

Труды МАИ. 2025. № 141
Trudy MAI. 2025. No. 141. (In Russ.)

Научная статья
УДК 621.396.96+51.001.57
URL: <https://trudymai.ru/published.php?ID=184504>
EDN: <https://www.elibrary.ru/MVUSHU>

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ДЛЯ РАСПОЗНАВАНИЯ РАСПРЕДЕЛЕННЫХ ОБЪЕКТОВ НА РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЯХ

Александр Николаевич Тонких
Научно-производственное объединение НаукаСофт,
Москва, Российская Федерация
alex_tonkih@mail.ru

Аннотация. Рассмотрены подходы к построению алгоритмов решения задач обнаружения и распознавания распределенных искусственных объектов на радиолокационных изображениях. Проведен анализ нейросетевых технологий в решении задач дешифрирования изображений. Обоснована необходимость математического моделирования для информационного обеспечения обучения нейросетевых алгоритмов. Построена архитектура свёрточной нейронной сети по совместному обнаружению и распознавания объектов на радиолокационных изображениях с последующим обучением. Анализ полученных результатов подтвердил работоспособность предлагаемого решения.

Ключевые слова: радиолокация, радиолокационное изображение, математическое моделирование, свёрточная нейронная сеть, обнаружение, распознавание

Для цитирования: Тонких А.Н. Применение нейросетевых технологий для распознавания распределенных объектов на радиолокационных изображениях // Труды МАИ. 2025. № 141. URL: <https://trudymai.ru/published.php?ID=184504>

Original article

APPLICATION OF NEURAL NETWORK TECHNOLOGIES FOR RECOGNIZING DISTRIBUTED OBJECTS IN RADAR IMAGES

Aleksandr N. Tonkikh

NaukaSoft Scientific and Production Association,

Moscow, Russian Federation

alex_tonkih@mail.ru

Abstract. The paper considers approaches to the construction of algorithms for solving the problem of detection and recognition of distributed artificial objects in radar images. A brief review of existing architectures of convolutional neural networks is carried out, their main advantages and applied solutions in the interests of improving performance are shown. For information support of training of neural network algorithms the necessity of application of mathematical modeling of radar images of distributed artificial objects is justified. In the course of the work the architecture of convolutional neural network for joint detection and recognition of objects in radar images is proposed. The analysis of the obtained results showed that the application of convolutional neural networks allows solving the problem of joint detection and recognition of objects in radar images. Such a solution is realized in real time. In this case, the main hardware and time costs are required at the stage of training of convolutional neural network. Comparability of the results of correct detection and recognition of the neural network trained on model radar images with the results of Faster R-CNN and VGG-16 allows us to speak about the suitability of mathematical modeling to inform the training process. The work can be continued by developing a convolutional neural network based on the Mask R-CNN model, where the problem of segmenting the possible region of the object location is solved. This approach will allow to use the shape of the object as an additional classification feature, thereby increasing the accuracy of identification. In addition, it is advisable to consider the

inclusion in the architecture of the convolutional neural network of an additional branch that estimates the shadow of the object, which is in some cases more informative than the image of the object itself.

Keywords: radar, radar image, mathematical modeling, convolutional neural network, detection, recognition

For citation: Tonkikh A.N. Application of neural network technologies for recognizing distributed objects in radar images. *Trudy MAI*. 2025. No. 141. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=184504>

Введение

В настоящее время расширяется сфера применения радиолокационных станций с синтезированной апертурой антенны (РСА), позволяющих формировать высокодетальные радиолокационные изображения (РЛИ) вне зависимости от времени суток и погодных условий. Одной из актуальных задач, решаемых с помощью данного средства дистанционного зондирования, является обнаружение и распознавание распределенных искусственных объектов. Под распределенным объектом понимается объект, у которого один или оба габаритных размера много больше размера элемента разрешения. На РЛИ таких объектов воспроизводятся форма, размеры и текстурные признаки, что позволяет в отношении них решать задачу совместного обнаружения и распознавания. С повышением разрешающей способности радиолокационных станций все большее число объектов переходит в разряд распределенных. Стоит отметить, что интерпретация РЛИ, даже при разрешении, сопоставимом с разрешением изображений оптического диапазона длин электромагнитных волн (ЭМВ), вызывает затруднения в силу специфики отображения объектов на РЛИ, которые определяется особенностями формирования радиолокационных изображений [1]: зеркальные отражения в противоположную сторону от плоских поверхностей при малых углах падения ЭМВ; зеркальные отражения в сторону радиолокационной станции при близком к нормальному падению ЭМВ; флуктуации яркости элементов изображения по поверхности распределенных объектов; тени от выступающих по высоте элементов объекта и т.д.

Цель статьи: оценка возможностей применения нейросетевых технологий в решении задач обнаружения и распознавания распределенных объектов на радиолокационных изображениях, а также оценка пригодности математического моделирования радиолокационных изображений объектов для информационного обеспечения задачи обучения нейронной сети.

Анализ подходов к обнаружению и распознаванию объектов на РЛИ.

Постановка задачи

Анализ существующих подходов к обнаружению и распознаванию распределенных искусственных объектов показывает, что традиционными являются визуальные и визуально-инструментальные методы дешифрирования, которые, в силу особенностей РЛИ, не обеспечивают требования по полноте, достоверности, точности и оперативности получения информации. Производительность современных РСА составляет более 10^7 элементов (пикселей) РЛИ в секунду, а производительность оператора-дешифровщика при визуальной обработке РЛИ характеризуется величиной порядка $10^3 \dots 10^4$ пикс/с [1]. Таким образом, необходимо решение задачи автоматизации процесса дешифрирования, в частности - автоматизированного обнаружения и распознавания искусственных объектов.

Для решения задачи совместного обнаружения и распознавания распределенных объектов на РЛИ можно выделить два подхода:

1. Использование оптимальных статистических алгоритмов [2, 3]. При полной априорной определенности в отношении полезных и помеховых сигналов оптимальной процедурой распознавания является байесовское правило, при котором в случае простой функции потерь принимается решение о классе цели по максимуму апостериорной вероятности. Обеспечение полной априорной информацией практически не представляется возможным, в связи с чем выполняют различные упрощения, включая синтез квазиоптимальных алгоритмов. В частности, квазиоптимальная процедура алгоритма распознавания распределенного объекта может быть выполнена в три этапа [1]. Первый этап состоит в формировании РЛИ по максимуму отношения сигнала от цели и фона к шуму аппаратуры путем

согласованной обработки [2]. Второй этап заключается в корреляции полученных РЛИ целей и фона с эталонными РЛИ заданного набора (алфавита) классов, хранимыми в «банке» эталонных изображений. Результаты коррелятора подаются на решающую процедуру классификатора по максимуму апостериорной вероятности, реализуемую компаратором.

2. Использование алгоритмов машинного обучения, которые показали высокую эффективность [4, 5] на изображениях видимого диапазона ЭМВ. Примеры и оценка возможностей внедрения нейросетевых технологий в теорию и технику дешифрирования РЛИ приведены в работах [6, 7, 8]. При использовании свёрточных нейронных сетей (СНС) описание объектов и решающие процедуры классификации реализуются в процессе обучения распознающих систем.

Стоит отметить тот факт, что решение задачи по распознаванию распределенных объектов, вне зависимости от используемого подхода, невозможно без наличия банка данных РЛИ таких объектов. Практическое формирование такого банка крайне затруднительно в силу специфики формирования изображения и, как следствие, высокой зависимости РЛИ от характеристик аппаратуры и условий наблюдения. Кроме того, формирование банка по экспериментальным данным затруднительно из-за высоких стоимостных и временных затрат на выполнение съемок. В настоящее время существуют доступные архивы данных информации зарубежных космических радиолокационных станций – ERS, RADARSAT, ENVISAT, а также российского РСА АЛМАЗ-1. Ограничением их применения в качестве обучающих данных является разрешающая способность хранимых в них РЛИ. Также в открытом доступе представлены материалы по двум архивам данных MSTAR (Moving and Stationary Targets Acquisition and Recognition) [9, 10]. Первый набор MSTAR-1 был получен в 1995 году на полигоне Redstone (штат Алабама, США) [9]. Второй набор данных получен в 1996 году на авиабазе Eglin (штат Флорида, США) [11, 12]. Данные MSTAR имеют разрешение 0.3x0.3 м, что позволяет использовать их для обучения СНС. Альтернативой экспериментальным базам данных РЛИ является применение математического моделирования [13, 14],

которое позволяет варьировать условия наблюдения и параметры радиолокационной станции в широких пределах.

Таким образом, в рамках данной работы рассмотрим разработку архитектуры СНС для решения задачи совместного обнаружения и распознавания искусственных распределенных объектов на РЛИ, проведем обучение нейронной сети на данных моделирования, выполним оценку и анализ полученных результатов.

Разработка архитектуры свёрточной нейронной сети по обнаружению и распознаванию распределенных объектов

Коротко рассмотрим некоторые наиболее известные архитектуры свёрточных нейронных сетей, показавшие высокую эффективность при решении задач обнаружения и распознавания объектов в оптическом диапазоне длин ЭМВ. В описываемых архитектурах прослеживаются определенные проблематики СНС и способы их решения:

1. Модель VGG-16 (VGG-19) [15] представляет собой архитектуру СНС, предложенную Visual Geometry Group в Оксфордском университете. Она характеризуется своей глубиной, состоящей из 16 слоев, включая 13 свёрточных и 3-х полносвязанных слоёв. Достоинствами VGG-16 являются простота и эффективность, а также высокая производительность.
2. InceptionNet [16] – СНС, первая версия которой представлена в 2014 году компанией Google. Отличительной особенностью данной архитектуры является использование факторизации свёртки, то есть замена одной свертки на две, например 5×5 заменяют на 5×1 и 1×5 , что в конечном счете снижает требования к памяти и увеличивает скорость работы.
3. ResNets (Residual neural network) [17] — это архитектура свёрточной нейронной сети была разработана в 2015 году. Основная особенность заключается во введении остаточных блоков, которые используются для обучения и позволяют решить проблему ограничения на количество слоев в СНС. Ограничение на количество слоев возникает вследствие эффекта «исчезающего градиента». Данный эффект обусловлен тем, что в процессе обучения путем обратного распространения

ошибки вычисляются производные всей сети, продвигаясь от последнего слоя к первому, путем последовательного перемножения производных каждого слоя. Это повторяющееся умножение может приводить к бесконечно малым значениям, и как следствие, обновление весов и порогов на слоях, близких к входным, не будет эффективным на каждой эпохе обучения.

4. NFNets (Normalizer-Free ResNets) [18] – это архитектура свёрточной нейронной сети разработанная группой исследователей DeepMind. Основным является отказ от пакетной нормализации. Нормализация в СНС используется для повышения точности обобщения и скорости обучения. Однако нормализация не решает полностью эти задачи, которые находятся в определенном противоречии, так как остается зависимость от случайных «выбросов» в данных пакета при малых его размерах, а при больших размерах сильно возрастают вычислительные затраты и требуемый объем памяти для выполнения нормализации. В данной архитектуре вместо нормализации используется адаптивное отсечение градиента (AGC) [18], которое отсекает градиенты на основе поэлементного отношения нормы градиента к норме параметра. Такой подход позволяет обучать сети без нормализации на больших размерах пакетов, уменьшая время на обучение сети, а также позволяя достаточно просто выполнять распределенное обучение (на разных вычислительных машинах).

5. YOLO [19] - СНС, получившая наиболее широкое распространение в настоящее время благодаря эффективному обнаружению и распознаванию объектов в реальном времени и возможности работы на мобильных устройствах. Ключевой особенностью является разбиение входного изображения на сетке и параллельность обработки каждого такого фрагмента. Кроме того, применяются решения, описанные выше для архитектур 1-4.

Для оценки возможностей применения СНС при решении задачи обнаружения и распознавания объектов на РЛИ в качестве прототипа выберем VGG-16 (рисунок 1), как наиболее простую и показавшую высокую эффективность. В частности, вероятность правильной классификации на наборе данных PASCAL VOC 2007 составляет 89,3% и на наборе PASCAL VOC 2012 - 89.0% [15].

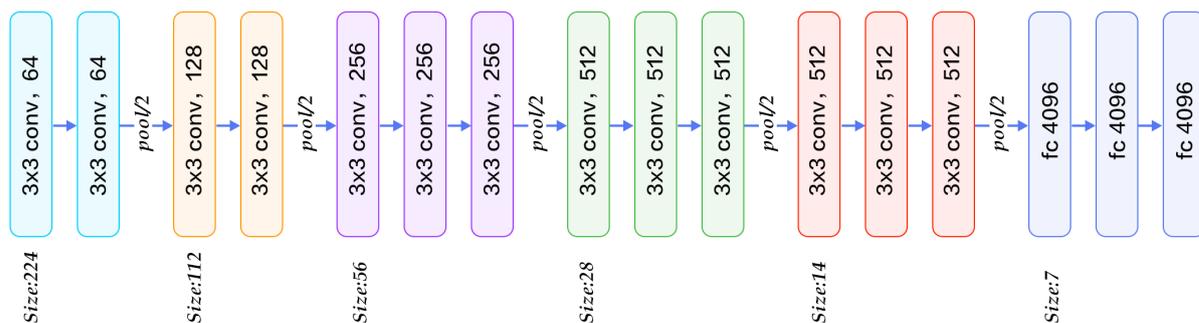


Рисунок 1 – Архитектура свёрточной нейронной сети VGG16 [11]

VGG16 состоит из 16 слоев, разделенных на две части:

1. Первая часть сети выделяет характерные признаки объектов на изображении. Состоит из пяти чередующихся каскадов свертки и подвыборки.
2. Вторая часть отвечает за классификацию объекта на изображении по выделенным признакам и представляется тремя полносвязными слоями.

Для сокращения времени обработки изображения, воспользуемся решением, предложенным при построении архитектуры Faster R-CNN [20], а именно введем дополнительную часть по обнаружению возможной области объекта на основе признаков, выделенных первой частью сети. Таким образом, предлагаемая СНС будет состоять из 3 частей: первая часть выделяет характерные признаки, вторая определяет местоположение (область предполагаемого объекта), третья осуществляет классификацию. Архитектура такой СНС приведена на рисунке 2. При разработке данной архитектуры произведена модификация слоёв VGG-16 с учетом специфики РЛИ (изображение одноканальное, динамический диапазон до 80 дБ, представление в формате с плавающей точкой 32 бит).

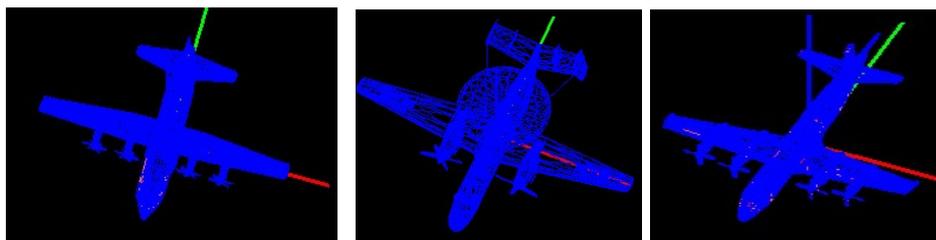
Проведение исследования

В данной работе для получения обучающих наборов данных использовался подход на основе математического моделирования [14], который позволяет по трехмерным геометрическим моделям объектов и описанию электромагнитных свойств поверхностей формировать РЛИ, а также маски объектов и теней.

В качестве алфавита классов рассмотрим три объекта: самолет типа С130 (длина - 29.8 м, размах крыла – 40.4 м, высота - 11.8 м), самолет типа Р3С (длина - 35.6 м, размах крыла – 30.4 м, высота - 10.3 м) и самолет типа Е2С (длина - 17.5 м, размах крыла – 24.6 м, высота - 5.6 м). Геометрические модели объектов представлены на рисунке 3 а-в, соответственно.



Рисунок 2 – Архитектура сверточной нейронной сети



а)

б)

в)

Рисунок 3 - Геометрические модели самолетов типа С130 (а), Р3С (б) и Е2С (в)

В ходе подготовки наборов данных для обучения было сформировано 5973 эталонных изображения каждого объекта в диапазоне углов наблюдения: в угломестной плоскости 45-55 град. с шагом 1 град. и в азимутальной плоскости в диапазоне 0-180 град. с шагом 1 град. Моделирование проводилось при условии наблюдения на фоне свободного пространства. Итого, для обучения и валидации процесса обучения, было сформировано 17919 эталонных радиолокационных изображения объектов размером 512x512 пикселей. Валидационная выборка соответствовала 30% от объема смоделированных изображений. Примеры радиолокационных портретов объектов, полученных в результате математического моделирования, приведены на рисунке 4. При обучении путем предварительной обработки (аугментации), сформированные РЛИ объектов помещались со случайными координатами, учитывая маски объекта и тени [14], на радиолокационные изображения однородных поверхностей с удельными эффективными площадями рассеяния -30дБ, -20дБ и -10дБ.

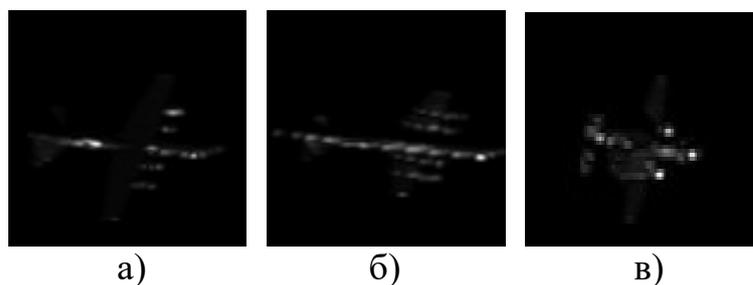


Рисунок 4 – Примеры эталонных РЛИ объектов, полученные путем моделирования:

а) — объект типа С-130; б) — объект типа РЗС; в) — объект типа Е2С

Программная реализация СНС осуществлялась с использованием открытой нейросетевой библиотеки Keras, где в качестве фреймворка применялся TensorFlow. Аппаратно обучение проводилось на графическом процессоре Nvidia GeForce GTX 1050Ti.

Для оценки результатов (тестирования) обучения использовались РЛИ (рисунки 5-7), полученные РСА, размещенной на космическом аппарате "Кондор-Э" [4, 6, 21]. В частности были использованы: фрагмент стоянки объектов типа С-130 3000x1200 пикселей, содержащий 108 объектов (рисунок 5); фрагмент стоянки

объектов типа РЗС 1300x700 пикселей, содержащий 33 объекта (рисунок 6); фрагмент стоянки объектов типа Е2С 800x800 пикселей, содержащий 10 объектов (рисунок 7). Таким образом, в тестировании использовались радиолокационные изображения, содержащие 151 объект интереса.

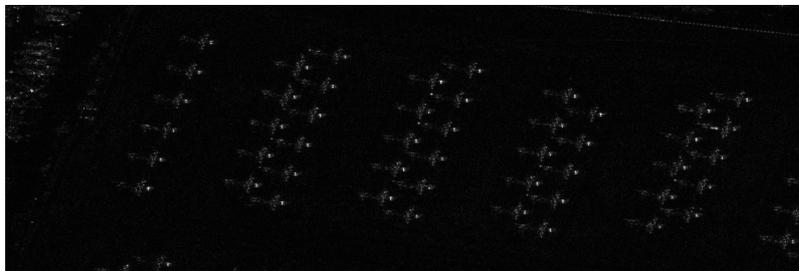


Рисунок 5 – Фрагмент РЛИ с объектами типа С-130

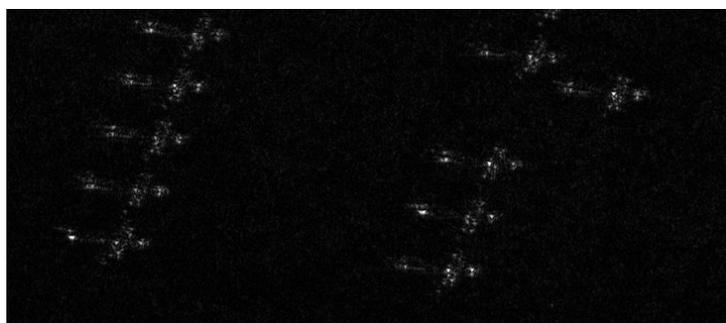


Рисунок 6 – Фрагмент РЛИ с объектами типа РЗС

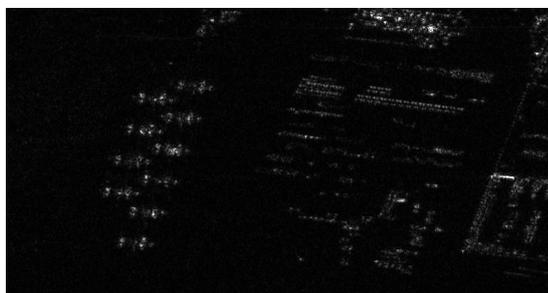


Рисунок 7 – Фрагмент РЛИ с объектами типа Е2С

В процессе работы были рассмотрены:

1. Свёрточная нейронная сеть, с архитектурой приведенной на рисунке 2. Обучение проводилось на модельных данных с использованием GPU (Nvidia GeForce GTX 1050Ti ОЗУ 4Гб), время обучения одной эпохи составило 450 с. При обучении использовался метод обратного распространения ошибки в режиме пакетного градиентного спуска. Оптимизация гиперпараметров нейросети (размера пакета (batch), скорости обучения, количества эпох) осуществлялась поиском по решётке, то есть реализовывался полный перебор по заданному подмножеству

пространства гиперпараметров. При этом было реализовано последовательное приближение: на начальном этапе выполнялась оптимизация на решетке с большим шагом с последующим поиском на решетке с меньшим шагом. Количество таких приближений соответствовало 5 итерациям. Время решения задачи по обнаружению и распознаванию обученной нейронной сетью составило 0.23 с для кадра 512x512 пикселей. Пример результата работы СНС приведен на рисунке 8. При тестировании на экспериментальных данных (рисунки 5-7) были получены следующие характеристики: вероятность правильного обнаружения - 94.7% (143 объекта), вероятность правильного обнаружения и распознавания - 74.2% (112 объектов), вероятность перепутывания - 20.5% (31 объект), количество ложно обнаруженных объектов - 115. Полученные результаты характеризуются высоким уровнем ложных обнаружений. Такой результат обусловлен тем, что при обучении все объекты наблюдались на однородном фоне. Полученные результаты сопоставимы с характеристиками СНС VGG16 [15] и технологией Faster R-CNN [20], что подтверждает работоспособность рассматриваемой сверточной нейронной сети и говорит о возможности обучения на данных, полученных путем математического моделирования.

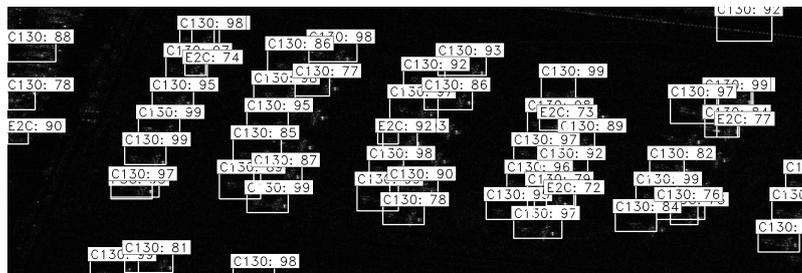


Рисунок 8 – Пример результата работы СНС

2. Для уменьшения количества ложных обнаружений было использовано расширение обучающей выборки путем имитации неоднородной фоновой обстановки. Для этих целей, в процессе аугментации, осуществлялась генерация случайных поверхностей в виде примитивов: линий, прямоугольников, окружностей и овалов с произвольной ориентацией на изображении, и добавление их к обучающим изображениям. Примеры сгенерированных изображений приведены на

рисунке 9. При этом производилось дообучение СНС, полученной на этапе обучения на однородном фоне. Время каждой эпохи дообучения составило порядка 570с. При дообучении также использовался метод обратного распространения ошибки в режиме пакетного градиентного спуска, с размером пакета, уменьшенным в два раза по сравнению с оптимальным, определенным поиском по решетке гиперпараметров при обучении нейронной сети (с 16 изображений в пакете до 8). Скорость обучения оставалась неизменной и соответствовала оптимальной, определенной на этапе обучения СНС. В процессе тестирования на экспериментальных радиолокационных изображениях были получены следующие результаты: вероятность правильного обнаружения - 91.4% (138 объектов); вероятность правильного обнаружения и распознавания - 70.2% (106 объектов); вероятность перепутывания - 21.2% (32 объекта); ложных обнаружений - 51 объект (уменьшение ложных обнаружений на 64 объекта или 55.7%). Анализ полученных результатов позволяет заключить, что для обучения необходимо использовать не РЛИ объектов на однородном фоне, а моделировать РЛИ сцен фоно-целевой обстановки [14].

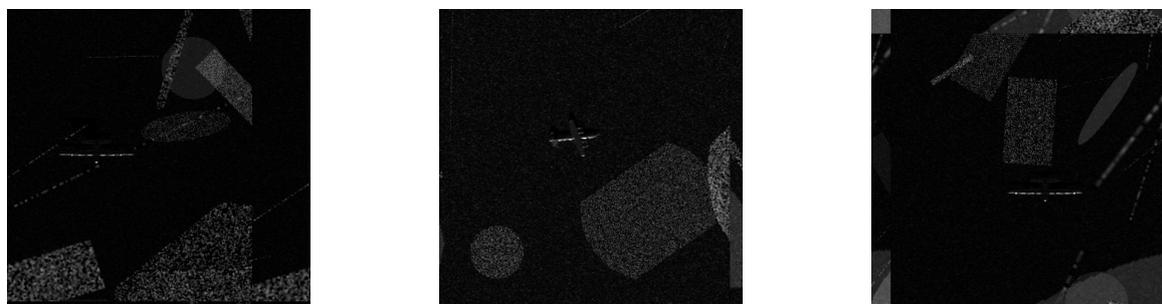


Рисунок 9 – Примеры сгенерированных РЛИ со случайной структурой фона

3. В интересах увеличения вероятности правильного обнаружения и распознавания часть экспериментального РЛИ была размечена и использовалась в обучении. Были выделены: 20 объектов типа С-130, 13 объектов типа РЗС и 4 объекта типа Е2С. Таким образом тестовая выборка была уменьшена до 114 объектов. При дообучении на экспериментальных данных использовался метод обратного распространения ошибки в стохастическом режиме, то есть внесение поправок в весовые коэффициенты после вычисления выхода сети на одном образце. Скорость обучения оставалась неизменной. Путем аугментации количество данных

для обучения в одной эпохе было увеличено до 2000 образцов. В ходе тестирования на экспериментальных данных были получены следующие результаты: вероятность правильного обнаружения - 95.6% (109 объектов из 114); вероятность правильного распознавания - 95.6% (109 объектов); вероятность перепутывания - 0.0% (0 объектов); вероятность ложных обнаружений - 29 объектов. Анализ полученных результатов показывает резкое снижение количества перепутываний, что может говорить о неполном воспроизведении математическим моделированием особенностей объектов на радиолокационных изображениях. Соответственно, необходима валидация результатов математического моделирования, а исходная геометрическая модель должна соответствовать реальным объектам в той мере, чтобы было возможным воспроизведение их особенностей на РЛИ. В работах [7, 22, 23] предложены подходы к проведению валидации модельных РЛИ, в том числе с учетом различных искажающих и дестабилизирующих факторов. В виду малого объема исходных экспериментальных данных, которые в процессе обучения аугментировались, также возможно говорить и об эффекте переобучения. Таким образом, целесообразно предложить на начальном этапе, при отсутствии экспериментальных данных, проводить обучение СНС на данных, формируемых путем математического моделирования с последующим дообучением СНС на экспериментальных данных, по мере их накопления в процессе эксплуатации.

4. В интересах сопоставления результатов нейросетевого алгоритма и алгоритма корреляционного поиска и идентификации объектов [3, 24] была проведена оценка работы алгоритма корреляционного поиска. Эталоны для объектов С130, РЗС и Е2С были сформированы путем математического моделирования, а также путем формирования из экспериментальных РЛИ. В качестве тестовых изображений использовались РЛИ, фрагменты которых представлены на рисунках 5-7. Результаты тестирования сведены в таблицу 2. На рисунках 10 и 11 приведены примеры результатов работы алгоритма при использовании модельного эталона и реального эталона соответственно. Анализ результатов показывает пригодность математического моделирования для формирования эталонных изображений объектов для решения задачи идентификации объектов на РЛИ путем

корреляционного поиска. Стоит отметить, что как эталоны, полученные путем моделирования, так и эталоны, сформированные из экспериментальных данных, при корреляционном методе поиска и идентификации объекта, дают высокий уровень ложных обнаружений.

Таблица 2

Результаты работы алгоритма корреляционного поиска

Эталон		обнаружено		
		всего, шт.	правильно, шт. (%)	ложно, шт.
модельный	типа С130	92	88 (81.5%)	4
	типа РЗС	73	29 (96.7%)	44
	типа Е2С	128	9 (69.2%)	117
экспериментальный	типа С130	125	98 (90.7%)	27
	типа РЗС	40	27 (90.0%)	13
	типа Е2С	122	10 (76.9%)	112

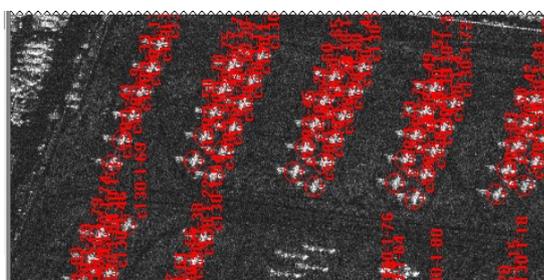


Рисунок 10 – Результат корреляционного поиска и идентификации объектов на основе модельного эталона

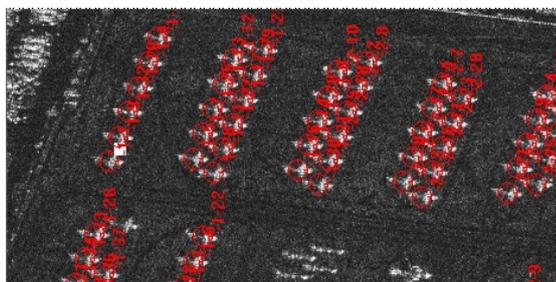


Рисунок 11– Результат корреляционного поиска и идентификации объектов на основе реального эталона

Заключение

Полученные результаты позволяют сделать следующие выводы:

1. Применение свёрточных нейронных сетей позволяет решать задачу совместного обнаружения и распознавания объектов на радиолокационных изображениях. Такое решение реализуется в масштабе реального времени. При этом основные аппаратные и временные затраты требуются на этапе обучения СНС.
2. Сопоставимость результатов правильного обнаружения и распознавания нейронной сети, обученной на модельных РЛИ, с результатами Faster R-CNN и VGG-16 позволяет говорить о пригодности для обучения радиолокационных портретов объектов, сформированных путём математического моделирования.
3. Характеристики обученной нейронной сети сильно зависят от гиперпараметров, используемых при обучении. Целесообразно исследование и применение различных оптимизационных решений (поиск по решетке, случайный поиск, Байесовская оптимизация, оптимизация на основе градиентов, эволюционная оптимизация и т.д.). Обусловленные зависимостью от гиперпараметров высокие временные затраты на обучение могут быть уменьшены за счет аппаратных решений.
4. Рассматриваемое в работе решение характеризуется высокими показателями перепутывания объектов, что предъявляет требования к точности моделирования радиолокационных изображений объектов.
5. Обучение СНС на объектах, наблюдаемых на однородном фоне, приводит к высокому уровню ложных тревог, что обуславливает необходимость моделировать не только объекты, но и фоно-целевую обстановку в целом.
6. Упорядоченные группы объектов обнаруживаются и распознаются хуже, чем одиночные объекты, следовательно, обучающая выборка должна включать как одиночные объекты, так и группы этих объектов в различных конфигурациях.
7. Целесообразно предложить на начальном этапе, при отсутствии экспериментальных данных, проводить обучение на данных, полученных путем

математического моделирования. В процессе эксплуатации и накопления экспериментальных данных проводить на них дообучение СНС.

8. Рассматриваемая в работе архитектура СНС является одной из самых простых со всеми присущими ей недостатками, такими как ограничение на количество слоев, пакетная нормализация и т. д. В связи с этим необходимо исследовать возможности применения решений, реализованных в InceptionNet, ResNets, NFNets.

9. Дальнейшим развитием Faster R-CNN является Mask R-CNN, где решается задача по сегментации возможного региона местоположения объекта путем введения еще одной ветви СНС, что позволяет использовать форму объекта как дополнительный признак классификации, тем самым повышая точность идентификации. Целесообразно проведение исследований по включению в архитектуру СНС обнаружения и распознавания объектов на РЛИ ветвей по сегментации объекта и тени от объекта. Стоит отметить, что тень от объекта на РЛИ может быть более информативной, чем само изображение объекта.

Список источников

1. Школьный Л.А., Толстов Е.Ф., Детков А.Н., Карпов О.А. Радиолокационные системы воздушной разведки, дешифрирование радиолокационных изображений. – М.: ВВИА им. проф. Н.Е. Жуковского, 2008. – 531 с.
2. Кондратенков Г.С., Потехин В.А., Реутов А.П., Феоктистов Ю.А. Радиолокационные станции обзора Земли. – М.: Радио и связь, 1983. - 272 с.
3. Школьный Л.А., Тонких А.Н., Ясько С.И. Алгоритм автоматического обнаружения и распознавания некомпактных групповых объектов по радиолокационным данным // Радиотехника. 2008. № 6. С. 32-37.
4. Власов С.О. и др. Решение задачи обнаружения объекта с помощью нейросетевых технологий // Препринты ИПМ им. М.В. Келдыша. 2023. № 16. 27 с.
5. Дзюба В.А. Исследование алгоритмов и методов обнаружения и распознавания на основе нейросетевых систем // Современные научные исследования и инновации. 2021. № 12. URL: <https://web.snauka.ru/issues/2021/12/97280>

6. Ярцев И.М., Прохоров А.Г., Дмитриев И.Н. Технология создания системы нейросетевого автоматического распознавания одиночных наземных и надводных объектов вооружений, военной и специальной техники на основе системы исходных данных, полученных методом математического моделирования. – М.: Юнити-Дана, 2023. С. 299-315.
7. Савченко Б.С., Соболев А.В. Технология обнаружения и классификации объектов искусственного происхождения на высокодетальных снимках, полученных космическими радиолокаторами с синтезированной апертурой антенны // Материалы XXXIII Всероссийского симпозиума «Радиолокационное исследование природных сред» (Санкт-Петербург, 19–20 апреля 2023): сборник трудов. – Санкт-Петербург: Военно-космическая академия имени А.Ф. Можайского, 2024. С. 146-151.
8. 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 // Труды Международной конференции по компьютерной графике и зрению "Графикон". 2023. № 33. С. 572-580. DOI: [10.20948/graphicon-2023-572-580](https://doi.org/10.20948/graphicon-2023-572-580)
9. Moving and Stationary Target Acquisition Recognition (MSTAR). Program Review. Denver. CO. Nov., 1996.
10. Novak L.M., Owirka G.J., Brower W.S., Weaver A.I. The Automatic Target-Recognition System in SAIP // Lincoln Laboratory Journal. 1997. Vol. 10, No. 2. P. 187-201.
11. Novak L.M., Owirka G.J., Brower W.S. An Efficient Multi-Target SAR ATR Algorithm // Asilomar Conference. Pacific Grove. CA. November 1998.
12. Owirka G.J., Verbout S.M., Novak L.M. Template-based SAR ATR performance using different image enhancement techniques. In Algorithms for Synthetic Aperture Radar Imagery VI // Proc. of SPIE. 1999. Vol. 3721, P. 302-319.
13. Гаврилов К.Ю., Каменский К.В., Малютин О.А. Моделирование траекторного сигнала в радаре с синтезированием апертуры на основе оптических изображений земной поверхности // Труды МАИ. 2021. № 118. URL:

<https://trudymai.ru/published.php?ID=158252>. DOI: [10.34759/trd-2021-118-12](https://doi.org/10.34759/trd-2021-118-12)

14. Кузнецова В.А., Тонких А.Н. Программный комплекс моделирования радиолокационных данных // VII Международная научно-практическая конференция «Актуальные проблемы и перспективы развития радиотехнических и инфокоммуникационных систем» «Радиоинфоком-2023» (Москва, 20-24 ноября 2023): сборник трудов. – М.: МИРЭА, 2023. С. 43-46.

15. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. In: Bengio Y., LeCun Y. (eds.) // Proceedings of the 3rd International Conference on Learning Representations (ICLR-2015). San Diego, CA, USA; 2015. DOI: <https://doi.org/10.48550/arxiv.1409.1556>

16. Akshay Kapoor, Rishi Shah, Rushi Bhuvra, Tejas Pandit. Understanding inception network architecture for image classification. University of Waterloo, February 2020. DOI: [10.13140/RG.2.2.16212.35204](https://doi.org/10.13140/RG.2.2.16212.35204)

17. He K., Zhang OX., Ren S., Sun J. Deep Residual Learning for Image Recognition. Computer Vision and Pattern Recognition, Dec 2015. DOI: [10.48550/arXiv.1512.03385](https://doi.org/10.48550/arXiv.1512.03385)

18. Brock A., De S., Smith S., Simonyan K. High-Performance Large-Scale Image Recognition Without Normalization. Feb 2021. DOI: [10.48550/arXiv.2102.06171](https://doi.org/10.48550/arXiv.2102.06171)

19. Joseph Redmon, Ali Farhadi. YOLO9000: Better, Faster. University of Washington, Institute for AI/ 2016. DOI: [10.48550/arXiv.1612.08242](https://doi.org/10.48550/arXiv.1612.08242)

20. Girshick R. Fast R-CNN. Computer Vision and Pattern Recognition, Sep 2015. DOI: [10.48550/arXiv.1504.08083](https://doi.org/10.48550/arXiv.1504.08083)

21. Бабокин М.И., Ефимов А.В., Зайцев С.Э., Карпов О.А. и др. Космический аппарат "Кондор-Э" с РСА и его возможности // Исследование Земли из космоса. 2017. № 3. С. 85-95. DOI: [10.7868/S0205961417030010](https://doi.org/10.7868/S0205961417030010)

22. Гусев С.Н., Сахно И.В., Хуббиев Р.В. Методика оценивания качества формирования виртуальных объектов на радиолокационных изображениях // Труды МАИ. 2019. № 104. URL: <https://trudymai.ru/published.php?ID=102169>

23. Каменский К.В. Влияние траекторных неустойчивостей и характеристик бортовой навигационной системы на качество радиолокационного изображения при синтезировании апертуры // Труды МАИ. 2022. № 125. URL:

<https://trudymai.ru/published.php?ID=168186>. DOI: [10.34759/trd-2022-125-14](https://doi.org/10.34759/trd-2022-125-14)

24. Сенцов А.А., Ненашев В.А., Иванов С.А., Турнецкая Е.Л. Совмещение сформированных радиолокационных изображений с цифровой картой местности в бортовых системах оперативного мониторинга земной поверхности // Труды МАИ. 2021. № 117. URL: <https://trudymai.ru/published.php?ID=156227>. DOI: [10.34759/trd-2021-117-08](https://doi.org/10.34759/trd-2021-117-08)

References

1. Shkol'nyi L.A., Tolstov E.F., Detkov A.N., Karpov O.A. *Radiolokatsionnye sistemy vozdushnoi razvedki, deshifrirovaniye radiolokatsionnykh izobrazhenii* (Radar systems of air reconnaissance, interpretation of radar images). Moscow: VVIA im. prof. N.E. Zhukovskogo Publ., 2008. 531 p.
2. Kondratenkov G.S., Potekhin V.A., Reutov A.P., Feoktistov Yu.A. *Radiolokatsionnye stantsii obzora Zemli* (Earth observation radar stations). Moscow: Radio i svyaz' Publ., 1983. 272 p.
3. Shkolny L.A., Tonkikh A.N., Yasko S.I. Algorithm of automatic detection and recognition of noncompact group objects by radar data. *Radiotekhnika*. 2008. No. 6. P. 32. (in Russ.)
4. Vlasov S.O. et al. Solving the problem of object detection using neural network technologies. *Preprinty IPM im. M.V. Keldysha*. 2023. No. 16. 27 p. (In Russ.)
5. Dzyuba V.A. Investigation of the algorithms and methods of detection and recognition on the basis of the neural network systems. *Sovremennyye nauchnyye issledovaniya i innovatsii*. 2021. No. 12. (In Russ.). URL: <https://web.snauka.ru/issues/2021/12/97280>
6. Yartsev I.M., Prokhorov A.G., Dmitriev I.N. *Tekhnologiya sozdaniya sistemy neirosetevogo avtomaticheskogo raspoznavaniya odinochnykh nazemnykh i nadvodnykh ob'ektov vooruzhenii, voennoi i spetsial'noi tekhniki na osnove sistemy iskhodnykh dannykh, poluchennykh metodom matematicheskogo modelirovaniya* (Technology of creating a system of neural network automatic recognition of single ground and surface

objects of armaments, military and special equipment on the basis of the system of initial data obtained by mathematical modeling). Moscow: Yuniti-Dana Publ., 2023. P. 299-315.

7. Savchenko B.S., Sobolev A.V. Technology of detection and classification of objects of artificial origin on highly detailed images acquired by space radars with synthetic antenna aperture. *Materialy XXXIII Vserossiiskogo simpoziuma «Radiolokatsionnoe issledovanie prirodnykh sred» (Sankt-Peterburg, 19–20 aprelya 2023): sbornik trudov.* Saint-Petersburg: Voenno-kosmicheskaya akademiya imeni A.F. Mozhaiskogo Publ., 2024. P. 146-151.

8. Nenashev V.A. Nenashev S.A. Classification and recognition of ground objects in the stream of radar frames on the basis of the neural network approach in the front viewing area of the airborne radars of the multi-position system. *Trudy Mezhdunarodnoi konferentsii po komp'yuternoi grafike i zreniyu "Grafikon".* 2023. No. 33. P. 572-580. (In Russ.). DOI: [10.20948/graphicon-2023-572-580](https://doi.org/10.20948/graphicon-2023-572-580)

9. *Moving and Stationary Target Acquisition Recognition (MSTAR).* Program Review. Denver. CO. Nov., 1996.

10. Novak L.M., Owirka G.J., Brower W.S., Weaver A.I. The Automatic Target-Recognition System in SAIP. *Lincoln Laboratory Journal.* 1997. Vol. 10, No. 2. P. 187-201.

11. Novak L.M., Owirka G.J., Brower W.S. An Efficient Multi-Target SAR ATR Algorithm. *Asilomar Conference.* Pacific Grove. CA. November 1998.

12. Owirka G.J., Verbout S.M., Novak L.M. Template-based SAR ATR performance using different image enhancement techniques. In Algorithms for Synthetic Aperture Radar Imagery VI. *Proc. of SPIE.* 1999. Vol. 3721, P. 302-319.

13. Gavrilov K.YU., Kamenskii K.V., Malyutina O.A. Trajectory signal modelling in the aperture synthesis radar based on optical images of the Earth surface. *Trudy MAI.* 2021. No. 118. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=158252>. DOI: [10.34759/trd-2021-118-12](https://doi.org/10.34759/trd-2021-118-12)

14. Kuznetsova V.A., Tonkikh A.N. Software complex of radar data modeling. Collection of scientific articles. *VII Mezhdunarodnaya nauchno-prakticheskaya konferentsiya «Aktual'nye problemy i perspektivy razvitiya radiotekhnicheskikh i*

infokommunikatsionnykh sistem» «Radioinfokom-2023»: sbornik trudov. Moscow: MIREA Publ., 2023. P. 43-46.

15. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. In: Bengio Y., LeCun Y. (eds.) // Proceedings of the 3rd International Conference on Learning Representations (ICLR-2015). San Diego, CA, USA; 2015. DOI: <https://doi.org/10.48550/arxiv.1409.1556>

16. Akshay Kapoor, Rishi Shah, Rushi Bhuvra, Tejas Pandit. Understanding inception network architecture for image classification. University of Waterloo, February 2020. DOI: [10.13140/RG.2.2.16212.35204](https://doi.org/10.13140/RG.2.2.16212.35204)

17. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. Computer Vision and Pattern Recognition, Dec 2015. DOI: [10.48550/arXiv.1512.03385](https://doi.org/10.48550/arXiv.1512.03385)

18. Brock A., De S., Smith S., Simonyan K. High-Performance Large-Scale Image Recognition Without Normalization. Feb 2021. DOI: [10.48550/arXiv.2102.06171](https://doi.org/10.48550/arXiv.2102.06171)

19. Joseph Redmon, Ali Farhadi. YOLO9000: Better, Faster. University of Washington, Institute for AI/ 2016. DOI: [10.48550/arXiv.1612.08242](https://doi.org/10.48550/arXiv.1612.08242)

20. Girshick R. Fast R-CNN. Computer Vision and Pattern Recognition, Sep 2015. DOI: [10.48550/arXiv.1504.08083](https://doi.org/10.48550/arXiv.1504.08083)

21. Babokin M.I., Efimov A.V., Zaitsev S.E., Karpov O.A. et al. Kondor-E spacecraft with RSA and its capabilities. *Issledovanie Zemli iz kosmosa*. 2017. No. 3. P. 85-95. (In Russ.). DOI: [10.7868/S0205961417030010](https://doi.org/10.7868/S0205961417030010)

22. Gusev S.N., Sakhno I.V., Khubbiev R.V. Evaluation technique for virtual objects on radar images formation quality. *Trudy MAI*. 2019. No. 104. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=102169>

23. Kamenskii K.V. Trajectory instabilities and onboard navigation system characteristics influence on synthetic aperture radar image quality. *Trudy MAI*. 2022. No. 125. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=168186>. DOI: [10.34759/trd-2022-125-14](https://doi.org/10.34759/trd-2022-125-14)

24. Sentsov A.A., Nenashev V.A., Ivanov S.A., Turnetskaya E.L. Combining the generated radar images with a digital map of the area in on-board systems for operational

monitoring of the earth's surface. *Trudy MAI*. 2021. No. 117. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=156227>. DOI: [10.34759/trd-2021-117-08](https://doi.org/10.34759/trd-2021-117-08)

Статья поступила в редакцию 04.12.2024

Одобрена после рецензирования 13.01.2025

Принята к публикации 25.04.2025

The article was submitted on 04.12.2024; approved after reviewing on 13.01.2025; accepted for publication on 25.04.2025