

РЕШЕНИЕ ЗАДАЧ ОБНАРУЖЕНИЯ И ИДЕНТИФИКАЦИИ ОБЪЕКТОВ НА РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЯХ НЕЙРОСЕТЕВЫМ МЕТОДОМ

Б.С. Савченко (Фирма «Ракурс»)

В 2022 г. окончил Физтех-школу аэрокосмических технологий Московского физико-технического института по специальности «прикладные математика и физика». С 2019 г. работает в АО «Фирма «Ракурс», в настоящее время — программист-разработчик.

Н.А. Вьюков (Фирма «Ракурс»)

В 2022 г. окончил Физтех-школу аэрокосмических технологий Московского физико-технического института по специальности «прикладные математика и физика». С 2020 г. работает в АО «Фирма «Ракурс», в настоящее время — программист-разработчик.

И.В. Елизаветин (ВПК «НПО машиностроения»)

В 1984 г. окончил радиотехнический факультет Московского авиационного института (национальный исследовательский университет) по специальности «радиотехника», специализация «радиолокация и радионавигация». С 1986 г. работает в АО «ВПК «НПО машиностроения», в настоящее время — ведущий научный сотрудник. Кандидат технических наук.

А.В. Соболев (МГТУ им. Н.Э. Баумана)

В 1989 г. окончил факультет космонавтики и автоматических летательных аппаратов Московского авиационного института (национальный исследовательский университет) по специальности «двухсредные аппараты». После окончания института работал в АО «ВПК «НПО машиностроения». С 2007 г. работает в Московском государственном техническом университете им. Н.Э. Баумана, в настоящее время — старший преподаватель.

На современном этапе развития систем дистанционного зондирования Земли особое внимание уделяется наращиванию орбитальных группировок малогабаритных спутников, оснащенных как оптическими и инфракрасными, так и радиолокационными средствами наблюдения. Последние, в силу своих характерных особенностей, способны решать задачи круглосуточного и всепогодного мониторинга земной поверхности. Мониторинг земной поверхности может включать в

себя как задачи по контролю сельхозугодий, лесных и водных массивов, так и мониторинг чрезвычайных ситуаций, природных катаклизмов, а также зон локальных конфликтов. Наличие оперативной информации о классе техники и ее координатах дает стратегическое преимущество как при построении оборонных систем, так и при решении задач гражданско-го характера.

На данный момент поиском и классификацией объектов на радиолокационных изобрае-

ниях (РЛИ) зачастую занимаются профильные операторы-дешифровщики. В условиях постоянного роста объема получаемых данных актуальным становится вопрос снижения нагрузки на операторов-дешифровщиков путем автоматизации процесса поиска и классификации объектов.

В силу существенных особенностей РЛИ, обусловленных, главным образом, спецификой дифракции электромагнитных волн радиодиапазона на поверхностях сложной формы,

объекты на изображении представляются в виде наборов областей ярких точек. С незначительным изменением ракурса наблюдаемого объекта, угла наблюдения, поляризации, частоты электромагнитной волны или с изменением других параметров съемки объект на полученном изображении может в значительной степени изменить свой вид. Описанный эффект ощутимо усложняет задачу поиска и классификации объекта. Еще одним фактором, снижающим дешифровочные признаки РЛИ и усложняющим решение задачи классификации, является спекл-шум. В этих условиях классические алгоритмы, основанные на корреляционном анализе, не всегда способны обеспечить требуемую точность и скорость работы, так что актуальным становится вопрос применения нейросетевых алгоритмов.

Главным преимуществом искусственных нейронных сетей является то, что их принцип работы аналогичен принципам организации и функционирования биологических нейронных сетей — сетей нервных клеток живого организма. Нейронная сеть в отличие от традиционных алгоритмов должна пройти процесс обучения, в ходе которого она сама выявляет сложные зависимости между входными и выходными данными, выполняет их обобщение. Характерные признаки, описывающие объект интереса, и решающие процедуры классификации также формируются в процессе обучения системы. Впоследствии правильно обученная сеть способна давать верный результат на данных, изначально отсутствующих в обучающей выборке (в том числе на зашумленных или частично искаженных данных).

Так, первым принципиально важным этапом при построении систем, работающих на нейро-

сетевом принципе, является формирование обучающей выборки. На данный момент именно объем и качество обучающей выборки играют определяющую роль в создании эффективных систем распознавания, базирующихся на использовании нейросетей. Обучающая выборка должна быть определена достаточным количеством разнообразных обучающих примеров, отражающих закономерности и правила, которые в ходе обучения будут выделены нейронной сетью, т. е. быть репрезентативной. Репрезентативность обучающей выборки определяется следующими аспектами:

— достаточность — количество изображений в обучающей выборке должно быть достаточным для обучения (для сети Alexnet насчитывается порядка 62 млн обучаемых параметров, сети VGG16 — 138 млн, сети Resnet18 — 11 млн). Если это условие не соблюдается, существует вероятность того, что модель может не приобрести способность к обобщению;

— разнообразие — обучающая выборка должна содержать большое число разнообразных комбинаций входных данных и ожидаемых выходных результатов в обучающих примерах. Нейронная сеть не получит способность к обобщению, если обучающих примеров недостаточно, но в выборке для интересующего класса представлены только одинаковые, либо очень похожие друг на друга портреты объектов интереса. Также, если обучающие изображения обладают высоким уровнем закономерности расположения на них объектов интереса, модель (в зависимости от архитектуры) может научиться выделять такие области и не будет проверять остальные, потенциально представляющие интерес;

— равномерность — классы должны быть представлены в

обучающей выборке либо равномерно, либо в соответствии с тем, как они представлены в реальных условиях конкретной задачи.

В сетях, решающих задачу обнаружения и классификации объектов на изображениях, обучающая выборка состоит из набора размеченных изображений, имитирующих реальную обстановку наблюдаемой радиолокатором области. Такие изображения должны обладать всеми характерными признаками, которые ожидаются на целевом РЛИ. К таким признакам можно отнести плотность заполнения изображения объектами интереса, уровень зашумленности изображения и характер спекл-шума.

В приложении для поиска и классификации объектов на РЛИ в составе программного комплекса PHOTOMOD Radar реализованы два подхода к формированию обучающей выборки нейронной сети: при помощи разметки реальных РЛИ и с помощью генерации синтетических обучающих РЛИ.

Программный модуль, реализующий разметку реальных РЛИ, содержит набор инструментов для выделения областей интереса оператором, а также задания их класса. Модуль работает с растром, представленным во внутреннем формате и описывающем обобщенную модель радиолокатора с синтезированной апертурой (РСА). Использование подхода обобщенной модели РСА позволяет проводить разметку РЛИ независимо от изначального формата представленных данных конкретного датчика. Модуль обладает широким функционалом и позволяет оператору, среди прочего, задавать размерность выходных обучающих РЛИ, тип данных, формат, в котором изображения будут сохранены (RDP, TIF, BMP), формат представления аннотаций (COCO-json, Dlib-xml,

Simple-txt annotation formats). Полученная выборка может быть использована как для обучения, так и для проверки качества обнаружения и классификации с использованием нейронной сети.

В настоящее время в открытом доступе практически отсутствуют наборы реальных радиолокационных портретов (РЛП), которые учитывали бы различные углы наблюдения радиолокатора, ракурс объекта и конкретные параметры съемки. В таких условиях возникает потребность в моделировании предположительного синтетического РЛП интересующей техники. В программном комплексе PHOTOMOD Radar описанная задача решается в соответствующем модуле. Модуль Генерации синтетических эталонов по входной трехмерной модели объекта и заданным параметрам наблюдения РСА с учетом параметров съемки, угла места и ракурса объекта формирует эталонные РЛП объектов. Полученный эталон представлен в формате с плавающей точкой размером 4 байта и содержит относительные коэффициенты обратного рассеяния. Такой эталон может быть использован для корреляционного поиска объектов на РЛИ, одна-

ко, не может применяться для генерации обучающей выборки нейронной сети, поскольку он в значительной мере не соответствует фактическому виду этого объекта на реальном РЛИ.

Существующий генератор синтетических портретов не учитывает случайные флуктуации фазы. Так, при повторной генерации эталона без изменения параметров съемки в сформированном РЛП не произойдет никаких изменений. Таким образом, для каждого угла места имеет смысл генерировать только один эталон, поскольку вновь сгенерированный эталон будет являться его полной копией. Эта особенность определяет ключевую проблему в формировании репрезентативной синтетической обучающей выборки — недостаточное разнообразие образов объекта интересующего класса для каждого конкретного ракурса и угла наблюдения. Для решения этой проблемы был разработан метод, представленный на рис. 1.

Модуль генерации обучающей выборки позволяет создавать наборы искусственных РЛИ, имитирующих фоно-целевую обстановку в условиях ограниченности или отсутствия реальных данных. В состав модуля входят: блок формиро-

вания наборов синтетических эталонов, блок корреляционно-го отбора синтетических эталонов и блок формирования обучающих изображений.

Полученный на выходе генератора эталонов РЛП проходит этап синтеза эталонов — создания набора эталонов, отличающихся друг от друга площадью областей ярких точек и фактическими значениями яркости, что способствует искусственному повышению вариативности синтезированных эталонов. На вход блока формирования наборов синтетических эталонов подается сгенерированный РЛП и РЛИ, относительно которого будет проводиться пересчет относительных коэффициентов обратного рассеяния в яркость. На выходе блока получаем набор вариативных искусственно-синтезированных эталонов, отличающиеся от имеющихся комбинациями отражающих точек и степенью отражения этих точек. Потенциально такие эталоны уже могут быть использованы для формирования обучающих изображений нейронной сети.

Блок корреляционного отбора синтетических эталонов, ближайших к реальному портрету, позволяет из переданных на вход программы эталонов отобрать лишь те, которые обладают наибольшим уровнем взаимной корреляции. Такие синтетические эталоны более приближены к реальным и за счет своего количества формируют вариативность представления объекта интереса для указанного ракурса и угла наблюдения, что при обучении позволит повысить обобщающую способность нейронной сети. Блок отбора эталонов, имеющих наибольший уровень корреляции с реальным изображением, представлен на рис. 1 (отмечен пунктирной рамкой). Этот этап не является обязательным, но рекомендуется использовать, если

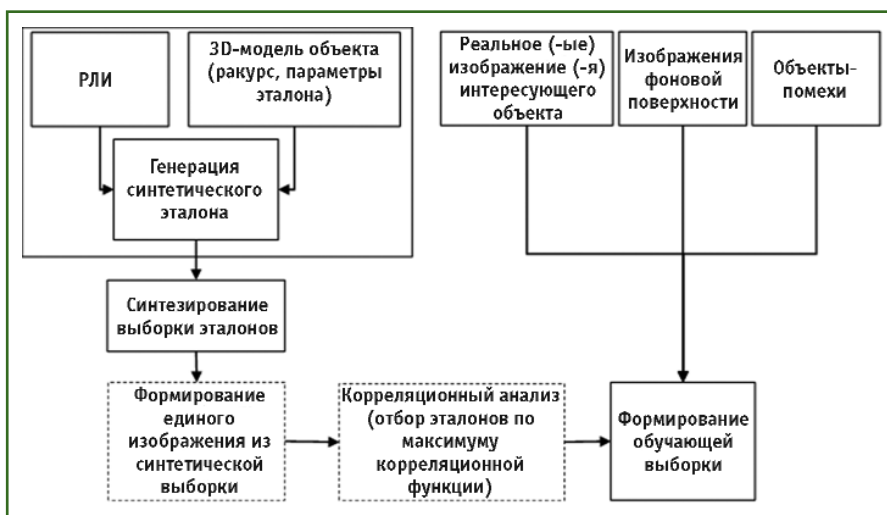


Рис. 1

Схема формирования обучающей выборки

для синтезированного эталона имеется в наличии как минимум один реальный портрет искомого объекта, совпадающий по углам наблюдения, ракурсу и параметрам радиолокатора.

Блок формирования обучающих изображений позволяет объединять имеющиеся в доступе изображения фоновой поверхности, изображения объектов интересующих классов и объектов-шумов в единое РЛИ, тем самым моделируя предположительную ситуацию их расположения. Также блок готовит входные данные в специфическом для выбранной нейросети формате для дальнейшего обучения. Таким образом, от оператора не требуется никаких временных затрат на ручную разметку больших объемов данных. В работе блока реализовано два алгоритма генерации синтетических обучающих РЛИ — статический и итерационный. Использование обоих алгоритмов в комбинации позволяет моделировать как ситуации плотного расположения объектов одного класса с отсутствием объектов-шумов, что характерно для стоянок техники, аэропортов и т. п., так и ситуации, когда на изображении представлены объекты разных классов с низкой плотностью расположения. При этом статический метод менее ресурсозатратный и выполняется быстрее, чем итерационный, однако, обладает низким уровнем нелинейности в расположении объектов. Итерационный метод позволяет внести нелинейность в закон распределения объектов на изображении за счет случайного расчета координат для вставки объекта. Наличие размеченной обучающей выборки определяет возможность провести обучение нейронной сети. В программном комплексе PHOTOMOD Radar можно выбрать разные конфигурации сети — FasterRCNN или RetinaNet, в зависи-



Рис. 2
Пример обнаружения и классификации нефтяных вышек на РЛИ (фрагмент снимка КА TerraSAR-X, Кувейт, Бурганское нефтяное месторождение)



Рис. 3
Пример обнаружения и классификации самолетов на РЛИ (фрагмент снимка КА «Кондор-Э», авиабаза Дэвис-Монтен, г. Тусон, США)

мости от решаемой задачи и имеющихся вычислительных ресурсов. Архитектура сетей была модифицирована под поддержку радиолокационных данных с высоким динамическим диапазоном, что позволяет получать более обширную и полную информацию о представленных на них объектах. Оператор имеет возможность корректировать гиперпараметры нейронной сети для более эффективного обучения. После запуска процесса обучения сети функции оператора сводятся к контролю работы программы и периодическому анализу отчетов о ходе обучения. По окончании процесса обучения сфор-



Рис. 4
Пример обнаружения и классификации самолетов класса Р-3С (фрагмент снимка КА «Кондор-Э», авиабаза Дэвис-Монтен, г. Тусон, США)

мированные весовые коэффициенты нейронной сети могут быть использованы для обнаружения и классификации объектов на новых данных.

В рамках тестирования программного комплекса решались задачи инфраструктурного мониторинга, мониторинга морской поверхности, прибрежных зон, а также мониторинга аэродромов.

Для обучения и тестирования сети были использованы разновременные снимки, полученные космическим аппаратом (КА) TerraSAR-X (X-диапазон, НН-поляризация). Результаты обнаружения объектов класса «нефтедобывающая вышка» представлены на рис. 2.

В рамках другого проекта обучение сети производилось на сгенерированной синтетической выборке, в состав которой входили реальные РЛП объектов интереса. Тестирование осуществлялось на снимке, полученном космическим аппаратом «Кондор-Э» (S-диапазон, НН-поляризация). Результаты обнаружения объектов класса «В-52», «КС-135», «С-5», «РЗ-С» представлены на рис. 3, 4.

Предварительные результаты работы нейронной сети FasterRCNN-FPN показывают максимальную точность обнаружения и классификации объектов равной 97,93% при пороге обнаружения 0,7. Количество ошибочно классифицированных объ-

ектов при такой границе равно 14. Повышение порога обнаружения на 0,2 позволяет снизить количество ложных срабатываний до 8.

Результаты мониторинга акватории порта на интерферометрических снимках, полученных космическим аппаратом TerraSAR-X (X-диапазон, НН-поляризация) представлены на рис. 5. Для обучения и тестирования сети были использованы разновременные снимки.

Результаты обнаружения кораблей на снимке, полученном космическим аппаратом GaoFen-3 (С-диапазон, VН-поляризация, режим съемки ScanSAR) представлены на рис. 6. Для тестирования использовалась модель, обученная ранее на обнаружение кораблей на интерферометрических снимках, полученных космическим аппаратом TerraSAR-X.

Таким образом, в настоящее время в программном комплексе PHOTOMOD Radar реализованы прототипы модулей и инструментов для подготовки данных, формирования обучающей выборки нейронной сети, обучения сети и обнаружения объектов с использованием обученной модели. Предложен подход, позволяющий обеспечить полную автономность работы в рамках одного программного комплекса. В рамках тестирования программного комплекса получены результаты, демонстрирующие возможность применения нейронных сетей для обнаружения и классификации объектов на снимках, получаемых РСА в разных поляризациях и при различных длинах волн. При грантовой поддержке Фонда содействия развитию малых форм предприятий в научно-технической сфере ведется работа по созданию практически применимого коммерческого продукта нейросетевой обработки радиолокационных данных на базе уже имеющихся наработок.



Рис. 5
Пример мониторинга акватории порта на предмет наличия кораблей (фрагмент снимка КА TerraSAR-X, г. Барселона, Испания)



Рис. 6
Пример обнаружения кораблей (фрагмент снимка КА GaoFen-3, Охотское море, район острова Сахалин)