

КУРОЧКА К.С., ПРОКОПЕНКО Д.В., ПАНАРИН К.А.

## РАСПОЗНАВАНИЕ СИГНАЛОВ СВЕТОВЫХ ПРИБОРОВ АВТОМОБИЛЕЙ ДЛЯ УМНЫХ СВЕТОФОРОВ

Гомельский государственный технический университет имени П.О. Сухого  
г. Гомель, Республика Беларусь

Статья исследует применение методов машинного обучения для распознавания сигналов световых приборов автомобилей с целью использования данных в умных светофорах. Для решения задачи распознавания машин на видео была использована библиотека Keras, и была применена архитектура нейронной сети RetinaNet [1]. Для распознавания состояний фар транспорта была использована архитектура YOLOv8. Процесс сбора данных, аннотации и обучения модели был проведён с использованием платформы Roboflow. В результате работы были получены веса обученной модели, которые позволяют распознавать состояние передних и задних фар различных видов транспорта в различных погодных условиях. Предложена адаптация нейросетевой модели на основе YOLOv8 для решения задачи распознавания сигналов световых приборов светофоров, которая может быть использована как для статического распознавания на фотографиях, так и в режиме реального времени или видео.

**Ключевые слова:** умные светофоры, нейронные сети, обработка изображения, задача распознавания, обучение модели

### Введение

В современных городах стоит актуальная задача оптимизации дорожного движения, обеспечения безопасности пешеходов и улучшения общей эффективности транспортной инфраструктуры: увеличение пропускной способности дорог и сокращение времени ожидания водителей. В этом контексте технологии «умных светофоров» становятся всё более актуальными и перспективными. Одной из ключевых составляющих таких систем является разработка и внедрение инновационных методов распознавания сигналов световых приборов автомобилей.

Распознавание сигналов световых приборов автомобилей представляет собой сложную и важную задачу. Точное и быстрое распознавание этих сигналов позволяет умным светофорам адаптироваться к текущей ситуации на дороге и оптимизировать потоки транспорта, минимизируя время ожидания на светофорах и снижая вероятность дорожно-транспортных происшествий.

Для реализации распознавания сигналов световых приборов автомобилей применяются передовые технологии: компьютерное зрение, машинное обучение и глубокие нейронные сети. Современные алгоритмы искусственного интеллекта позволяют автоматически обнаруживать и классифицировать сигналы световых приборов, даже в условиях ограниченной видимости, ночного времени или плохих погодных условий.

Интеграция распознавания сигналов световых приборов в умные светофоры открывает новые горизонты

в области управления дорожным движением. «Умные» светофоры, объединённые в единую сеть, могут анализировать потоки транспорта в реальном времени и адаптироваться к текущим условиям, что приводит к сокращению пробок и повышению безопасности на дорогах.

Распознавание сигналов световых приборов автомобилей для умных светофоров имеет огромный потенциал для совершенствования транспортной инфраструктуры и повышения качества жизни городских жителей. Внедрение таких технологий открывает путь к созданию «умных городов», где транспортная система становится более эффективной, устойчивой и безопасной для всех участников движения.

### Существующие подходы для решения задачи детекции объектов

Существует несколько подходов для решения задачи детекции объектов. Некоторые из наиболее распространённых подходов включают в себя:

– *R-CNN (Region Convolutional Neural Network)* – использует методы селекции регионов (*region proposal methods*) для выделения потенциальных областей объектов, а затем применяет свёрточные нейронные сети для классификации и точной локализации объектов;

– *Faster R-CNN* – интегрирует процесс выделения регионов (*region proposal*) в саму модель с использованием нейронной сети. Это делает процесс детекции более быстрым;

– *YOLO (You Only Look Once)* – обрабатывает на всё изображение сразу и предсказывает классы и координаты объектов напрямую;

– *Mask R-CNN* – расширение *Faster R-CNN*, которое добавляет возможность предсказания масок объектов. Это позволяет не только обнаруживать объекты, но и точно выделить их форму.

– *RetinaNet* – объединяет детекцию на разных масштабах и предсказание классов в одну сеть, что помогает справиться с проблемой неравномерного распределения объектов разных размеров;

– *EfficientDet* – использует эффективные блоки для извлечения признаков на разных масштабах и оптимизирован для высокой скорости и точности.

Эти методы могут быть использованы в зависимости от конкретной задачи и требований к скорости и точности. Они часто используют нейронные сети для извлечения признаков и оптимизации обнаружения объектов на изображениях.

### Распознавание машин на видео

Для решения задачи распознавания машин на видео была использована надстройка над *Tensorflow – Keras* – открытая библиотека, написанная на языке *Python* и обеспечивающая взаимодействие с искусственными нейронными сетями [2, 6].

В качестве архитектуры для нейронной сети была применена *RetinaNet* [1], состоящая из 4 основных частей: *backbone*, *feature pyramid net*, *classification subnet*, *regression subnet*.

– *Backbone* (основа сети) – первый шаг в обработке изображения, в котором применяется свёрточная нейронная сеть для извлечения признаков из входного изображения. *Backbone* может быть предобученной свёрточной сетью, например, *ResNet* или *ResNeXt*, которая выдаёт высокоуровневые признаки из входного изображения.

– *Feature Pyramid Network (FPN)* (сеть пирамиды признаков) используется для эффективного использования многомасштабных признаков из *backbone*. Он позволяет выделить объекты разных размеров на изображении, что улучшает точность обнаружения. Основная задача *FPN* заключается в эффективном использовании признаков из различных уровней (масштабов) свёрточной сети (*backbone*), чтобы обнаруживать объекты разных размеров на изображении. Признаки, полученные на более глубоких слоях *backbone*, обладают высокой семантической информацией, что позволяет обнаруживать объекты общего вида.

– *Classification Subnet* (подсеть классификации) – часть сети, которая используется для определения, присутствует ли объект на изображении, и если присутствует, то определить его класс (категорию). *Classification Subnet* принимает на вход признаки, полученные из *Feature Pyramid Network*, и выполняет классификацию объектов, используя

свёрточные слои и полносвязные слои. Для классификации объектов используется функция *Softmax*, которая преобразует выходы классификационной подсети в вероятности принадлежности объекта к каждому из возможных классов.

– *Regression Subnet* (подсеть регрессии) – часть сети предназначена для определения ограничивающих рамок (*bounding boxes*) объектов на изображении. Ограничивающая рамка – это прямоугольник, который обозначает положение и размер обнаруженного объекта. Для каждого обнаруженного объекта на изображении, *Regression Subnet* предсказывает относительные смещения (*delta*) для координат *x*, *y*, *width* и *height*, которые корректируют предварительно заданные якорные (*anchor*) рамки. Активация *Regression Subnet* преобразует эти относительные смещения в абсолютные значения, которые определяют окончательные координаты ограничивающей рамки для каждого объекта.

Для обучения нейронной сети был использован набор данных *COCO2017*, дополненный собственными изображениями, полученными с видеорегастратора.

### Распознавание состояний фар транспорта

Для решения поставленной задачи была использована архитектура *YOLOv8*.

*YOLOv8* – это модель обнаружения объектов и сегментации изображений в реальном времени, которая может определять и классифицировать различные объекты на изображении, а также выделять их контуры [4].

Для сбора набора данных для дальнейшего обучения предлагаются следующие требования к проектируемой модели:

– перед поиском данных на основе проанализированных требований было принято решение искать данные, которые соответствуют следующим критериям: на картинке должны быть как передние, так и задние фары в разных состояниях в разное время суток и в разную погоду, это должны быть любые виды транспорта;

– в ходе поиска были найдены различные наборы данных, общее количество фотографий, среди которых отбирались наилучшие, было примерно 10000;

– в результате для обучения был отобран набор данных на 500 фотографиях.

Следующим шагом был проведён процесс аннотации данных, то есть присвоение

меток каждому изображению в соответствии с состоянием фар. Для этой цели был использован специальный сайт, предназначенный для такой цели – *roboflow* [5].

*Roboflow* – это платформа, которая позволяет использовать для аннотации данных свой собственный инструмент *Roboflow Annotate*.








Рисунок 5. Распознавание разных состояний фар в дневное время суток




Рисунок 6. Кривая точности

Каждый обнаруженный моделью объект имеет некоторую точность обнаружения. Для того, чтобы распознавать максимальное число объектов, необходимо учитывать как высокие, так и низкие значения точности.

График выше показывает, что при пороге 0.811 точность определения всех объектов достигает 100 %.

## Заключение

В работе было исследовано применение методов машинного обучения для распознавания сигналов световых приборов автомобилей с целью использования этих данных в «умных светофорах». Для решения задачи распознавания машин на видео была использована библиотека *Keras*, основанная на *Tensorflow*, и применена архитектура *RetinaNet*.

Также были рассмотрены и проанализированы две разные технологии – *YOLOv8* и *uNet* – для распознавания состояний фар транспорта. По результатам исследования было установлено, что *YOLOv8* в общем случае лучше подходит для распознавания состояния фар, поскольку обладает более высокой скоростью и точностью, способен обнаруживать и классифицировать несколько объектов на изображении и обладает более удобным интерфейсом для обучения и использования.

Для сбора и аннотации данных были выполнены необходимые шаги, и в результате был получен набор данных для обучения модели. Для обучения были разделены данные на тренировочную и тестовую выборки. Обучение проводилось с использованием конфигурационного файла *data.yaml* и выбранных лучших весов – *best.pt*.

В результате обучения модели была достигнута высокая точность распознавания состояний фар разных видов транспорта в различных погодных условиях. Полученная модель может быть использована для статического распознавания на фотографиях, а также в режиме реального времени или на видео.

Представленная статья представляет важный вклад в области распознавания сигналов световых приборов автомобилей для умных светофоров. Результаты исследования могут быть применены в различных сферах, таких как управление транспортным движением, повышение безопасности дорожного движения и разработка инновационных систем «умных светофоров».

## ЛИТЕРАТУРА

1. Tan M., Le Q.V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. 2019. [Электронный ресурс]. URL: [arxiv.org/abs/1905.11946](https://arxiv.org/abs/1905.11946)
2. С. В. Верёвкин, К. С. Курочка. Законы распределения движения автомобилей для распределения дорожного трафика и создания имитационной модели. // Материалы XXIII Республиканской научной конференции студентов и аспирантов (2020): 39-40.
3. Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. // N., Hornegger, J., Wells, W., Frangi, A. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science(), vol 9351. Springer, Cham. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
4. Ultralytics YOLOv8 [Электронный ресурс]. URL: <https://habr.com/ru/articles/710016/> Дата доступа: 31.07.2023.
5. Computer Vision Templates [Электронный ресурс]. URL: <https://roboflow.com/templates>. Дата доступа: 31.07.2023.
6. Kurochka K., Panarin K. Algorithm for real-time binary classification of adenomas and norms images obtained by confocal microscopy //15<sup>th</sup> International Conference Mechatronic Systems and Materials, MSM 2020. – 2020. – С. 9202107-9202107

## REFERENCES

1. **Tan M., Le Q. V.** EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. 2019. [Electronic resource]. URL: [arxiv.org/abs/1905.11946](https://arxiv.org/abs/1905.11946)
2. **S. V. Verevkin, K. S. Kurochka.** Distribution Laws of Vehicle Movement for Traffic Distribution and Creation of a Simulation Model. // Proceedings of the XXIII Republican Scientific Conference of Students and Postgraduates (2020): 39-40.
3. **Ronneberger, O., Fischer, P., Brox, T.** (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. // N., Hornegger, J., Wells, W., Frangi, A. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science(), vol 9351. Springer, Cham. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
4. **Ultralytics YOLOv8** [Electronic resource]. URL: <https://habr.com/ru/articles/710016/> Access date: 31.07.2023.
5. **Computer Vision Templates** [Electronic resource]. URL: <https://roboflow.com/templates>. Access date: 31.07.2023.
6. **Kurochka K., Panarin K.** Algorithm for real-time binary classification of adenomas and norms images obtained by confocal microscopy //15<sup>th</sup> International Conference Mechatronic Systems and Materials, MSM 2020. – 2020. – P. 9202107-9202107

*KUROCHKA K.S., PROKOPENKO D.V., PANARIN K.A.*

## RECOGNITION OF VEHICLE LIGHT SIGNALS FOR SMART TRAFFIC LIGHTS

*Sukhoi State Technical University of Gomel  
Gomel, , Republic of Belarus*

*This paper explores the application of machine learning methods for recognizing automobile light signals to enhance smart traffic light systems. For vehicle detection in video footage, the Keras library was employed along with the RetinaNet neural network architecture [1]. The YOLOv8 architecture was used for identifying the status of vehicle headlights and taillights. Data collection, annotation, and model training were conducted using the Roboflow platform. The research resulted in trained model weights capable of recognizing the state of front and rear lights on various vehicle types under different weather conditions. The paper proposes an adaptation of the YOLOv8-based neural network model for recognizing traffic light signals, which can be utilized for both static recognition in photographs and in real-time or video applications.*

**Keywords:** smart traffic lights, neural networks, image processing, recognition task, model training



**Курочка Константин Сергеевич**, к.т.н, доцент, заведующий кафедрой «Информационные технологии», «Гомельский государственный технический университет имени П.О. Сухого».

**Kurochka Konstantin Sergeevich**, Position and Department: Associate Professor, Ph.D., Head of the Information Technologies Department, Sukhoi Gomel State Technical University.

**E-mail:** [kurochka@gstu.by](mailto:kurochka@gstu.by)



**Панарин Константин Александрович**, инженер-программист кафедры «Информационные технологии», «Гомельский государственный технический университет имени П.О. Сухого».

**Panarin Konstantin Alexandrovich**, Position and Department: Software Engineer at the Information Technologies Department, Sukhoi Gomel State Technical University.

**E-mail:** [logran2@gmail.com](mailto:logran2@gmail.com)



**Прокopenко Дмитрий Викторович**, доцент кафедры информатики, «Гомельский государственный технический университет имени П.О. Сухого».

**Prokopenko Dmitry Viktorovich**, Position and Department: Associate Professor at the Computer Science Department, Sukhoi Gomel State Technical University.

**E-mail:** [prokopenko.dmitry@yandex.ru](mailto:prokopenko.dmitry@yandex.ru)