

DOI: <https://doi.org/10.30898/1684-1719.2022.4.2>

УДК: 621.396.969.3:004.032.26

МОНИТОРИНГ ОБЪЕКТОВ МОРСКОГО СУДОХОДСТВА ПО АЭРОКОСМИЧЕСКИМ ДАННЫМ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ В СВЧ ДИАПАЗОНЕ С ПРИМЕНЕНИЕМ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

М.Л. Белокопытов, Д.А. Шленских, С.В. Морозов, С.В. Сирота

Военно-космическая академия имени А.Ф. Можайского
197198, Санкт-Петербург, ул. Ждановская, 13

Статья поступила в редакцию 22 апреля 2022 г.

Аннотация. Статья посвящена вопросам автоматизированного поиска объектов морского судоходства на радиолокационных изображениях. Проведен сравнительный анализ семейства нейросетей *Yolov5*. Для детектирования объектов использован одноэтапный автоматический обнаружитель, построенный на базе сверточной нейронной сети типа *Yolov5x* и обученный на наборе данных *SAR Ship Dataset*. Произведено цифровое моделирование предложенной системы распознавания. Проведена верификация обученной модели, а также оценка качества работы алгоритма сверточной нейронной сети. Рассмотрены основные трудности, возникающие при подготовке обучающей выборки. Предложены пути их решения. Сделаны выводы относительно возможности применения разработанного обнаружителя с целью автоматизации процесса распознавания морских объектов.

Ключевые слова: объекты морского судоходства, распознавание, нейронная сеть, радиолокационное изображение.

Автор для переписки: Белокопытов Марк Львович, hommer1990@mail.ru

Введение

Проблема обнаружения, оценки параметров и классификации пространственно-распределенных объектов была и остается определяющей при разработке и создании современных воздушных и космических средств дистанционного зондирования космической, воздушной и наземной обстановки перспективными радиолокационными системами (РЛС). Применяемые в настоящее время сверхширокополосные сигналы и эффект синтезирования апертуры за счет движения Земли, перемещения космических и воздушных летательных аппаратов позволяют получить радиолокационное изображение (РЛИ) пространственно-распределенных объектов, характеризующееся достаточно высокой разрешающей способностью, при которой наблюдатель имеет возможность решать все вышеперечисленные задачи [1].

Пространственно-распределенный объект представляет собой совокупность локальных центров рассеивания (ЛЦР), описывающих ее наиболее информативные и устойчивые признаки в сверхвысокочастотном (СВЧ) диапазоне и большого числа статистически однородных отражателей, равномерно распределенных по поверхности цели. Количество, положение и эффективная площадь рассеивания (ЭПР) ЛЦР остаются практически постоянными при изменении ракурса объекта на несколько градусов.

Так, на рис. 1 представлен пример РЛИ надводного корабля, расположенного в открытом море. Съемка проводилась при различных условиях наблюдения. РЛИ, соответствующие пунктам а) и б) рис.1, сделаны съемочной аппаратурой космического аппарата *Gaofen-3* в С-диапазоне длин волн с разрешающей способностью радиолокатора с синтезированной апертурой (РСА) равной 1 м.




Рис. 1. РЛИ корабля с характерными ЛЦР

1. Исходные данные и постановка задачи

В настоящее время РСА ежедневно производят огромные объемы данных. При этом радиолокационное распознавание морских объектов, когда РСА функционирует в обзорном режиме и бóльшая часть РЛИ соответствует участкам открытого моря, является едва ли не самой сложной задачей современной радиолокации [2]. Долгое время эта задача не могла быть решена автоматически. Обученный оператор на основе визуального анализа на устройствах отображения информации отраженных от цели сигналов определял класс обнаруженного объекта без учета его ракурса и степени освещенности.

Для решения данной проблемы применяются различные методы и средства автоматизации процессов обнаружения и классификации объектов на получаемых с помощью РСА РЛИ. Одним из таких методов является использование автоматизированных обнаружителей, которые позволяют значительно снизить нагрузку на аналитиков радиолокационных данных (дешифровщиков) при наблюдении протяженных участков морской поверхности, направляя их внимание только на те области изображений, которые трудно поддаются автоматической интерпретации.

В основу построения современных автоматических обнаружителей и классификаторов входит использование концепции глубокого обучения, которая хорошо зарекомендовала себя при решении множества прикладных задач

технического зрения [3]. Глубокое обучение представляет собой подмножество методов машинного обучения, главным образом основанных на применении сверточных нейронных сетей (СНС). Преимущество таких сетей состоит в способности автоматического извлечения ими информативных признаков объектов, что выгодно отличает этот подход от традиционных методов, где признаки приходится проектировать вручную. Однако основной трудностью становится подготовка большого набора размеченных данных для обучения СНС.

2. Выбор типа автоматического обнаружителя

Как уже отмечалось ранее, в настоящее время наблюдается повышенный интерес к нейросетевым методам обнаружения и построенным на их базе СНС. В отличие от классических методов обработки информации, базирующихся на изучении и априорном задании более или менее сложной модели процесса или системы, СНС сами формируют модель явления в процессе обучения, т.е. практически не требуют априорных данных о модели.

СНС отличаются своей заранее заданной универсальной структурой с большим числом неизвестных параметров, уточняемых в процессе адаптации. После обучения они могут достигать потенциальных пределов качества функционирования при решении задач обнаружения, оценки параметров сигналов или распознавания объектов. Таким образом, применение СНС можно рассматривать как один из наиболее перспективных путей для повышения эффективности и сокращения сложности системы распознавания.

Исходя из того, что объемы типовых РЛИ достаточно велики, а первоочередной задачей является их быстрая обработка, в настоящей работе предлагается использовать одноэтапную архитектуру обнаружителя. Проведенный сравнительный анализ доступных СНС показывает, что наиболее подходящими для целей обнаружения, селекции и классификации объектов заданных типов являются *SSD*, *Yolov5* и *RFBNet* [4]. Однако семейство моделей

Yolo обладает рядом преимуществ, таких как быстроедействие и малый размер весов (порогов) обнаружения. В таблице 1 приведены характеристики моделей семейства *Yolov5*.

Таблица 1. Характеристики СНС семейства *Yolov5*

Тип сети	Размер РЛИ, пкс	Средняя точность (mAP^{val})	Скорость распознавания на ЦП, мс	Скорость распознавания на видеокарте <i>NVIDIA TESLA V100</i> , мс	Прочность связей	Количество операций в секунду
<i>Yolov5n</i>	640	46,0	45	6,3	1,9	4,5
<i>Yolov5s</i>	640	56,0	98	6,4	7,2	16,5
<i>Yolov5m</i>	640	63,9	224	8,2	21,2	49,0
<i>Yolov5l</i>	640	67,2	430	10,1	46,5	109,1
<i>Yolov5x</i>	640	68,9	766	12,1	86,7	205,7

В качестве архитектуры обнаружителя, обеспечивающей относительно высокую точность распознавания морских объектов, предлагается использовать модель СНС *Yolov5x*. Она реализована на фреймворке *PyTorch* и встроена в одноименный модуль для скриптового языка программирования *Python*. Отличительной особенностью *Yolo* является подход к решению задачи детектирования, который заключается в сжатии исходного изображения таким образом, чтобы получить квадратную матрицу размером 13 на 13, в каждой клетке которой записана информация о наличии объекта и классе этого объекта на соответствующей части картинки. Такая архитектура обнаружителя предоставляет очень хорошую инфраструктуру как для обучения, так и для тестирования модели.

3. Обучение сверточной нейронной сети

Для обеспечения работы СНС необходимо заранее провести ее обучение. Как правило, обучение проводится в несколько этапов (эпох) на базе исходных данных, которые делятся на обучающую и тестовую выборки. С целью построения качественного классификатора обучение должно проходить на натуральных РЛИ рассматриваемых объектов на фоне подстилающей поверхности. При этом набор данных должен быть достаточно полным и представительным.

В данной работе для обучения СНС авторы использовали обновленный набор данных *SAR Ship Dataset*, появившийся в открытом доступе летом 2021 года. В нем, в отличие от его предшественника, вышедшего весной 2019 года, исправлены некоторые ошибки, такие как неправильное расположение ограничивающих окон разметки и присутствие повторяющихся изображений. Данный набор сформирован из 102 РЛИ, полученных спутником *Gaofen-3*, и 108 РЛИ, полученных спутником *Sentinel-1*. Примеры данных РЛИ представлены на рис. 2.




Рис. 2. Примеры РЛИ

На основе данных РЛИ получено 39729 изображений кораблей разрешением 256 пикселей как по дальности, так и по азимуту (в оригинальном наборе данных 43820 изображений), которые были размечены специалистами компании *SAR* (все объекты отнесены к одной категории – «корабль») [5]. Разметка изображений представляет собой набор «.txt» файлов, каждая строка которого представляет собой корабль. Строки файлов состоят из пяти чисел: «категория объекта», «относительная координата ограничивающей рамки объекта по оси OX », «относительная координата ограничивающей рамки объекта по оси OY », «относительная ширина ограничивающей рамки объекта», «относительная высота ограничивающей рамки объекта» (рис. 3). Изображения в наборе данных *SAR Ship Dataset* имеют различный масштаб и фон, что позволяет использовать его для обучения нейросетевых моделей с целью обнаружения как крупномасштабных, так и малоразмерных объектов в условиях сложной фоноцелевой обстановки.

0 0.481719 0.634028 0.690625 0.713278
 0 0.741094 0.524306 0.314750 0.933389

Рис. 3. Формат разметки изображений из набора данных *SAR Ship Dataset*

Обучение СНС происходило 15 эпох на оборудовании *Nvidia GeForce GTX 1080 8 Gb* и заняло примерно 20 часов (рис. 4). Набор данных *SAR Ship Dataset* был разбит на обучающую и тестовую выборку в соотношении 80% на 20% соответственно.

```
15 epochs completed in 19.26 hours.
Optimizer stripped from runs/train/exp2/weights/last.pt, 173.1MB
Optimizer stripped from runs/train/exp2/weights/best.pt, 173.1MB

Validating runs/train/exp2/weights/best.pt...
Fusing layers...
Model Summary: 444 layers, 86173414 parameters, 0 gradients, 204.0 GFLOPs
  Class      Images      Labels      P          R      mAP@.5  mAP@.5:.95: 100%
    all         7593         9771      0.937      0.95      0.971      0.644
```

Рис. 4. Характеристики обучения СНС на наборе данных *SAR Ship Dataset*

После окончания процесса обучения классификатора авторами была апробирована работа СНС на ряде РЛИ, находящихся в открытом доступе. Анализ исходных РЛИ в наборе данных *SAR Ship Dataset*, которым соответствовал *.txt* файл с метками объектов в формате *Yolo* и обработанных СНС, показывает, что обучение одноэтапного обнаружителя прошло успешно. Так, на всех обработанных снимках присутствуют как ранее размеченные корабли, так и вновь обнаруженные и размеченные объекты. На рис. 5 представлен ряд исходных РЛИ, на рис. 6 – те же РЛИ, но после обработки СНС.





Рис. 5. Пример РЛИ из набора данных *SAR Ship Dataset*

Рис. 6. РЛИ, обработанные СНС *Yolov5x*

Однако в работе обнаружителя выявлен и ряд ошибок. Так, на нескольких РЛИ присутствовали ложные разметки, а на других, напротив, были пропуски разметки. На рис. 7 в верхней части представлены два исходных РЛИ, а в нижней – те же РЛИ, но после обработки СНС.




Рис. 7. РЛИ, характеризующие ошибки в работе обнаружителя

Для оценки качества обученной модели и работы алгоритма введем метрики: *precision*, *recall*, *mAP@0.5* и *F*-метрика [6].

Precision (точность) – мера того, сколько из сделанных положительных прогнозов являются верными. Точность метрики *Precision* рассчитывается в

соответствии с выражением (1). Данная метрика описывается кривой *precision-confidence* (*P_curve*) и для выбранной нейросетевой модели имеет вид, представленный на рис. 8.

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

где *TP* (*True Positive*) – правильное определение класса «корабль», *FP* (*False Positive*) – ошибка 1-го рода, (принятие неправильного объекта за «корабль»).

Recall (полнота) – мера того, сколько положительных случаев правильно спрогнозировал классификатор по всем положительным случаям. Точность метрики *Recall* рассчитывается в соответствии с выражением (2), описывается кривой *recall-confidence* (*R_curve*) и для выбранной нейросетевой модели имеет вид, представленный на рис. 9.

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

где *FN* (*False Negative*) – ошибка 2-го рода (пропуск объекта «корабль»).

mAP@0.5 – средняя оценка точности работы классификатора, рассчитываемая нахождением площади под кривой *precision-recall* (*PR_curve*) (рис. 10).

F-метрика (в общем случае F_β) – метрика, позволяющая объединить *Precision* и *Recall* в агрегированный критерий качества, где β определяет вес точности в метрике. Данная метрика объединяет и в то же время взвешивает два отношения (*Precision* и *Recall*) сбалансированным образом. Она достигает максимума в случае, когда *Precision* и *Recall* равны единице, и близка к нулю, если один из аргументов близок к нулю. *F*-метрика рассчитывается в соответствии с выражением (3), описывается кривой *F1-confidence* (*F1_curve*) и для выбранной модели имеет вид, представленный на рис. 11.

$$F_\beta = (1 + \beta^2) \frac{precision * recall}{(\beta^2 * precision) + recall}. \quad (3)$$




Рис. 8. *P_curve*




Рис. 9. *R_curve*




Рис. 10. *PR_curve*




Рис. 11. *F1_curve*

Значения вышеперечисленных метрик, характеризующих качество обученной нейросетевой модели, сведены в таблицу 2.

Таблица 2. Оценка качества обученной СНС *Yolov5x*

Метрика	<i>Precision</i>	<i>Recall</i>	<i>mAP@0.5</i>	<i>F1</i>
Значение точности	0.937	0.95	0.971	0.94

Таким образом, анализируя ресурсы, затраченные на процесс обучения (рис. 4) и предельные значения метрик, характеризующих качество обучения (табл. 2), можно сделать вывод о том, что нейросетевая модель одноэтапного обнаружителя на базе *Yolov5x* обладает достаточно высокой точностью обнаружения морских объектов при сравнительно малых затратах на время обучения.

В данной работе авторами для обучения СНС использовался уже размеченный набор данных *SAR Ship Dataset*, который имеется в открытом доступе. Однако подготовка подобного рода набора данных требует наличия и привлечения большого количества сил и материально-технических ресурсов при получении экспериментальных радиолокационных данных в требуемых объемах с априорными знаниями характеристик наблюдаемой сцены, что на практике зачастую является затруднительным. Кроме того, не всегда представляется возможным получение экспериментальных радиолокационных данных по всей номенклатуре объектов для всех возможных условий их наблюдения и параметров функционирования радиолокационных датчиков.

В этом случае становится целесообразным использование методов математического моделирования металлических объектов сложной пространственной конфигурации. Для этих целей широко применяются аналитические методы и методы дифракции электромагнитных волн на телах сложной формы совместно с методами вычислительной электродинамики.

Исследования по моделированию РЛИ были проведены в работах [7, 8], но наиболее подробно они изложены в работе [9]. В данной работе разработанная авторами модельно-ориентированная методика позволяет произвести расчет разноракурсных радиолокационных портретов квазистационарных объектов, к которым относятся различные виды наземной, авиационной и морской техники на фоне подстилающей поверхности применительно к заданным параметрам и условиям радиолокационного наблюдения земной поверхности. В перспективе предлагается использовать данные методы с целью дополнения базы данных и увеличения количества распознаваемых СНС типов (классов) объектов.

Кроме того, с целью эффективного обеспечения органов военного управления информацией о наличии на РЛИ того или иного объекта, процессы обнаружения, локализации и классификации должны быть неразрывно связаны с геоинформационной системой (ГИС) [10]. Данная интеграция обеспечит возможность ускорения разработки карт оперативной обстановки, экономии сил

и средств, а также своевременность изменения карты ввиду быстрой смены местоположения подразделений во время учений и боевых действий.

Заключение

Повышение степени автоматизации комплексной обработки радиолокационных данных, особенно на этапах обнаружения и распознавания объектов морской техники, является в настоящее время важной и актуальной задачей для повышения эффективности информационного обеспечения органов военного управления и своевременного принятия ими управленческих решений. Одним из перспективных направлений ее решения является реализация процессов обработки РЛИ с использованием методов и технологий искусственного интеллекта на основе СНС. При этом подготовка набора обучающих данных и выбор архитектуры обнаружителя является одной из главных задач при реализации нейросетевой модели.

В настоящей статье для этих целей авторами был использован набор данных *SAR Ship Dataset* и автоматический обнаружитель на базе СНС *Yolov5x*. Точность архитектуры данной нейросети составляет 97,1%, что является достаточно приемлемым результатом при детектировании любых объектов на радиолокационных изображениях.

Одним из путей дальнейшего исследования может быть увеличение размера исходного набора РЛИ искусственным образом с помощью аугментации данных и тестирование разработанного обнаружителя на реалистичных снимках, полученных в ходе летно-экспериментальных исследований и дистанционного зондирования Земли.

Литература

1. Доросинский Л.Г., Трухин М.П. *Теория и практика обработки сигналов от пространственно-распределенных целей*. Ульяновск, Зебра. 2015. 243 с.

2. Насыров И.А. *Введение в современные спутниковые радионавигационные системы. Часть 1: общие принципы, современное состояние, перспективы развития.* Учебное пособие. Казанский государственный университет. 2005. 43 с.
3. Zhao Z., Zheng P., Xu S., Wu X. Object Detection with Deep Learning: A Review *IEEE Transactions on Neural Networks and Learning Systems*. 2018. P.1-21.
4. Вакуленко С.А., Жихарева А.А. *Практический курс по нейронным сетям.* СПб., Университет ИТМО. 2018. 71 с.
5. Zhang T., Zhang X., Jianwei Li. SAR Ship Detection Dataset (SSDD): Official Release and Comprehensive Data Analysis. *Remote Sensing MDPI*. 2021. V.13. P.3690.
6. Траск Эндрю. *Глубокое обучение.* СПб., Питер. 2019. 352 с.
7. Ананьин Э.В., Андрющенко М.С. Методы исследований радиолокационной сигнатуры при разработке малозаметных образцов военной техники. *Вопросы оборонной техники. Серия 16: технические средства противодействия терроризму.* 2015. №87-88. С.102-108.
8. Тертышник В.В., Зиновьев А.В. Методика расчета радиолокационных портретов аэродинамических объектов. *Радиотехника и связь: материалы Междунар. науч.-техн. конф., посвящ. 15-летию каф. Радиотехники.* Саратов, Саратов. гос. техн. ун-т. 2004. С.11-24.
9. Филиппских Е.Э., Попов А.В., Галкин Ф.А. Модельно-ориентированная методика расчета радиолокационных портретов (сигнатур) металлических объектов. *Труды ВКА им. А.Ф.Можайского: материалы XXXII Всероссийского симпозиума «Радиолокационное исследование природных сред».* СПб., ВКА им. А.Ф. Можайского. 2021. С.87-99.
10. Иванов В.Г., Гаврилин И.В., Насыпов Д.Н. Интегрированная электронная карта как единая информационная система боевой обстановки *САПР и графика.* 2017. №8. С.67-72.

Для цитирования:

Белокопытов М.Л., Шленских Д.А., Морозов С.В., Сирота С.В. Мониторинг объектов морского судоходства по аэрокосмическим данным дистанционного зондирования в СВЧ диапазоне с применением нейросетевых технологий. *Журнал радиоэлектроники* [электронный журнал]. 2022. №4. <https://doi.org/10.30898/1684-1719.2022.4.2>