

УДК 004.932.2:629.3.05

## РАЗРАБОТКА АЛГОРИТМА ДЕТЕКЦИИ СВЕТОФОРОВ И РАСПОЗНАВАНИЕ ИХ СИГНАЛОВ ДЛЯ АВТОНОМНОГО ТРАНСПОРТА



**К.А. Хаджинова**

Студентка 3 курса факультета информационных технологий и управления специальности СУИ (АСОИ) БГУИР  
[kseiniyakhadzhyanova@gmail.com](mailto:kseiniyakhadzhyanova@gmail.com)



**А.Г. Савчиц**

Директор научно-технического центра МАЗ, главный конструктор  
[savchits@maz.by](mailto:savchits@maz.by)



**Р.В. Земляник**

Студентка 3 курса факультета информационных технологий и управления специальности СУИ (АСОИ) БГУИР  
[rzemlanik@gmail.com](mailto:rzemlanik@gmail.com)



**Д.А. Хаджинов**

Учащийся 10 класса лицея им. Ф.Э. Дзержинского БГУ  
[deniskhajyn@gmail.com](mailto:deniskhajyn@gmail.com)

### **К.А. Хаджинова**

Студентка 3 курса факультета информационных технологий и управления, специальности «СУИ (АСОИ)» Белорусского государственного университета информатики и радиоэлектроники. Является автором статей по обработке данных в информационных системах и оптимизации алгоритмов анализа данных. Область научных интересов связана с обработкой больших данных, оптимизацией процессов их анализа и хранения, детерминированными процессами, а также методами и алгоритмами искусственного интеллекта.

### **А.Г. Савчиц**

Директор научно-технического центра Минского автомобильного завода, главный конструктор. Основная профессиональная деятельность направлена на развитие и модернизацию бортовых систем управления и диагностических комплексов современных транспортных средств, интеграцию современных цифровых технологий и методов анализа изображений в системы автономного и полуавтономного вождения.

### **Р.В. Земляник**

Студентка 3 курса факультета информационных технологий и управления Белорусского государственного университета информатики и радиоэлектроники, автор публикаций по тематике машинного обучения, обработки и анализа больших данных, а также разработки алгоритмов автоматизации процессов в информационных системах.

### **Д.А. Хаджинов**

Учащийся 10 класса лицея им. Ф.Э. Дзержинского Белорусского государственного университета. Область интересов связана с разработкой робототехнических систем, созданием печатных плат, 3D-моделированием, проектированием аппаратных решений и применением компьютерного зрения для анализа и управления техническими объектами.

**Аннотация.** В статье рассматривается разработка легковесной модели детекции и классификации сигналов светофора для интеграции в систему автономного вождения (ADAS). Представлено полное описание последовательности обработки видеопотока, методов компенсации дисбаланса классов и архитектуры системы на основе YOLOv8. Проведена оценка качества на агрегированном датасете, продемонстрировавшая высокую точность работы алгоритма. Результаты могут быть использованы для оптимизации ИТ-решений в автомобильной промышленности.

**Ключевые слова:** детекция светофоров, автономный автомобиль, компьютерное зрение, YOLO, дисбаланс классов, машинное обучение

**Введение.** Определение (детектирование) в видеопотоке светофоров и точное распознавание их сигналов являются критически важными компонентами системы восприятия («мозга») автономного транспортного средства.

В процессе оценки дорожной ситуации светофоры выступают ключевым регулятором проезда перекрестков.

Данная задача отличается высокой сложностью из-за относительно малого размера объектов в кадре, изменчивых погодных условий, наличия перекрытий и сильных визуальных искажений (засветка, блики).

Для обеспечения безопасности стандартов ADAS (Advanced Driver Assistance Systems) автомобилю необходимо не только фиксировать красный сигнал, но и уверенно распознавать разрешающие фазы для своевременного маневрирования.

Целью описанных в работе исследований является разработка и оптимизация нейросетевой модели определения и распознавания светофоров, которая обеспечивает функционирование в реальном времени на вычислительном устройстве транспортного средства.

Предложен подход к построению компактного и производительного алгоритма, ориентированного на работу в реальных дорожных условиях, который позволяет получить удовлетворительную точность локализации, устойчив к внешним факторам и показывает высокую скорость обработки данных.

**Постановка задачи и обзор используемых наборов данных (датасетов).** На вход системы подается видеопоток с фронтальной камеры автомобиля.

Алгоритм должен локализовать светофор (определить ограничивающую рамку), определить тип сигнала, осуществить межкадровое отслеживание (трекинг) и передать результаты обработки в модуль принятия решений.

Для обучения использовалась агрегированная выборка, включающая открытые датасеты Bosch Small TrafficLights Dataset (BSTLD) и LISA Traffic Light Dataset, а также собственные данные для покрытия сложных условий (ночь, блики).

В таблице 1 представлено сравнение использованных открытых наборов данных.

Таблица 1. Сравнение характеристик наборов данных

Характеристика	BSTLD	LISA
Разрешение изображений	1280x720	1280x960
Количество классов	4	7
Объем обучающей выборки	5093	10220
Объем тестовой выборки	8334	3348

Данные наборы данных содержат разметку в виде ограничивающих рамок с указанием класса сигнала. Пример исходного кадра из обучающей выборки в сложных условиях освещения приведен на рисунке 1.




Рисунок 1. Исходный кадр из обучающей выборки

В процессе разметки объединённой выборки был выделен следующий набор классов сигналов светофора: red, yellow, green, off. Существенной проблемой при формировании обучающего набора стал естественный дисбаланс: красные и зелёные сигналы присутствуют большую часть времени, тогда как переходные фазы (жёлтый) и состояние off встречаются значительно реже. Для снижения влияния дисбаланса (различного соотношения длительности и частоты появления сигналов светофора) применялась аугментация (увеличение объема) миноритарных классов и взвешивание функции потерь по классам.

Распределение количества примеров (сигналов и состояния светофора) по категориям представлено на рисунке 2.

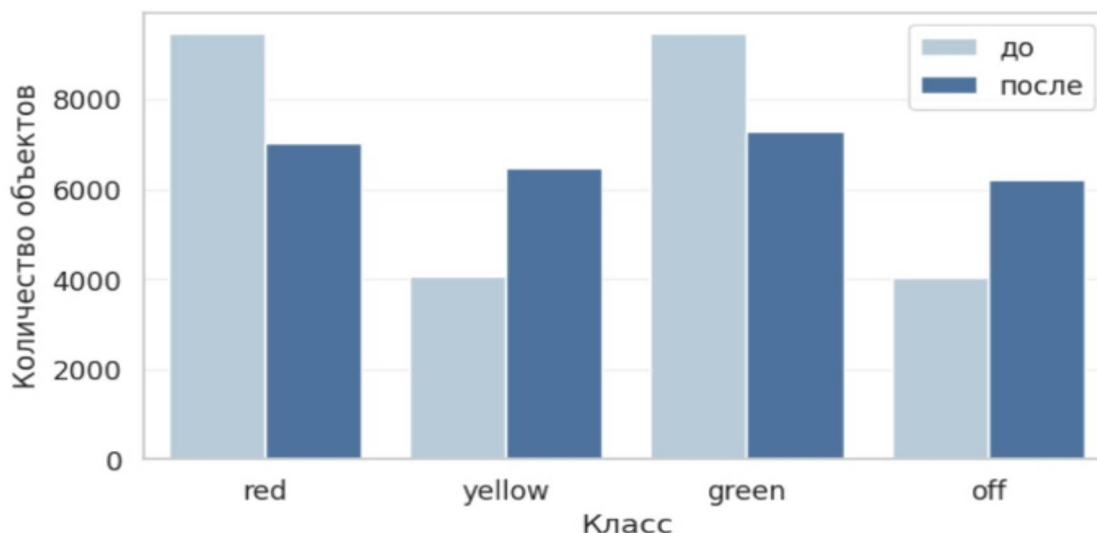


Рисунок 2. Исходный кадр из обучающей выборки

В результате объединения открытых и собственных датасетов удалось сформировать достаточно разнообразный и репрезентативный набор данных, покрывающий как типичные, так и сложные, малоизученные сценарии, что обеспечивает возможность построения и проверки нейросетевой модели, способной обобщать полученные знания на реальные условия эксплуатации.

**Архитектура модели и математический аппарат.** В качестве базовой архитектуры выбрано семейство моделей YOLOv8 (одноэтапный детектор без использования якорных рамок). Модель состоит из Backbone для извлечения признаков, Neck (FPN/PAN) для их агрегации на разных масштабах и Head для предсказания координат рамки и вероятности класса.

Оптимизация модели в процессе обучения производится путем минимизации комплексной функции потерь, которая состоит из трёх компонентов (1).

$$L_{YOLOv8} = \lambda_{cls} L_{cls} + \lambda_{box} L_{box} + \lambda_{dfl} L_{dfl}, \quad (1)$$

где – общая суммарная функция потерь («общая ошибка» модели за эпоху или батч);

– потери по локализации (насколько предсказанные координаты bounding-box близки к реальной разметке);

– потери по классификации (ошибки в определении типа сигнала: red/yellow/green/off);

– потери по распределению границ рамки (Distribution Focal Loss, помогает точнее регулировать «размытие» координат рамки для маленьких объектов);

, , – коэффициенты-веса (гиперпараметры), которые задают, насколько важна каждая часть: локализация, классификация, распределение.

В общем виде взвешенная кросс-энтропия для истинного класса используется для устранения дисбаланса классов (2).

$$CE(p_t) = -\alpha_t \log(p_t), \quad (2)$$

где – взвешенная кросс-энтропия для истинного класса на одном примере;

– вероятность (от 0 до 1), с которой модель предсказала истинный (правильный) класс для данного объекта;

– вес класса (коэффициент, который можно поднять для миноритарных классов, например yellow и off);

– натуральный логарифм (или логарифм по основанию 2, в зависимости от реализации, но смысл тот же).

Использование архитектуры YOLOv8 в сочетании с гибкой настройкой функции потерь позволяет совместить высокую точность определения малоразмерных объектов с требованиями к быстродействию, предъявляемым к вычислительным бортовым системам автономного транспортного средства. Выбранные компоненты комплексной функции потерь нацелены на обеспечение баланса между точностью позиционирования и правильной классификацией сигнала светофора.

**Обучение модели и оценка качества.** Обучение проводилось на протяжении 64 эпох с динамическим снижением шага обучения от 0.00047 до 0.000058.

График изменения функции потерь в процессе обучения приведён на рисунке 3.

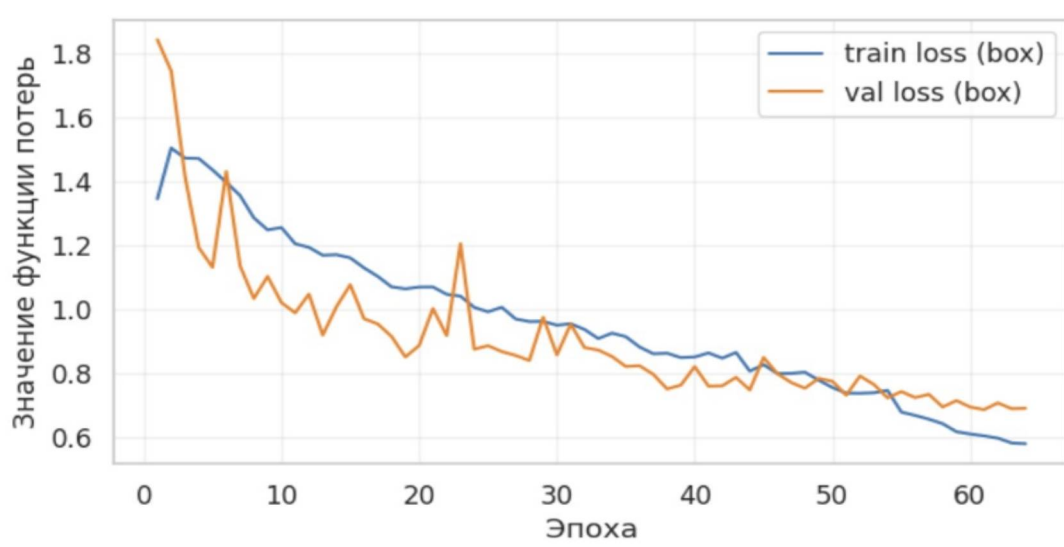


Рисунок 3. Изменение функции потерь в процессе обучения

Для оценки точности локализации и классификации использовались метрики Precision (точность), Recall(полнота) и Mean Average Precision (mAP). Метрика mAP усредняет значения средней точности по всем классам при различных порогах перекрытия IoU от 0.50 до 0.95. Интегральная метрика  $mAP@50-95$  вычисляется по формуле (3). Сумма идёт по 10 порогам: .

$$mAP_{50-95} = \frac{1}{10} \sum_{k=0}^9 mAP_{0.50+0.05k} \quad (3)$$

Здесь — значение метрики mean Average Precision, усреднённое по десяти порогам перекрытия IoU от 0.50 до 0.95 с шагом 0.05; обозначает значение mAP, рассчитанное по всем классам при фиксированном пороге IoU .

Множитель соответствует простому усреднению по этим десяти значениям, что позволяет получить интегральную характеристику качества детектора при разных уровнях строгости к совпадению предсказанных и истинных ограничивающих рамок, где – средняя точность (mean Average Precision) по диапазону порогов перекрытия IoU от 0.5 до 0.95;

– средняя точность по всем классам при пороге IoU = T, то есть считается отдельно для каждого класса и затем усредняется.

Коэффициент – это простое усреднение по 10 порогам, то есть формируется интегральная метрика, отражающая производительность модели при разных уровнях строгости (от «слабого» перекрытия до очень точного).

Динамика обучения показывает отсутствие переобучения: ошибки на проверочной (валидационной) выборке стабильно снижались вместе с ошибками на тренировочном наборе.

Динамика изменения метрик в процессе обучения показана на рисунке 4.

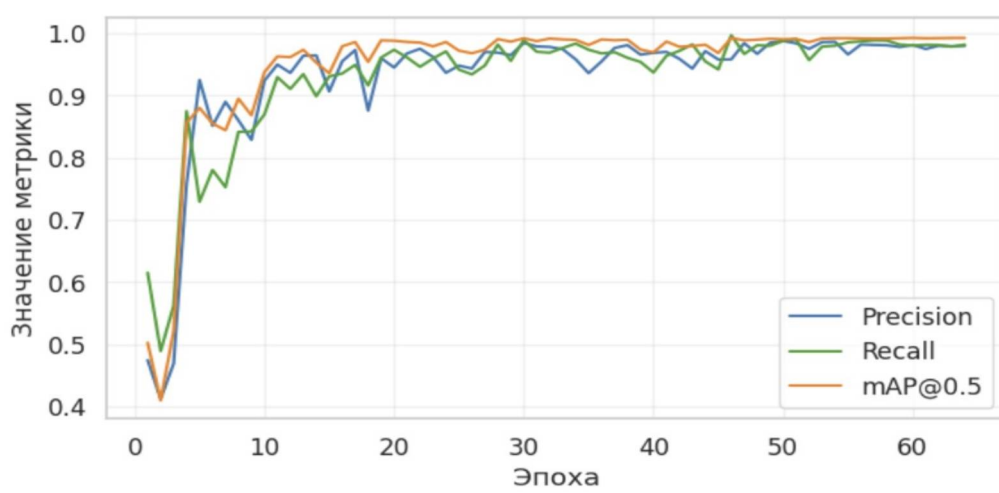


Рисунок 4. Динамика изменения метрик в процессе обучения

Количественные результаты работы модели на финальной 64-й эпохе сведены в таблицу 2.

Таблица 2. Метрики качества модели на 64-й эпохе обучения

Метрика	Значение на обучающей выборке	Значение на валидационной выборке
Ошибка локализации (box_loss)	0.57792	0.68844
Ошибка классификации (cls_loss)	0.33153	0.34535
Ошибка распределения границ (dfl_loss)	0.89995	0.90337
Точность (Precision)	–	0.97977
Полнота (Recall)	–	0.98175
mAP@50	–	0.99249
mAP@50-95	–	0.79718

Модель достигла показателя mAP@50 на уровне 0.99249, а интегральная метрика mAP@50–95 составила 0.79718. Применение алгоритма Non-Maximum Suppression (NMS) в сочетании с межкадровым трекингом позволило устранить дублирующие рамки и стабилизировать детекцию во времени.



Рисунок 5. Результаты детекции светофоров

Приведённые результаты показывают, что предложенная модель достигает высоких значений метрик как на обучающей, так и на валидационной выборках, при этом отсутствуют признаки переобучения. Таким образом, алгоритм может рассматриваться в качестве перспективной основы для интеграции в систему автономного управления транспортным средством и требует лишь дальнейшей оптимизации и адаптации к используемому вычислительному оборудованию.

**Заключение.** Использование модуля детекции светофоров в общем процессе организации (пайплайне) системы управления автономным транспортным средством позволяет передавать точные координаты и фазу сигнала в модуль планирования движения (Motion Planning). Разработанная и реализованная модель продемонстрировала высокую точность и стабильность: сбалансированная архитектура YOLOv8 и применение специфических функций потерь (DFL и CIoU) обеспечили высокое качество детекции малоразмерных объектов без потери скорости обработки потока данных для практических задач (инференса нейросети). В дальнейшем планируется расширение обучающей выборки контекстными данными HD-карт и квантизация модели для оптимизации вычислений на edge-устройствах, что в конечном итоге позволит повысить безопасность и комфорт эксплуатации автономного транспорта.

#### Список литературы

- [1] Redmon, J. You only look once: Unified, real-time object detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – P. 779–788.
- [2] Jocher, G. YOLO by Ultralytics / G. Jocher, A. Chaurasia, J. Qiu. – 2023.
- [3] Behrendt, K. A deep learning approach to traffic lights: Detection, tracking, and classification / K. Behrendt, L. Novak, R. Botterweck // 2017 IEEE International Conference on Robotics and Automation (ICRA). – 2017. – P. 1370–1377.
- [4] Jensen, M. B. Vision for looking at traffic lights: Issues, survey, and perspectives / M. B. Jensen, M. P. Philipsen, A. Møgelmoose, T. B. Moeslund, M. M. Trivedi // IEEE Transactions on Intelligent Transportation Systems. – 2016. – Vol. 17(7). – P. 1800–1815.

#### Авторский вклад

**К.А. Хаджинова** – формирование и обработка обучающего датасета, сбалансирование и расширение обучающей выборки, разработка и описание методологии исследования.

**А.Г. Савчиц** – постановка технического задания и общей тематики исследования, формирование требования к содержанию статьи, а также научное и организационное руководство проектом.

**Р.В. Земляник** – основной инженер машинного обучения: реализация и настройка YOLOv8-модели, обучение и оценка качества, подготовка экспериментов.

**Д.А. Хаджинов** – интеграция алгоритма детекции в систему компьютерного зрения робота, разработка и отладка связки аппаратной и программной части, тестирование работы модели в реальных экспериментах, оформление текста статьи.

## **DEVELOPMENT OF A TRAFFIC LIGHT DETECTION AND SIGNAL CLASSIFICATION ALGORITHM FOR AN AUTONOMOUS VEHICLE PERCEPTION SYSTEM**

***K.A. Khadzhynava***

*Third-year student,  
Faculty of Information  
Technologies and  
Management,  
specialization Information  
Systems Control  
(Automated Information  
Processing Systems),  
BSUIR*

***A.G. Savchits***

*Director of the Scientific  
and Technical Center,  
Minsk Automobile Plant  
(MAZ), Chief Designer*

***R.V. Ziamlianik***

*Third-year student,  
Faculty of Information  
Technologies and  
Management,  
specialization Information  
Systems Control  
(Automated Information  
Processing Systems),  
BSUIR, Minsk, Belarus*

***D.A. Khadzhynau***

*Student of the 10th  
grade, F.E.  
Dzerzhinsky  
Lyceum of the BSU*

**Abstract.** The article discusses the development of a lightweight model for detecting and classifying traffic light signals for integration into an autonomous driving system (ADAS). The full video stream processing pipeline, methods for combating class imbalance, and the YOLOv8-based architecture are described. The quality of the algorithm is evaluated on an aggregated dataset, demonstrating high detection accuracy. The results can be used for optimizing IT-solutions in the automotive industry.

**Keywords:** traffic light detection, autonomous vehicle, computer vision, YOLO, class imbalance, machine learning