

16. Giray L. Prompt engineering with ChatGPT: a guide for academic writers, *Annals of biomedical engineering*, 2023, Vol. 51, No. 12. pp. 2629-2633.
17. Marvin G., Hellen N., Jjingo D., Nakatumba-Nabende J. Prompt Engineering in Large Language Models, *Data Intelligence and Cognitive Informatics: Algorithms for Intelligent Systems*, eds. I.J. Jacob, S. Piramuthu, P. Falkowski-Gilski. Singapore: Springer Nature Singapore, 2024, pp. 387-402. ISBN 978-981-9979-99-8.
18. Mahmoud Bsharat S., Myrzakhan A., Shen Z. Principled Instructions Are All You Need for Questioning LLaMA-1/2, GPT-3.5/4, *arXiv e-prints*, 2023, pp. arXiv-2312.
19. Mann B., Ryder N., Subbiah M., Kaplan J., Dhariwal P., Neelakantan A., Shyam P., Sastry G., Askell A., Agarwal S. Language models are few-shot learners, *arXiv preprint arXiv:2005.14165*, 2020, Vol. 1, pp. 3.
20. Sabbah T., Selamat A., Selamat M.H., Al-Anzi F.S., Viedma E.H., Krejcar O., Fujita H. Modified frequency-based term weighting schemes for text classification, *Applied Soft Computing*, 2017, Vol. 58, pp. 193-206.

Мансур Али Махмуд – Южный федеральный университет; e-mail: mansur@sfedu.com; г. Таганрог, Россия; тел.: +79880158697; кафедра систем автоматизированного проектирования им. В.М. Курейчика; программист.

Мохаммад Жуман Хуссейн – Южный федеральный университет; e-mail: zmohammad@sfedu.ru; г. Таганрог, Россия; тел.: +79880158697; кафедра систем автоматизированного проектирования им. В.М. Курейчика; соискатель.

Кравченко Юрий Алексеевич – Южный федеральный университет; e-mail: yakravchenko@sfedu.ru; г. Таганрог, Россия; тел.: +79289080151; кафедра систем автоматизированного проектирования им. В.М. Курейчика; профессор.

Mansour Ali Mahmoud – Southern Federal University; e-mail: mansur@sfedu.com; Taganrog, Russia; phone: +79880158697; the Department of Computer Aided Design named after V.M. Kureichik; programmer.

Mohammad Juman Hussain – Southern Federal University; e-mail: zmohammad@sfedu.ru; Taganrog, Russia; phone: +79880158697; the Department of Computer Aided Design named after V.M. Kureichik; applicant.

Kravchenko Yury Alekseevich – Southern Federal University; e-mail: yakravchenko@sfedu.ru; Taganrog, Russia; phone: +79289080151; the Department of Computer Aided Design named after V.M. Kureichi; professor.

УДК 621.396.969

DOI 10.18522/2311-3103-2025-3-171-180

В.А. Деркачев

КЛАССИФИКАЦИЯ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ БЕСПИЛОТНЫХ ЛЕТАТЕЛЬНЫХ АППАРАТОВ МУЛЬТИРОТОРНОГО ТИПА С ПРИМЕНЕНИЕМ АЛГОРИТМА YOLO11

Рассматривается классификатор радиолокационных изображений беспилотных летательных аппаратов, основанный на нейронной сети, построенной на алгоритме YOLO 11 версии. Решение задачи обнаружения и классификации беспилотных летательных аппаратов стало одной из приоритетных задач в настоящее время. Увеличение числа модификаций беспилотных летательных аппаратов сильно усложняет применение статистических методов классификации, что требует применения новых подходов в решении задачи классификации. Развитие нейросетевых методов, одновременно с увеличением производительности вычислителей для обучения, с одной стороны, и встраиваемых решений, с другой, позволяет осуществлять классификацию летательных аппаратов с применением радиолокационных изображений в реальном масштабе времени. Применение алгоритма YOLO11 позволяет, помимо определения класса цели, осуществить оценку дальности до наблюдаемого объекта. Использование радиолокационных изображений оправданно в связи с тем, что визуальное наблюдение не всегда является возможным, из-за сложных погодных условий и темного времени суток. Для обучения нейронной сети предполагается использовать набор радиолокационных изображений, полученный с применением авторской модели генерации данных с произвольной конфигурацией беспилотных летательных аппаратов. Проведено обучение

нейронной сети класса *Detection YOLO11s* (9,4 млн. параметров) на выборке радиолокационных изображений двух классов общим числом 8192. В результате обучения получена точность 0,99 для классификации на 2 классах объектов (на тестовых модельных данных). Были проведены тесты с применением натуральных данных, снятых с применением радиолокационной системы миллиметрового диапазона *TI IWR1642*, в результате которых достигнута безошибочная классификация объектов на малой выборке.

Классификатор; беспилотный летательный аппарат; радиолокационное изображение; нейронная сеть; БПЛА.

V.A. Derkachev

CLASSIFICATION OF RADAR IMAGES OF MULTI-ROTOR UNMANNED AERIAL VEHICLES USING THE YOLO11 ALGORITHM

This article discusses a classifier of radar images of unmanned aerial vehicles based on a neural network built on the YOLO algorithm version 11. Solving the problem of detecting and classifying unmanned aerial vehicles has become one of the priority tasks at present. The increase in the number of modifications of unmanned aerial vehicles greatly complicates the use of statistical classification methods, which requires the use of new approaches to solving the classification problem. The development of neural network methods, simultaneously with an increase in the performance of computers for training, on the one hand, and embedded solutions, on the other, allows for the classification of aircraft using radar images in real time. The use of the YOLO11 algorithm allows, in addition to determining the class of the target, to estimate the range to the observed object. The use of radar images is justified due to the fact that visual observation is not always possible due to difficult weather conditions and darkness. To train the neural network, it is proposed to use a set of radar images obtained using the author's model of data generation with an arbitrary configuration of unmanned aerial vehicles. The neural network of the Detection YOLO11s class (9.4 million parameters) was trained on a sample of radar images of two classes, a total of 8192. As a result of training, an accuracy of 0.99 was obtained for classification in 2 classes of objects (on test model data). Tests were conducted using natural data taken using the TI IWR1642 millimeter-range radar system, as a result of which error-free classification of objects on a small sample was achieved.

Classifier; unmanned aerial vehicle; radar image; neural network; UAV.

Введение. В последнее время к проблеме обнаружения и классификации беспилотных летательных аппаратов (БПЛА) наблюдается повышенный интерес [1, 2]. Задача классификации беспилотных летательных аппаратов с применением средств радиолокации может решаться применением двух подходов: статистического и нейросетового. Наиболее часто используемые статистические методы: корреляционный [3] и с применением оптимальных байесовских классификаторов [4]. Применение статистических методов является достаточно сложной задачей, ввиду необходимости выделения отдельных признаков в классифицируемых данных, особенно при наличии сложной структуры радиолокационного изображения. Прогресс в развитии архитектур нейронных сетей обработки данных в последние годы позволяет создавать классификаторы радиолокационных изображений [5–7].

В работе [8] описан алгоритм обнаружения с применением на основе сверточных нейронных сетей и профилей, полученных из дальностно-скоростных матриц. В статьях [9, 10] показана возможность классификации БПЛА с применением дальностно-скоростных изображений и различных архитектур нейронных сетей. В приведенных работах обучение и тестирование нейронных сетей осуществлялось на данных, полученных в результате натуральных экспериментов.

Применение нейронных сетей приводит к необходимости формирования данных для обучения. В случае БПЛА можно осуществить генерацию дальностно-скоростных портретов мультироторных БПЛА с заданными параметрами (геометрией, скоростью полета, размером и расположением винтов) используя авторскую методику [11, 12]. Применяя последнюю версию архитектуры YOLO11 в паре с вышеупомянутым алгоритмом, становится возможно создать классификатор мультироторных БПЛА, имеющий возможность работы в реальном времени на мобильных устройствах [13, 14].

Постановка задачи. В данной работе необходимо осуществить создание классификатора БПЛА с применением нейронных сетей. В качестве обучающих данных применялись радиолокационные изображения синтезировались с применением авторской мето-

дики. Применение синтезированных изображений обусловлено необходимостью использования большого объема данных для обучения нейронной сети, что требует больших материальных и трудовых затрат. В качестве архитектуры нейронной сети используется YOLO11, которая совместима с набором синтезированных изображений. Тестирование проводилось с применением РЛС миллиметрового диапазона, что обусловило выбор параметров для синтеза радиолокационных изображений. Решаемую задачу можно разбить на два этапа. Первый этап – формирование набора радиолокационных изображений необходимых для обучения нейронной сети. Второй этап заключается в обучении нейронной сети и тестировании полученного классификатора.

Описание архитектуры нейронной сети. Обнаружение и классификация объектов является неотъемлемой частью компьютерного зрения. В настоящее время достигнуты большие успехи в развитии данной технологии в связи с развитием нейросетевых методов обработки визуальной информации [15]. Одним из представителей данного класса нейронных сетей является алгоритм You Only Look Once (YOLO) [16]. YOLO v1 использовал механику разделения изображения на сегменты и прогнозирования вероятностей классов для каждого сегмента [17]. Далее в версиях 2 и 3 были добавлены пакетная нормализация, опорные блоки и обнаружение с изменением размера окна [18], дальнейшие версии (с 4 по 7) были направлены на улучшения скорости, вычислительной эффективности, точности [19]. В YOLO v8 была представлена поддержка сегментации, отслеживания и механизмы обнаружения без привязки к опорным блокам, тем самым увеличивая эффективность обобщения данных при обучении [20].

Архитектура YOLO11 представлена в 2024 году, показана структурная схема модели показана на рис. 1 [21]. Данная версия основана на версии YOLOv8, и как предшественница включает многочисленные приложения, такие как обнаружение объектов, сегментация экземпляров, классификация изображений, оценка позы и ориентированное обнаружение объектов.

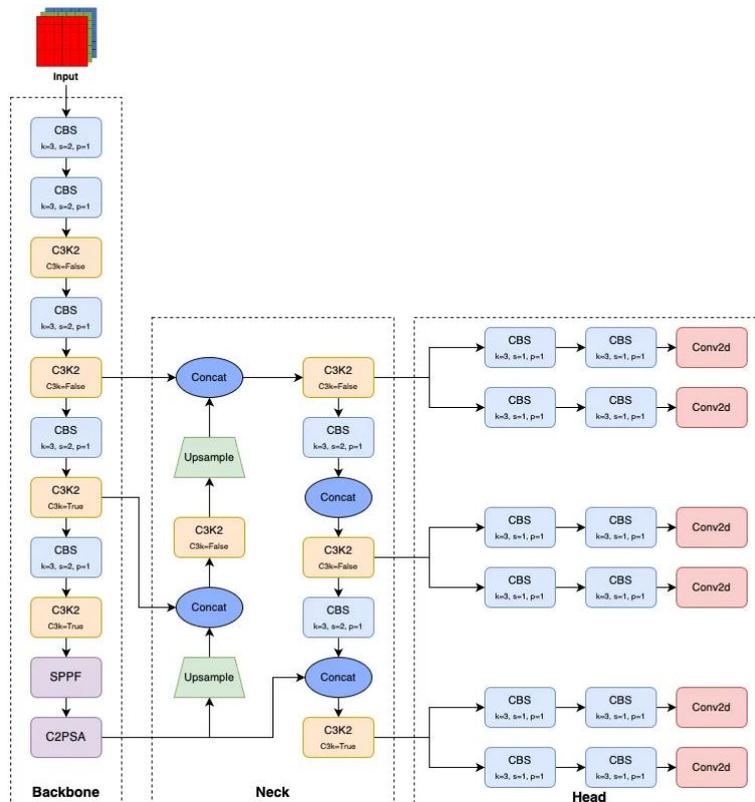


Рис. 1. Архитектура нейронной сети YOLO11

В архитектуре YOLO11 можно выделить 3 основные части: Backbone, Neck и Head. Backbone – это важнейший компонент архитектуры YOLO, отвечающий за извлечение признаков из входного изображения в нескольких масштабах. Этот процесс включает в себя наложение сверточных слоев и специализированных блоков для генерации карт признаков в различных разрешениях [22]. Neck объединяет признаки в разных масштабах и передает их в Head для прогнозирования. Head YOLOv11 отвечает за генерацию окончательных прогнозов с точки зрения обнаружения и классификации объектов. Она обрабатывает карты признаков, переданные из шеи, в конечном итоге выводя ограничивающие рамки и метки классов для объектов на изображении.

Архитектура YOLO11 представлена в виде 5 различных классов нейросетей: обнаружения (Detection, COCO), сегментации (Segmentation, COCO), классификации (Classification, ImageNet), оценки позы (Pose, COCO), ориентированного обнаружения (OBB, DOTAv1). В рамках задачи обнаружения и классификации радиолокационного изображения БПЛА на дальностно-скоростных портретах наиболее подходящей является нейросеть обнаружения (Detection, COCO). Выбранный класс архитектуры YOLO11 так же имеет 5 вариантов нейросетей различающихся числом параметров, а, соответственно, точностью, скоростью исполнения и требованиям к аппаратному обеспечению. В табл. 1 показаны основные характеристики нейросетей обнаружения архитектуры YOLO11. В представленной таблице фигурирует параметр mAPval 50-95, который является средней точностью, рассчитанной по пороговым значениям IoU (метрики степени пересечения между двумя ограничивающими рамками) от 0,5 до 0,95.

Таблица 1

Модель	mAPval 50-95	Кол-во параметров (млн.)	Сложность (GFLOPS)
YOLO11n	39,5	2,6	6,5
YOLO11s	47,0	9,4	21,5
YOLO11m	51,5	20,1	68,0
YOLO11l	53,4	25,3	86,9
YOLO11x	54,7	56,9	194,9

Формирование данных для обучения. Данные для обучения нейросети получены с применением авторского алгоритма формирования радиолокационных сигналов от БПЛА [11, 12, 23]. Обобщенная схема алгоритма показана на рис. 2.

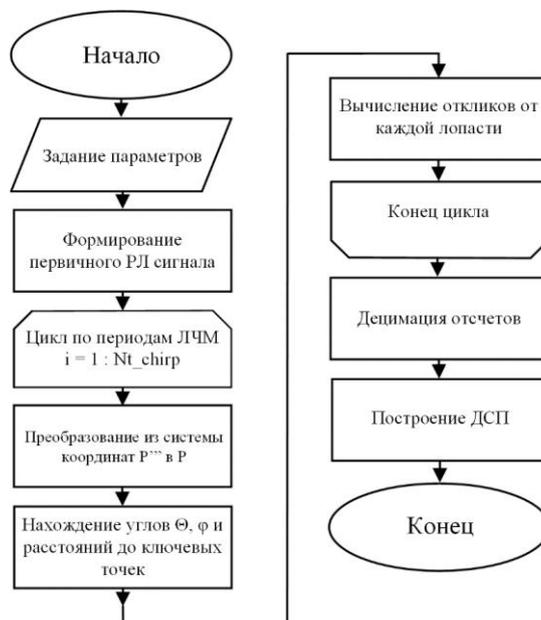


Рис. 2. Обобщенный алгоритм построения радиолокационных изображений

В качестве радиолокационной системы выбрана РЛС миллиметрового диапазона TI IWR1642, основные параметры моделирования радиолокационного сигнала показаны в табл. 2.

Таблица 2

Параметр	Величина
Центральная частота сигнала	77 ГГц
Ширина спектра сигнала (используемая)	767,54 МГц
Частота дискретизации ВЧ	1,6 ГГц
Число периодов ЛЧМ импульсов	128
Длительность ЛЧМ импульса	60 мкс
Период ЛЧМ импульсов	160 мкс
Частота дискретизации АЦП	10 МГц
Число отсчетов АЦП за один период	256
Время моделирования	20 мс

Для обучения было выбрано 2 класса БПЛА Xiaomi Mi Drone Mini (рис. 3,а) и DJI Mavic2 PRO (рис. 3,б), основные характеристики данных БПЛА представлены в табл. 3.



Рис. 3. Моделируемые БПЛА

Таблица 3

Параметр	Величина	
	Xiaomi Mi Drone Mini	DJI Mavic2 PRO
Число лопастей на роторе	2	2
Число роторов	4	4
Длина лопасти	0,038 м	0,107 м
Радиус оси ротора	0,0025 м	0,011 м
Ширина лопасти	0,005 м	0,022 м
Частота вращения лопастей	±100 Гц	±100 Гц

В результате работы модели формируются радиолокационные изображения без шума, далее добавляется шум с нецентральным χ^2 -распределением, ОСШ при этом составляет 10 дБ. Далее сформированные изображения разрешением 128x128 точек интерполируются до разрешения 640x640 точек. Необходимость в этом связана с требованиями к входным данным нейронной сети и достаточно высокой вычислительной сложностью алгоритма формирования изображений. Для обучения генерируется по 4096 изображений каждого из классов, примеры полученных изображений показаны на рис. 4.

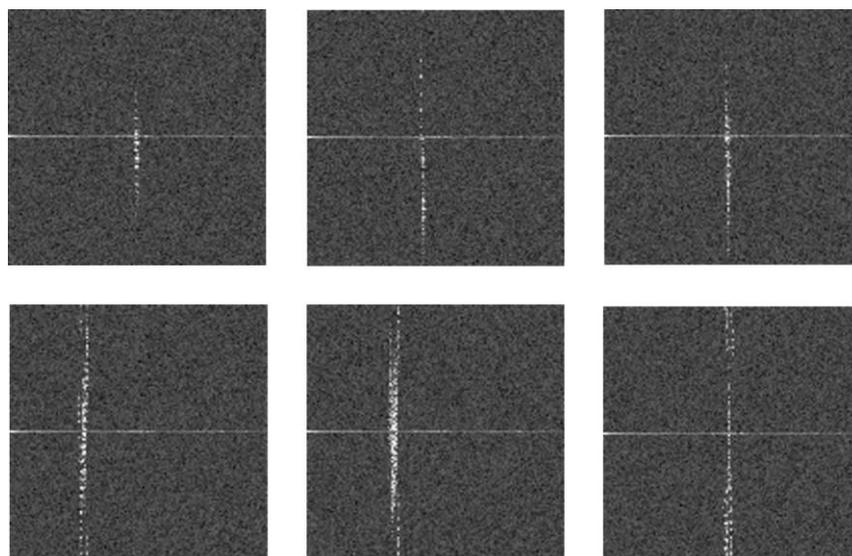


Рис. 4. Формируемые РЛИ

Обучение нейронной сети. Обучение нейронной сети производилось с применением библиотеки Ultralytics версии 8.3.72 построенной на основе библиотеки PyTorch версии 2.4.1+cu124. Моделируемые РЛИ, полученные в предыдущем разделе, разделены на 3 выборки: обучающую состоящую из 5734 изображения 2 классов (70% от всех изображений), валидационную, состоящую из 820 изображений 2 классов (10% от всех изображений) и тестовую, состоящую из 1638 изображений 2 классов (20% от всех изображений). Для обучения был выбран вариант YOLO11s, число эпох обучения 100. Время обучения составило 1,5 часа с применением видеокарты Nvidia RTX3090.

Анализ матрицы ошибок

Матрица ошибок (рис. 5) дает полное представление о точности классификации YOLO11 по различным типам БПЛА. Нейросеть демонстрирует высокую точность для определения всех классов, достигая высоких показателей классификации с минимальными ошибками классификации.

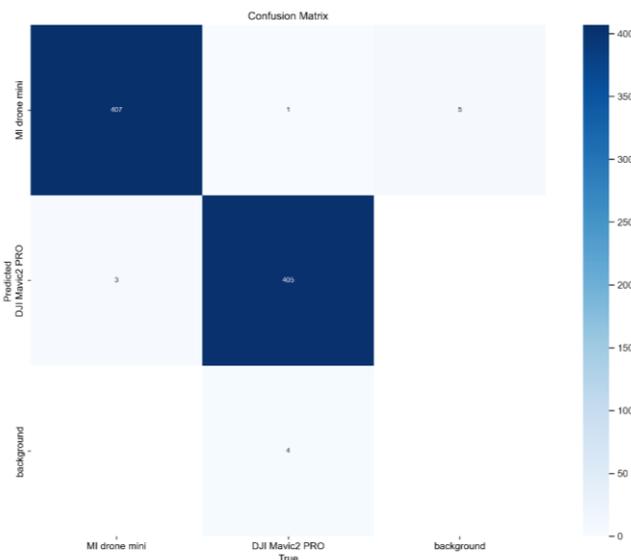


Рис. 5. Матрица ошибок

Для оценки полученного результата обучения использовались следующие метрики [24–26]: F-мера, Precision-Confidence Curve, Precision-Recall Curve, Recall-Confidence Curve, (рис. 6). Кривая достоверности F1 дает представление о компромиссе между порогом достоверности модели и ее оценкой F1. Обученная модель достигает оптимальной оценки F1 0,99 при пороге достоверности 0,619, что указывает на сбалансированную точность и полноту обученной нейронной сети. Кривая Precision-Confidence показывает, как точность меняется в зависимости от уровня достоверности для каждого типа класса. Модель поддерживает высокую точность при большинстве порогов. Кривая Precision-Recall Curve подчеркивает эффективность модели в балансировке точности и полноты по классам, уровень $mAP@0.5$ составляет 0,995 для всех классов. Кривая Recall-Confidence показывает, как точность меняется в зависимости от уровня достоверности для каждого типа БПЛА. Нейросеть сохраняет высокую точность при большинстве порогов, достигая 1,0 при пороге 0,996.

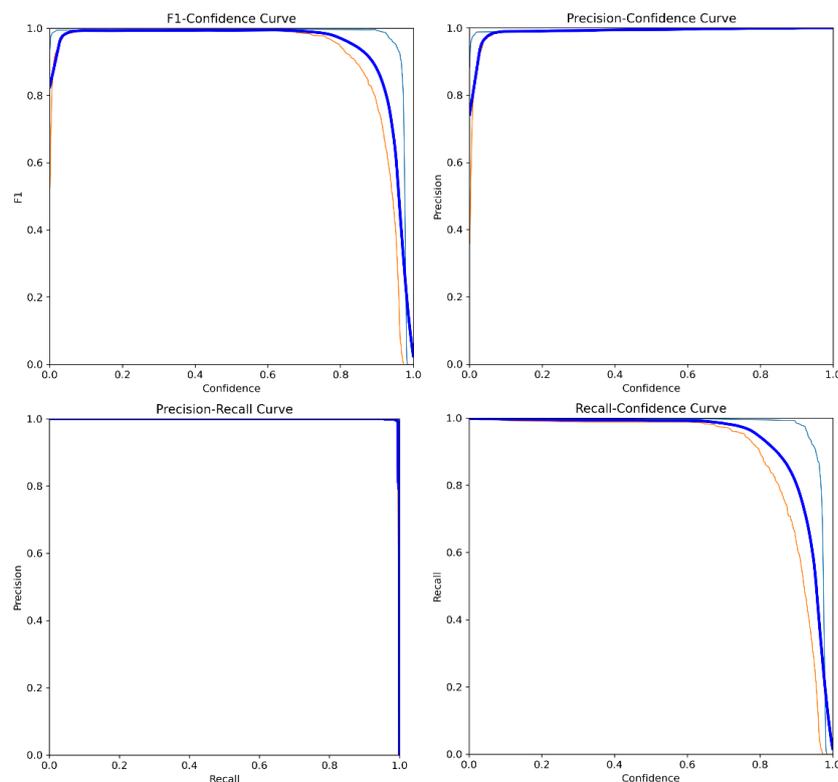


Рис. 6. Метрики оценки обученной модели

На рис. 7 показаны кривые обучения нейросети, кривая $metrics/precision$ (B) показывает точность обнаружения объектов в процессе обучения, а кривая $metrics/recall$ показывает, насколько полно нейросеть может найти объекты на изображении. Достигнута точность классификации 0,99 для двух классов изображений.

Тестирование на экспериментальных данных. Нейросеть протестирована с применением тестовых данных, полученных на полигоне в июле 2021 года с применением радиолокатора TI IWR1642 с параметрами сигнала, показанными в табл. 2 и БПЛА Xiaomi Mi Drone Mini и DJI Mavic2 PRO. В результате из 56 радиолокационных изображений было правильно классифицированы все изображения. На рис. 8,а показан пример правильной классификации РЛИ с БПЛА DJI Mavic2 PRO, а на рис. 8,б показан пример правильной классификации РЛИ с БПЛА Xiaomi Mi Drone Mini.

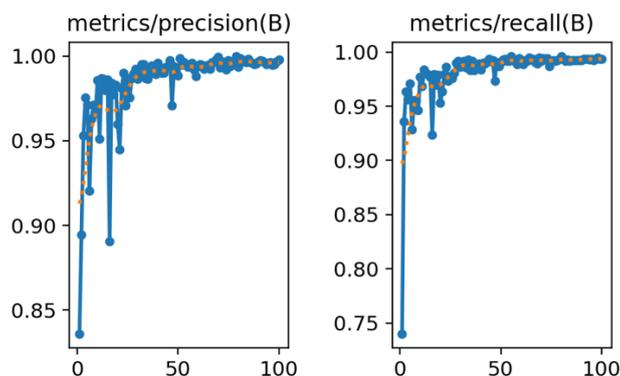


Рис. 7. Метрики точности во время обучения

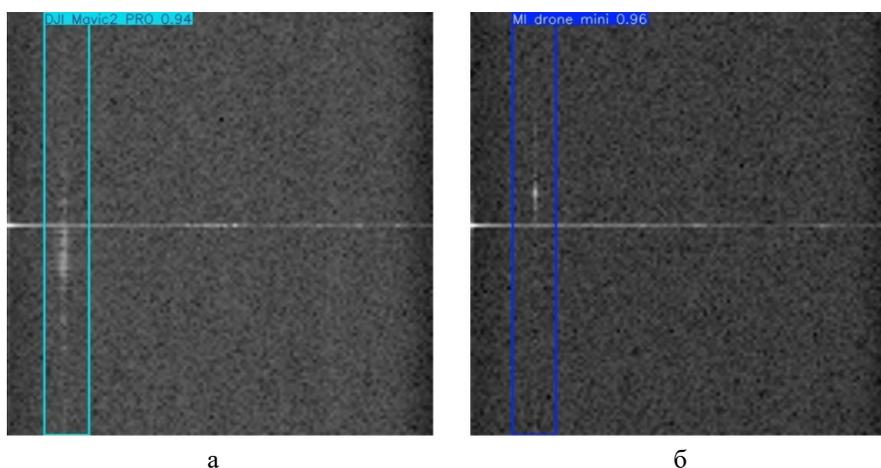


Рис. 8. Классификация экспериментальных РЛИ

Выводы. Предложенный нейросетевой классификатор БПЛА, основанный на применении архитектуры YOLO11, позволяет осуществить классификацию радиолокационных изображений, содержащих отклики от целевых БПЛА. Применение авторской модели рассеяния радиолокационных сигналов в качестве генератора обучающих данных позволило сформировать достаточно качественные изображения для обучения нейронной сети. Архитектура YOLO в основе классификатора позволяет получить стабильные результаты в классификации БПЛА. Точность на тестовых (сгенерированных) изображениях составила 0,99, а на малой выборке (из 56 изображений), полученных в результате натурального эксперимента, точность составила 1,0.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Coluccia A., Parisi G., Fascista A. Detection and classification of multirotor drones in radar sensor networks: A review // *Sensors*. – 2020. – Vol. 20, No. 15. – P. 4172.
2. Ezuma M. et al. Micro-UAV detection and classification from RF fingerprints using machine learning techniques // 2019 IEEE Aerospace Conference. – IEEE, 2019. – P. 1-13.
3. Гонзалес Р., Вудс Р. Цифровая обработка изображений: пер. с англ. – М.: Издательский дом Техносфера, 2005. – 1073 с.
4. Anderson T.W., Goodman L.A. Statistical inference about Markov chains // *The Annals of Mathematical Statistics*. – 1957. – P. 89-110.
5. Mendis G.J. et al. Deep learning based doppler radar for micro UAS detection and classification // MILCOM 2016-2016 IEEE Military Communications Conference. – IEEE, 2016. – P. 924-929.
6. Hinton G.E., Osindero S., Teh Y.W. A fast learning algorithm for deep belief nets // *Neural computation*. – 2006. – Vol. 18, No. 7. – P. 1527-1554.

7. *Martinez J. et al.* Convolutional neural network assisted detection and localization of UAVs with a narrowband multi-site radar // 2018 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM). – IEEE, 2018. – P. 1-4.
8. *Samaras S. et al.* UAV classification with deep learning using surveillance radar data // International Conference on Computer Vision Systems. – Springer, Cham, 2019. – P. 744-753.
9. *Lee H. et al.* CNN-based UAV detection and classification using sensor fusion // IEEE Access. – 2023. – Vol. 11. – P. 68791-68808.
10. *Roldan I. et al.* DopplerNet: A convolutional neural network for recognising targets in real scenarios using a persistent range-Doppler radar // IET Radar, Sonar & Navigation. – 2020. – Vol. 14, No. 4. – P. 593-600.
11. *Деркачев В.А.* Программа для формирования набора радиолокационных изображений летательных аппаратов // Свидетельство о государственной регистрации программы для ЭВМ. №2021665908. 2021.
12. *Деркачев В.А.* Модель рассеяния радиолокационных сигналов от беспилотных летательных аппаратов // Известия ЮФУ. Технические науки. – 2021. – № 2 (219). – С. 120-129.
13. *Viswanatha V., Chandana R.K., Ramachandra A.C.* Iot based smart mirror using raspberry pi 4 and yolo algorithm: A novel framework for interactive display // Indian Journal of Science and Technology. – 2022. – Vol. 15, No. 39. – P. 2011-2020.
14. *Shin D.J., Kim J.J.* A deep learning framework performance evaluation to use YOLO in Nvidia Jetson platform // Applied Sciences. – 2022. – Vol. 12, No. 8. – P. 3734.
15. *Zhao X. et al.* A review of convolutional neural networks in computer vision // Artificial Intelligence Review. – 2024. – Vol. 57, No. 4. – P. 99.
16. *Redmon J.* You only look once: Unified, real-time object detection // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016.
17. *Alif M.A.R., Hussain M.* YOLOv1 to YOLOv10: A comprehensive review of YOLO variants and their application in the agricultural domain // arXiv preprint arXiv:2406.10139. – 2024.
18. *Joseph Redmon and Ali Farhadi.* Yolo9000: Better, faster, stronger. arxiv. arXiv preprint arXiv:1612.08242, 394, 2016.
19. *Wang C.Y., Bochkovskiy A., Liao H.Y.M.* YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors // Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. – 2023. – P. 7464-7475.
20. *Glenn Jocher, Ayush Chaurasia, and Jing Qiu.* Ultralytics yolov8, 2023.
21. *Glenn Jocher and Jing Qiu.* Ultralytics yolo11, 2024.
22. *Ghosh A.* YOLO11: Faster Than You Can Imagine! // LearnOpenCV. – <https://learnopencv.com/yolo11>. – 2024.
23. *Деркачев В.А., Бахчевников В.В., Бакуменко А.Н.* Классификатор БПЛА мультироторного типа // Известия ЮФУ. Технические науки. – 2023. – № 2 (232). – С. 90-99.
24. *Sanchez S.A., Romero H.J., Morales A.D.* A review: comparison of performance metrics of pretrained models for object detection using the TensorFlow framework // IOP Conf. Series: Materials Science and Engineering. – 2020. – 15 p. – DOI: 10.1088/1757-899X/844/1/012024.
25. *Sokolova M., Lapalme G.* A systematic analysis of performance measures for classification tasks // Information processing & management. – 2009. – Vol. 45, No. 4. – P. 427-437.
26. *Miao J., Zhu W.* Precision-recall curve (PRC) classification trees // Evolutionary intelligence. – 2022. – Vol. 15, No. 3. – P. 1545-1569.

REFERENCES

1. *Coluccia A., Parisi G., Fascista A.* Detection and classification of multirotor drones in radar sensor networks: A review, *Sensors*, 2020, Vol. 20, No. 15, pp. 4172.
2. *Ezuma M. et al.* Micro-UAV detection and classification from RF fingerprints using machine learning techniques, *2019 IEEE Aerospace Conference*. IEEE, 2019, pp. 1-13.
3. *Gonzalez R., Vuds R.* Tsifrovaya obrabotka izobrazheniy [Digital image processing]: transl. from English. Moscow: Izdatel'skiy dom Tekhnosfera, 2005, 1073 p.
4. *Anderson T.W., Goodman L.A.* Statistical inference about Markov chains, *The Annals of Mathematical Statistics*, 1957, pp. 89-110.
5. *Mendis G.J. et al.* Deep learning based doppler radar for micro UAS detection and classification, *MILCOM 2016-2016 IEEE Military Communications Conference*. IEEE, 2016, pp. 924-929.
6. *Hinton G.E., Osindero S., Teh Y.W.* A fast learning algorithm for deep belief nets, *Neural computation*, 2006, Vol. 18, No. 7, pp. 1527-1554.
7. *Martinez J. et al.* Convolutional neural network assisted detection and localization of UAVs with a narrowband multi-site radar, *2018 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)*. IEEE, 2018, pp. 1-4.

8. *Samaras S. et al.* UAV classification with deep learning using surveillance radar data, *International Conference on Computer Vision Systems*. Springer, Cham, 2019, pp. 744-753.
9. *Lee H. et al.* CNN-based UAV detection and classification using sensor fusion, *IEEE Access*, 2023, Vol. 11, pp. 68791-68808.
10. *Roldan I. et al.* DopplerNet: A convolutional neural network for recognising targets in real scenarios using a persistent range–Doppler radar, *IET Radar, Sonar & Navigation*, 2020, Vol. 14, No. 4, pp. 593-600.
11. *Derkachev V.A.* Programma dlya formirovaniya nabora radiolokatsionnykh izobrazheniy letatel'nykh apparatov [Program for generating a set of radar images of aircraft], *Svidetel'stvo o gosudarstvennoy registratsii programmy dlya EVM. №2021665908. 2021* [Certificate of state registration of a computer program. No. 2021665908. 2021].
12. *Derkachev V.A.* Model' rasseyaniya radiolokatsionnykh signalov ot bespilotnykh letatel'nykh apparatov [Model of scattering of radar signals from unmanned aerial vehicles], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2021, No. 2 (219), pp. 120-129.
13. *Viswanatha V., Chandana R.K., Ramachandra A.C.* Iot based smart mirror using raspberry pi 4 and yolo algorithm: A novel framework for interactive display, *Indian Journal of Science and Technology*, 2022, Vol. 15, No. 39, pp. 2011-2020.
14. *Shin D.J., Kim J.J.* A deep learning framework performance evaluation to use YOLO in Nvidia Jetson platform, *Applied Sciences*, 2022, Vol. 12, No. 8, pp. 3734.
15. *Zhao X. et al.* A review of convolutional neural networks in computer vision, *Artificial Intelligence Review*, 2024, Vol. 57, No. 4, pp. 99.
16. *Redmon J.* You only look once: Unified, real-time object detection, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016.
17. *Alif M.A.R., Hussain M.* YOLOv1 to YOLOv10: A comprehensive review of YOLO variants and their application in the agricultural domain, *arXiv preprint arXiv:2406.10139*, 2024.
18. *Joseph Redmon and Ali Farhadi.* Yolo9000: Better, faster, stronger. arxiv. arXiv preprint arXiv:1612.08242, 394, 2016.
19. *Wang C.Y., Bochkovskiy A., Liao H.Y.M.* YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors, *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2023, pp. 7464-7475.
20. *Glenn Jocher, Ayush Chaurasia, and Jing Qiu.* Ultralytics yolov8, 2023.
21. *Glenn Jocher and Jing Qiu.* Ultralytics yolo11, 2024.
22. *Ghosh A.* YOLO11: Faster Than You Can Imagine!, *LearnOpenCV*. Available at: <https://learnopencv.com/yolo11>, 2024.
23. *Derkachev V.A., Bakhchevnikov V.V., Bakumenko A.N.* Klassifikator BPLA multitirotnogo tipa [Classifier of multicopter UAVs], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2023, No. 2 (232), pp. 90-99.
24. *Sanchez S.A., Romero H.J., Morales A.D.* A review: comparison of performance metrics of pretrained models for object detection using the TensorFlow framework, *IOP Conf. Series: Materials Science and Engineering*, 2020, 15 p. DOI: 10.1088/1757-899X/844/1/012024.
25. *Sokolova M., Lapalme G.* A systematic analysis of performance measures for classification tasks, *Information processing & management*, 2009, Vol. 45, No. 4, pp. 427-437.
26. *Miao J., Zhu W.* Precision–recall curve (PRC) classification trees, *Evolutionary intelligence*, 2022, Vol. 15, No. 3, pp. 1545-1569.

Деркачев Владимир Александрович – Южный федеральный университет; e-mail: vderkachev@sfedu.ru; г. Таганрог, Россия; тел.: +79614154733; кафедра радиотехнических и телекоммуникационных систем; старший преподаватель.

Derkachev Vladimir Aleksandrovich – Southern Federal University; e-mail: vderkachev@sfedu.ru; Taganrog, Russia; phone +79614154733; the Department of Radio engineering & Telecommunication Systems; senior lecturer.