

**Александр Владимирович Игнатьев**✉

д-р техн. наук, доцент, профессор кафедры цифровых технологий в урбанистике, архитектуре и строительстве, Волгоградский государственный технический университет (ВолгГТУ). Россия, 400074, Волгоград, ул. Академическая, 1;  
e-mail: alignat70@yandex.ru

**Владимир Вячеславович Тырин**

магистрант, Волгоградский государственный технический университет (ВолгГТУ). Россия, 400074, Волгоград, ул. Академическая, 1;  
e-mail: kickerinthedark@gmail.com

**Дмитрий Николаевич Цапиев**

магистрант, Волгоградский государственный технический университет (ВолгГТУ). Россия, 400074, Волгоград, ул. Академическая, 1;  
e-mail: sambarlingkv@gmail.com

**Дмитрий Александрович Саушкин**

магистрант, Волгоградский государственный технический университет (ВолгГТУ). Россия, 400074, Волгоград, ул. Академическая, 1;  
e-mail: saushkin\_2014@mail.ru

**ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ  
ДЛЯ ОПРЕДЕЛЕНИЯ ОСНОВНЫХ ХАРАКТЕРИСТИК  
АВТОТРАНСПОРТНЫХ ПОТОКОВ В ГОРОДЕ<sup>1</sup>**

Предлагается методика автоматического распознавания и классификации транспортных средств, основанная на использовании сверточной нейронной сети Mask R-CNN. Разработанная методика позволяет автоматизировать получение информации о составе транспортного потока и его интенсивности для каждого из видов транспортных средств, лежащих в основе любого метода расчета выбросов загрязняющих веществ автомобильным транспортом. Статья содержит описание этапов обучения нейронной сети, а также результаты, полученные при ее использовании. Разработанная методика оценки интенсивности транспортных потоков, основанная на анализе данных, полученных с видеокамер, установленных на магистралях, с использованием сверточной нейронной сети Mask R-CNN показала хорошие результаты. При расширении тестовой выборки количество классов распознаваемых автомобилей может быть увеличено.

**Ключевые слова:** классификация транспортных средств, интенсивность транспортного потока, компьютерное зрение, распознавание изображений, сверточные нейронные сети, анализ видеопотока, сегментация изображений, Mask R-CNN.

---

<sup>1</sup> Исследование выполнено за счет гранта Российского научного фонда и Администрации Волгоградской области № 22-11-20024. URL: <https://rscf.ru/project/22-11-20024/> (дата обращения: 20.12.2022).

**Для цитирования:** *Игнатъев А. В., Тырин В. В., Цапиев Д. Н., Саушкин Д. А.* Применение нейронных сетей для определения основных характеристик автотранспортных потоков в городе // Социология города. 2022. № 4. С. 70—80. DOI: 10.35211/19943520\_2022\_4\_70

Для принятия экологически обоснованных архитектурно-строительных решений на всех этапах использования населенных территорий необходимо иметь информацию о влиянии на них воздействия различных неблагоприятных факторов, таких как стационарные источники загрязнения атмосферного воздуха, автомобильный транспорт (как источник загрязнения атмосферного воздуха, так и шумового загрязнения), неблагоустроенные (пылящие) территории и др.

В данной работе рассматривается оценка влияния автотранспорта на состояние атмосферного воздуха.

### **1. Характеристики транспортных потоков, используемые для расчета количества выбросов загрязняющих веществ**

Воздействие влияния автотранспорта на состояние атмосферного воздуха определяется прежде всего характеристиками транспортных потоков на различных участках автомобильных дорог. Именно информация о составе транспортного потока и его интенсивности по каждому из видов транспортных средств лежит в основе любого метода расчета выбросов, как от каждого вида транспортных средств, так и суммарных выбросов по отдельным видам загрязняющих веществ.

Рассмотрим ГОСТ Р 56162—2019 «Выбросы загрязняющих веществ в атмосферу. Метод расчета количества выбросов загрязняющих веществ в атмосферу потоками автотранспортных средств на автомобильных дорогах разной категории». В соответствии с ним расчет выбросов загрязняющих веществ от движущихся транспортных средств проводится как на линейных пробегах, так и в зонах регулируемых перекрестков, где значительное количество загрязняющих веществ выбрасывается за счет вынужденного торможения, остановки перед запрещающим сигналом светофора и последующее движение в режиме «разгон» по разрешающему сигналу светофора.

Для выполнения этих расчетов необходимо знать ряд характеристик транспортного потока, определяемых по результатам натурных обследований. К этим характеристикам, например, относятся:

- фактическая наибольшая интенсивность движения;
- средняя скорость движения потока автотранспортных средств на выбранной автомобильной дороге (или ее участке);
- количество автомобилей каждой из групп, находящихся в очереди в районе перекрестка в конце каждого цикла действия запрещающего движение сигнала светофора;
- количество автомобилей каждой из групп, проходящих через зону перекрестка в одном направлении при разрешающем движении сигнале светофора.

## 2. Визуальный метод учета интенсивности движения потока

В ГОСТ 32965—2014 «Дороги автомобильные общего пользования. Методы учета интенсивности движения транспортного потока» для получения этих характеристик рекомендуется использовать метод учета интенсивности, основанный на визуальном наблюдении и регистрации количества проезжающих транспортных средств по выбранному участку трассы.

При этом основной проблемой является то, что идентификация типов, конструктивных и технических особенностей всех транспортных средств, движущихся в потоке, а также учет интенсивности движения выполняется вручную (визуально). Поэтому возникает необходимость разработки методики автоматического определения характеристик транспортных потоков.

В нашем исследовании мы ограничились подсчетом количества автомобилей каждой из групп и определением интенсивности движения потока автотранспортных средств. Именно эти данные в дальнейшем позволят перейти к расчету количества выбросов загрязняющих веществ на обследуемых участках.

## 3. Разработка методики автоматического определения базовых характеристик транспортных потоков

**3.1. Выбор инструментов разработки.** Глубокие нейронные сети в настоящее время становятся одним из самых популярных подходов к созданию систем искусственного интеллекта (Созыкин, 2017). Для обучения глубоких нейронных сетей создано множество библиотек (Jia et al., 2014; Kruchinin et al., 2015; Bahrampour et al., 2016). Среди самых популярных из них Caffe, Theano, TensorFlow, Torch и CNTK (Jia et al., 2014; Bergstra et al., 2010; Abadi et al., 2016; Collobert et al., 2011; Seide, Agarwal, 2016).

Сверточные сети используются в задачах семантической сегментации изображений (Доррер, Корюкин, 2017), обработки потоковых данных, поступающих с камер наблюдения за дорожным движением (Иванов, 2016), распознавания дорожных знаков (Сабилов и др., 2021), распознавания номерных знаков автомобилей (Винокуров, 2018; Козырь, 2017), распознавание типов автомобилей в видеопотоке (Савинов, 2020) и др.

Наибольшую эффективность при решении задач распознавания изображений, в том числе сегментации изображений, показывают сверточные нейронные сети различной архитектуры: YOLO (Redmon et al., 2016), YOLO9000 (Redmon, Farhadi, 2016), YOLOv3 (Redmon, Farhadi, 2018), YOLOv4 (Bochkovskiy et al., 2020), YOLOv5 (Zhu et al., 2021), Mask R-CNN (He et al., 2017; Johnson, 2018), U-Net (Ronneberger et al., 2015).

Задачу учета количества экземпляров всех автомобилей, принадлежащих разным классам, можно отнести к задаче сегментации экземпляров.

Задачи сегментации изображения требуют использования в качестве обучающих меток бинарных масок. Такие маски состоят из массивов того же размера, что и исходное изображение, но вместо значений пикселей RGB содержат нули и единицы, указывающие, где находится объект на изображении.

Архитектура Mask R-CNN — одна из ведущих архитектур, способных уверенно классифицировать объекты изображения на уровне пикселей.

Исходя из этого, при реализации методики определения характеристик транспортных потоков мы выбрали Mask R-CNN.

Для создания самой нейросети мы использовали одноименную библиотеку Mask R-CNN, обладающую рядом преимуществ. Она проверяет правильность разметки и соответствие загруженных в датасет фотографий с камер дорожного наблюдения файлу описания разметки. Кроме того, не обязательно приводить изображения к одному формату (это делает сама библиотека).

**3.2. Обучение нейронной сети.** При обучении нейросети использовалась классификация автомобилей, принятая в ГОСТ Р 56162—2019:

- I Легковые автомобили (car);
- II Фургоны и микроавтобусы массой до 3,5 т (microbus);
- III Грузовые автомобили массой от 3,5 до 12 т (truck 3.5—12);
- IV Грузовые автомобили массой более 12 т (truck 12);
- V Автобусы массой более 3,5 т (bus).

Разработанная нами нейронная сеть содержит шесть скрытых слоев (количество типов классифицируемых объектов плюс один).

Для качественного обучения нейронной сети требуется большой набор данных, включающий 2000 и более аннотированных изображений. Есть готовые наборы для обучения, такие как ImageNet, MS COCO и др. Например, выборка MS COCO 2018 г. включает около 330 тыс. изображений, на которых выделено 1,5 млн объектов. Каждый такой объект принадлежит к одному из 80 классов. К сожалению, в этом наборе данных всего 3 класса транспортных средств: легковые автомобили, грузовики и автобусы. Поэтому для переобучения нейронной сети нам пришлось самостоятельно подготовить обучающий набор данных, размер которого оказался относительно небольшим.

Для создания набора данных, который впоследствии использовался для обучения нейросети, использовались 500 изображений автомобилей (по 100 изображений для каждого типа автомобилей), которые были получены с общедоступных камер. Доступ к камерам предоставляет сервис «Город на ладони» (<https://cam.powernet.com.ru/>). Затем изображения были размечены с помощью программы VGG Image Annotator (рис. 1).

На каждом из кадров отмечался только один из типов транспортных средств, даже если в кадре присутствовало несколько разных типов автомобилей. Так, например, в кадре, показанном на рис. 2, а, находятся легковой автомобиль, микроавтобус и грузовой автомобиль массой более 12 т, но при разметке выделен только грузовик массой более 12 т (рис. 2, б).

Полученный набор данных разделен на обучающую и тестовую выборки в соотношении 3:2 соответственно.

При обучении сети для полного покрытия всего набора данных было задано 500 итераций на эпоху.

Для уверенного распознавания автомобилей на видео понадобилось 50 эпох.




Рис. 1. Разметка автомобилей с помощью программы VAG Image Annotator



*a*



*б*

Рис. 2. Пример разметки изображения: *a* — кадр с изображением автомобилей до разметки; *б* — кадр с размеченным грузовым автомобилем массой более 12 т (truck 12)

### 3.3. Подсчет количества автомобилей и определение интенсивности движения потока автотранспортных средств. При обработке ви-

деофайла на его первом кадре нужно установить контрольную линию, которая нужна для подсчета автотранспортных средств (рис. 3).



**Рис. 3.** Пример установки контрольной линии (красная черта)

При первом пересечении ограничивающей линии автотранспортным средством счетчик регистрирует его во внутренней базе данных, хранящей информацию о местоположении автомобильного средства, его категории, а также техническую информацию, которая необходима для работы счетчика. При повторном пересечении линии, например на следующем кадре, автомобиль повторно не регистрируется, так как перед регистрацией новых автомобилей проверяется присутствие уже найденных автомобильных средств в базе данных для исключения возможного повторного обнаружения.

Отдельно отметим, что алгоритм поиска уже обнаруженных транспортных средств учитывает их возможное передвижение в границах одного кадра. Это делается посредством вычисления геометрического центра с помощью данных о местоположении ограничивающей рамки для каждого автотранспортного средства, предоставленных Mask R-CNN. Если разница между найденным геометрическим центром определенного автомобильного транспорта нового кадра и геометрическим центром того же автомобильного средства, но на предыдущем кадре совпадает или отличается на определенное число, которое можно считать погрешностью, объясняемой передвижением автомобильного средства за один кадр, то счетчик не регистрирует автомобиль повторно, а всего лишь обновляет данные о его местоположении, затем приступая к поиску новых автомобильных средств.

При обработке каждого из кадров разработанная нейронная сеть сохраняет информацию о местоположении каждого обнаруженного автотранспортного средства, его категории, размере и адресации ограничивающей рамки, а также полное имя категории, которую нужно вывести на экран. На основе этих данных счетчик оценивает местоположение

автотранспортного средства относительно ограничивающей линии, делая вывод о количестве автотранспорта, пересекающего ограничивающую линию.

Если при проверке транспортных средств автотранспортное средство, обнаруженное на предыдущем кадре, не найдено, оно помечается как покинувшее зону осмотра (как неактивное). Делается это во избежание конфликтов с другим автотранспортным средством при его обнаружении на этом же или близком к этому месту на обрабатываемом кадре, так как информация о местоположении прошлого транспортного средства все еще остается в базе данных, что может повлечь конфликт, если не проводить проверку, описанную выше.

В ходе выполнения указанных действий при обработке каждого кадра счетчик получает необходимые данные о транспортных средствах, пересекших контрольную линию в течение всего промежутка времени, зафиксированного на видео.

Результатом обработки видеофайла на этом этапе является текстовый файл, содержащий информацию о количестве обнаруженных транспортных средств с разбивкой их по категориям (рис. 4). Эти данные являются основой для расчета характеристик транспортного потока, рассмотренных выше в разделе 1.

Отмеченная в алгоритме поиска возможность учета передвижения транспортных средств в границах одного кадра позволяет делать расчет интенсивности и средней скорости потока автомобилей. В то же время категоризованные количественные оценки потока автотранспорта являются основой для вычисления приведенных параметрам автомобилей выбросов загрязняющих веществ.

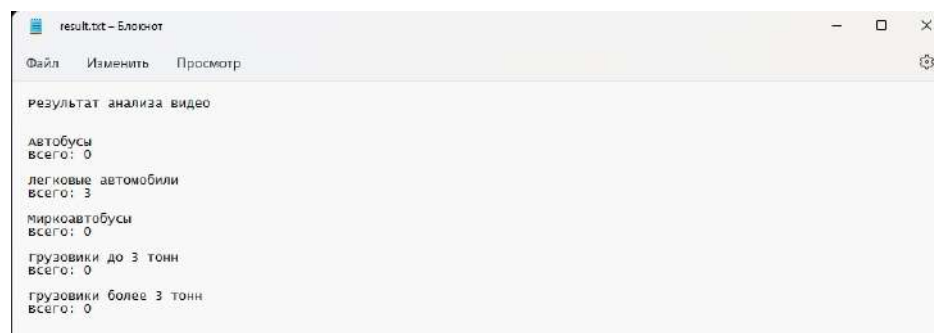


Рис. 4. Пример результата обработки видеофайла

### Заключение

Разработанная методика оценки интенсивности транспортных потоков, основанная на анализе данных, полученных с видеокамер, установленных на магистралях, с использованием сверточной нейронной сети Mask R-CNN показала хорошие результаты. При расширении тестовой выборки количество классов распознаваемых автомобилей может быть увеличено.

Созданные программные инструменты интеллектуального анализа исходных характеристик транспортного потока в дальнейшем могут быть

использованы для комплексного обследования экологической обстановки. При этом такой анализ может производиться одновременно на всех контролируемых камерами видеонаблюдения участках улично-дорожной сети, в том числе в реальном времени, при наличии достаточных вычислительных ресурсов.

### Благодарности

Авторы выражают благодарность коллегам по кафедре цифровых технологий в урбанистике, архитектуре и строительстве ИАиС ВолгГТУ, принимавшим участие в разработке проекта.

### БИБЛИОГРАФИЧЕСКИЙ СПИСОК

*Винокуров И. В.* Адаптивное распознавание элементов регистрационного номера автомобиля // Международный научно-исследовательский журнал. 2018. № 1-1(67). С. 44—47.

*Доррер Г. А., Корюкин М. С.* Семантическая сегментация изображений с применением сверточных нейронных сетей // Актуальные проблемы авиации и космонавтики. 2017. Т. 2. № 13. С. 141—143.

*Иванов Е. С.* Использование модульной системы обработки потоковых данных, поступающих с камер наблюдения, для выделения объектов с помощью сегментации // Программные системы: теория и приложения. 2016. Т. 7. № 4(31). С. 305—316.

*Козырь М. В.* Сверточная нейронная сеть для распознавания символов номерного знака автомобиля // Россия молодая: передовые технологии — в промышленность. 2017. № 2. С. 73—78.

*Сабиров А. И., Катасев А. С., Дагаева М. В.* Нейросетевая модель распознавания знаков дорожного движения в интеллектуальных транспортных системах // Компьютерные исследования и моделирование. 2021. Т. 13. № 2. С. 429—435.

*Савинов Е. Д.* Распознавание типов автомобилей в видеопотоке // Цифровые технологии в образовании, науке, обществе: Материалы XIV всероссийской науч.-практич. конф., Петрозаводск, 01—04 декабря 2020 года. Петрозаводск: Петрозаводский государственный университет, 2020. С. 142—144.

*Созыкин А. В.* Обзор методов обучения глубоких нейронных сетей // Вестник Южно-Уральского государственного университета. Серия: Вычислительная математика и информатика. 2017. № 6. С. 28—59.

*Abadi M., Agarwal A., Barham P.* TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems // Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation. 2016. Pp. 265—283.

*Bahrampour S, Ramakrishnan N, Schott L, Shah M.* Comparative Study of Deep Learning Software Frameworks. URL: <https://arxiv.org/abs/1511.06435> (accessed: 30.03.2016).

*Bergstra J., Breuleux O., Bastien F.* Theano: a CPU and GPU Math Expression Compiler // Proceedings of the Python for Scientific Computing Conference. 2010. Pp. 3—10.

*Bochkovskiy A., Wang C., Liao H.M.* YOLOv4: Optimal Speed and Accuracy of Object Detection. 2020. URL: <https://arxiv.org/abs/2004.10934> (accessed: 23.04.2020).

*Collobert R., Kavukcuoglu K., Farabet C.* Torch7: a Matlab-like Environment for Machine Learning. NIPS Workshop. 2011. URL: <https://infoscience.epfl.ch/record/192376> (accessed: 24.01.2022).

*He K., Gkioxari G., Dollár P., Girshick R.* Mask R-CNN. URL: <https://arxiv.org/abs/1703.06870> (accessed: 24.01.2018).



*Jia Y., Shelhamer E., Donahue J.* Caffe: Convolutional Architecture for Fast Feature Embedding // Proceedings of the 22nd ACM International Conference on Multimedia. 2014. Pp. 675—678.

*Johnson J. W.* Adapting Mask-RCNN for Automatic Nucleus Segmentation. URL: <https://arxiv.org/abs/1805.00500> (accessed: 01.05.2018).

*Kruchinin D., Dolotov E., Korniyakov K.* Comparison of Deep Learning Libraries on the Problem of Handwritten Digit Classification. Analysis of Images, Social Networks and Texts // Communications in Computer and Information Science. 2015. Pp. 399—411.

*Redmon J., Divvala S., Girshick R., Farhadi A.* You Only Look Once: Unified, Real-Time Object Detection. URL: <https://arxiv.org/abs/1506.02640> (accessed: 09.05.2016).

*Redmon J., Farhadi A.* YOLO9000: Better, Faster, Stronger. URL: <https://arxiv.org/abs/1612.08242> (accessed: 25.12.2016).

*Redmon J., Farhadi A.* YOLOv3: An incremental improvement. URL: <https://arxiv.org/abs/1804.02767> (accessed: 08.04.2018).

*Ronneberger O., Fischer P., Brox T.* U-Net: Convolutional Networks for Biomedical Image Segmentation. URL: <https://arxiv.org/abs/1505.04597> (accessed: 18.05.2015).

*Seide F., Agarwal A.* CNTK: Microsoft's Open-Source Deep-Learning Toolkit // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016. Pp. 2135. DOI: 10.1145/2939672.2945397.

*Zhu X., Lyu S., Wang X., Zhao Q.* TPH-YOLOv5: Improved YOLOv5 Based on Transformer Prediction Head for Object Detection on Drone-captured Scenarios. URL: <https://arxiv.org/abs/2108.11539> (accessed: 26.08.2021).

#### **Alexander V. Ignatyev**

Doctor of Engineering Sciences, Docent, Professor of Digital Technologies for Urban Studies, Architecture and Civil Engineering Department, Volgograd State Technical University (VSTU). 1, Akademicheskaya st., Volgograd, 400074, Russia;  
e-mail: [alignat70@yandex.ru](mailto:alignat70@yandex.ru)

#### **Vladimir V. Tirin**

Master' Degree student, Volgograd State Technical University (VSTU). 1, Akademicheskaya st., Volgograd, 400074, Russia

#### **Dmitry N. Tsapiev**

Master' Degree student, Volgograd State Technical University (VSTU). 1, Akademicheskaya st., Volgograd, 400074, Russia;  
e-mail: [sambarlingkv@gmail.com](mailto:sambarlingkv@gmail.com)

#### **Dmitry A. Saushkin**

Master' Degree student, Volgograd State Technical University (VSTU). 1, Akademicheskaya st., Volgograd, 400074, Russia;  
e-mail: [saushkin\\_2014@mail.ru](mailto:saushkin_2014@mail.ru)

## APPLICATION OF NEURAL NETWORKS TO DETERMINE THE MAIN CHARACTERISTICS OF ROAD TRAFFIC FLOWS IN THE CITY<sup>2</sup>

**Abstract.** The article proposes a technique for automatic recognition and classification of vehicles based on the use of convolutional neural network Mask-R-CNN. The developed methodology makes it possible to automate obtaining information about the composition of the traffic flow and its intensity for each of the types of vehicles underlying any method of calculating emissions of pollutants by road. The article contains a description of the stages of neural network training, as well as the results obtained when using it. The proposed method of automating the process of assessing the intensity of the flow of vehicles, extracting data about it by analyzing the video stream from cameras installed on highways, and based on the use of the convolutional neural network Mask-R-CNN, showed good results. With the expansion of the test set, the number of classes of recognized cars can be increased, which will allow it to be used when applying methods for calculating emissions of pollutants that include a larger number of types of vehicles.

**Keywords:** classification of vehicles, intensity of traffic flow, computer vision, image recognition, convolutional neural networks, video stream analysis, image segmentation, Mask R-CNN.

**For citation:** Ignatyev A. V., Tirin V. V., Tsapiev D. N., Saushkin D. A. (2022) Application of neural networks to determine the main characteristics of road traffic flows in the city. *Sotsiologiya Goroda* [Urban Sociology], no. 4, pp. 70—80 (in Russian). DOI: 10.35211/19943520\_2022\_4\_70

### Acknowledgments

The authors express gratitude to colleagues from the Department of Digital Technologies for Urban Studies, Architecture and Civil Engineering VSTU involved in the development of the project.

### REFERENCES

Abadi M., Agarwal A., Barham P. (2016) TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems. *Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation*, pp. 265—283.

Bahrampour S., Ramakrishnan N., Schott L., Shah M. (2015) *Comparative Study of Deep Learning Software Frameworks*. URL: <https://arxiv.org/abs/1511.06435> (accessed: 30.03.2016).

Bergstra J., Breuleux O., Bastien F., et al (2010) Theano: a CPU and GPU Math Expression Compiler. *Proceedings of the Python for Scientific Computing Conference*, pp. 3—10.

Bochkovskiy A., Wang C., Liao H. M. (2020) *YOLOv4: Optimal Speed and Accuracy of Object Detection*. URL: <https://arxiv.org/abs/2004.10934> (accessed: 23.04.2020).

---

<sup>2</sup> The study has been supported by the grant from the Russian Science Foundation and the Administration of the Volgograd Oblast (Russia) No. 22-11-20024. URL: <https://rscf.ru/en/project/22-11-20024/> (accessed: 20.12.2022).

Collobert R., Kavukcuoglu K., Farabet C. (2011) *Torch7: a Matlab-like Environment for Machine Learning, NIPS Workshop*. URL: <https://infoscience.epfl.ch/record/192376> (accessed: 24.01.2022).

Dorrer G. A., Koriukin M. S. (2017) Semantic image segmentation of convolutional neural networks. *Aktual'nye problemy aviatsii i kosmonavтики* [Current Problems of Aviation and Space], vol. 2, no. 13, pp. 141—143 (in Russian).

He K., Gkioxari G., Dollár P., Girshick R. (2017) *Mask R-CNN*. URL: <https://arxiv.org/abs/1703.06870> (accessed: 24.01.2018).

Ivanov E. S. (2016) Using a modular system for processing streaming data from surveillance cameras to select objects using segmentation. *Programmnyye sistemy: teoriya i prilozheniya* [Program Systems: Theory and Applications], vol. 7, no. 4(31), pp. 305—316 (in Russian).

Jia Y., Shelhamer E., Donahue J., et al. (2014) Caffe: Convolutional Architecture for Fast Feature Embedding. *Proceedings of the 22nd ACM International Conference on Multimedia*, pp. 675—678. DOI: 10.1145/2647868.2654889

Johnson J. W. (2018) *Adapting Mask-RCNN for Automatic Nucleus Segmentation*. URL: <https://arxiv.org/abs/1805.00500> (accessed: 01.05.2018).

Kozyr M. V. (2017) Convolutional Neural Network for License Plate Character Recognition. *Rossiya molodaya: peredovye tekhnologii — v promyshlennost'* [Young Russia: Advanced Technologies for Industry], no. 2, pp. 73—78 (in Russian).

Kruchinin D., Dolotov E., Korniyakov K. (2015) Comparison of Deep Learning Libraries on the Problem of Handwritten Digit Classification. Analysis of Images, Social Networks and Texts. *Communications in Computer and Information Science*, pp. 399—411.

Redmon J., Divvala S., Girshick R., Farhadi A. (2015) *You Only Look Once: Unified, Real-Time Object Detection*. URL: <https://arxiv.org/abs/1506.02640> (accessed: 09.05.2016).

Redmon J., Farhadi A. (2016) *YOLO9000: Better, Faster, Stronger*. URL: <https://arxiv.org/abs/1612.08242> (accessed: 25.12.2016).

Redmon J., Farhadi A. (2018) *YOLOv3: An incremental improvement*. URL: <https://arxiv.org/abs/1804.02767> (accessed: 08.04.2018).

Ronneberger O., Fischer P., Brox T. (2015) *U-Net: Convolutional Networks for Biomedical Image Segmentation*. URL: <https://arxiv.org/abs/1505.04597> (accessed: 18.05.2015).

Sabirov A. I., Katasev A. S., Dagaeva M. V. (2021) A neural network model for traffic signs recognition in intelligent transport systems. *Komp'yuternye issledovaniya i modelirovaniye* [Computer Research and Modeling], vol. 13, no. 2, pp. 429—435 (in Russian).

Savinov E. D. (2020) Recognition of car types in a video stream. *XIV All-Russian Scientific and Practical Conference Digital Technologies in Education, Science, Society* [Tsifrovyye tekhnologii v obrazovanii, nauke, obshchestve: Materialy XIV vserossiiskoi nauch.-praktich. konf., Petrozavodsk, 01—04 dekabrya 2020 goda]. Petrozavodsk, pp. 142—144 (in Russian).

Seide F., Agarwal A. (2016) CNTK: Microsoft's Open-Source Deep-Learning Toolkit. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 2135.

Sozykin A. V. (2017) An overview of methods for deep learning in neural networks. *Vestnik YuUrGU. Ser. Vych. Matem. Inform.*, no. 6, pp. 28—59 (in Russian).

Vinokurov I. V. (2018) Adaptive recognition of elements of vehicle registration number. *Mezhdunarodnyi nauchno-issledovatel'skii zhurnal* [International Research Journal], no. 1 (67), pp. 44—47 (in Russian).

Zhu X., Lyu S., Wang X., Zhao Q. (2021) *TPH-YOLOv5: Improved YOLOv5 Based on Transformer Prediction Head for Object Detection on Drone-captured Scenarios*. URL: <https://arxiv.org/abs/2108.11539> (accessed: 26.08.2021).

Поступила в редакцию 21.12.2022

Received 21.12.2022

Принята в печать 27.12.2022

Accepted for publication 27.12.2022