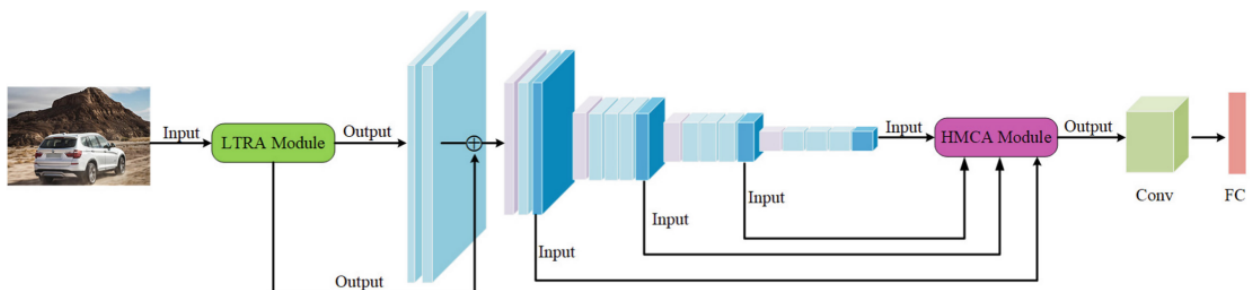


Рис. 3. Пример внедрения модулей LTRA и HFCA

В статье [16] исследованы методы повышения эффективности моделей глубокого обучения в системах ALPR. Метод понижения класса, объединяющий редкие категории в

группу «Другие», повысил точность ViT b16 на 8-12%. Метод выборочного предсказания, отсеивающий недостоверные прогнозы, дал прирост в 8%, а их комбинация – свыше 20%.

В работе [17] предложен классификатор на основе критерия Фишера, используемый совместно с ResNet и VGG. В исследовании [18] для детальной классификации транспортных средств усовершенствован алгоритм WS-DAN методом FAFCC, использующим многоуровневые признаки изображений. В статье [19] сравниваются два подхода: дообучение предобученных сетей и извлечение признаков с последующим использованием SVM. Наилучший результат показал метод дообучения на основе Inception-v3.

В статье [20] для решения задачи детекции была модифицирована модель многообъектного отслеживания FairMOT. Исходная архитектура ResNet34 заменена на CSPDarknet53 для повышения точности в условиях городского трафика. Усовершенствованный алгоритм решает три ключевые задачи: детектирование и повторную идентификацию транспортных средств, расчет их скорости и измерение объема трафика. Для последнего в кадре определяется специальная зона учета, проезд через которую фиксируется, как состоявшееся событие (рис. 4).

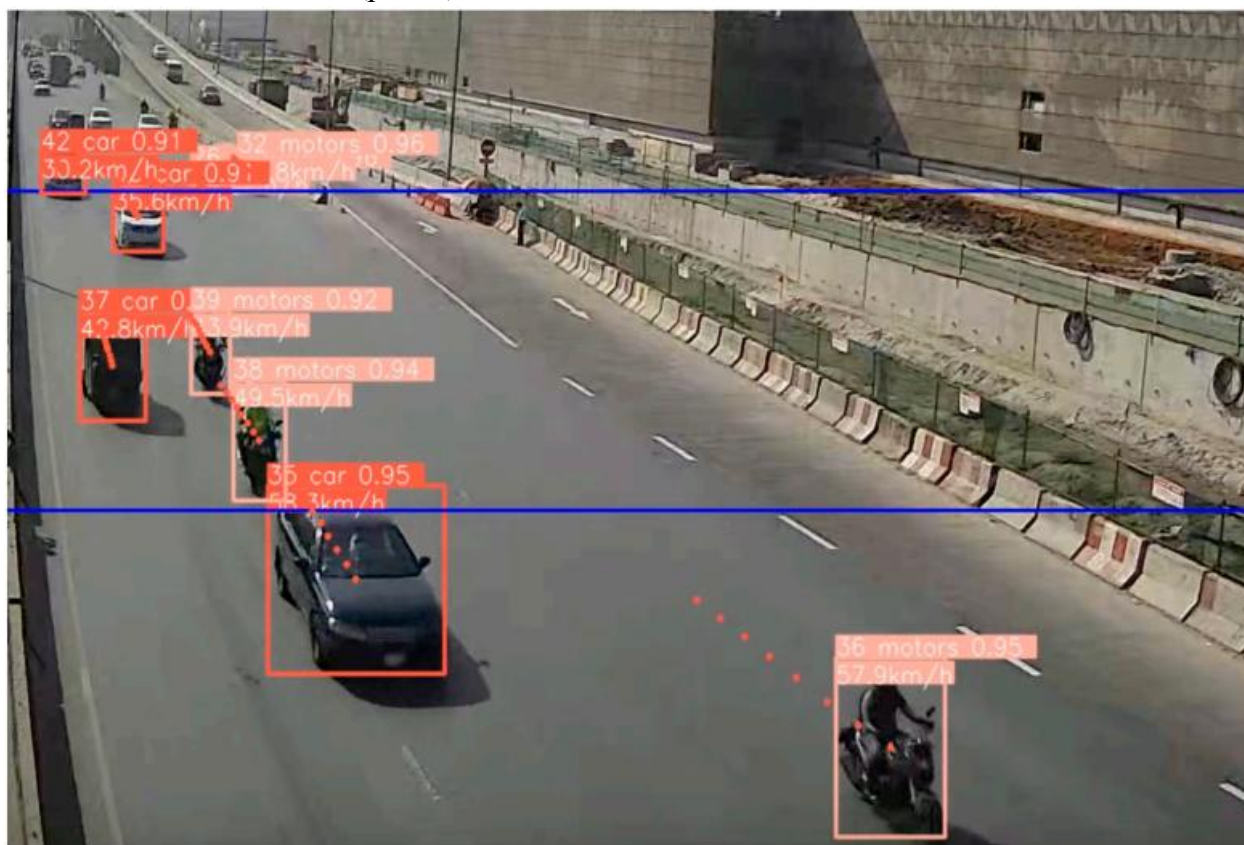


Рис. 4. Пример работы алгоритма Fairmot с CSPDarknet53

В статье [21] представлен алгоритм на основе YOLOv5 и DeepSORT, улучшенный модулем Swin Transformer. Для точного определения скорости транспортных средств используется преобразование координат изображения в реальные с помощью ориентиров. Исследование [22] сравнивает популярные архитектуры для распознавания атрибутов автомобиля. Модель RCNN показала наилучшие результаты по точности и F1-мере, тогда как YOLO лидирует по показателю precision. В работе [23] модифицирована архитектура YOLOv5 для повышения эффективности распознавания: добавлен модуль внимания для детекции мелких объектов, заменена агрегирующая сеть на ViFPN и функция потерь на Clou. Для отслеживания объектов используется сиамская полносвязная сеть (SNN), обеспечивающая устойчивость работы в реальных условиях.

В статье [24] описывается собранный авторами датасет, который объединяет в себе 4 других общедоступных набора данных: CitiFlow, VeRi-776, CompCar и VehicleID. В статье [25] представлено расширение для набора данных Cityscapes, в котором авторы добавили дополнительные атрибуты для каждого класса.

В ранее рассмотренной статье [20] авторы представили свой набор данных THS-10, который включает в себя 4250 изображений и 10 классов. На изображениях представлены японские автомобили марок Honda, Suzuki и Toyota. Авторы статьи [26] представили набор данных с метками, содержащими название марок и моделей автомобилей. Описанный в данной статье набор данных DVMM содержит в себе 43 модели и 495 марок автомобилей в разных ракурсах.

Статья [27] представляет два набора данных для распознавания моделей автомобилей. Первый набор данных представляет собой набор изображений, разделенных метками с типом кузова изображенного транспорта. Другой набор данных представлен изображениями эмблем производителей автомобилей, например, «Chevrolet», «Ford», «Honda» и др.

В статье [28] представлен набор данных из разделенных на кадры видеозаписей с дорожных камер видеонаблюдения. Всего таких кадров в наборе содержится 416314, а всего уникальных автомобилей – 40671. В каждом изображении показана автодорога с несколькими размеченными автомобилями.

**2. Исследование моделей для идентификации транспортных средств.** В результате исследования были выбраны наиболее популярные модели машинного обучения для детекции и классификации транспортных средств. В этом разделе будет выполнена оценка их эффективности по различным метрикам.

Для решения поставленной задачи требуются две модели: одна – для обнаружения автомобилей на изображении, другая – для их классификации по маркам и моделям. Поскольку задача классификации в данном случае сложнее детекции, основной акцент будет сделан на анализе классифицирующих моделей. Для детектирования будет выбрана одна модель для последующего использования.

**2.1. Постановка задачи.** По итогам анализа, проведенного в первом разделе, были выбраны следующие три сверточные модели, решающие задачу классификации: YOLO, ResNet, Inception-v3. Подходы, основанные на архитектуре трансформеров, также используются для решения задач компьютерного зрения, однако, как правило, требуют значительных вычислительных мощностей и памяти для обучения и инференса, что на текущий момент ограничивает их применение в рассматриваемых нами сценариях.

YOLO – это популярная архитектура для детекции и классификации объектов в изображениях и видео, которая была разработана для обеспечения высокой скорости и точности. Основная идея YOLO – способность модели выдавать результат всего за один проход по изображению. Мы возьмем актуальную 11 версию модели, как наиболее новую из всех версий. Также, мы будем использовать два варианта этой модели – YOLOv11 для задачи детекции и YOLO-cls для задачи классификации.

ResNet – это архитектура глубокой нейронной сети, разработанная для решения проблемы затухающего градиента, которая возникает при обучении очень глубоких моделей. Данная архитектура состоит из повторяющихся блоков, каждый из которых включает в себя несколько сверточных слоев и остаточную связь. Исходя из анализа предметной области, мы возьмем вариант с 50-ю слоями, который имеет название ResNet50

Inception-v3 – это модель машинного обучения, которая была разработана для решения задачи классификации изображений и других задач компьютерного зрения. Основная идея модели заключается в параллельном использовании нескольких сверточных слоев, которые позволяют модели извлекать признаки из слоев разных масштабов. Так, модель может

одновременно извлекать признаки из слоев с разным ядром свертки, с разным количеством самих сверточных слоев.

Для выбора классифицирующей модели проведем анализ описанных архитектур и сравним их по различным параметрам. Для детекции будем использовать модель YOLOv11.

Для эксперимента был собран набор данных, содержащий изображения автомобилей разных марок и моделей с различных ракурсов (рис. 5). Набор данных включает в себя 10006 изображений в тренировочной выборке, 4582 изображений в валидационной и 1563 в тестовой. Он включает 23 различных бренда автомобилей, из которых 19 – это легковые автомобили, а 4 – грузовые, автобусы и т.д.




Рис. 5. Пример изображений в наборе данных

Дополнительно был собран небольшой набор данных, состоящий из реальных изображений автомобилей с камер видеонаблюдения. Его отличительной особенностью является реалистичные, но более сложные условия (рис. 6). Набор данных включает в себя не все классы, на которых обучалась модель, но и не содержит классов, на которых модель не обучалась. Представленные изображения были получены при дневном освещении в ясную погоду, съемка осуществлялась с верхней точки, под углом к изображению. Размер изображений не превышал 200 на 200 пикселей. Цель этого набора – исследование того, насколько модель, обученная на описанном наборе данных, сможет ориентироваться на реальных данных.




Рис. 6. Автомобили с камер видеонаблюдения

**2.2. Результаты эксперимента.** В первую очередь было проведено обучение предобученных моделей на описанном наборе данных. Обучение проводилось в 90 эпох, размер пакета был установлен в 16 для YOLO, 32 для ResNet и Inception. Размер входного изображения был установлен в «224 на 224» пикселя, для Inception – в «229 на 229». В качестве оптимизатора использовался стохастический градиентный спуск для YOLO, а для моделей YOLO и Inception был установлен оптимизатор Adam. Все параметры были подобраны экспериментальным путем. Для чистоты поставленного эксперимента у модели YOLO были отключены все параметры, осуществляющие автоматическую аугментацию данных. Результаты можно увидеть в таблице 1. По ней можно сказать, что среди предобученных моделей лучше всего справилась архитектура YOLO. Она имеет наилучшие показатели среди других моделей. Скорость обработки у всех трех моделей остается на высоком уровне.

С учетом достаточно специфичной задачи была сделана гипотеза, что предобученные модели не могут улучшить точность конечной модели, и, более того, могут усложнить процесс обучения. Был проведен ряд экспериментов со случайными начальными весами у моделей. Однако, видимого результата добиться не удалось, все модели показали себя хуже по всем качественным метрикам. В результате наиболее успешной моделью оказалась YOLO-cls, ее точность составила более 82% на тестовой выборке.

Таблица 1. Результаты эксперимента с предобученными моделями

	Точность (топ-1)	Точность (топ-5)	Полнота	Точность (precision)	F1-мера	Скорость предсказания (сек.)
YOLOv11-cls	0.8292	0.9687	0.8292	0.8545	0.8286	0.0226
ResNet50	0.4722	0.7377	0.4722	0.5640	0.4679	0.0220
Inception-v3	0.3225	0.6040	0.3225	0.3225	0.3236	0.0124



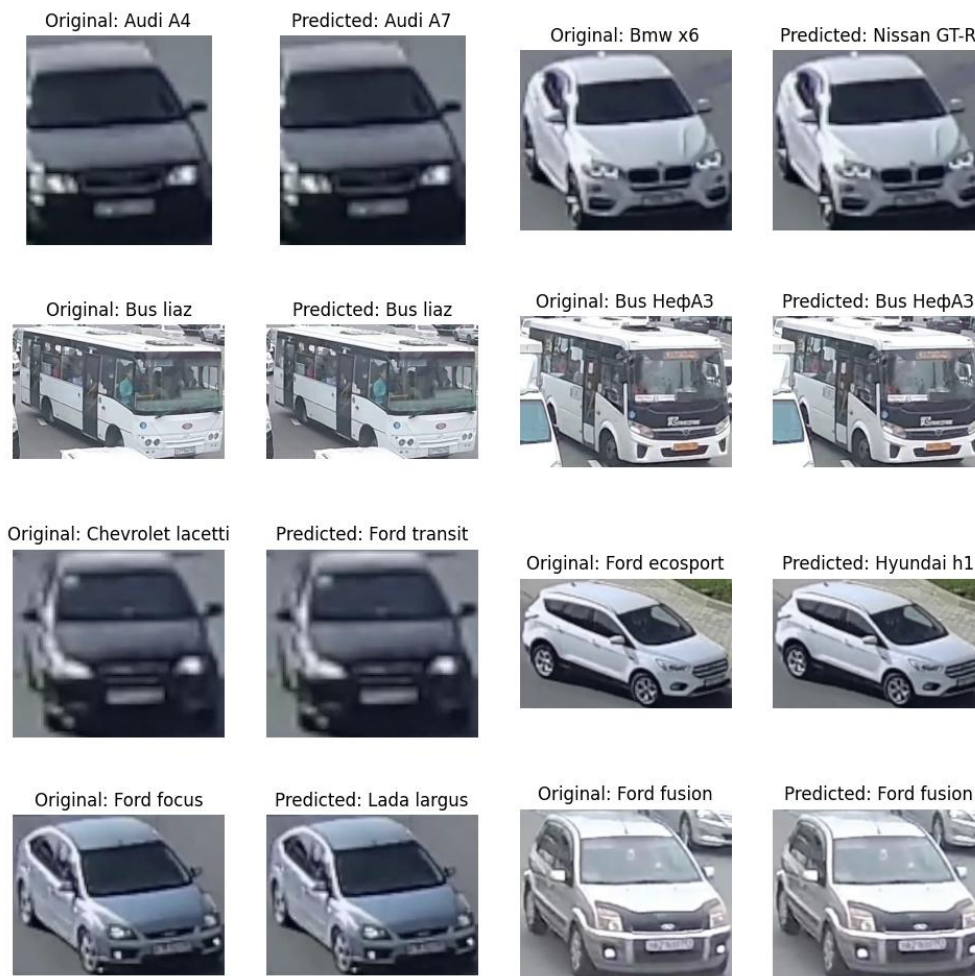


Рис. 8. Предсказания модели на реальных данных

**3. Разработка метода идентификации транспортного средства на изображении.** В этом разделе описана разработка метода идентификации транспортных средств на основе анализа, проведенного в предыдущих главах. Основное внимание уделено разработке оптимизированной модели для точной детекции и классификации автомобилей на изображениях с камер видеонаблюдения.

Для улучшения качества обучения будет использован модифицированный набор данных с применением методов аугментации (вращение, изменение яркости, масштабирование), что особенно актуально в условиях ограниченного объема исходных данных. Дополнительно будет проведен детальный анализ классов транспортных средств для более точной настройки модели.

Завершающий этап – интеграция классифицирующей модели с детектором и комплексная оценка результатов, позволяющая выявить сильные и слабые стороны предложенного метода.


**3.1. Обучение классифицирующей модели.** Исходя из результатов эксперимента, было принято решение об оптимизации набора данных. Изображения были кадрированы по размеру автомобиля. Для некоторых классов было выполнено разделение на несколько разных классов, или объединение в один класс.

Для увеличения количества изображений были применены сдвиг и поворот в качестве методов аугментации для классов, чьих изображений оказалось меньше всего. Далее, для всех изображений было применено зеркальное отражение и наложен гауссовский шум на все получившиеся изображения (рис. 9).



При обучении модель достаточно быстро обучается до ошибки, равной примерно 2 и точности на валидационной выборке 90%. Однако после этого для каждой эпохи модели трудно перешагнуть этот порог.

**3.2. Внедрение детектирующей модели.** Для обработки видео будет применен алгоритм, показанный на рис. 11. Он позволяет на выходе получать обработанное видео с обнаруженными автомобилями и предсказанными их классами.



**Рис. 11.** Алгоритм обработки видеофайла

Из всех распознанных объектов мы будем выбирать только автомобили. Каждый объект, прошедший данную фильтрацию, отправляется на классификацию модели YOLO-cls. На выходе получается видео с предсказанием модели.


Дополнительно было решено создать алгоритм, определяющий цвет автомобиля. Добиться этого удалось при помощи библиотек `opencv` [29] и `numpy` [30]. Основа алгоритма – это перевод изображения в HSV, удобное пространство для выделения цвета (оттенок, насыщенность, яркость). По яркости и насыщенности мы определяем, является ли автомобиль белым, серым или черным, в остальных случаях мы определяем цвет по оттенку – в зависимости от того, в какой диапазон он попадает, мы назначаем цвет. Помимо этого, была использована кластеризация K-средних, которая позволила объединить области пикселей и улучшить результат распознавания. Итоговый результат работы программы можно увидеть на рис. 12.



**Рис. 12.** Результат работы программы

Для удобства работы с алгоритмом был разработан пользовательский интерфейс на базе библиотеки Streamlit [31]. Выбор обусловлен минимальными требованиями к веб-разработке и наличием готовых компонентов для загрузки медиафайлов и визуализации данных. Интерфейс обеспечивает: загрузку видеофайлов, отображение видео с детекцией и классификацией объектов, вывод статистики, включая скорость обработки. Также была добавлена таблица со статистикой, которая содержит все найденные на видео автомобили и их цвет. Это может быть полезно, если мы ищем какое-то определенное транспортное средство. Пример интерфейса представлен на рис. 13.

Обработка завершена!



Время обработки: 152.17 секунд

### Обнаруженные объекты

	Класс	Цвет
0	Nissan X-Trail	Белый
1	Toyota Yaris	Белый
2	Kia optima	Белый
5	Nissan Terrano	Белый
6	Citroen c3	Белый
7	Gaz GAZ cargo	Белый
11	Bus НефАЗ	Белый
12	Citroen jumper	Белый
13	Peugeot 408	Белый
14	Kia optima	Серый

Скачать таблицу CSV

Рис. 13. Реализованный интерфейс

**Заключение.** В ходе исследования была успешно разработана система идентификации транспортных средств, основанная на анализе видеопотока. Предложенный метод позволяет определять характеристики транспортных средств за счет комбинации современных моделей детекции и классификации. Ключевым результатом работы является интегрированное решение, объединяющее модель YOLO для детекции транспортных средств на видео и сверточную модель YOLO-cls для их последующей классификации. Выбор моделей был сделан на основе проведенного сравнительного анализа. Аугментация и расширение данных позволили увеличить робастность модели, а разработанный интерфейс обеспечил практическую применимость системы.

Разработанная система может быть внедрена в реальные сценарии, такие, как автоматизированные парковочные комплексы, интеллектуальные системы видеонаблюдения и управления дорожным движением. Это будет способствовать повышению уровня автоматизации и снижению эксплуатационных затрат в указанных областях. В дальнейшем, работа может быть расширена за счет внедрения визуальных трансформеров, что позволит повысить точность идентификации в сложных условиях.

#### Список источников

1. Liu W., Liu J., Yu Q. et al. Optimal speed ranges for different vehicle types for exhaust emission control. *Sustainability*, 2024, vol. 16, no. 23, p. 10344, DOI: 10.3390/su162310344.
2. Об утверждении Правил применения обязательных требований в отношении отдельных колесных транспортных средств и проведения оценки их соответствия: постановление Правительства Российской Федерации от 12 мая 2022 г. № 855 // Официальный сайт Правительства Российской Федерации. – URL: <http://government.ru/docs/all/140920/> (дата обращения: 25/03/2025).
3. Dong L., Xie X., Zhang L. et al. Satisfaction-based optimal lane change modelling of mixed traffic flow and intersection vehicle guidance control method in an intelligent and connected environment. *Sustainability*, 2025, vol. 17, no. 3, p. 1077, DOI: 10.3390/su17031077.
4. Aworinde O.H. et al. Development of a prioritized traffic light control system for emergency vehicles. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 2024, vol. 13, no. 4, pp. 4019-4028, DOI: 10.11591/ijai.v13.i4.pp4019-4028.
5. Организация и безопасность дорожного движения на автомагистралях и скоростных автомобильных дорогах: ГОСТ Р 70124–2022: утвержден и введен в действие Приказом Федерального агентства по техническому регулированию и метрологии от 26 мая 2022 г. № 376-ст // Официальный сайт ФГУП «Стандартинформ». – URL: <https://docs.cntd.ru/document/1200184428> (дата обращения: 25.03.2025).
6. Ruan G., Hu T., Ding C. et al. Fine-grained vehicle recognition under low light conditions using EfficientNet and image enhancement on LiDAR point cloud data. *Scientific Reports*, 2025, vol. 15, p. 4691, DOI: 10.1038/s41598-025-89002-3.
7. Cui C., Ma Y., Lu J. et al. Radar enlighten the dark: enhancing low-visibility perception for automated vehicles with camera-radar fusion. *arXiv*, 2023, DOI: 10.48550/arXiv.2305.17318.

8. Kowol K., Rottmann M., Bracke S. et al. YODar: uncertainty-based sensor fusion for vehicle detection with camera and radar sensors. International Conference on Agents and Artificial Intelligence, 2020. Available at: <https://api.semanticscholar.org/CorpusID:222177987> (accessed: 03/25/2025).
9. Nabati R., Qi H. Radar-camera sensor fusion for joint object detection and distance estimation in autonomous vehicles. arXiv, 2020. Available at: <https://api.semanticscholar.org/CorpusID:221761289> (accessed: 03/25/2025).
10. Shi K., He S., Shi Z. et al. Radar and camera fusion for object detection and tracking: a comprehensive survey. arXiv, 2024. Available at: <https://arxiv.org/abs/2410.19872> (accessed: 03/25/2025).
11. Siahkali F., Alavi S., Masouleh M. SIVD: dataset of Iranian vehicles for real-time multi-camera video tracking and recognition. 2022 7th International Conference on Signal Processing and Intelligent Systems (ICSPIS), 2022, pp. 1-7, DOI: 10.1109/ICSPIS56952.2022.10043932.
12. Maleki P., Ramazani A., Khotanlou H. et al. Iranian vehicle images dataset for object detection algorithm. Journal of Artificial Intelligence and Data Mining, 2024, pp. 127-136, DOI: 10.22044/jadm.2024.13858.2501.
13. Usama M., Anwar H., Anwar A. et al. Vehicle and license plate recognition with novel dataset for toll collection. arXiv, 2022, DOI: 10.48550/arXiv.2202.05631.
14. Liu D. Progressive multi-task anti-noise learning and distilling frameworks for fine-grained vehicle recognition. IEEE Transactions on Intelligent Transportation Systems, 2024, vol. 25, no. 9, pp. 10667–10678, DOI: 10.1109/tits.2024.3420151.
15. Cai W., Zhu W., Cheng B. et al. Dual-rank attention module for fine-grained vehicle model recognition. Pattern Recognition and Computer Vision, 2022, pp. 17-28, DOI: 10.1007/978-3-031-18907-4\_2.
16. Santos E., Lima G.E., Laroca R. et al. Enhancing vehicle identification in challenging conditions through fine-grained classification. Anais da 37ª Conferência de Gráficos, Padrões e Imagens (SIBGRAPI 2024), Manaus, Brazil, 2024, pp. 129-134, DOI: 10.5753/sibgrapi.est.2024.31657.
17. Hayee S., Hussain F., Yousaf M.H. A novel FDLSR-based technique for view-independent vehicle make and model recognition. Sensors, 2023, vol. 23, no. 18, p. 7920, DOI: 10.3390/s23187920.
18. Chen J., Chen Z., Tao S. et al. Fine-grained vehicle classification based on feature augmentation. Journal of Physics: Conference Series, 2022, vol. 2404, p. 012041, DOI: 10.1088/1742-6596/2404/1/012041.
19. Najeeb S.A., Raza R.H., Yusuf A. et al. Fine-grained vehicle classification in urban traffic scenes using deep learning. arXiv, 2021, DOI: 10.48550/arXiv.2111.09403.
20. Cai B., Feng Y., Wang X. et al. Highly accurate deep learning models for estimating traffic characteristics from video data. Applied Sciences, 2024, vol. 14, no. 19, p. 8664, DOI: 10.3390/app14198664.
21. Luo Z., Bi Y., Yang X. et al. Enhanced YOLOv5s + DeepSORT method for highway vehicle speed detection and multi-sensor verification. Frontiers in Physics, 2024, vol. 12, DOI: 10.3389/fphy.2024.1371320.
22. Kanagamalliga S., Kovalan P., Kiran K. et al. Traffic management through cutting-edge vehicle detection, recognition, and tracking innovations. Procedia Computer Science, 2024, vol. 233, pp. 793-800, DOI: 10.1016/j.procs.2024.03.268.
23. Allak A.S.H., Yi J., Al-Sabbagh H.M. et al. Siamese neural networks in unmanned aerial vehicle target tracking process. IEEE Access, 2025, vol. 13, pp. 24309-24322, DOI: 10.1109/ACCESS.2025.3536461.
24. Zheng Z., Ruan T., Wei Y. et al. VehicleNet: learning robust visual representation for vehicle re-identification. IEEE Transactions on Multimedia, 2021, vol. 23, pp. 2683–2693, DOI: 10.1109/tmm.2020.3014488.
25. Metwaly K., Kim A., Branson E. et al. CAR – Cityscapes attributes recognition: a multi-category attributes dataset for autonomous vehicles. arXiv, 2021, DOI: 10.48550/arXiv.2111.08243.
26. Lyu Y., Schioppa I., Cornelis B. et al. Framework for vehicle make and model recognition—a new large-scale dataset and an efficient two-branch–two-stage deep learning architecture. Sensors, 2022, vol. 22, no. 21, p. 8439, DOI: 10.3390/s22218439.
27. Boonsirisumpun N., Okafor E., Surinta O. Vehicle image datasets for image classification. Data in Brief, 2024, vol. 53, p. 110133, DOI: 10.1016/j.dib.2024.110133.
28. Lou Y., Bai Y., Liu J. et al. VERI-Wild: a large dataset and a new method for vehicle re-identification in the wild. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019, pp. 3230-3238, DOI: 10.1109/CVPR.2019.00335.
29. OpenCV documentation. Available at: <https://docs.opencv.org/> (accessed: 03/25/2025).
30. NumPy documentation. Available at: <https://numpy.org/doc/stable/> (accessed: 03/25/2025).
31. Streamlit documentation. Available at: <https://docs.streamlit.io/> (accessed: 03/25/2025).

**Горский Максим Сергеевич.** Магистрант кафедры «Математическая кибернетика и информационные технологии», Московский технический университет связи и информатики. ORCID: 0009-0002-6534-1853, [m.s.gorskiy@edu.mtu.ci.ru](mailto:m.s.gorskiy@edu.mtu.ci.ru), 111024, г. Москва, Авиамоторная 8с2.

**Мосева Марина Сергеевна.** Кандидат технических наук, Доцент кафедры Программная инженерия, Московский технический университет связи и информатики. AuthorID: 946893, SPIN: 1313-0436, ORCID: 0000-0002-9778-124X, [m.s.moseva@mtuci.ru](mailto:m.s.moseva@mtuci.ru), 111024, г. Москва, Авиамоторная 8, с.2.

UDC 004.93'12

DOI:10.25729/ESI.2026.42.2.005

## **Vehicle identification method development**

**Maxim S. Gorskiy, Marina S. Moseva**

Moscow technical university of communications and informatics,  
Russia, Moscow, *m.s.gorskiy@edu.mtu.ru*

**Abstract.** This paper aims to describe the development and training of a model capable of classifying vehicles by make and model based on images, as well as an interface for convenient interaction with the model. The novelty of the work is demonstrated by the use of modern vehicle identification methods for fine-grained classification. The paper is divided into three sections, each covering key aspects of the research. The first section provides a domain analysis, reviewing existing vehicle identification methods, including lidar-based technologies, as well as methods using images and videos. Particular attention is paid to the analysis of modern approaches to classifying vehicles by make, model, and other attributes. This analysis allowed us to identify the strengths and weaknesses of various approaches and justify the choice of deep learning architectures for further research. The second section describes the collected dataset with detailed labeling by make and model used for the study. Three machine learning models are compared using various metrics, such as precision, recall, and f1-score. As a result of the analysis, the model that demonstrated the best results for vehicle classification tasks was selected. A quantitative evaluation of the detector used subsequently was also conducted, confirming the effectiveness of the selected model. The third section describes the practical part of the study, which involved augmenting and expanding the dataset. After further training the model on the improved data, the classifier was integrated with the YOLOv11 detector. A web interface was implemented that provides convenient interaction with the system, allowing users to upload videos, view detection and classification results in real time, and analyze statistical data. Testing the system on real-world video surveillance data confirmed the effectiveness of the approach, although it revealed the need for further optimization for complex camera angles and lighting conditions.

**Keywords:** vehicle identification, machine learning, YOLO, computer vision, data augmentation

### **References**

1. Liu W., Liu J., Yu Q. et al. Optimal speed ranges for different vehicle types for exhaust emission control. *Sustainability*, 2024, vol. 16, no. 23, p. 10344, DOI: 10.3390/su162310344.
2. Decree of the Government of the Russian Federation No. 855 of May 12, 2022. On approval of the rules for applying mandatory requirements for certain wheeled vehicles and conducting their conformity assessment. Available at: <http://government.ru/docs/all/140920/> (accessed: 03/25/2025).
3. Dong L., Xie X., Zhang L. et al. Satisfaction-based optimal lane change modelling of mixed traffic flow and intersection vehicle guidance control method in an intelligent and connected environment. *Sustainability*, 2025, vol. 17, no. 3, p. 1077, DOI: 10.3390/su17031077.
4. Aworinde O.H. et al. Development of a prioritized traffic light control system for emergency vehicles. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 2024, vol. 13, no. 4, pp. 4019-4028, DOI: 10.11591/ijai.v13.i4.pp4019-4028.
5. Organizaciya i bezopasnost' dorozhnogo dvizheniya na avtomagistralyah i skorostnyh avtomobil'nyh dorogah [Organization and Road Safety on Highways and Express Roads]: GOST R 70124–2022: approved and enacted by the Order of the Federal Agency on Technical Regulating and Metrology dated May 26, 2022 no. 376-st // Oficial'nyj sait FGUP «Standartinform» [Official website of the FGUP "Standartinform"]. (accessed: 03/25/2024).
6. Ruan G., Hu T., Ding C. et al. Fine-grained vehicle recognition under low light conditions using EfficientNet and image enhancement on LiDAR point cloud data. *Scientific Reports*, 2025, vol. 15, p. 4691, DOI: 10.1038/s41598-025-89002-3.
7. Cui C., Ma Y., Lu J. et al. Radar enlighten the dark: enhancing low-visibility perception for automated vehicles with camera-radar fusion. *arXiv*, 2023, DOI: 10.48550/arXiv.2305.17318.
8. Kowol K., Rottmann M., Bracke S. et al. YODar: uncertainty-based sensor fusion for vehicle detection with camera and radar sensors. *International Conference on Agents and Artificial Intelligence*, 2020. Available at: <https://api.semanticscholar.org/CorpusID:222177987> (accessed: 03/25/2025).
9. Nabati R., Qi H. Radar-camera sensor fusion for joint object detection and distance estimation in autonomous vehicles. *arXiv*, 2020. Available at: <https://api.semanticscholar.org/CorpusID:221761289> (accessed: 03/25/2025).
10. Shi K., He S., Shi Z. et al. Radar and camera fusion for object detection and tracking: a comprehensive survey. *arXiv*, 2024. Available at: <https://arxiv.org/abs/2410.19872> (accessed: 03/25/2025).

11. Siahkali F., Alavi S., Masouleh M. SIVD: dataset of Iranian vehicles for real-time multi-camera video tracking and recognition. 2022 7th International Conference on Signal Processing and Intelligent Systems (ICSPIS), 2022, pp. 1-7, DOI: 10.1109/ICSPIS56952.2022.10043932.
12. Maleki P., Ramazani A., Khotanlou H. et al. Iranian vehicle images dataset for object detection algorithm. Journal of Artificial Intelligence and Data Mining, 2024, pp. 127-136, DOI: 10.22044/jadm.2024.13858.2501.
13. Usama M., Anwar H., Anwar A. et al. Vehicle and license plate recognition with novel dataset for toll collection. arXiv, 2022, DOI: 10.48550/arXiv.2202.05631.
14. Liu D. Progressive multi-task anti-noise learning and distilling frameworks for fine-grained vehicle recognition. IEEE Transactions on Intelligent Transportation Systems, 2024, vol. 25, no. 9, pp. 10667–10678, DOI: 10.1109/tits.2024.3420151.
15. Cai W., Zhu W., Cheng B. et al. Dual-rank attention module for fine-grained vehicle model recognition. Pattern Recognition and Computer Vision, 2022, pp. 17-28, DOI: 10.1007/978-3-031-18907-4\_2.
16. Santos E., Lima G.E., Laroca R. et al. Enhancing vehicle identification in challenging conditions through fine-grained classification. Anais da 37<sup>a</sup> Conferência de Gráficos, Padrões e Imagens (SIBGRAPI 2024), Manaus, Brazil, 2024, pp. 129-134, DOI: 10.5753/sibgrapi.est.2024.31657.
17. Hayee S., Hussain F., Yousaf M.H. A novel FDLRS-based technique for view-independent vehicle make and model recognition. Sensors, 2023, vol. 23, no. 18, p. 7920, DOI: 10.3390/s23187920.
18. Chen J., Chen Z., Tao S. et al. Fine-grained vehicle classification based on feature augmentation. Journal of Physics: Conference Series, 2022, vol. 2404, p. 012041, DOI: 10.1088/1742-6596/2404/1/012041.
19. Najeeb S.A., Raza R.H., Yusuf A. et al. Fine-grained vehicle classification in urban traffic scenes using deep learning. arXiv, 2021, DOI: 10.48550/arXiv.2111.09403.
20. Cai B., Feng Y., Wang X. et al. Highly accurate deep learning models for estimating traffic characteristics from video data. Applied Sciences, 2024, vol. 14, no. 19, p. 8664, DOI: 10.3390/app14198664.
21. Luo Z., Bi Y., Yang X. et al. Enhanced YOLOv5s + DeepSORT method for highway vehicle speed detection and multi-sensor verification. Frontiers in Physics, 2024, vol. 12, DOI: 10.3389/fphy.2024.1371320.
22. Kanagamalliga S., Kovalan P., Kiran K. et al. Traffic management through cutting-edge vehicle detection, recognition, and tracking innovations. Procedia Computer Science, 2024, vol. 233, pp. 793-800, DOI: 10.1016/j.procs.2024.03.268.
23. Allak A.S.H., Yi J., Al-Sabbagh H.M. et al. Siamese neural networks in unmanned aerial vehicle target tracking process. IEEE Access, 2025, vol. 13, pp. 24309-24322, DOI: 10.1109/ACCESS.2025.3536461.
24. Zheng Z., Ruan T., Wei Y. et al. VehicleNet: learning robust visual representation for vehicle re-identification. IEEE Transactions on Multimedia, 2021, vol. 23, pp. 2683–2693, DOI: 10.1109/tmm.2020.3014488.
25. Metwaly K., Kim A., Branson E. et al. CAR – Cityscapes attributes recognition: a multi-category attributes dataset for autonomous vehicles. arXiv, 2021, DOI: 10.48550/arXiv.2111.08243.
26. Lyu Y., Schiopu I., Cornelis B. et al. Framework for vehicle make and model recognition—a new large-scale dataset and an efficient two-branch–two-stage deep learning architecture. Sensors, 2022, vol. 22, no. 21, p. 8439, DOI: 10.3390/s22218439.
27. Boonsirirumpun N., Okafor E., Surinta O. Vehicle image datasets for image classification. Data in Brief, 2024, vol. 53, p. 110133, DOI: 10.1016/j.dib.2024.110133.
28. Lou Y., Bai Y., Liu J. et al. VERI-Wild: a large dataset and a new method for vehicle re-identification in the wild. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019, pp. 3230-3238, DOI: 10.1109/CVPR.2019.00335.
29. OpenCV documentation. Available at: <https://docs.opencv.org/> (accessed: 03/25/2025).
30. NumPy documentation. Available at: <https://numpy.org/doc/stable/> (accessed: 03/25/2025).
31. Streamlit documentation. Available at: <https://docs.streamlit.io/> (accessed: 03/25/2025).

**Gorskiy Maxim Sergeevich.** Master's Student, Department of «Mathematical Cybernetics and Information Technology», Moscow Technical University of Communications and Informatics. ORCID: 0009-0002-6534-1853, m.s.gorskiy@edu.mtuci.ru, 111024, Moscow, Aviamotornaya 8s2.

**Moseva Marina Sergeevna.** Candidate of Sciences (Engineering), Associate Professor of the Software Engineering Department, Moscow Technical University of Communications and Informatics. AuthorID: 946893, SPIN: 1313-0436, ORCID: 0000-0002-9778-124X, m.s.moseva@mtuci.ru, 111024, Moscow, Aviamotornaya 8s2.

Статья поступила в редакцию 06.11.2025; одобрена после рецензирования 26.12.2025; принята к публикации 12.05.2026.

The article was submitted 11/06/2025; approved after reviewing 12/26/2025; accepted for publication 05/12/2026.