

УДК 004.932

DOI: 10.18413/2518-1092-2020-5-4-0-3

Чорбаа Н.А.
Ле Ань Ту
Толстой И.М.

**СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ ДЕТЕКТИРОВАНИЯ
ОБЪЕКТОВ НА РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЯХ
ПРИ ПОМОЩИ НЕЙРОННЫХ СЕТЕЙ**

Федеральное государственное автономное образовательное учреждение высшего образования «Санкт-Петербургский национальный исследовательский университет информационных технологий, механики и оптики», Кронверкский пр., д. 49, г. Санкт-Петербург, 197101, Россия

e-mail: nchorbaa@mail.ru, leanhtutcdt@gmail.com, imtolstoi@itmo.ru

Аннотация

Радиолокационные системы являются эффективным средством получения оперативной информации о состоянии и динамике объектов и районов земного шара в различных масштабах независимо от метеорологических условий и времени суток. В настоящее время разработан ряд методов для автоматизированного поиска объектов на радиолокационных изображениях, которые применяются в зависимости от целевой области. Для детектирования объектов на радиолокационных изображениях в большинстве работ используются сверточные нейронные сети, но существует множество алгоритмов для решения задач, отсюда возникает проблема выявления наиболее эффективного алгоритма сверточной нейронной сети с высокой точностью детектирования объектов на основе радиолокационных изображений из рассматриваемых источников. В статье рассматриваются алгоритмы и программные аспекты детектирования объектов на радиолокационных изображениях. Построена сравнительная таблица методов по критериям – точность детектирования и время на обработку, и выявлен наиболее эффективный алгоритм сверточной нейронной сети.

Ключевые слова: детектирование объектов; сверточные нейронные сети; обработка изображений; классификация изображений; радиолокационные изображения.

UDC 004.932

Chorbaa N.A.
Le Anh Tu
Tolstoy I.M.

**COMPARATIVE ANALYSIS OF METHODS FOR DETECTING OBJECTS
ON RADAR IMAGES USING NEURAL NETWORKS**

Saint Petersburg National Research University of Information Technologies, Mechanics and Optics,
49 Kronverkskiy prospekt, St. Petersburg, 197101, Russia

e-mail: nchorbaa@mail.ru, leanhtutcdt@gmail.com, imtolstoi@itmo.ru

Abstract

Radar systems are an effective means of obtaining operational information about the state and dynamics of objects and areas of the globe at different scales regardless of meteorological conditions and time of day. Currently, a number of methods have been developed for automated search for objects on radar images, which are applied depending on the target area. To detect objects on radar images in most works convolutional neural networks are used, but there are many algorithms to solve the problems, hence the problem of identifying the most effective convolutional neural network algorithm with high accuracy in detecting objects on the basis of radar images from the sources under consideration. In this article algorithms and software aspects of object detection on radar images are considered. A comparative table of methods by the criteria – detection accuracy and processing time – is constructed, and the most effective algorithm of convolutional neural network is revealed.

Keywords: object detection; convolutional neural networks; image processing; image classification.

ВВЕДЕНИЕ

На сегодняшний день разработан ряд методов [14, 5, 2] для автоматизированного поиска объектов на изображениях, которые применяются в зависимости от целевой области: наблюдение, распознавание и классификация различных объектов (морские суда, самолеты, наземные и подземные сооружения), мониторинг и охрана окружающей среды (анализ природных катаклизмов, оценка морских, лесных, сельскохозяйственных, арктических и других зон с целью выявления различных аномалий и объектов, не характерных для данных зон, например, незаконное проникновение и нахождение в данной местности).

Обнаружение объектов на изображениях – одна из важных и сложных проблем компьютерного зрения, которой в последние годы уделяется большое внимание. Непрерывное расширение сферы применения систем компьютерного зрения требует разработки новых методов и алгоритмов обработки изображений как для детектирования разнообразных сложных объектов, так и для повышения точности обнаружения. Поэтому высокой актуальностью, в частности для охраны окружающей среды, обладает проблема обнаружения объектов с высокой точностью на радиолокационных изображениях. Радиолокационная аппаратура имеет широкое применение во многих сферах жизни, следовательно, повышение эффективности ее работы позволит значительно увеличить как точность мониторинга, так и степень защиты окружающей среды, и безопасность жизни людей.

В статье рассматриваются алгоритмы и программные аспекты детектирования объектов на радиолокационных изображениях. В качестве объектов выступают морские суда, потому что данные судов можно найти в открытом доступе и их можно использовать для обучения нейронных сетей. Проанализированный ряд методов выделяет наиболее оптимальный алгоритм для работы с большими массивами получаемых данных (радиолокационных изображений) по скорости, точности и эффективности выявления объектов на изображениях.

Получаемая радиолокационная информация в цифровом виде представляет собой комплексные радиолокационные изображения, в которых каждый пиксель характеризуется комплексным числом – амплитудой и фазой, численное значение которых определяет параметры сигнала, принятого от соответствующего элемента на земной поверхности [4].

Радиолокационная съемка имеет несколько преимуществ и особенностей по сравнению с другими – оптической и инфракрасной:

- независимость от метеорологических условий и освещенности;
- повышенная точность измерения геометрических характеристик;
- возможность наблюдения и обнаружения объектов, невидимых в оптическом и ИК-диапазонах электромагнитного спектра.



Рис. 1. Оптическое и радиолокационное изображения
Fig. 1. Optical and SAR image

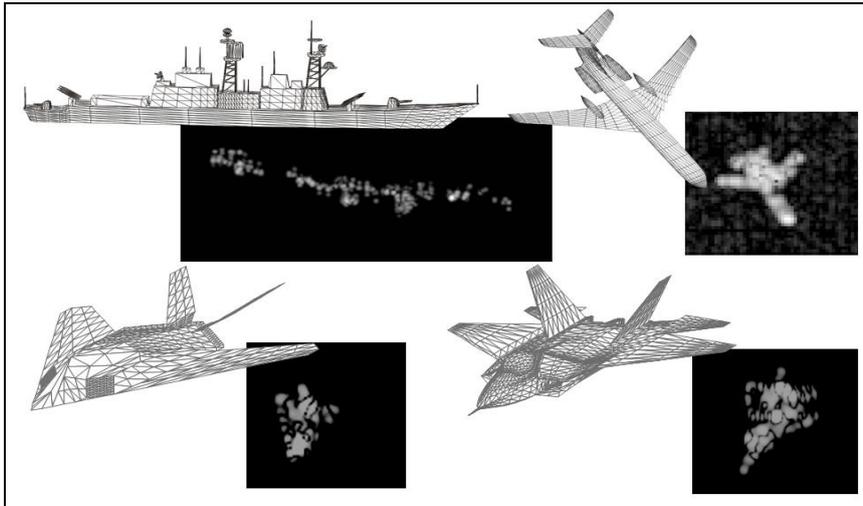


Рис. 2. Детектирование объектов на радиолокационных изображениях
Fig. 2. Object detection in SAR images

В ряде современных работ [3] описаны и сравнены свойства и характеристики радиолокационных и оптических изображений. Показано, что радиолокационные изображения обладают рядом преимуществ для детектирования объектов по сравнению с оптическими изображениями. Радиолокационные изображения более информативны и позволяют передать больше деталей или увидеть невидимые в других диапазонах объекты. Все вышесказанное дает возможность понять, что с помощью радиолокационных изображений можно детектировать объекты с большей точностью.

В настоящее время для детектирования объектов на радиолокационных изображениях в большинстве работ используются сверточные нейронные сети. Данные нейронные сети являются системами обработки информации, направленными на распознавание образов.

Применение алгоритмов компьютерного зрения в решении задач мониторинга земной и морской поверхности позволяет оперативно обнаружить и классифицировать объект, обеспечивая наблюдения за состоянием окружающей среды. Системы аэрокосмического мониторинга позволяют решать задачи картографии, разведки, прогнозирования глобальных природных процессов, в том числе опасных, управления транспортными потоками, поиска полезных ископаемых, научных исследований.

Целью данной работы является выявление оптимального по точности распознавания и скорости обработки алгоритма сверточной нейронной сети для детектирования объектов на основе радиолокационных изображений из рассматриваемых источников.

ОСНОВНАЯ ЧАСТЬ

В работе [14] авторами для детектирования кораблей использованы сверточные нейронные сети с архитектурой *You Only Look Once version 2* (YOLOv2) [11]. В статье применяется усовершенствованный метод глубокого обучения на основе графического процессора для обнаружения корабля по изображениям синтезированной апертурой.

Архитектура YOLOv2 состоит из 30 слоев, из которых первые 25 предназначены для формирования карт признаков исходного изображения. Комбинации из двух *route* и одного *reorg* слоев выполняют задачу объединения выходных данных предыдущих слоев и их реструктуризации. Завершают модель два сверточных слоя. Результатом работы сети является трехмерная матрица размером $13 \times 13 \times 30$. Размерность ее первых двух измерений соответствует размеру сетки, делящей изображение на 169 ячеек. Каждой ячейке соответствует вектор из 30 чисел, который преобразуется в двумерную матрицу размерностью 5×6 .

Каждая строка матрицы содержит информацию о прямоугольнике, представленную в виде 6 чисел. Первые 4 числа – это геометрические параметры прямоугольника: x , y – координаты центра, а также ширина и высота, остальные 2 параметра соответствуют вероятности нахождения объекта в данном прямоугольнике, и классу объекта. Геометрический центр прямоугольника соответствует геометрическому центру рассматриваемой ячейки изображения.

В некоторых случаях, в одной ячейке сетки могут находиться несколько объектов, для более точного распознавания используется концепция «якорная коробка». Якорная коробка позволяет алгоритму YOLOv2 добавлять еще одно измерение к меткам, находящимся в одной ячейке сетки.

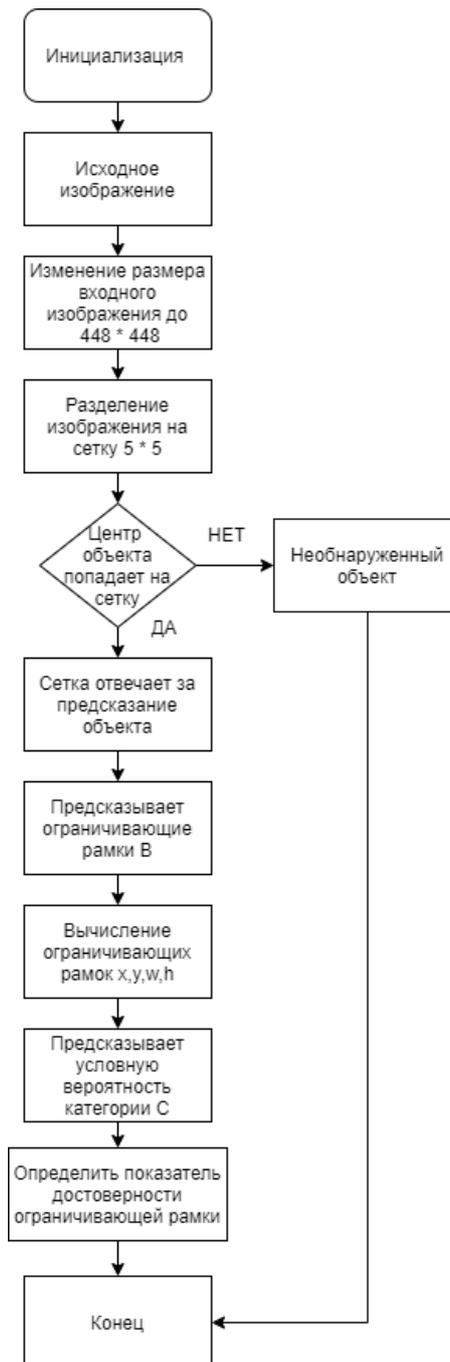


Рис. 3. Блок-схема алгоритма YOLOv2
Fig. 3. Block diagram of the YOLOv2 algorithm

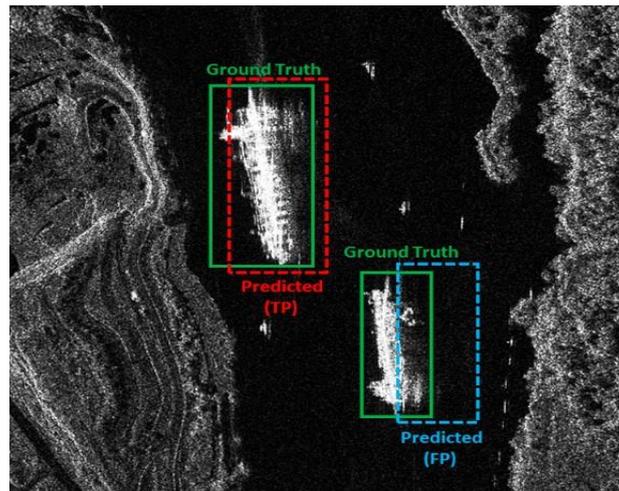


Рис. 4. Пример обнаружения кораблей

(TP – истинно-положительное решение; FP – ложноположительное решение)

Fig. 4. Example of ship detection (TP – true positive decision; FP – false positive decision)

На рисунке 2, пунктирные линии красного и синего цвета означают ограничительные рамки распознавания кораблей, а сплошными линиями зеленого цвета выделены распознанные суда.

Для обучения и оценки точности детектирования кораблей на радиолокационных изображениях авторы использовали две базы данных: база данных обнаружения судов (SSDD) и разнообразный набор данных по поиску и обнаружению судов (DSSDD) [14]. Первая база состоит из 1160 изображений, на которых в общей сложности содержится 2456 кораблей. Вторая база данных собрана из нескольких источников: RadarSat-2 [10], TerraSAR-X [16] и Sentinel-1. В результате авторами получено 50 изображений высокого разрешения, которые впоследствии разделены на меньшие изображения. Таким образом, общий размер второй базы данных составил 1174 РЛИ. Авторы исследования проводили эксперимент сравнивая сети Faster-R-CNN и YOLOv2 (Таблица 1).

Таблица 1

Точность определения судов и сравнение скорости

Table 1

Accuracy of ship detection and speed comparison

Методы	Точность детектирования, %	Время на обработку, мс
Faster-R-CNN	70,1%	198
YOLOv2	90,05%	25

В результате экспериментов авторами исследования получены следующие данные: 70,1 % точности для Faster-R-CNN и 90,05 % точности для YOLOv2.

Из экспериментальных результатов можно сделать вывод, что архитектура YOLOv2 требовала меньше вычислительного времени, чем Faster-R-CNN и обладает высокой точностью обнаружения.

Рассмотрим еще один пример успешного применения сверточной нейронной сети. В статье [5] авторы анализируют преимущества сети Faster-R-CNN [9] в области компьютерного зрения и ее модификации. Сеть Faster-R-CNN в отличие от предыдущей версии сети Fast-RCNN [6] использует вместо блока, реализующего алгоритм selective search [13], сверточную нейронную сеть для выявления регионов-кандидатов, содержащих искомые объекты.

В данной работе авторы считают, что сеть Faster-R-CNN несмотря на то, что получает высокую точность на нескольких наборах данных, не дает идеальных результатов по обнаружению кораблей. Данный факт обусловлено тем, что Faster-R-CNN имеет проблемы с

детектированием маленьких объектов на больших изображениях. Причина заключается в том, что слои ROI-оповещения строят объекты только из последних карт, вследствие, детектору сложно предсказать класс объекта и местоположение ограничивающего ящика. Основываясь на преимуществах Faster-R-CNN, авторы предлагают усовершенствованный метод архитектуры. Предложенный метод объединяет функции различных уровней для улучшения возможности обнаружения кораблей на радиолокационных изображениях: *feature fusion*, *transfer learning*, *hard negative mining*.

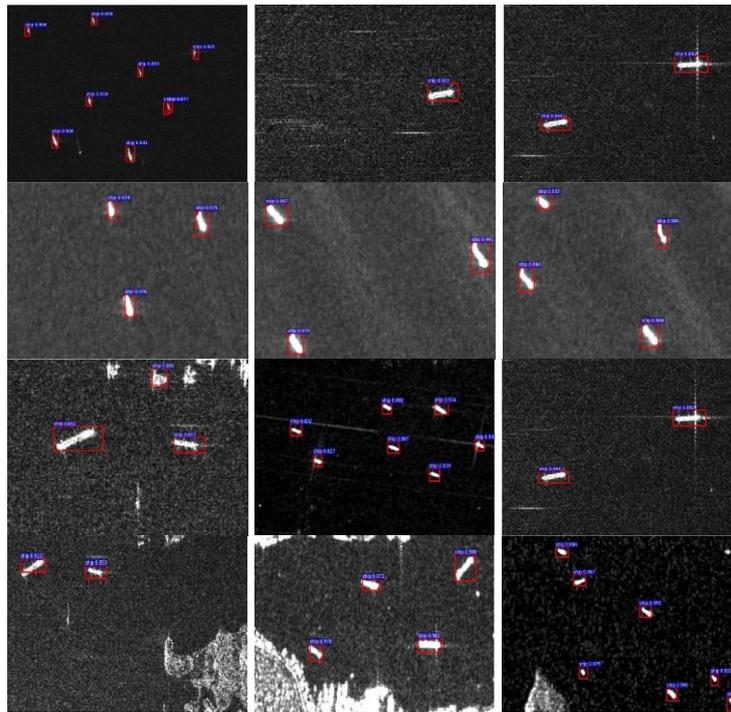


Рис. 5. Пример детектирования кораблей Faster-R-CNN
Fig. 5. Example of Faster-R-CNN ship detection

Сравнивая усовершенствованный метод с Faster-R-CNN и YOLOv2 авторами проведен эксперимент по детектированию объектов на радиолокационных изображениях. Результаты приведены в Таблице 2.

Таблица 2

Сравнение рассматриваемых архитектур

Table 2

Comparison of the architectures in question

Методы	Точность детектирования, %	Время на обработку, мс
Faster-R-CNN	70,1 %	198
YOLOv2	90,05%	25
Усовершенствованный метод	78,8 %	173

Среднее время обработки одного изображения на ЭВМ, оснащенной процессором Intel(R) Core(TM) i7-6770K @ 4.00 ГГц × 8 и видеокартой NVIDIA GTX1080, обладающей 8 Гб памяти, составило 198 мс и 173 мс для оригинальной и оптимизированной архитектур соответственно.

В ходе обучения модели с оптимизированной под решаемую задачу архитектурой получена нейронная сеть, точность которой при детектировании кораблей на радиолокационных изображениях составила 78,8 %, что на 8,7 % больше показателя сети с оригинальной

архитектурой, но меньше на 11,25 % по сравнению с YOLOv2. Время на обработку изображения уменьшилось от оригинального метода, а относительно YOLOv2 на порядок больше.

Еще одним примером распознавания морских объектов на радиолокационных изображениях является работа [2], где авторы рассматривают варианты обнаружения объектов на основе глубоких сверточных нейронных сетей, таких как Single Shot Detector (SSD) [6], YOLOv3 [13], RetinaNet [15].

В качестве набора радиолокационных данных применяется SAR Ship Dataset. Данная база сформирована из 102 РЛИ Gaofen-3 и 108 РЛИ Sentinel-1, значительно отличается от уже существующих наборов данных SAR Ship [8] и Open SAR Ship [12] по нескольким параметрам: объем данных и размеры изображений, размер окна обнаружения, типы разметки объектов, что имеет возможность применения его для обучения моделей на базе современных архитектур.

Авторами статьи проведены исследования рассматриваемых сверточных сетей по детектированию объектов и результаты представлены в Таблице 3.

Таблица 3

Характеристики тестируемых моделей

Table 3

Characteristics of the models being tested

Архитектура	SSD	YOLOv3	RetinaNet
Базовая сеть	ResNet-101	DarkNet-53	ResNet-101
Коэфф. сходства Жаккара	0,4	0,4	0,4
Время на обработку, мс	51	24	175
Точность детектирования, %	89,2	91,1	94,3

Из таблицы характеристик заметим, что коэффициент сходства Жаккара (отношение площади пересечения размеченного и предсказанного прямоугольников к их совокупной площади) одинаковые у всех моделей и составляет 40%.

Несмотря, на наибольшую точность детектирования 94,3%, модель RetinaNet является самой медленной на обработку изображения и занимает 175 мс. Оптимальным вариантом из списка рассматриваемых архитектур выделяется модель YOLOv3, которая обеспечивает точность 91,1% и наименьшее время выполнения.

РЕЗУЛЬТАТЫ

По итогам анализа всех источников была сделана сравнительная таблица (Таблица 4), где приведены особенности и полученные результаты каждого метода, которые в них рассмотрены.

Таблица 4

Сравнительная таблица методов

Table 4

Comparison table of methods

№	Архитектура нейронной сети	Особенности применяемых архитектур	Входные данные	Результат детектирования
1	YOLOv2	1. Применяется концепция «Якорная рамка», которая выделяет несколько объектов, находящихся в одной ячейке сетки, при этом увеличивая возможность более детально детектировать объекты.	База данных обнаружения судов (SSDD) -1160 изображений и 2456 кораблей	90,5 % [14]

Продолжение таблицы 4

№	Архитектура нейронной сети	Особенности применяемых архитектур	Входные данные	Результат детектирования
1	YOLOv2	2. Используется предварительно обученная модель Darknet-19, требующая 5,58 млрд операций (для сравнения: нейросеть CNN, использует фреймворк VGG-16 с 30,69 млрд операций)	Набор данных по поиску и обнаружению судов (DSSDD) – 1174 РЛИ.	89,13 % [14]
2	Faster-RCNN	Усовершенствование существующей архитектуры, объединяя различные уровни методов для повышения точности детектирования: 1) <i>feature fusion, transfer learning</i> – для детектирования как крупных, так и мелких кораблей; 2) <i>hard negative mining</i> – для увеличения показателей точности модели. Данная архитектура направлена на распознавание таких объектов, как люди, автомобили, животные.	Набор данных изображений с синтезированной апертурой (SSDD) В SSDD всего 1160 изображений и 2456 кораблей.	78,8 % [5]
3	SSD	1) SSD смешивает объекты с похожими категориями (например, животные), что делает точность детектирования низким. 2) SSD дает худшую производительность для небольших объектов, так как они могут отображаться не на всех картах объектов. Увеличение разрешения входного изображения облегчает эту проблему, но не решает ее полностью.	Набор данных SAR Ship Dataset Сформировано 210 РЛИ и получено 43820 изображений, на которых размечено 59536 объектов (кораблей)	89,2 % [2]
4	RetinaNet	1. Создана путем двух улучшений по сравнению с существующими одноэтапными моделями обнаружения объектов, такими как YOLO и SSD. 2. Использует магистраль Feature Pyramid Network (FPN) поверх архитектуры ResNet с прямой связью для создания богатой, многомасштабной пирамиды сверточных функций.	Набор данных SAR Ship Dataset Сформировано 210 РЛИ и получено 43820 изображений, на которых размечено 59536 объектов (кораблей)	94,3 % [2]

Окончание таблицы 4

№	Архитектура нейронной сети	Особенности применяемых архитектур	Входные данные	Результат детектирования
5	YOLOv3	1. Применяется базовая сеть Darknet-53, которая показывает высокую точность детектирования, при этом имея меньшее количество операций над изображениями, чем ResNet. Также данная сеть имеет удвоенную скорость при одинаковой производительности с ResNet. 2. Используются дополнительные ограничительные рамки, которые игнорируют другие объекты, не попадающие в выбранный порог (используется значение 0,7)	Набор данных SAR Ship Dataset Сформировано 210 РЛИ и получено 43820 изображений, на которых размечено 59536 объектов (кораблей)	91,1 % [2]

Из таблицы видно, что авторами каждой статьи применялись различные архитектуры нейронных сетей и в большинстве работ были получены высокие точности обнаружения объектов.

Наименьшего результата в 78,8% при времени 178 мс добились авторы с нейросетью архитектуры Faster-R-CNN. Такой результат объясняется тем, что Faster-R-CNN имеет проблемы с обнаружением небольших объектов на изображении с низким качеством. Данная архитектура направлена на распознавание таких объектов, как люди, автомобили, животные. Поэтому детектор будет испытывать большие трудности чтобы предсказать класс объекта и местоположение объекта.

Наибольший результат детектирования получили авторы, использующие архитектуру RetinaNet с показателем 94,3 %. Несмотря, на большую точность детектирования RetinaNet является самой медленной на обработку изображения, время которой составляет 175 мс.

YOLOv3 обладает практически на порядок большей скоростью обработки изображений – 24 мс по сравнению с 175 мс (RetinaNet) и 178 мс (Faster-R-CNN), что позволяет быть более оперативной при работе с массивами данных. Точность архитектуры YOLOv3 составляет 91,1 % – это является достаточно приемлемым результатом при детектировании любых объектов на радиолокационных изображениях.

Таким образом, самым оптимальным и производительным вариантом из рассмотренных является YOLOv3, которая обладает хорошим показателем точности и наилучшей скоростью обработки изображений.

ЗАКЛЮЧЕНИЕ

В данной статье были проанализированы работы, в которых рассматривались различные архитектуры сверточных нейронных сетей – Faster-R-CNN, SSD, RetinaNet, YOLOv2, YOLOv3.

Были проведены сравнительные анализы среди методов по критериям – точность детектирования и время на обработку, и выявлен наиболее эффективный алгоритм сверточной нейронной сети. По итогам сравнения была достигнута цель – из всех рассмотренных архитектур YOLOv3 обладает оптимальными показателями.

Одним из путей дальнейшего исследования может быть применение сверточных нейронных сетей для мониторинга и охраны окружающей среды, в том числе для выявления нелегальных действий (браконьерство, вырубка лесов, разжигание костров) и стихийных бедствий (пожары, оползни, наводнения). В качестве объектов можно использовать людей, транспортные средства и объекты инфраструктуры.

Список литературы

1. Гончаренко Ю.Ю., Нестеренко В.Р. Использование случайных биометрических образов для генерации криптостойких последовательностей с применением генеративно-состязательных нейронных сетей // Научный результат. Информационные технологии. – Т.4, №2, 2019. С. 69-74.
2. Клейменов В.В., Сахно В.И., Сахно Д.И. Сравнительный анализ эффективности применения нейросетевых обнаружителей морских объектов на радиолокационных изображениях // Труды Военно-космической академии имени АФ Можайского. – 2020. – №. 672. – С. 110-120.
3. Кулагин В.П., Затыгалова В.В. Информационная поддержка наблюдений объектов на морской поверхности // Вестник МГТУ МИРЭА. – 2015. – №. 1. – С. 23-38.
4. Радиолокационные системы землеобзора космического базирования / Верба, В.С., Неронский, Л.Б., Осипов, И.Г., & Турук, В.Э. (2010).
5. Faster r-cnn: Towards real-time object detection with region proposal networks / Ren, S., He, K., Girshick, R., & Sun, J. // In Advances in neural information processing systems (2015). P. 91-99.
6. Fu C.Y. et al. Dssd: Deconvolutional single shot detector // arXiv preprint arXiv:1701.06659. – 2017.
7. Girshick R. Fast r-cnn // Proceedings of the IEEE international conference on computer vision. – 2015. – P. 1440-1448.
8. Lemoine G. et al. An open source framework for integration of vessel positions detected in spaceborne SAR Imagery in operational fisheries monitoring and control // Envisat & ERS Symposium. – 2005. – Т. 572.
9. Li J., Qu C., Shao J. Ship detection in SAR images based on an improved faster R-CNN // 2017 SAR in Big Data Era: Models, Methods and Applications (BIGSARDATA). – IEEE, 2017. – P. 1-6.
10. Morena L. C., James K. V., Beck J. An introduction to the RADARSAT-2 mission // Canadian Journal of Remote Sensing. – 2004. – Т. 30. – №. 3. – P. 221-234.
11. Redmon J., Farhadi A. YOLO9000: better, faster, stronger // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2017. – P. 7263-7271.
12. Schwegmann C. P. et al. Very deep learning for ship discrimination in synthetic aperture radar imagery // 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). – IEEE, 2016. – Pp. 104-107.
13. Selective search for object recognition / Uijlings, J.R., Van De Sande, K.E., Gevers, T., & Smeulders, A.W. // International journal of computer vision, (2013). 104(2), P. 154-171.
14. Ship detection based on YOLOv2 for SAR imagery / Chang, Y.L., Anagaw, A., Chang, L., Wang, Y.C., Hsiao, C.Y., & Lee, W.H. // Remote Sensing, (2019), 11(7), Pp. 786.
15. Wang Y. et al. Automatic ship detection based on RetinaNet using multi-resolution Gaofen-3 imagery // Remote Sensing. – 2019. – Т. 11. – №. 5. – Pp. 531.
16. Werninghaus R. TerraSAR-X mission // SAR Image Analysis, Modeling, and Techniques VI. – International Society for Optics and Photonics, 2004. – Т. 5236. – P. 9-16.

References

1. Goncharenko Yu.Yu., Nesterenko V.R. the Use of random biometric images for generating cryptographic sequences using generative-binding neural networks. Research Result. Information technologies, Vol. 4, No. 2, 2019. P. 69-74.
2. Kleimenov V.V., Sakhno V.I., Sakhno D.I. Comparative analysis of the effectiveness of applying neural network detectors of marine objects on radar images // Proceedings of the Military Space Academy named after AF Mozhaisky. – 2020. – №. 672. – P. 110-120.
3. Kulagin V.P., Zatyagalova V.V. Information support for observations of objects on the sea surface // Vestnik MSTU MIREA. – 2015. – №. 1. – P. 23-38.
4. Verba V.S., Neronsky L.B., Osipov I.G., & Turuk V.E., Space-based ground survey radar systems. – 2010.
5. Faster r-cnn: Towards real-time object detection with region proposal networks / Ren, S., He, K., Girshick, R., & Sun, J. // In Advances in neural information processing systems (2015). P. 91-99.
6. Fu C.Y. et al. Dssd: Deconvolutional single shot detector // arXiv preprint arXiv:1701.06659. – 2017.
7. Girshick R. Fast r-cnn // Proceedings of the IEEE international conference on computer vision. – 2015. – Pp. 1440-1448.
8. Lemoine G. et al. An open source framework for integration of vessel positions detected in spaceborne SAR Imagery in operational fisheries monitoring and control // Envisat & ERS Symposium. – 2005. – Т. 572.

9. Li J., Qu C., Shao J. Ship detection in SAR images based on an improved faster R-CNN //2017 SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA). – IEEE, 2017. – P. 1-6.
10. Morena L. C., James K. V., Beck J. An introduction to the RADARSAT-2 mission // Canadian Journal of Remote Sensing. – 2004. – Т. 30. – №. 3. – P. 221-234.
11. Redmon J., Farhadi A. YOLO9000: better, faster, stronger // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2017. – P. 7263-7271.
12. Schwegmann C. P. et al. Very deep learning for ship discrimination in synthetic aperture radar imagery // 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). – IEEE, 2016. – P. 104-107.
13. Selective search for object recognition / Uijlings, J.R., Van De Sande, K.E., Gevers, T., & Smeulders, A.W. // International journal of computer vision, (2013). 104(2), P. 154-171.
14. Ship detection based on YOLOv2 for SAR imagery / Chang, Y.L., Anagaw, A., Chang, L., Wang, Y.C., Hsiao, C.Y., & Lee, W.H. // Remote Sensing, (2019), 11(7), 786 pp.
15. Wang Y. et al. Automatic ship detection based on RetinaNet using multi-resolution Gaofen-3 imagery // Remote Sensing. – 2019. – Т. 11. – №. 5. – P. 531.
16. Werninghaus R. TerraSAR-X mission // SAR Image Analysis, Modeling, and Techniques VI. – International Society for Optics and Photonics, 2004. – Т. 5236. – P. 9-16.

Чорбаа Начын Александрович, магистрант Санкт-Петербургского национального исследовательского университета информационных технологий, механики и оптики

Ле Ань Ту, аспирант Санкт-Петербургского национального исследовательского университета информационных технологий, механики и оптики

Толстой Иван Михайлович, инженер, Национальный центр когнитивных разработок Санкт-Петербургского национального исследовательского университета информационных технологий, механики и оптики

Chorbaa Nachyn Alexandrovich, master of Saint Petersburg National Research University of Information Technologies, Mechanics and Optics

Le Anh Tu, post-graduate student of Saint Petersburg National Research University of Information Technologies, Mechanics and Optics

Tolstoy Ivan Mikhailovich, engineer, ITMO University's National Center for Cognitive Technologies