

УДК 004.93'1

<https://doi.org/10.32362/2500-316X-2025-13-4-25-36>

EDN WWWVCJ



НАУЧНАЯ СТАТЬЯ

Исследование эффективности применения моделей нейронных сетей YOLO для распознавания объектов на радиолокационных изображениях

А.С. Красноперова[@], А.С. Твердохлебов, А.А. Карташов,
В.И. Вебер, В.Ю. Куприц

Томский государственный университет систем управления и радиоэлектроники», Томск,
634050 Россия

[@] Автор для переписки, e-mail: alenacergeevna2@icloud.com

• Поступила: 10.10.2024 • Доработана: 24.02.2025 • Принята к опубликованию: 21.05.2025

Резюме

Цели. В статье рассматривается проблема применения нейронных сетей для обнаружения и классификации объектов на радиолокационных изображениях в условиях ограниченных вычислительных ресурсов. Целью работы является исследование быстродействия и точности моделей нейронных сетей YOLO¹ при решении задач обнаружения и классификации объектов на радиолокационных изображениях для оценки возможностей практической реализации на микрокомпьютере с нейронным процессором.

Методы. В работе использовались методы машинного обучения, обнаружения и классификации объектов на изображении.

Результаты. Результатом работы является оценка и сравнение быстродействия и точности моделей нейронных сетей YOLO 5-го, 8-го и 11-го поколений с разным количеством обучаемых параметров (модели nano, small, medium, large, extra large) для исследования возможности их использования на микрокомпьютере с нейронным процессором. При сравнении различных моделей YOLO по метрике оценки точности лучшие результаты показали модели YOLOv11n (0.925), YOLOv5l (0.889), YOLOv11s (0.883); по метрике полноты – YOLOv5n (0.932), YOLOv11n (0.928), YOLOv11s (0.914); по метрике mAP50 – YOLOv11s (0.961), YOLOv5n (0.954), YOLOv11n (0.953); по метрике mAP50-95 – YOLOv5n (0.756), YOLOv11s (0.74), YOLOv5l (0.727).

Выводы. Проведенные исследования показывают возможность применения моделей нейронных сетей YOLO на микрокомпьютере с нейронным процессором при соответствии вычислительных ресурсов микрокомпьютера и вычислительных требований нейронных сетей. Микрокомпьютер ROC-RK3588S-PC (Firefly Technology Co., Китай) обеспечивает быстродействие до 6 TOPS (Тера-операций в секунду), что позволяет применять модели YOLOv5n (7.1 GFLOPs), YOLOv11n (6.3 GFLOPs), YOLOv11s (21.3 GFLOPs).

Ключевые слова: системы распознавания образов, нейронные сети, радиолокационное изображение, алгоритмы машинного обучения

¹ You only look once (YOLO) – серия нейросетевых моделей для задачи детекции объектов. [You Only Look Once is a series of neural network models for the real-time object detection.]

Для цитирования: Красноперова А.С., Твердохлебов А.С., Карташов А.А., Вебер В.И., Куприц В.Ю. Исследование эффективности применения моделей нейронных сетей YOLO для распознавания объектов на радиолокационных изображениях. *Russian Technological Journal*. 2025;13(4):25–36. <https://doi.org/10.32362/2500-316X-2025-13-4-25-36>, <https://www.elibrary.ru/WWWVCJ>

Прозрачность финансовой деятельности: Авторы не имеют финансовой заинтересованности в представленных материалах или методах.

Авторы заявляют об отсутствии конфликта интересов.

RESEARCH ARTICLE

Efficiency of YOLO neural network models applied for object recognition in radar images

Alena S. Krasnoperova[@], Alexander S. Tverdokhlebov, Alexey A. Kartashov,
Vladislav I. Weber, Vladimir Y. Kuprits

Tomsk State University of Control Systems and Radioelectronics, Tomsk, 634050 Russia

[@] Corresponding author, e-mail: alenacergeevna2@icloud.com

• Submitted: 10.10.2024 • Revised: 24.02.2025 • Accepted: 21.05.2025

Abstract

Objectives. The paper addresses the problem of applying neural networks for object detection in radar images and their recognition under conditions of limited computational resources. The aim was to investigate the speed and recognition quality of YOLO² neural network models in solving object detection and classification tasks in radar images in order to evaluate the feasibility of their practical implementation on a microcomputer with a neural processor.

Methods. Machine learning, object detection, and classification techniques were used to detect and classify objects in a radar image.

Results. The study compared the speed and recognition quality of the 5th, 8th, and 11th generation YOLO neural network models with varying numbers of trainable parameters (nano-, small-, medium-, large-, and extra-large-sized) to assess their potential use on a microcomputer with a neural processor. As a result of comparing various YOLO models using evaluation metrics, YOLOv11n (0.925), YOLOv5l (0.889), and YOLOv11s (0.883) showed the highest precision metric; YOLOv5n (0.932), YOLOv11n (0.928), and YOLOv11s (0.914) showed the highest recall metric; YOLOv11s (0.961), YOLOv5n (0.954), and YOLOv11n (0.953) showed the highest mAP50 metric; and YOLOv5n (0.756), YOLOv11s (0.74), and YOLOv5l (0.727) showed the highest mAP50-95 metric.

Conclusions. The conducted research confirmed the feasibility of running YOLO neural network models on a microcomputer with a neural processor, provided that the computational resources of the microcomputer match the computational requirements of the neural networks. The ROC-RK3588S-PC microcomputer (Firefly Technology Co., China) provides up to 6 TOPS of performance, allowing the use of YOLOv5n (7.1 GFLOPs), YOLOv11n (6.3 GFLOPs), and YOLOv11s (21.3 GFLOPs) models.

Keywords: pattern recognition systems, neural networks, radar images, machine learning algorithms

² You Only Look Once is a series of neural network models for the real-time object detection.

For citation: Krasnoperova A.S., Tverdokhlebov A.S., Kartashov A.A., Weber V.I., Kuprits V.Y. Efficiency of YOLO neural network models applied for object recognition in radar images. *Russian Technological Journal*. 2025;13(4):25–36. <https://doi.org/10.32362/2500-316X-2025-13-4-25-36>, <https://www.elibrary.ru/WWWWCJ>

Financial disclosure: The authors have no financial or proprietary interest in any material or method mentioned.

The authors declare no conflicts of interest.

ВВЕДЕНИЕ

В настоящее время для формирования радиолокационного изображения (РЛИ) местности широко используются бортовые радиолокаторы с синтезированной апертурой антенны (РСА) [1, 2]. В качестве примеров практического применения РЛИ, полученных с помощью бортовых радаров с РСА, установленных на беспилотных летательных аппаратах (БПЛА), можно отметить следующее:

- поиск транспортных средств при проведении поисково-спасательных операций, контроль передвижения и обеспечение безопасности производственных площадок, складских терминалов, месторождений, портов и городских территорий (парки, водоохранные зоны), обнаружение наводнений;
- дистанционный мониторинг объектов протяженной инфраструктуры, особенно в удаленных районах: нефтепроводов, газопроводов, линий электропередач, инфраструктурных объектов железных дорог;
- автоматизированное построение цифровых карт высот (3D-моделей) земной поверхности, классификация земного покрова: сельскохозяйственные угодья, город, деревня, вода, лес, дорога.

Обычно обработка данных и формирование РЛИ происходит в стационарных условиях при использовании высокопроизводительных компьютеров, но в ряде случаев для повышения эффективности работы системы требуется обработка РЛИ на борту БПЛА. Например, для повышения эффективности поисково-спасательных работ реализация обработки и формирования РЛИ в бортовой системе позволит существенно сократить время поиска транспортных средств и повысить оперативность оказания помощи. Данная операция может быть реализована с помощью нейронных сетей, установленных на микрокомпьютерах (МК) бортовой аппаратуры.

Эффективным решением для распознавания наземных объектов является размещение различных датчиков на БПЛА. Новый подход к созданию многофункционального бортового радиоэлектронного комплекса включает использование различных режимов радиолокации, интеграцию локатора с оптико-электронными средствами, включая инфракрасные, а также использование бортовых радиолокационных станций с синтезированной апертурой

антенны. Современные радиолокационные станции обеспечивают высокое разрешение и эффективно выполняют задачи обнаружения и распознавания скрытых объектов, дополняя оптические и инфракрасные системы [3].

Радиолокационное наблюдение с использованием технологии РСА в настоящее время относят к эффективным методам дистанционного мониторинга объектов интереса, итогом которого являются высокоинформативные двумерные РЛИ, возможность получения которых не ограничивается временем суток и параметрами метеоусловий [4, 5].

Основные принципы формирования РЛИ известны и достаточно подробно рассмотрены в литературе³ [6, 7]. При обработке данных РСА необходимо учитывать особенности формирования РЛИ, например:

- геометрические и радиометрические искажения на формируемых РЛИ;
- наличие радиолокационных теней;
- спекл-шум, который образуется в результате когерентного суммирования отраженных электромагнитных волн от пространственно случайных источников рассеяния, попадающих в элемент разрешения РСА;
- различие отражающих свойств объектов в разных частотных диапазонах;
- режим радиолокационной съемки;
- рабочий диапазон частот и поляризацию сигнала.

В то же время основные принципы и особенности формирования РЛИ необходимо учитывать при создании баз данных изображений, которые будут использоваться для обучения, валидации и тестирования моделей нейронных сетей.

Актуальность данной работы подтверждается различными публикациями. В работах [8–10] проводилось исследование эффективности нейронных сетей для обнаружения и распознавания объектов морского судоходства. Так, в [8] приводятся оценки точности нейронной сети YOLOv5x⁴ на основе базы

³ Основы обработки радиолокационных данных дистанционного зондирования Земли. <https://habr.com/ru/articles/787074/>. Дата обращения 02.12.2024. [Fundamentals of processing radar data from Earth remote sensing. <https://habr.com/ru/articles/787074/> (in Russ.). Accessed December 02, 2024.]

⁴ You only look once – серия нейросетевых моделей для задачи детекции объектов. [You Only Look Once is a series of neural network models for the real-time object detection.]

данных SAR Ship Dataset [11] с использованием соответствующих метрик оценки точности ее работы, а в [9] исследуются нейронные сети для обнаружения и распознавания кораблей. Приводится количественное описание результатов различных моделей нейронных сетей, таких как YOLOv4, YOLOv7, YOLOv7-tiny, RetinaNet, Cascade R-CNN, SSD, OE-YOLO. В работе [10] дано описание нейронных сетей для обнаружения и распознавания объектов по базе данных MSTAR (Moving and Stationary Target Acquisition and Recognition)⁵. В ней исследуются различные модели нейронных сетей с оценкой качества их работы по следующим метрикам: Recall, Precision, mAP50, mAP50-95.

Новизна результатов, приведенных в настоящей статье, заключается в сравнении быстродействия и точности моделей нейронных сетей YOLO 5-го, 8-го и 11-го поколений с разным количеством обучаемых параметров и оценка возможности их использования на МК с нейронным процессором.

ФОРМИРОВАНИЕ БАЗЫ ДАННЫХ РЛИ

Для формирования базы данных РЛИ существуют 3 основных подхода:

- с помощью экспериментальной съемки интересующих объектов на земной поверхности бортовым РСА с учетом различных факторов, влияющих на формирование РЛИ;
- с помощью моделирования процессов распространения радиоволн, отраженных от земной поверхности, и дальнейшей обработки принятых сигналов в соответствии с алгоритмами работы РСА;
- на основе поиска РЛИ, полученных с применением РСА из открытых источников.

Первый подход позволяет получить наиболее точную базу данных РЛИ, но требует привлечения большого количества ресурсов и времени. Моделирование РЛИ представляет собой сложный процесс, который определяется многими факторами. Это связано и со сложностью имитации отражений от местности и протяженных объектов, и с формированием большого потока радиолокационной информации с приемных устройств РСА и т.п. [12, 13]. В настоящей статье используется третий подход, основная цель которого – использовать базы данных РЛИ, размещенные в открытых источниках, для решения поставленной задачи.

В работе использовалась открытая часть базы данных MSTAR. Радиолокационные изображения

в этой базе данных сформированы в соответствии с характеристиками радиолокационной системы и условиями формирования изображений, которые приведены в табл. 1.

Таблица 1. Характеристики радиолокационной системы и условия получения изображений

Характеристика	Значение
Частотный диапазон	X-диапазон
Центральная частота зондирующего сигнала	9.6 ГГц
Ширина полосы зондирующего сигнала	591 МГц
Поляризация излучения и приема сигнала	Горизонтальная
Разрешающая способность по углу места и азимуту	1 фут (~30.5 см)
Режим съемки	Прожекторный (spot light)
Носитель	Самолет (Twin Otter)
Скорость носителя	140–170 км/ч
Наклонная дальность	~5 км
Углы места съемки от плоскости земли	15°–45°
Углы съемки в азимутальной плоскости	0°–360°
Погодные условия	Ясные, сухие
Местность	Равнинная
Растительность	Травянистая, низкая
Время года	Осень (сентябрь, ноябрь)
Место съемки	Военная база Армии США, Арсенал «Рэдстоун», Хантсвилл

База данных MSTAR состоит из 2 наборов данных:

- MSTAR target, в котором каждое изображение имеет простой фон и одно транспортное средство в центре, в этом случае радиолокационная съемка осуществляется под разными углами места съемки;
- MSTAR clutter, содержащий РЛИ сельской местности с дорогами, лесами без изображений транспортных средств.

База данных MSTAR содержит 8890 изображений транспортных средств, 2539 изображений радиоотражателей и 100 изображений сельской местности. Полный перечень РЛИ базы приведен в табл. 2.

⁵ <https://www.mathworks.com/help/radar/ug/sar-target-classification-using-deep-learning.html>. Дата обращения 02.12.2024. / Accessed December 02, 2024.

Таблица 2. Перечень РЛИ базы данных MSTAR

Цель	Описание	Углы места, °	Примечание
T-72	Танк T-72	15	3 набора из 195 изображений 8 наборов из 274 изображения
		17	3 набора из 230 изображений 8 наборов из 248 изображений
		30	1 набор из 288 изображений 1 набор из 133 изображений
		45	1 набор из 303 изображения 1 набор из 120 изображений
BMP2	БМП 2 – гусеничная боевая машина пехоты	15	3 набора из 196 изображений
		17	3 набора из 235 изображений
BTR-60	БТР-60 – бронетранспортер	15	1 набор из 195 изображений
		17	1 набор из 256 изображений
BTR-70	БТР-70 – бронетранспортер	15	1 набор из 196 изображений
		17	1 набор из 233 изображения
2S1	2С1 «Гвоздика» – самоходная гаубица	15	1 набор из 274 изображений
		17	1 набор из 299 изображений
		30	1 набор из 288 изображений
		45	1 набор из 303 изображений
BRDM-2	БРДМ-2 (ГАЗ-41) – бронированная разведывательно-дозорная машина	15	1 набор из 274 изображений
		17	1 набор из 298 изображений
		30	1 набор из 287 изображений 1 набор из 133 изображений
		45	1 набор из 303 изображений 1 набор из 120 изображений
T-62	Танк T-62	15	1 набор из 273 изображений
		17	1 набор из 299 изображений
ZSU_23_4	ЗСУ-23-4 «Шилка» – зенитная самоходная установка	15	1 набор из 274 изображений
		17	1 набор из 299 изображений
		30	1 набор из 288 изображений 1 набор из 118 изображений
		45	1 набор из 303 изображений 1 набор из 119 изображений
ZIL131	ЗИЛ-131 – грузовой автомобиль повышенной проходимости	15	1 набор из 274 изображений
		17	1 набор из 299 изображений
D7	D7 – гусеничный бульдозер	15	1 набор из 274 изображений
		17	1 набор из 299 изображений
SLICY	Конструкция из геометрических фигур, содержащая базовые формы радиолокационных отражателей, такие как плоские пластины, двугранные, трехгранные и цилиндры	15	1 набор из 274 изображений
		16	1 набор из 286 изображений
		17	1 набор из 288 изображений
		29	1 набор из 210 изображений
		30	1 набор из 288 изображений
		31	1 набор из 323 изображений
		43	1 набор из 255 изображений
		44	1 набор из 312 изображений
		45	1 набор из 303 изображений
CLUTTER	Радиолокационные изображения города Хантсвилл и его окрестностей	15	1 набор из 100 изображений

Примеры РЛИ из базы данных MSTAR target приведены на рис. 1.




Рис. 1. Примеры РЛИ из базы данных MSTAR target

Пример изображения из выборки MSTAR clutter приведен на рис. 2.




Рис. 2. Изображение сельской местности из выборки MSTAR clutter

Формирование РЛИ земной поверхности (MSTAR clutter) и транспортных средств (MSTAR target) осуществлялось в одинаковых условиях, что позволило применить методику размещения объектов на фоне сельской местности, как в [10].

Процесс слияния и генерации изображений осуществлялся в 3 этапа [10]:

- выбирались точки размещения РЛИ объекта (MSTAR target) на РЛИ сельской местности (MSTAR clutter);
- осуществлялась коррекция яркости пикселей РЛИ объекта (MSTAR target) и выбранного участка РЛИ сельской местности (MSTAR clutter);
- проводилось слияние РЛИ объекта (MSTAR target) и выбранного участка РЛИ сельской местности (MSTAR clutter).

При этом угол места съемки размещаемых РЛИ объектов (MSTAR target) соответствовал углу места съемки РЛИ сельской местности (MSTAR clutter).

Размещенные на РЛИ объекты соответствовали следующим классам: class 0 – радиотрагетель (SLICY), class 1 – бронетранспортер, class 2 – бронированная разведывательно-дозорная машина, class 3 – зенитная самоходная установка, class 4 – танк. На рис. 3 представлено изображение из сгенерированной базы данных.



Рис. 3. Пример изображения из сгенерированной базы данных

Таким образом, была сгенерирована база данных для решения задачи обнаружения и распознавания размещенных на земной поверхности объектов. Выборка состояла из 350 изображений, на каждом изображении размещено по 5 объектов. Для обучения выделено 300 изображений, для валидации и тестирования – 50 изображений. К каждому изображению подготовлен текстовый файл с координатами объектов и информации об их классе.

В работе исследовалось быстродействие и точность моделей нейронных сетей YOLO 5-го, 8-го и 11-го [14] поколений из библиотеки ultralytics⁶ с разным количеством обучаемых параметров (модели nano, small, medium, large, extra large) при следующих параметрах обучения нейронных сетей:

- количество эпох обучения для всех алгоритмов – 40;
- оптимизатор – AdamW с шагом сходимости 0.001111, с моментумом, равным 0.9.

⁶ Ultralytics | Revolutionizing the World of Vision AI. <https://www.ultralytics.com/>. Дата обращения 02.12.2024. / Accessed December 02, 2024.

РЕЗУЛЬТАТЫ ОБУЧЕНИЯ И ОЦЕНКА ЭФФЕКТИВНОСТИ НЕЙРОННЫХ СЕТЕЙ

Для мониторинга процесса обучения моделей и оценки их эффективности на тренировочных и валидационных наборах данных использовались приведенные ниже метрики [9]:

1. Точность (Precision) – доля объектов, названных классификатором положительными и при этом действительно являющихся положительными:

$$\text{Precision} = \frac{TP}{TP + FP}, \quad (1)$$

где TP (True Positive, истинно-положительная классификация) – доля правильных классификаций о принадлежности к положительному классу, FP (ошибка 2-го рода – ложная тревога) – доля неправильных классификаций о принадлежности к положительному классу (False Positive). Эта метрика оценивает модель на наличие ошибок 2-го рода.

2. Полнота (Recall) – какую долю объектов заданного класса из всех объектов заданного класса нашел алгоритм:

$$\text{Recall} = \frac{TP}{TP + FN}, \quad (2)$$

где FN (ошибка 1-го рода – пропуск цели) – доля неправильных классификаций об отсутствии принадлежности к положительному классу (False Negative). Эта метрика оценивает модель на наличие ошибок 1-го рода.

Точность и полнота получены для разных порогов уверенности модели (confidence level). Эти пороги задаются вручную, и при этом одновременно оцениваются предсказание ограничивающей рамки и предсказание класса модели. Чем выше этот порог, тем меньше будет срабатываний детектора, но это позволит уменьшить ошибку 2-го рода (FP), тем самым увеличит точность, но уменьшит значение полноты. Следовательно, можно построить зависимость Precision от Recall. Средняя точность (Average Precision, AP) – это площадь под кривой Precision–Recall:

$$AP = \int_0^1 P(R) dR. \quad (3)$$

Средневзвешенная точность (mean Average Precision, mAP) – это площадь под кривой Precision–Recall, взвешенная по всем классам

$$mAP = \frac{1}{N} \sum_{i=1}^N AP(i). \quad (4)$$

Например, величина mAP50-95 – это средневзвешенная точность с учетом значений IoU $\in [0.5; 0.95]$, IoU (intersection over union) – метрика степени пересечения между истинной ограничивающей рамкой и предсказанной ограничивающей рамкой. Если предсказанная рамка совпадает с истинной, тогда IoU = 1.

На рис. 4 представлен пример результата распознавания объектов на тестовом изображении.




Рис. 4. Результат распознавания объектов на РЛИ с помощью модели YOLOv11s:
(а) РЛИ до распознавания, (б) РЛИ после распознавания

Лучшей моделью по итогам обучения считается та модель, которая имеет наибольшую метрику mAP50-95 на валидационных данных.

В табл. 3 приведены полученные численные значения метрик при обучении нейронных сетей семейства YOLO.

В результате сравнения различных моделей YOLO по метрике оценки точности лучшие результаты показали модели YOLOv11n (0.925), YOLOv5l (0.889), YOLOv11s (0.883); по метрике полноты – YOLOv5n (0.932), YOLOv11n (0.928), YOLOv11s (0.914); по метрике mAP50 – YOLOv11s (0.961), YOLOv5n (0.954), YOLOv11n (0.953); по метрике mAP50-95 – YOLOv5n (0.756), YOLOv11s (0.74), YOLOv5l (0.727).

Результаты анализа количества операций с плавающей точкой представлены гистограммой на рис. 5.

Таблица 3. Метрики моделей нейронных сетей семейства YOLO

Модель нейронной сети	Precision	Recall	mAP50	mAP50-95	Количество операций с плавающей точкой
YOLOv5n	0.844	0.932	0.954	0.756	7.1e9
YOLOv5s	0.76	0.808	0.871	0.649	23.8e9
YOLOv5m	0.789	0.801	0.889	0.695	64e9
YOLOv5l	0.889	0.881	0.933	0.727	134.7e9
YOLOv5x	0.725	0.802	0.844	0.678	246e9
YOLOv8n	0.748	0.84	0.897	0.65	8.1e9
YOLOv8s	0.643	0.79	0.828	0.617	28.4e9
YOLOv8m	0.739	0.832	0.871	0.678	78.7e9
YOLOv8l	0.694	0.806	0.843	0.648	164.8e9
YOLOv8x	0.772	0.821	0.895	0.697	257.4e9
YOLOv11n	0.925	0.928	0.953	0.725	6.3e9
YOLOv11s	0.883	0.914	0.961	0.74	21.3e9
YOLOv11m	0.804	0.893	0.91	0.726	67.7e9
YOLOv11l	0.566	0.7	0.761	0.573	86.6e9
YOLOv11x	0.63	0.772	0.82	0.627	194.4e9




Рис. 5. Сравнение количества операций с плавающей точкой для исследуемых моделей

Из полученных данных можно сделать вывод о том, что модели l и x с большим количеством операций с плавающей точкой по всем параметрам хуже, чем модели n, s и m, что связано с недообучением моделей l и x.

Относительно значений метрик mAP50 и mAP50-95 лучшие результаты показали YOLOv5n, YOLOv11n и YOLOv11s. В работе [10] для исследования точности распознавания использовались модели FasterRCNN (mAP50 = 0.8786),

RetinaNet (mAP50 = 0.916) и различные модификации YOLOv5: YOLOv5 базовая (mAP50 = 0.9169), YOLOv5 модифицированная (mAP50 = 0.9555). В табл. 4 приведены значения метрики mAP50 для сравнения моделей нейронных сетей YOLO.

Таблица 4. Метрика mAP50 моделей нейронных сетей

Модель нейронной сети	mAP50
YOLOv5n	0.954
YOLOv11n	0.953
YOLOv11s	0.961

На основе данных табл. 4 можно сделать вывод о том, что модели YOLO 11-го поколения хорошо показывают себя при решении задачи обнаружения и распознавания наземных объектов на РЛИ.

На рис. 6 изображена матрица ошибок для нейронной сети YOLOv11s, которая показывает, сколько ошибочных классификаций допустила модель.

Слева обозначены классы по предсказаниям модели, снизу – истинные классы. Помимо 5 классов, распознаваемых объектов, также имеется класс заднего фона (background), который показывает ошибки классификации фона.

Логично предположить, что изображения радиотраектор чаще остальных будут классифицированы как фон, т.к. они имеют небольшую, в сравнении с остальными классами, эффективную площадь рассеяния.

Предсказывая класс 1, модель YOLOv11s имела наибольшую ошибку 1-го рода: 5 из 50 были классифицированы как класс 2, 6 из 50 были классифицированы как класс 4. Наибольшую ошибку 2-го рода имеет класс 4: 6 объектов класса 1, 3 объекта класса 3 и 3 фрагмента с задним фоном были отнесены к классу 4.




Рис. 6. Матрица ошибок нейронной сети YOLOv11s

Для оценки возможности применения нейронных сетей на МК [15] сравнивалось количество операций, которые требуют модели YOLO с количеством операций в секунду, которые может обеспечить МК. За основу взят МК Firefly ROC-RK3588S-PC (Firefly Technology Co., Китай), на борту которого имеется нейронный процессор RK3588, обеспечивающий быстродействие до 6 TOPS (Tera Operations per Second – Тера-операций в секунду)⁷.

Вычислительный ресурс, потребляемый моделями нейронных сетей при подаче на вход одного изображения, можно выразить через параметр GFLOPs (Giga Float Operations – Гига-операций

с плавающей точкой). Для релевантной оценки необходимо привести TOPS к формату с операциями с плавающей запятой, т.к. величина TOPS определяет количество операций в секунду⁸, а GFLOPs определяет количество операций с плавающей точкой с поступающим на вход изображением. Производительность 4 TOPS приблизительно равна производительности 1 TFLOPS⁹, следовательно, преобразовав 6 TOPS, получим 1.5 TFLOPS. Таким образом, быстродействие МК ROC-RK3588S-PC позволяет устанавливать модели YOLOv5n (7.1 GFLOPs), YOLOv11n (6.3 GFLOPs), YOLOv11s (21.3 GFLOPs), обеспечивая быстродействие более 10 кадров в секунду, что является положительным результатом.

ЗАКЛЮЧЕНИЕ

Результаты исследований показали, что из рассмотренных моделей нейронных сетей наилучший результат по приведенным метрикам дают следующие модели: YOLOv5n, YOLOv5l, YOLOv11n, YOLOv11s. Разница значений метрик mAP50-95 между моделями YOLOv5l и YOLOv11n составляет ~0.003. Разница значений метрик Precision между моделями YOLOv5l и YOLOv11s составляет ~0.006. Разница в вычислительных затратах составляет ~10² операций с плавающей точкой, что оказывает существенное влияние на быстродействие. Таким образом, были выбраны следующие модели: YOLOv5n, YOLOv11n, YOLOv11s. Анализ вычислительных затрат моделей и оценка быстродействия МК ROC-RK3588S-PC позволяют сделать вывод о возможности установки этих моделей на МК для работы в режиме реального времени.

Вклад авторов

А.С. Красноперова – проведение исследования, интерпретация и обобщение результатов, написание текста статьи.

А.С. Твердохлебов – интерпретация результатов исследований, подготовка выводов.

А.А. Карташов – определение темы исследования и обоснование финального текста статьи.

В.И. Вебер – планирование исследования, интерпретация результатов, научное редактирование статьи.

В.Ю. Куприц – постановка целей и задач исследования, методов машинного обучения.

Authors' contributions

A.S. Krasnoperova – conducting research, interpreting and summarizing results, writing the text of the article.

⁸ What is TOPS and TeraFLOPS in AI? https://www.candtsolution.com/news_events-detail/tops-and-teraflops-in-AI/#:~:text=What%20is%20TOPS%20in%20AI,peak%20performance%20of%20AI%20hardware. Дата обращения 02.12.2024. / Accessed December 02, 2024.

⁹ What Is The Relationship Between the Units of Tops and Flops? <https://premioinc.com/blogs/blog/what-is-tops-and-teraflops-in-ai>. Дата обращения 02.12.2024. / Accessed December 02, 2024.

⁷ ROC-RK3588S-PC 8-Core 8K AI Mainboard. <https://www.rock-chips.com/a/cn/product/RK35xilie/2022/0926/1656.html>. Дата обращения 02.12.2024. / Accessed December 02, 2024.

A.S. Tverdokhlebov – interpreting research results, preparing conclusions.

A.A. Kartashov – defining the research topic and discussing the final text of the article.

V.I. Weber – planning the research, interpreting results, scientific editing of the article.

V.Y. Kuprits – setting the aims and objectives of the research, methods of machine learning.

СПИСОК ЛИТЕРАТУРЫ

1. Malmgren-Hansen D., Engholm R., Østergaard Pedersen M. Training Convolutional Neural Networks for Translational Invariance on SAR ATR. In: *Proceedings of EUSAR 2016: 11th European Conference on Synthetic Aperture Radar*. IEEE; 2016. P. 459–462.
2. Cruz H., Véstias M.P., Monteiro J., et al. A Review of Synthetic-Aperture Radar Image Formation Algorithms and Implementations: A Computational Perspective. *Remote Sens.* 2022;14(5):1258. <https://doi.org/10.3390/rs14051258>
3. Ильин Е.М., Полубехин А.И., Савостьянов В.Ю., Самарин О.Ф., Черевко А.Г. Малогабаритный многофункциональный бортовой РЛК для беспилотных летательных аппаратов малой дальности. *Вестник СибГУТИ*. 2017;4:104–109. <https://www.elibrary.ru/item.asp?id=30793295>
4. Поль В.Г., Симонов А.В. Космическая радиолокационная съемка рельефа и совместный полет пары космических аппаратов. *Инженерный журнал: наука и инновации*. 2020;7:1–21. <https://doi.org/10.18698/2308-6033-2020-7-1999>, <https://www.elibrary.ru/item.asp?id=43566045>
5. Хахулина Н.Б. Системы сбора и обработки информации результатов геодезических изысканий и дистанционного зондирования. Воронеж: Воронежский государственный технический университет; 2022. 78 с.
6. Радиолокационные станции воздушной разведки; под ред. Г.С. Кондратенкова. М.: Воениздат; 1983. 154 с.
7. Радиолокационные системы многофункциональных самолетов: в 3 т. Т. 1. РЛС – информационная основа боевых действий многофункциональных самолетов. Системы и алгоритмы первичной обработки радиолокационных сигналов; под ред. А.И. Канащенкова, В.И. Меркулова. М.: Радиотехника; 2006. 656 с.
8. Купряшкин И.Ф., Мазин А.С. Классификация объектов военной техники с использованием сверточной нейронной сети на радиолокационных изображениях, сформированных в условиях шумовых помех. *Вестник Концерна ВКО «Алмаз – Антей»*. 2022;1:71–81. <https://www.elibrary.ru/item.asp?id=48138675>
9. Chen D., Ju R., Tu C., Long G., Liu X., Liu J. GDB-YOLOv5s: Improved YOLO-based Model for Ship Detection in SAR Images. *IET Image Process.* 2024;18(11):2869–2883. <https://doi.org/10.1049/ipr2.13140>
10. Song Y., Wang S., Li Q., Mu H., Feng R., Tian T., Tian J. Vehicle Target Detection Method for Wide-Area SAR Images Based on Coarse-Grained Judgment and Fine-Grained Detection. *Remote Sens.* 2023;15(13):3242. <https://doi.org/10.3390/rs15133242>
11. Zhang T., Zhang X., Li J., Xu X., Wang B., Zhan X., Xu Y., Ke X., Zeng T., Su H., et al. SAR Ship Detection Dataset (SSDD): Official Release and Comprehensive Data Analysis. *Remote Sens.* 2021;13(18):3690. <https://doi.org/10.3390/rs13183690>
12. Карманова Н.А., Карманов А.Г., Петров А.А. Разработка модели радара с синтезированной апертурой беспилотного летательного аппарата для дистанционного зондирования лесных массивов. *Информация и Космос*. 2021;4:114–122. <https://www.elibrary.ru/item.asp?edn=esiivj>
13. Брызгалов А.П., Ковальчук И.В., Хныкин А.В., Шевела И.А., Юсупов Р.Г. Моделирование радиолокатора с синтезированной апертурой при решении задач его внутреннего и внешнего проектирования. *Труды МАИ*. 2011;43:25. <https://www.elibrary.ru/item.asp?id=15632049>
14. Terven J., Córdova-Esparza D.-M., Romero-González J.-A. A comprehensive review of YOLO architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS. *Mach. Learn. Knowl. Extr.* 2023;5(4):1680–1716. <https://doi.org/10.3390/make5040083>
15. Baller S., Jindal A., Chadha M., Gerndt M. DeepEdgeBench: benchmarking deep neural networks on edge devices. In: *Proceedings of the 2021 IEEE International Conference on Cloud Engineering (IC2E)*. IEEE; 2021. P. 20–30. <https://doi.org/10.1109/IC2E52221.2021.00016>

REFERENCES

1. Malmgren-Hansen D., Engholm R., Østergaard Pedersen M. Training Convolutional Neural Networks for Translational Invariance on SAR ATR. In: *Proceedings of EUSAR 2016: 11th European Conference on Synthetic Aperture Radar*. IEEE; 2016. P. 459–462.
2. Cruz H., Véstias M.P., Monteiro J., et al. A Review of Synthetic-Aperture Radar Image Formation Algorithms and Implementations: A Computational Perspective. *Remote Sens.* 2022;14(5):1258. <https://doi.org/10.3390/rs14051258>
3. Il'in E.M., Polubekhin A.I., Savostyanov V.Yu., Samarina O.F., Cherevko A.G. Airborne multi-functional radar complex for short-range UAVs. *Vestnik SibGUTI = The Herald of the Siberian State University of Telecommunications and Information Science*. 2017;4:104–109 (in Russ.). <https://www.elibrary.ru/item.asp?id=30793295>
4. Paul V.G., Simonov A.V. Space radar terrain survey and the joint flight of a spacecraft pair. *Inzhenernyi zhurnal: nauka i innovatsii = Engineering Journal: Science and Innovation*. 2020;7:1–21 (in Russ.). <https://doi.org/10.18698/2308-6033-2020-7-1999>, <https://www.elibrary.ru/item.asp?id=43566045>

5. Khakhulina N.B. *Sistemy sbora i obrabotki informatsii rezul'tatov geodezicheskikh izyskanii i dstantsionnogo zondirovaniya* (Systems of Information Collection and Processing of Geodetic Surveys and Remote Sensing Results). Voronezh: Voronezh State Technical University; 2022. 78 p. (in Russ.).
6. Kondratenkov G.S. (Ed.). *Radiolokatsionnye stantsii vozdushnoi razvedki* (Airborne Reconnaissance Radar Stations). Moscow: Voenizdat; 1983. 154 p. (in Russ.).
7. Kanaschenkov A.I., Merkulov V.I. (Eds.). *Radiolokatsionnye sistemy mnogofunktsional'nykh samoletov: V 3 t. T. 1. RLS – informatsionnaya osnova boevykh deistvii mnogofunktsional'nykh samoletov. Sistemy i algoritmy pervichnoi obrabotki radiolokatsionnykh signalov* (Radar Systems of Multi-Functional Aircraft: in 3 v. V. 1. Radar Systems – Information Basis for Combat Operations of Multi-Functional Aircraft. Systems and Algorithms for Primary Processing of Radar Signals). Moscow: Radiotekhnika; 2006. 656 p. (in Russ.).
8. Kupryashkin I.F., Mazin A.S. Classification of military equipment targets on radar images generated in noise interference conditions using a convolutional neural network. *Vestnik Kontserna VKO Almaz-Antey*. 2022;1:71–81 (in Russ.). <https://www.elibrary.ru/item.asp?id=48138675>
9. Chen D., Ju R., Tu C., Long G., Liu X., Liu J. GDB-YOLOv5s: Improved YOLO-based Model for Ship Detection in SAR Images. *IET Image Process.* 2024;18(11):2869–2883. <https://doi.org/10.1049/ipr2.13140>
10. Song Y., Wang S., Li Q., Mu H., Feng R., Tian T., Tian J. Vehicle Target Detection Method for Wide-Area SAR Images Based on Coarse-Grained Judgment and Fine-Grained Detection. *Remote Sens.* 2023;15(13):3242. <https://doi.org/10.3390/rs15133242>
11. Zhang T., Zhang X., Li J., Xu X., Wang B., Zhan X., Xu Y., Ke X., Zeng T., Su H., et al. SAR Ship Detection Dataset (SSDD): Official Release and Comprehensive Data Analysis. *Remote Sens.* 2021;13(18):3690. <https://doi.org/10.3390/rs13183690>
12. Karmanova N.A., Karmanov A.G., Petrov A.A. Development of a synthetic aperture radar model for unmanned aerial vehicles for remote sensing of woodlands. *Informatsiya i Kosmos = Information and Space*. 2021;4:114–122 (in Russ.). <https://www.elibrary.ru/item.asp?edn=esiivj>
13. Bryzgalov A.P., Koval'chuk I.V., Khnykin A.V., Shevela I.A., Yusupov R.G. Simulation of Synthetic Aperture Radar Assigned to Solving the Problems of Its Internal and External Design. *Trudy MAI*. 2011;43:25 (in Russ.). <https://www.elibrary.ru/item.asp?id=15632049>
14. Terven J., Córdova-Esparza D.-M., Romero-González J.-A. A comprehensive review of YOLO architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS. *Mach. Learn. Knowl. Extr.* 2023;5(4):1680–1716. <https://doi.org/10.3390/make5040083>
15. Baller S., Jindal A., Chadha M., Gerndt M. DeepEdgeBench: benchmarking deep neural networks on edge devices. In: *Proceedings of the 2021 IEEE International Conference on Cloud Engineering (IC2E)*. IEEE; 2021. P. 20–30. <https://doi.org/10.1109/IC2E52221.2021.00016>

Об авторах

Красноперова Алена Сергеевна, инженер студенческого конструкторского бюро «Интеллектуальные радиотехнические системы», кафедра радиотехнических систем, ФГАОУ ВО «Томский государственный университет систем управления и радиоэлектроники» (634050, Россия, Томск, пр. Ленина, д. 40). E-mail: alenacergeevna2@icloud.com. SPIN-код РИНЦ 9055-6959, <https://orcid.org/0009-0001-5568-8290>

Твердохлебов Александр Сергеевич, инженер студенческого конструкторского бюро «Интеллектуальные радиотехнические системы», кафедра радиотехнических систем, ФГАОУ ВО «Томский государственный университет систем управления и радиоэлектроники» (634050, Россия, Томск, пр. Ленина, д. 40). E-mail: tverdohlebov.a.923-e.tusur.ru. <https://orcid.org/0009-0008-2250-6375>

Карташов Алексей Андреевич, инженер студенческого конструкторского бюро «Интеллектуальные радиотехнические системы», кафедра радиотехнических систем, ФГАОУ ВО «Томский государственный университет систем управления и радиоэлектроники» (634050, Россия, Томск, пр. Ленина, д. 40). E-mail: kartashov.a.923-m@e.tusur.ru. <https://orcid.org/0009-0009-6005-7539>

Вебер Владислав Игоревич, аспирант, ассистент кафедры радиотехнических систем, ФГАОУ ВО «Томский государственный университет систем управления и радиоэлектроники» (634050, Россия, Томск, пр. Ленина, д. 40). E-mail: vladweber00@gmail.com. SPIN-код РИНЦ 3880-2107, <https://orcid.org/0000-0002-0275-4127>

Куприц Владимир Юрьевич, к.т.н., доцент, руководитель студенческого конструкторского бюро «Интеллектуальные радиотехнические системы», кафедра радиотехнических систем, ФГАОУ ВО «Томский государственный университет систем управления и радиоэлектроники» (634050, Россия, Томск, пр. Ленина, д. 40). E-mail: vladimir.y.kuprits@tusur.ru. SPIN-код РИНЦ 4855-3318, <https://orcid.org/0000-0001-7190-3213>

About the Authors

Alena S. Krasnoperova, Engineer of the Student Design Bureau of Intelligent Radio Engineering Systems, Department of Radio Engineering Systems, Tomsk State University of Control Systems and Radioelectronics (40, Lenina pr., Tomsk, 634050 Russia). E-mail: alenacergeevna2@icloud.com. RSCI SPIN-code 9055-6959, <https://orcid.org/0009-0001-5568-8290>

Alexander S. Tverdokhlebov, Engineer of the Student Design Bureau of Intelligent Radio Engineering Systems, Department of Radio Engineering Systems, Tomsk State University of Control Systems and Radioelectronics (40, Lenina pr., Tomsk, 634050 Russia). E-mail: tverdohlebov.a.923-@e.tusur.ru. <https://orcid.org/0009-0008-2250-6375>

Alexey A. Kartashov, Engineer of the Student Design Bureau of Intelligent Radio Engineering Systems, Department of Radio Engineering Systems, Tomsk State University of Control Systems and Radioelectronics (40, Lenina pr., Tomsk, 634050 Russia). E-mail: kartashov.a.923-m@e.tusur.ru. <https://orcid.org/0009-0009-6005-7539>

Vladislav I. Weber, Postgraduate Student, Assistant, Department of Radio Engineering Systems, Tomsk State University of Control Systems and Radioelectronics (40, Lenina pr., Tomsk, 634050 Russia). E-mail: vladweber00@gmail.com. RSCI SPIN-code 3880-2107, <https://orcid.org/0000-0002-0275-4127>

Vladimir Y. Kuprits, Cand. Sci. (Eng.), Associate Professor, Head of the Student Design Bureau of Intelligent Radio Engineering Systems, Department of Radio Engineering Systems, Tomsk State University of Control Systems and Radioelectronics (40, Lenina pr., Tomsk, 634050 Russia). E-mail: vladimir.y.kuprits@tusur.ru. RSCI SPIN-code 4855-3318, <https://orcid.org/0000-0001-7190-3213>