

## КОНТРОЛЬ НАЗЕМНЫХ ОБЪЕКТОВ НА ОСНОВЕ НЕЙРОСЕТЕВОГО РАСПОЗНАВАНИЯ В АВИАЦИОННЫХ СИСТЕМАХ ТЕХНИЧЕСКОГО ЗРЕНИЯ

Ненашев В.А.<sup>1</sup>, Ненашев С.А.<sup>2</sup>, Бестугин А.Р.<sup>3</sup>, Киршина И.А.<sup>4</sup>, Куркова О.П.<sup>5</sup>

<sup>1-5</sup>Санкт-Петербургский государственный университет аэрокосмического приборостроения  
(Санкт-Петербург, Россия)

*Исследование выполнено за счет гранта Российского научного фонда (проект № 22-79-00303).*

**Аннотация.** Статья посвящена задаче автоматического распознавания наземных объектов интереса местности на основе обработки последовательности радиолокационных кадров, снятых с малого летательного аппарата. В статье рассматривается актуальная задача - мониторинг и контроль наземных объектов интереса на земной поверхности. Продемонстрированы возможности технического зрения, позволяющего распознавать наземные объекты и подсчитывать их количество на сформированных радиолокационных кадрах с малого летательного аппарата. Результаты исследования показывают высокий процент доли верно распознанных наземных объектов при использовании методов технического зрения.

Реализованный процесс по распознаванию наземных объектов имеет высокую практическую значимость. Особенно для целей, требующих решение задач оперативного характера, например, для реализации спасательных операций при поиске физических наземных объектов, в частности, людей.

**Ключевые слова.** Техническое зрение, контроль объектов, обработка видеокадров, распознавание наземных объектов, нейронная сеть, авиационные системы.

## GROUND OBJECT CONTROL BASED ON NEURAL NETWORK RECOGNITION IN AVIATION VISION SYSTEMS

Nenashev V.A.<sup>1</sup>, Nenashev S.A.<sup>2</sup>, Bestugin A.R.<sup>3</sup>, Kirshina I.A.<sup>4</sup>, Kurkova O.P.<sup>5</sup>

<sup>1-5</sup>Saint-Petersburg State University of Aerospace Instrumentation (Saint-Petersburg, Russia)

**Abstract.** The article is devoted to the task of automatic recognition of ground objects of interest on the basis of processing a sequence of radar frames taken from a small aircraft. The article deals with the actual task of monitoring and control of ground objects of interest on the earth's surface. The possibilities of technical vision, allowing to recognize ground objects and count their number on the formed radar frames from a small aircraft, are demonstrated. The results of the study show a high percentage of the proportion of correctly recognized ground objects when using vision techniques.

The implemented process for recognizing ground objects has high practical significance. Especially for purposes that require the solution of tasks of operational nature, for example, for the realization of rescue operations in the search for physical ground objects, in particular, people.

**Keywords.** Technical vision, object control, video frame processing, ground object recognition, neural network, aviation systems.

## **Введение**

В современных условиях стремительного развития авиационных технологий становится технически реализуемым использование радиолокационных источников визуальной потоковой информации, собираемой малогабаритными бортовыми радиолокационными системами (МБРЛС) [1-4], которые базируются на малых летательных аппаратах (МЛА), в том числе МЛА, объединенных во взаимодействующую группу [1, 2].

МБРЛС способны формировать потоки радиолокационных кадров (РЛК) на основе модификации метода радиолокационного синтезирования апертуры (РСА) антенны [5, 6].

Подобные системы технического зрения хорошо зарекомендовали себя и все чаще применяются для оперативного поиска наземных объектов (НО) в сложных погодных и сезонных условиях ограниченной видимости, а также в зонах чрезвычайных ситуаций (в случаях, когда требуется осуществлять именно оперативный мониторинг сквозь облака, туман, дождь, дым, песчаные бури и другие условия, которые затрудняют работу оптических систем) [1, 4, 7, 8].

Оперативный контроль состояния природных, техногенных и искусственных НО применяется в области сельского, лесного хозяйства, природопользования, а также при обнаружении аварий на нефтепроводах, пожаров в лесополосах и т.д.

При этом реализация процесса автоматического распознавания НО интереса (деревьев, автомобилей, зданий и т.д.) на радиолокационных потоковых данных является актуальной задачей контроля и мониторинга на обширных по площади территориях. Важнейшим аспектом этой разработки является обучение нейронной сети (НС) и последующее распознавание НО, находящихся на радиолокационных кадрах потока.

## **Постановка задачи**

Одна из основных проблем мониторинга за территориями – это необходимость постоянного оперативного контроля за находящимися на ней НО, особенно в случаях возникновения чрезвычайной ситуации. Это может быть довольно трудоемкой задачей, особенно при контроле больших территорий и в труднодоступных местах, а также в местах опасных для жизни человека.

С целью преодоления данной проблемы был реализован подход, основанный на использовании метода технического зрения. В результате применения данного подхода реализуется подсчет количества разнообразных НО на собранных с МЛА РЛК видеопотока.

Для решения поставленной задачи требуется:

- осуществить выбор архитектуры НС, наиболее подходящей для обучения с учетом специфики выбранных потоков данных – РЛК;
- определить требования к выборке потока РЛК;
- осуществить подготовку выборки РЛК для обучения НС;
- провести эксперименты на тестовой выборке;

- определить эффективность работы НС на основе конкретных метрик оценки качества.

### **Выбор модели нейронной сети**

На сегодняшний день известно множество моделей НС [9] с различными архитектурами, которые адаптированы (заточены) под решение конкретных задач с учетом их специфики и с учетом выбранных входных данных для обучения и тестирования.

Так, например, для задач распознавания, связанных с изображениями, применяются следующие модели НС: VGGNet, GoogLeNet, ResNet, DenseNet, MobileNet, WideResNet, полностью сверточные сети (fully convolutional networks, FCN), целостно-вложенный детектор краев (holistically-nested edge detector, HED), Faster R-CNN и др. Для задач, связанных с распознаванием видеоданных – YOLOv9, CNN+LSTM, Inflated 3D CNN, 3D ResNet, SiamFC, SiamRPN++, SiamRPN+CIR, FlowNet, SpyNet, PWC-Net, Back2Future, Epic Flow, LDOF и др. [10].

Проведенный анализ вышеуказанных моделей НС, а также их архитектур, с целью выбора наиболее подходящей, и с учетом специфики входных данных, которые представлены в виде набора радиолокационных кадров, показал, что наиболее приемлемым вариантом для данного рода и типа данных является модель НС YOLO версии 9.

Преимуществом использования НС YOLOv9 в целях выделения и распознавания НО в потоке радиолокационных кадров является высокий процент доли верно распознанных НО. Она позволяет обрабатывать входные данные с частотой кадров от 5 Гц на графическом процессоре и способна обеспечить высокую точность распознавания НО, а также обеспечивает режим реального времени, однако для объектов, размер которых сравним с размером пикселя на РЛК, заявленная точность обнаружения не достигается [11], поэтому далее будут рассмотрены требования к разрешению РЛК-в потока.

После выбора архитектуры НС, требуется определить требования к выборке потоковых данных для обучения, и осуществить их подготовку.

### **Требования к выборке данных для обучения**

Для дальнейших экспериментов следует определить характеристики обучающей выборки, а именно ее объем, разрешение кадров, состав, наличие синтетики, наличие экспериментальных данных и т.д.

Объем выборки должен составлять не менее 10 тысяч кадров потока для каждого класса НО. Дополнительно выборка должна включать не менее 2 тысяч кадров потока для каждого класса НО, сформированных в различных сложных условиях наблюдения.

Как было упомянуто ранее, важнейшим атрибутом для процесса обучения НС является детальность (качество) входных данных, в данном случае разрешение РЛК потока с наличием фрагментов НО на них.

Известно, что при разрешении РЛК 2 м можно судить о принадлежности объекта к определенному классу, а при повышении качества РЛК до 0,15 м

эффективность решения задачи распознавания повышается в несколько раз [5, 6]. Задача по увеличению доли верно распознанных НО (до 95% и больше) может быть решена при разрешении РЛК 0.15-0,25 м.

Таким образом, радиолокационные кадры потока должны быть высокого разрешения (от 0,25 м) для обеспечения детализации НО-в и их характеристик.

При этом в составе выборки должны присутствовать потоки РЛК земной поверхности с разнообразными типами НО, включая природные, техногенные и искусственные элементы. Частота следования радиолокационных кадров в потоке должна быть от 5 Гц.

Следует отметить, что в отдельных случаях допускается использование синтетических данных (не более 30% от общего объема обучающей выборки) для расширения перечня ключевых объектов распознавания, включая радиолокационные кадры потока с имитацией различных сценариев применения в потоке.

### **Подготовка данных для обучения модели нейросети**

Подготовка данных является ключевым этапом в процессе обучения НС при реализации авиационных систем с техническим зрением. Этот этап включает в себя сбор данных, их предварительную обработку и преобразование в формат, который может быть использован моделью НС для обучения. Впоследствии, данные разделяются на тренировочную (70%) и тестовую (30%) части выборки. В данном случае, были подготовлены данные для распознавания НО на РЛК видеопотока. Далее представлена методика подготовки видеоданных для обучения НС, которая состоит из 4 этапов.

**Этап 1: Обработка исходных данных.** Исходный видеоматериал был разбит на отдельные кадры с помощью инструмента «ffmpeg» [12]. Этот процесс называется разделением видеопотока на кадры. Этот шаг необходим для преобразования видео в формат, который можно использовать для обучения модели НС.

**Этап 2: Структурирование и аннотация необработанных данных.** Далее на основе использования программного средства «roboflow» [13], требуется осуществить разметку на РЛК, только тех их областей, где находятся НО интереса для формирования маски объекта распознавания.

Этот процесс по разметке данных осуществляет присвоение атрибутов НО-м на РЛК, которые затем используются для обучения модели НС.

Таким образом, все РЛК потока в обучающей выборке должны быть аннотированы, включая метки классов объектов и их геометрические параметры. Аннотации должны быть выполнены с учетом выявления отличительных и надежных признаков НО интереса, соответствующих сугубо данному классу данных.

**Этап 3: Детализация данных выборки.** Далее каждый отдельный кадр разделяется на 9 ячеек размером 3x3 для увеличения точности распознавания мелких объектов. Этот процесс называется разбиением кадров выборки для обучения на отдельные ячейки, что позволяет модели НС анализировать и

обрабатывать фрагменты кадров на более детализированном уровне, что впоследствии повышает точность и эффективность распознавания НО в потоке РЛК.

**Этап 4: Аугментация данных.** Также кадры для обучения требуется дополнить аналогичными, искусственно сформированными РЛК, на основе преобразования существующих. Например, дополнить выборку кадрами с различными искажающими их эффектами, возникающими в результате деструктивных воздействий естественного происхождения в процессе формирования потока РЛК.

Это требуется для того, чтобы модель НС могла в дальнейшем, в процессе реальных экспериментов, распознавать НО-ы интереса [14] и по отдельным кадрам потока, сформированным с некоторым искажением, в том числе в плохом качестве. Этот процесс называется аугментацией данных и включает в себя создание искусственных данных путем применения различных искажений к реальным данным, например, геометрические преобразования, яркостные, преобразование фона, а также искажения, характерные для конкретной решаемой задачи: шумы, расфокусировка, зернистость и т.д. Таким образом, для реализации данного процесса, требуется детально определить тип искажений, присущих выбранному набору данных.

Как было обозначено ранее, исходная последовательность РЛК была разделена на две части: 70% данных использовались для обучения модели НС, а 30% - для ее тестирования. Далее реализуется процесс обучения НС по 70 % размеченных данных в соответствии с вышеприведенными этапами 1-4.

Далее требуется провести эксперименты по распознаванию НО на тестовой выборке и определить эффективность работы НС на основе выбранных метрик качества. Это позволяет оценить, насколько точно обученная модель НС может распространить свои нейросетевые способности на ранее не используемые тестовые данные.

#### **Требования к выборке данных для тестирования и объекту распознавания**

Обучив НС на размеченных данных, далее требуется осуществить ее тестирование на данных, которые не участвовали в процессе ее обучения с целью оценки ее эффективности. Эти тестовые данные требуется также разделить из видеопоследовательности на отдельные кадры. Например, видеопоследовательность с частотой 10 кадров в секунду и длительностью 120 секунд будет разбита на 1200 отдельных РЛК.

Затем, каждый отдельный РЛК проходит через модель НС, которая выделяет НО на текущем кадре. Это может быть достигнуто с помощью различных методов, включая использование средств библиотеки «Ultralytics» [15].

После этого, осуществляется выделение каждого НО в рамку. При этом каждому НО [16] присваивается уникальный идентификационный номер (УИН), который позволяет определять, а также подсчитывать данные объекты, находящиеся в текущем кадре.

Таким образом, реализуется распознавание НО в текущем кадре в данный момент, а также используются УИН НО для подсчета общего количества наблюдаемых НО за время всего наблюдения за земной поверхностью. При подсчёте присвоение УИН позволяет избежать многократного учета одного и того же НО.

После обработки всех кадров они объединяются обратно в видео и сохраняются для дальнейшего использования.

Следует отметить, что объектами для распознавания (рис. 1) являются деревья, они представляют собой характерную структуру, легко узнаваемую, благодаря своей зонтиковидной форме. Эта форма позволяет отличать деревья от других объектов на РЛК, таких как здания или автотранспорт.



Рис. 1. Кадр для распознавания НО

Таким образом, отличительным атрибутом объекта распознавания, в данном случае дерева [17], является их форма, что позволяет использовать методы нейросетевого распознавания для их идентификации и выделения в кадре, что может быть полезно в таких приложениях, как мониторинг и контроль лесных массивов, планирование уборки урожая и оценка последствий пожаров.

### **Результаты экспериментов и оценка эффективности модели НС**

В результате экспериментов по распознаванию НО, обученная НС на основе обработки тестовой выборки должна осуществлять определение границ, координат и характеристик движения НО (при наличии) на радиолокационном кадре потока с детальным распознаванием этих объектов и с их выделением в ограничивающую рамку в системе координат текущего кадра.

На рис. 2 показаны отдельные РЛК - результат работы НС-ти, которая успешно распознала НО и осуществила подсчет их количества. Желтые, красные и розовые рамки вокруг НО указывают на корректное их распознавание с определением точности распознавания.

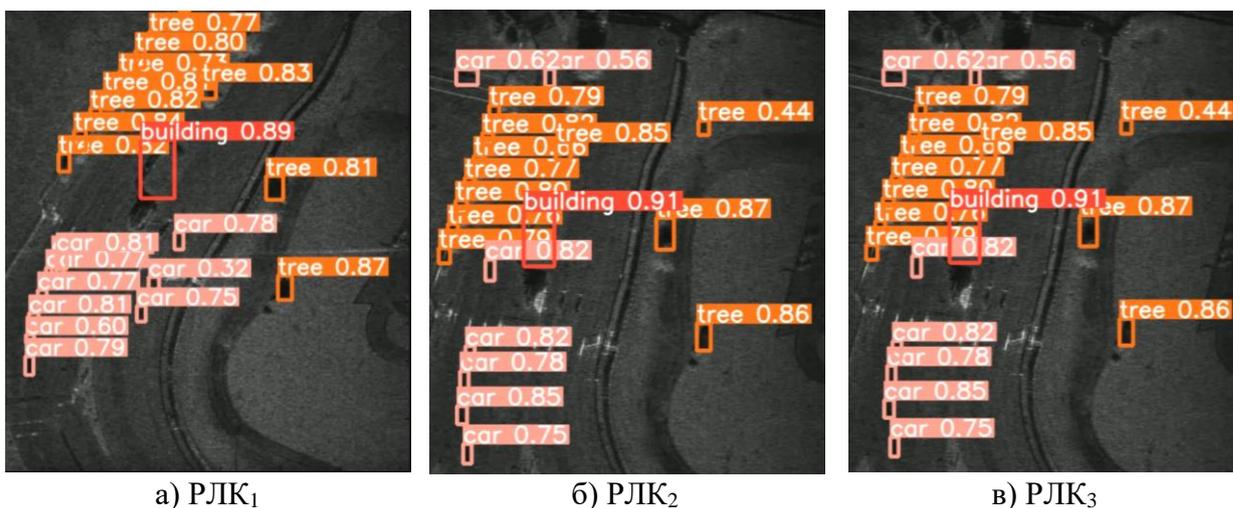


Рис. 2. Результаты работы НС

Таким образом, на основе применения НС на кадрах видеопотока распознаны следующие НО до уровня класса: дерево, здания и транспортные средства. Отдельно реализована процедура подсчета их общего количества в каждом классе, определение текущих координат в кадре, а также реализовано отслеживание каждого НО с УИН с построением соответствующей траектории движения НО.

Границы вокруг объектов указывают на корректное распознавание и присвоением им УИН. Следует отметить тот факт, что размер объектов достаточно мал, что усложняет их визуальное обнаружение, однако модель справилась с этой задачей успешно.

Из проведенного эксперимента (рис. 2), следует что модель НС верно распознала все НО интереса из возможных, это свидетельствует о приемлемой точности распознавания, которые составляют до 91% для зданий, 87% для деревьев и 85% для транспортных средств.

### Заключение

В рамках данного исследования реализован процесс, который позволяет автоматически распознавать НО на кадрах видеопотока и подсчитывать их количество. Это в совокупности позволяет автоматизировать процесс учета различных НО-в.

Большое внимание уделено процессу подготовки исходных данных, выбранных для обучения модели НС. Обученная модель, реализованная на базе НС – YOLOv9 [18-20], продемонстрировала приемлемую точность при распознавании деревьев, зданий и транспортных средств, достигнув приемлемого процента распознавания.

В итоге, успешно решается задача автоматического определения количества НО на РЛК. Обученная модель НС способна распознавать НО на кадрах видеопотока, отслеживать их общее количество, а и также количество в текущем кадре. Это делает модель эффективным инструментом для автоматизации и оптимизации различных процессов сугубо гражданского назначения.

## Литература

1. Ненашев В.А., Сенцов А.А. Пространственно-распределенные системы мультисенсорного мониторинга. - СПб.: ГУАП, 2022. 221 с.
2. Nenashev V.A., Shepeta A.P., Kryachko A.F. Fusion radar and optical information in multiposition on-board location systems // 2020 Wave Electronics and its Application in Information and Telecommunication Systems, WECONF 2020, Saint-Petersburg, 01–05 June 2020. Saint-Petersburg, 2020. P. 9131451. DOI 10.1109/WECONF48837.2020.9131451
3. Sorokin A.V., Shepeta A.P., Nenashev V.A., Wattimena G.M. Comparative characteristics of anti-collision processing of radio signal from identification tags on surface acoustic waves // Information and Control Systems. 2019. No. 1(98). P. 48-56. DOI 10.31799/1684-8853-2019-1-48-56
4. Nenashev V.A., Khanykov I.G. Formation of fused images of the land surface from radar and optical images in spatially distributed on-board operational monitoring systems // Journal of Imaging. 2021. Vol. 7, No. 12. DOI 10.3390/jimaging7120251
5. Ненашев В.А., Ненашев С.А. Классификация и распознавание наземных объектов в потоке радиолокационных кадров на основе нейросетевого подхода в передней зоне обзора бортовых РЛС многопозиционной системы. GraphiCon 2023: труды 33-й Междунар. конф. по компьютерной графике и машинному зрению (Москва, 19–21 сент. 2023 г.). М.: Институт прикладной математики им. М.В. Келдыша РАН, 2023. с. 572-580
6. Ненашев В.А., Ненашев С.А. Классификация и распознавание наземных объектов в потоке радиолокационных кадров на основе нейросетевого подхода // Автоматизация в промышленности, №1. 2024. с. 29-33.
7. Qian Y., Liu Q., Zhu H., Fan H., Du B. and Liu S. Mask R-CNN for Object Detection in Multitemporal SAR Images. 2019. 10th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp), Shanghai, China, 2019, pp. 1-4, doi: 10.1109/MultiTemp.2019.8866949.
8. Kumar, Durga Priya and Xiaoling Zhang. Ship Detection Based on Faster R-CNN in SAR Imagery by Anchor Box Optimization. 2019 International Conference on Control, Automation and Information Sciences (ICCAIS) (2019): 1-6
9. Ефанов Е.В. Нейронные сети для распознавания изображений // Теория и практика современной науки. №7 (25), 2017, с. 37-40.
10. Компьютерное зрение. Современные методы и перспективы развития / ред. Р. Дэвис, М. Терк; пер. с англ. В. С. Яценкова. М.: ДМК Пресс, 2022. 690 с.
11. Li J., Qu C., Shao J. Ship detection in SAR images based on an improved faster R-CNN // SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA). – IEEE, 2017. pp. 1-6.
12. Bondarchuk V.V., Shevchenko E.A. Investigation of the algorithm for detecting objects of interest in a video stream // Problems of artificial intelligence, No. 1, 2015, pp. 13-22.

13. Kopylov D.A., Ageshin E.S., Khomutskaya O.V. Formation of synthetic data for training a computer vision system // Automation and modeling in design and Management, No. 4 (18), 2022, pp. 18-28.

14. Стеценко А. И., Смагулова А.С. Разработка нейронной сети для распознавания изображений на базе tensorflow // E-Scio. no. 3 (78), 2023, pp. 133-139.

15. Ngo HUU-HUY. Vehicle-detection-based traffic density estimation at road intersections // International Journal of Open Information Technologies. vol. 11, no. 7, 2023, pp. 39-46.

16. Кобенко В.Ю., Кошеков А.К., Кошекoва Б.В., Латыпов С.И., Калантаевская Н.И., Гаврилова М.М. Идентификационный метод распознавания образов малоразмерных подводных объектов // Динамика систем, механизмов и машин, vol. 7, no. 2, 2019, pp. 212-220.

17. Грушин М.А. Распознавание крон деревьев на снимках высокого разрешения // Лесной вестник / Forestry bulletin, no. 6 (89), 2012, pp. 149-153.

18. Аксентов В.А. Обнаружение дефектов на зданиях и сооружения с помощью искусственного интеллекта // Вестник науки. vol. 4, no. 1 (70), 2024, pp. 422-426.

19. Chung L.B., Duy N.D. Real-time object detection and tracking for mobile robot using yolov8 and strong sort // Universum: технические науки, no. 11-6 (116), 2023, pp. 36-44. DOI:10.32743/UniTech.2023.116.11.16223

20. Chang, R. & Mao, Z.X. & Hu, J. & Bai, H.C. & Zhou, C.J. & Yang, Y. & Gao, S. (2023). Research on foreign body detection in transmission lines based on a multi-UAV cooperative system and YOLOv7. Computer Optics. 47. pp. 788-794. DOI: 10.18287/2412-6179-CO-1257.

### Reference

1. Nenashev V.A., Sentsov A.A. Spatially distributed multisensor monitoring systems. - SPb.: SUAI, 2022. 221 p. (In Russian)

2. Nenashev V.A., Shepeta A.P., Kryachko A.F. Fusion radar and optical information in multiposition on-board location systems // 2020 Wave Electronics and its Application in Information and Telecommunication Systems, WECONF 2020, Saint-Petersburg, 01–05 June 2020. Saint-Petersburg, 2020. P. 9131451. DOI 10.1109/WECONF48837.2020.9131451

3. Sorokin A.V., Shepeta A.P., Nenashev V.A., Wattimena G.M. Comparative characteristics of anti-collision processing of radio signal from identification tags on surface acoustic waves // Information and Control Systems. 2019. No. 1(98). P. 48-56. DOI 10.31799/1684-8853-2019-1-48-56

4. Nenashev V.A., Khanykov I.G. Formation of fused images of the land surface from radar and optical images in spatially distributed on-board operational monitoring systems // Journal of Imaging. 2021. Vol. 7, No. 12. DOI 10.3390/jimaging7120251

5. Nenashev V.A., Nenashev S.A. Classification and recognition of ground objects in a stream of radar frames based on a neural network approach in the forward viewing area of on-board radars of a multi-position system [*Klassifikatsiia*

*i raspoznavanie nazemnykh ob"ektov v potoke radiolokatsionnykh kadrov na osnove neurosetevogo podkhoda v perednei zone obzora bortovykh RLS mnogopozitsionnoi sistemy*] // Proceedings of the International Conference on Computer Graphics and Vision "Graphicon". 2023. No. 33. pp. 572-580. <https://doi.org/10.20948/graphicon-2023-572-580> (In Russian)

6. Nenashev V. A., Nenashev S. A. Classification and recognition of ground objects in a stream of radar frames based on a neural network approach [Klassifikatsiia i raspoznavanie nazemnykh ob"ektov v potoke radiolokatsionnykh kadrov na osnove neurosetevogo podkhoda] // Automation in industry [Avtomatizatsiia v promyshlennosti]. 2024. No. 1. P. 29-33. <https://doi.org/10.25728/avtprom.2024.01.07>. (In Russian)

7. Qian Y., Liu Q., Zhu H., Fan H., Du B. and Liu S. Mask R-CNN for Object Detection in Multitemporal SAR Images. 2019. 10th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp), Shanghai, China, 2019, pp. 1-4, doi: 10.1109/MultiTemp.2019.8866949.

8. Kumar, Durga Priya and Xiaoling Zhang. Ship Detection Based on Faster R-CNN in SAR Imagery by Anchor Box Optimization. 2019 International Conference on Control, Automation and Information Sciences (ICCAIS) (2019): 1-6

9. Efanov E.V. Neural networks for image recognition // Theory and Practice of Modern Science. №7 (25), 2017, pp. 37-40.

10. Computer Vision. Modern methods and prospects of development. ed. by R. Davis, M. Turk; transl. from Engl. by V. S. Yatsenkov. Moscow: DMK Press, 2022. 690 p.

11. Li J., Qu C., Shao J. Ship detection in SAR images based on an improved faster R-CNN // SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA). – IEEE, 2017. pp. 1-6.

12. Bondarchuk V.V., Shevchenko E.A. Investigation of the algorithm for detecting objects of interest in a video stream // Problems of artificial intelligence, No. 1, 2015, pp. 13-22.

13. Kopylov D.A., Ageshin E.S., Khomutskaya O.V. Formation of synthetic data for training a computer vision system // Automation and modeling in design and Management, No. 4 (18), 2022, pp. 18-28.

14. Stetsenko A.I., Smagulova A.S. Development of neural network for image recognition based on tensorflow // E-Scio. no. 3 (78), 2023, pp. 133-139. (In Russian)

15. Ngo Huu-Huy. Vehicle-detection-based traffic density estimation at road intersections // International Journal of Open Information Technologies. vol. 11, no. 7, 2023, pp. 39-46.

16. Kobenko V.Yu., Koshekov A.K., Koshekova B.V., Latypov S.I., Kalantayevskaya N.I., Gavrilova M.M. Identification method of pattern recognition of small-sized underwater objects // Dynamics of Systems, Mechanisms and Machines, vol. 7, no. 2, 2019, pp. 212-220. (in Russian)

17. Grushin M.A. Recognition of tree crowns on high-resolution images // Forestry bulletin / Forestry bulletin, no. 6 (89), 2012, pp. 149-153. (in Russian)

18. Aksentov, V.A. Detection of defects on buildings and structures with the help of artificial intelligence // Vestnik nauki. vol. 4, no. 1 (70), 2024, pp. 422-426. (in Russian)
19. Chung L.B., Duy N.D. Real-time object detection and tracking for mobile robot using yolov8 and strong sort // Universum: технические науки, no. 11-6 (116), 2023, pp. 36-44. DOI:10.32743/UniTech.2023.116.11.16223
20. Chang, R. & Mao, Z.X. & Hu, J. & Bai, H.C. & Zhou, C.J. & Yang, Y. & Gao, S. (2023). Research on foreign body detection in transmission lines based on a multi-UAV cooperative system and YOLOv7. Computer Optics. 47. pp. 788-794. DOI: 10.18287/2412-6179-CO-1257.