

Методика преобразования радиолокационных изображений, получаемых с различных РСА, для формирования композитного набора данных для обучения нейронной сети

Б. С. Савченко

*Московский физико-технический институт (НИИУ)
Долгопрудный, 141700, Московская обл., Россия
E-mail: savchenko.bs@phystech.edu
АО «Фирма «РАКУРС», Москва, 129366, Россия*

Исследования в области обнаружения и классификации искусственных объектов на радиолокационных снимках, полученных радиолокаторами с синтезированной апертурой антенны космического базирования, являются одними из наиболее перспективных в силу объективных свойств, которыми обладают радиолокационные данные (РЛД). Применение известных корреляционных алгоритмов обнаружения и классификации объектов показывает ограниченную эффективность при работе по широкой номенклатуре классов. Использование же нейросетевых алгоритмов, хорошо зарекомендовавших себя в решении ряда подобных задач по оптическим снимкам, затрудняется отсутствием качественной обучающей выборки и специфическими особенностями радиолокационных изображений (РЛИ). Доступные наборы обучающих РЛД по ряду интересующих классов могут быть получены в другом частотном диапазоне относительно данных, которые планируется обрабатывать. Цель работы заключается в подтверждении возможности совместного обучения нейронной сети на смешанных РЛД, полученных в нескольких частотных диапазонах. В работе предложена методика формирования единой обучающей выборки, состоящей из реальных данных, полученных в разных диапазонах зондирования и в различных комбинациях поляризации. Предложенная методика состоит из последовательных этапов геометрической и радиометрической коррекции РЛИ, а также их нормировки, что позволяет обеспечить согласованность РЛИ из состава обучающей выборки. Для подтверждения эффективности методики выполнен эксперимент с реальными данными по обучению нейронной сети на необработанных объединённых данных и на данных, прошедших предварительную обработку в соответствии с предложенной методикой. По результатам эксперимента сделан вывод о существенном улучшении качества совместного обучения на смешанных РЛД с использованием предложенной методики.

Ключевые слова: радиолокатор с синтезированной апертурой антенны, композитная выборка, нейронная сеть, распознавание, обнаружение и классификация объектов

Одобрена к печати: 07.02.2024

DOI: 10.21046/2070-7401-2024-21-1-135-145

Введение

Обстоятельства, осложняющие процесс распознавания распределённых и групповых целей на радиолокационных изображениях (РЛИ), можно разделить на три категории, которые связаны с фоновой обстановкой, целевой обстановкой и параметрами датчика. Рассогласование фоновой обстановки между РЛИ, получаемыми различными датчиками, может быть обусловлено изменением погодных условий или временем года, параметрами наблюдения (углом падения, состоянием растительности или режимами съёмки). Целевая обстановка меняется в зависимости от азимута наблюдаемого объекта — угла в горизонтальной плоскости между направлением на север и строительной осью объекта, отсчитываемой по часовой стрелке. Среди параметров радиолокаторов с синтезированной апертурой антенны (РСА), влияющих на представление объектов на РЛИ, можно выделить параметры зондирующего сигнала (несущая частота, ширина спектра), поляризацию электромагнитной волны при излучении зондирующих сигналов и приёме отражённых, коэффициенты усиления приборов приёма-передающей аппаратуры и системы наземной обработки, потери в радиолокационном тракте и др.

(Верба и др., 2010). Все перечисленные обстоятельства вносят свой вклад в то, как объект будет представлен на РЛИ.

Искусственные объекты, если речь идёт не о площадных объектах, в общем случае представлены на РЛИ в виде набора ярких точек или элементов разрешения, мощность в которых значительно превышает фоновые показатели. Это обусловлено синфазным сложением сигналов, отражённых от отдельных элементов объекта, обладающих свойством угловых отражателей, и принципиально отличает вид объектов или целей на оптических и радиолокационных снимках. Непосредственным следствием этого оказывается непригодность наборов данных, полученных в оптическом диапазоне, для использования при подготовке обучающей выборки для нейронной сети, работающей с радарными снимками.

Важным моментом, обуславливающим необходимость разработки методики подготовки радиолокационных данных (РЛД), является зависимость характера рассеяния отражающих элементов объекта, или «ярких точек», от длины волны сигнала РСА и его поляризации. Конфигурация ярких точек и уровень мощности сигнала в каждой точке будут варьироваться на снимках в зависимости от параметров РСА.

Кроме того, следует отметить, что представление искусственных объектов на РЛИ зависит от радиометрической чувствительности радиолокационного тракта, что выражается в степени различимости фонов на РЛИ. Мощность и текстура фонов, в свою очередь, оказывают влияние на качество обнаружения и классификации объектов и, как известно, зависят от параметров сигнала локатора. В такой трактовке фоновые поверхности становятся фактически одним из элементов объектов, и это необходимо учитывать при подготовке обучающей выборки.

На сегодняшний день набора данных, полученного во всех возможных комбинациях условий, описанных выше, в открытом доступе не существует. Модель, обученная на РЛИ, полученных в одной комбинации условий, может не демонстрировать такое же качество при обработке данных, полученных при других условиях (Inkawhich et al., 2021).

Имеющиеся в открытом доступе наборы данных (датасеты) зачастую содержат информацию, полученную в ограниченных комбинациях условий. Например, один из самых известных открытых датасетов *MSTAR* (англ. Moving and Stationary Target Acquisition and Recognition) был получен РСА в режиме ГГ-поляризации (горизонтально-горизонтальная) в X-диапазоне с разрешением 30×30 см и углом наблюдения 15 и 17° . Датасет включает РЛИ, содержащие 10 классов военной техники. В ряде исследований было показано, что качество распознавания на данных, полученных другим РСА, моделью, обученной на данных *MSTAR*, резко снижается (Camus et al., 2022; Wang et al., 2015).

В таких условиях возможным представляется либо формирование модели под конкретный РСА с фиксированными параметрами, либо разработка методики, которая бы позволила согласовать обрабатываемые данные с данными, на которых производилось обучение.

Входные данные

Исследование проводилось на данных РСА «Кондор-Э» и Chaohu-1. Для исследования были выбраны два снимка, полученные в прожекторном режиме на район г. Тусон (англ. Tucson), США. РЛИ содержат аэродром и стоянку с большим количеством самолётов разных классов. Снимки получены РСА в разных частотных диапазонах: S («Кондор-Э») и C (Chaohu-1), а также в разных комбинациях поляризации: ГГ («Кондор-Э») и ВВ (вертикально-вертикальная) (Chaohu-1). Уровень обработки исходных данных соответствует уровню 1А. РЛИ представлены в путевой системе координат в виде двумерного массива с осями азимута (направление путевой скорости космического аппарата) и наклонной дальности (направление линии визирования от РСА до точки на поверхности Земли).

На рис. 1 (см. с. 137) представлены фрагменты исходных РЛИ, используемых в исследовании. На рис. 2 (см. с. 137) показаны гистограммы исходных изображений.

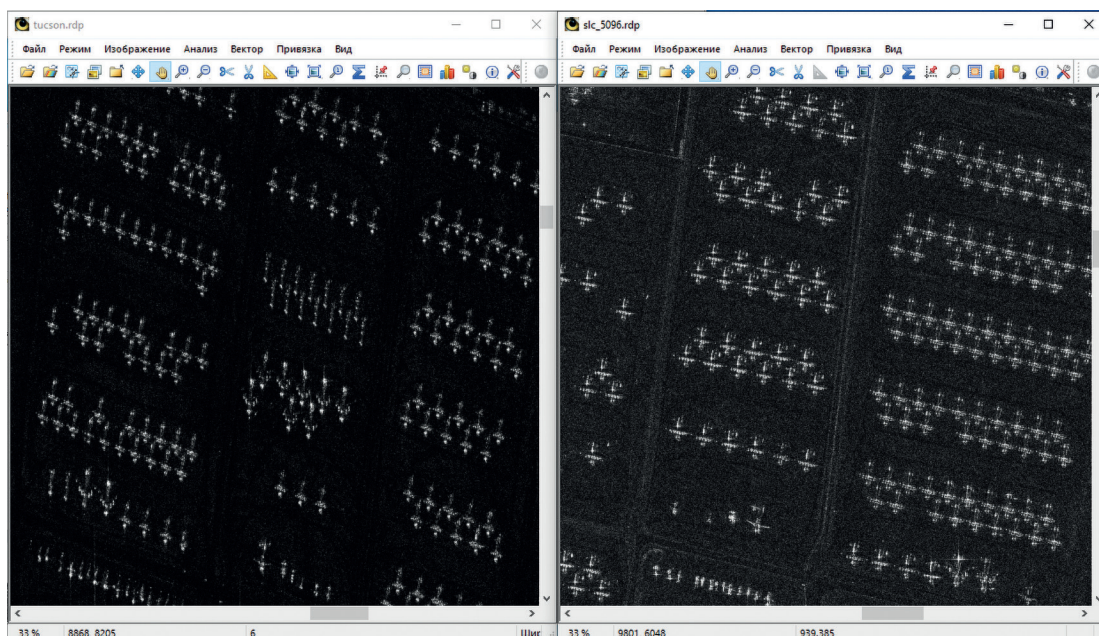


Рис. 1. Фрагменты обрабатываемых РЛИ, полученных РСА «Кондор-Э» (слева) и РСА Chaohu-1 (справа)

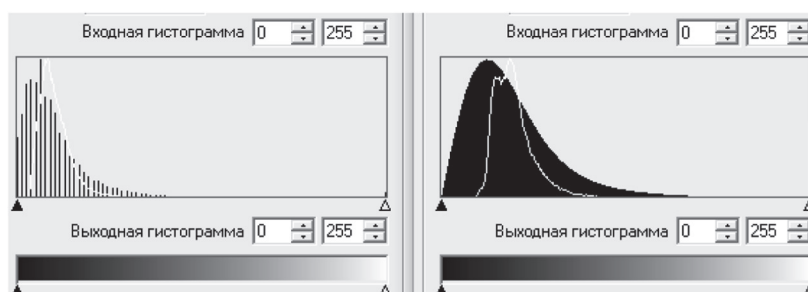


Рис. 2. Гистограммы обрабатываемых РЛИ, построенные по данным РСА «Кондор-Э» (слева) и РСА Chaohu-1 (справа)

Подстилающая поверхность на снимке, полученном РСА «Кондор-Э», более тёмная относительно снимка, полученного РСА Chaohu-1, а расположенные на ней искусственные объекты ярко выделяются. Сравнение снимков свидетельствует о значительно меньшем отражении электромагнитных волн от земной поверхности в S-диапазоне, в связи с чем на РЛИ, полученном РСА «Кондор-Э», отсутствуют силуэты теней от самолётов (Турук и др., 2017). В табл. 1 приведена статистика по амплитуде обрабатываемых РЛИ.

Таблица 1. Статистические показатели, рассчитанные по амплитудам входных РЛИ

РЛИ, полученное РСА	Минимум	Максимум	Среднее	Дисперсия
«Кондор-Э»	0	20805	9,011086	16,977507
Chaohu-1	0	46339,535798	3253,7114728	3031,917814

Для оценки уровня радиометрической несогласованности был проведён анализ характерных фоновых участков, пригодных для расположения на них объектов интереса. В ходе анализа данных, полученных разными датчиками, были определены усреднённые статистические показатели фоновых участков (табл. 2).

Таблица 2. Статистические показатели, рассчитанные по амплитуде РЛИ фоновых участков, пригодных для расположения на них объектов интереса

РЛИ, полученное РСА	Минимум	Максимум	Среднее	Дисперсия
«Кондор-Э»	0	36	5,589675	3,705839
Chaohu-1	6	11317,85492	2239,571322	1199,362577

Таким образом, средний уровень амплитуды на фоновом участке РЛИ, полученного РСА Chaohu-1, приблизительно в 400 раз выше, чем аналогичный участок на РЛИ, полученном РСА «Кондор-Э».

Методика предварительной обработки радиолокационных данных для формирования композитного набора

В условиях, когда входные данные несогласованы радиометрически, процесс обучения нейронной сети будет обладать высоким уровнем нестабильности. На текущий момент отсутствует возможность стабилизации процесса обучения нейросети на такого рода данных лишь путём изменения ряда ключевых гиперпараметров сети (Антонов и др., 2021).

Для обеспечения возможности обучения нейронной сети на данных, полученных различными РСА, предлагается осуществить ряд предварительных операций, направленных на повышение уровня их взаимной согласованности (Liu et al., 2023). Общая схема, демонстрирующая предлагаемый подход к процессу предварительной обработки РЛД для формирования композитного набора данных, представлена на рис. 3.

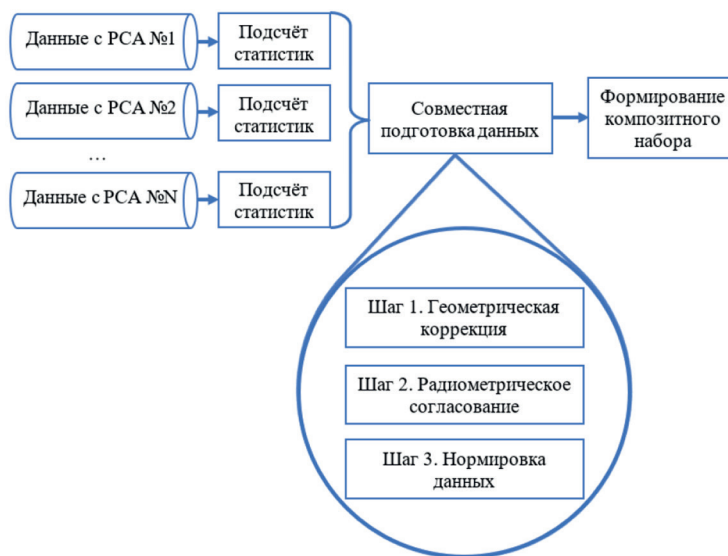


Рис. 3. Предлагаемая схема предварительной обработки РЛД для формирования композитного набора

На первом этапе с целью повышения дешифрируемости снимков, полученных с различных датчиков, необходимо обеспечить их пространственную согласованность. Пространственное согласование снимков достигается путём трансформации растров в соответствии с единой базисной системой координат. В качестве таковой может быть выбрана система координат одного из датчиков, геодезическая система или одна из наиболее распространённых картографических проекций. Геометрическую коррекцию необходимо осуществлять относительно каждого снимка, планируемого к формированию обучающей выборки.

На втором этапе выполняется радиометрическое согласование снимков и проводится коррекция растров относительно общих статистик.

На третьем этапе осуществляется масштабирование диапазонов яркости снимков с целью выделения полезного сигнала.

Этап геометрической коррекции

Задача этапа — обеспечение пространственной согласованности снимков и сопоставимости линейных размеров объектов на РЛИ, полученных с различных датчиков.

Геометрическая коррекция включает в себя две основные операции:

- геометрическую калибровку, или расчёт наземных координат элементов снимка;
- геометрическую трансформацию снимка на новую сетку, соответствующую параметрам выбранной базисной системы, результатам геометрической калибровки и заданному масштабу.

В современных системах обработки данных РСА реализуются несколько видов геометрической коррекции: геореференцирование, геокодирование, прецизионное геокодирование, орторектификация.

В процессе геометрической калибровки одновременно участвуют параметры относительного движения носителя РСА, цели и параметры их взаимного положения, включая:

- положение платформы в момент съёмки;
- положение цели или точки на поверхности;
- параметры движения платформы;
- параметры движения цели, обусловленные вращением Земли.

Применение операции геокодирования к исходному растру позволит преобразовать географические координаты точек снимка из антенной системы координат РСА в картографическую проекцию. Сетка выходного растра рассчитывается с учётом заданного значения шага по осям X и Y на земной поверхности.

С целью сохранения равнозначных масштабов представления объектов и их ориентации на снимках, полученных различными датчиками, необходимо определить единое значение шага сетки по осям X и Y и провести операцию геокодирования с этими значениями. Выбор величины шага проводится анализом имеющихся в доступе РЛИ, по которым будет строиться обучающая выборка. Для сохранения информации об объектах на высоко детальных изображениях шаг по сетке предлагается выбирать равным минимальному значению межпиксельного расстояния среди всех снимков, планируемых к формированию обучающей выборки. Таким образом, будут согласованы межпиксельные расстояния для объектов.

Этап радиометрической коррекции

Следующий этап заключается в понижении общего уровня радиометрической несогласованности. Для согласования среднего уровня амплитуды фоновых участков предлагается следующий алгоритм:

Algorithm 1. Алгоритм осуществления радиометрической коррекции

Вход:

- M — массив датасетов, полученных каждым РСА;
- D — датасет, полученный каждым РСА; РЛИ $I \in D$;
- N — массив датасетов фоновых поверхностей, полученных каждым РСА;
- B — датасет фоновых поверхностей, характерных для каждого РСА;

J — РЛИ фоновой поверхности, РЛИ $J \in B$;

$SIZE(M) = SIZE(N)$, массивы M и N упорядочены согласно обрабатываемым РСА.

Выход:

R — массив согласованных снимков, полученных каждым РСА; O — РЛИ, $O \in R$;

$MaxMeanBg$ — максимальное среднее значение амплитуды фоновых поверхностей;

$MaxMean$ — максимальное среднее значение амплитуды по всем согласованным снимкам;

$MaxStdDev$ — максимальное среднеквадратическое отклонение амплитуды по всем согласованным снимкам.

procedure RadiometryCorrection(M, N)

MBg_per_SAR — массив средних значений фоновых поверхностей для каждого РСА.

$MaxMeanBg \leftarrow 0$

$MaxMean \leftarrow 0$

$MaxStdDev \leftarrow 0$

for всех датасетов фоновых поверхностей, полученных каждым РСА $B \in N$ **do**

$MBg \leftarrow 0$

for всех изображений фоновых поверхностей, входящих в датасет $J \in B$ **do**

$MBg \leftarrow MBg + MEAN(J)$

end for

$MBg_per_SAR(B) \leftarrow MBg / SIZE(B)$

if $MBg_per_SAR(B) > MaxMeanBg$ **then**

$MaxMeanBg \leftarrow MBg_per_SAR(B)$

end if

end for

for всех датасетов, полученных каждым РСА $D \in M$ **do**

$coef \leftarrow MaxMeanBg / MBg_per_SAR(D)$

for всех изображений, входящих в датасет РСА $I \in D$ **do**

$O \leftarrow I * coef$

$R \leftarrow O$

if $Mean(O) > MaxMean$ **then**

$MaxMean \leftarrow Mean(O)$

end if

if $StdDev(O) > MaxStdDev$ **then**

$MaxStdDev \leftarrow StdDev(O)$

end if

end for

end for

return $R, MaxMean, MaxStdDev$

end procedure

На выходе процедуры получим массив амплитудных снимков, согласованных по общему среднему.

Этап нормировки данных

Следующим этапом становится нормировка полученных растров с целью выделения наиболее значимой информации. Ключевой шаг на этом этапе — выбор порогового значения, по которому будет произведено отсечение диапазона яркости. В исследовании пороговое значение было принято равным максимальному значению среднего, умноженного на три максимальных величины среднеквадратического отклонения, определённых путём анализа снимков, полученных на предыдущем этапе. Затем проводится линейная передискретизация раstra в новый диапазон. В исследовании диапазон был выбран в пределах от 0 до 255.

Псевдокод предложенного алгоритма нормировки данных представлен ниже.

Algorithm 2. Алгоритм осуществления нормировки данных

Вход:

R — массив согласованных снимков; O — РЛИ, $O \in R$;
 Threshold — порог отсеечения.

Выход:

N — массив нормированных снимков, полученных каждым РСА; I — нормированное РЛИ, $I \in N$.

procedure DataNormalization(R)

Threshold = MaxMean + 3 * MaxStdDev

scale = 255 / Threshold

for всех РЛИ O ∈ R **do**

for всех пикселей РЛИ p ∈ O **do**

if p > Threshold **then**

 p ← Threshold

end if

end for

 I ← O * scale

 N ← I

end for

return N

end procedure

На *рис. 4* приведены фрагменты растров, полученных на выходе функции предварительной обработки РЛД для формирования композитного набора данных.

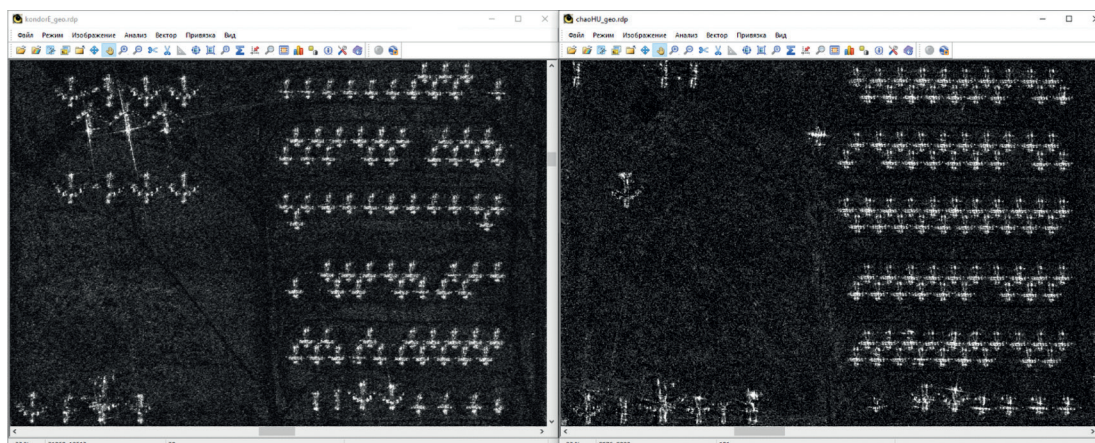


Рис. 4. Фрагменты РЛИ, полученных в результате предварительной обработки РЛД РСА «Кондор-Э» (слева) и РСА Chaohu-1 (справа)

В *табл. 3* приведена статистика по амплитуде изображений, полученных в результате предварительной обработки РЛД для формирования композитного набора.

Таблица 3. Статистические показатели, рассчитанные по амплитуде РЛИ, прошедших предварительную обработку

РЛИ, полученное РСА	Минимум	Максимум	Среднее	Дисперсия
«Кондор-Э»	0	255	61,735123	55,48591
Chaohu-1	0	255	64,813196	46,57328

Формирование обучающей выборки

На базе полученного композитного набора данных была проведена ручная разметка РЛИ. В результате разметки на снимках были определены четыре класса объектов. Размеченные РЛИ были разбиты на фрагменты размером 2500×2500 пикселей с перекрытием. На выходе получены 445 изображений. Разбиение на обучающую и тестовую выборку проводилось в соотношении 70 к 30 % соответственно. Таким образом, в обучающую выборку было включено 315 РЛИ, содержащих 2120 объектов различного класса. Тестовая выборка содержала 135 РЛИ с 681 объектом.

Анализ полученных результатов

Для подтверждения целесообразности использования набора алгоритмов предварительной обработки РЛД был поставлен эксперимент, оценивающий способность к обучению нейронной сети на предварительно обработанных и необработанных данных, к которым была применена геометрическая коррекция. Обучающая и тестовая выборки были идентичны по составу входных изображений. Снимки различались по радиометрическим показателям.

Для обучения нейронной сети была выбрана архитектура нейронной сети Faster-RCNN-FPN (*англ.* Region-based Convolutional Network Feature Pyramid Network) (Wu et al., 2019). Эта сеть хорошо себя зарекомендовала в исследованиях, проводимых ранее (Вьюков и др., 2020а, б). Преимущество сети состоит в работе с разномасштабными картами признаков (Lin et al., 2017). Обучение проводилось на одной и той же комбинации заданных гиперпараметров нейронной сети с использованием видеоускорителя NVidia Tesla A100.

С целью оценки качества работы алгоритма было принято решение использовать метрику усреднённой точности по всем классам. Для расчёта метрики были также использованы метрики достоверности, точности и полноты (Hui, 2018).

На основе анализа метрики точности и полноты была проведена оценка усреднённой точности (формула (1)). Если по оси X отложить точность, а по оси Y — полноту, то значение усреднённой точности определяется площадью под полученной кривой:

$$AP = \int_0^1 p(r) dr, \quad (1)$$

где AP — усреднённая точность по 10 пороговым значениям метрики пересечения над объединением и всем искомым классам; p — метрика точности; r — метрика полноты.

В ходе эксперимента обе модели прошли 3500 итераций обучения. Обучение на необработанных данных заняло 9,98 ч, обучение сети, работающей с предобработанными данными, — всего 2,2 ч. За это время первая сеть достигла усреднённой точности по 10 пороговым значениям метрики пересечения над объединением, равной 1,45. Вторая же сеть показала результат 52,41.

Внутренние показатели точности сеть, обучающаяся на предварительно обработанной композитной выборке, начала показывать уже с 1500-й итерации. Величина потерь на тестовой выборке на 1500-й итерации составила 0,12 и продолжала уменьшаться до момента останова процесса обучения, чего нельзя сказать про работу сети, обучающейся на необработанных данных.

Заключение

В представленной работе рассматриваются вопросы обнаружения и классификации искусственных объектов на изображениях, полученных радиолокаторами с синтезированной апертурой космического базирования, с использованием нейронной сети.

Предложена методика преобразования радиолокационных изображений, получаемых с РСА в различных частотных диапазонах и с разной поляризацией, для формирования композитного набора данных с целью повышения эффективности обучения нейронной сети.

Рассмотрены составляющие методики — набор операций предварительной обработки входных данных, позволяющий повысить уровень их взаимной согласованности.

Приведены результаты эксперимента по подтверждению целесообразности применения предложенной методики и составляющих её алгоритмов для повышения показателей качества работы нейронной сети. В процессе эксперимента в качестве входных данных использовались результаты реальных съёмок, выполненных космическими РСА. По результатам эксперимента можно сделать следующие основные выводы.

Обучение нейронной сети, решающей задачу обнаружения и классификации искусственных распределённых и групповых целей на данных, полученных с разных РСА, является малоэффективным. В процессе обучения сеть испытывает значительные трудности, что отражается как на скорости обучения, так и на конечных качественных показателях модели. В ходе исследования было установлено, что такое поведение сети связано с невозможностью одновременной коррекции весов таким образом, чтобы они одинаково хорошо работали с данными, обладающими высоким уровнем и геометрической, и радиометрической несогласованности.

Сформированная по предложенной методике единая обучающая выборка, полученная в разных диапазонах зондирования и в различных комбинациях поляризации, позволила осуществить эффективное обучение нейронной сети. Выборка содержала в себе групповые цели, расположенные на однородной подстилающей поверхности. По результатам исследования было выполнено сравнение сетей, обученных на необработанной выборке и выборке, подготовленной по представленной в работе методике. Так, обучение сети на выборке, сформированной по описанной методике, заняло в 4,5 раза меньше времени, за которое сеть смогла достичь внушительных показателей в усреднённой точности по 10 пороговым значениям метрики пересечения над объединением — 52,41, по сравнению со значением 1,45 для сети, обучающейся на необработанных данных.

Таким образом, экспериментальные исследования подтвердили, что предложенный алгоритм предварительной подготовки данных позволил обеспечить повышение обучаемости сети при работе с данными, получаемыми мультиполяризационными РСА.

Литература

1. Антонов И. К., Детков А. Н., Ницак Д. А., Тонких А. Н., Цветков О. Е. Воздушная разведка. Автоматизированное дешифрирование радиолокационных изображений. М.: Радиотехника, 2021. 296 с.
2. Верба В. С., Неронский Л. Б., Осипов И. Г., Турук В. Э. Радиолокационные системы землеобзора космического базирования. М.: Радиотехника, 2010. 680 с.
3. Вьюков Н. А., Елизаветин И. В., Савченко Б. С., Соболев А. В. (2020а) Разработка программного комплекса обнаружения объектов на изображениях, полученных космическими радиолокаторами с синтезированной апертурой антенны // 19-я Международ. конф. «Авиация и космонавтика»: сб. тез. М.: Перо, 2020. С 488–489.
4. Вьюков Н. А., Елизаветин И. В., Савченко Б. С., Соболев А. В. (2020б) Методы обнаружения искусственных объектов на снимках, получаемых радиолокаторами космического базирования // Тр. 63-й Всероссийской науч. конф. МФТИ. Аэрокосм. технологии. М.: МФТИ, 2020. С. 18–19.
5. Турук В. Э., Верба В. С., Голованова М. В. и др. РСА «Стриж» для малых космических аппаратов «Кондор-Э» // Современные проблемы дистанционного зондирования Земли из космоса. 2017. Т. 14. № 5. С. 69–83. DOI: 10.21046/2070-7401-2017-14-5-69-83.
6. Camus B., Barbu C. L., Monteux E. Robust SAR ATR on MSTAR with Deep Learning Models trained on Full Synthetic MOCeM data // arXiv preprint. arXiv:2206.07352. 2022. DOI: 10.48550/arXiv.2206.07352.
7. Hui J. MAP (Mean Average Precision) for Object Detection. 2018. <https://jonathan-hui.medium.com/map-mean-average-precision-for-object-detection-45c121a31173> (accessed 12.03.2023).
8. Inkawhich N., Inkawhich M. J., Davis E. K. et al. Bridging a gap in SAR-ATR: Training on fully synthetic and testing on measured data // IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing. 2021. V. 14. P. 2942–2955. DOI: 10.1109/JSTARS.2021.3059991.

9. Lin T. Y., Dollár P., Girshick R. et al. Feature pyramid networks for object detection // Proc. IEEE Conf. Computer Vision and Pattern Recognition. 2017. P. 2117–2125. DOI: 10.48550/arXiv.1612.03144.
10. Liu Z., Luo S., Wang Y. Mix MSTAR: A Synthetic Benchmark Dataset for Multi-Class Rotation Vehicle Detection in Large-Scale SAR Images // Remote Sensing. 2023. V. 15. No. 18. Article 4558. DOI: 10.3390/rs15184558.
11. Wang H., Chen S., Xu F., Jin Y. Q. Application of deep-learning algorithms to MSTAR data // 2015 IEEE Intern. Geoscience and Remote Sensing Symp. (IGARSS). 2015. P. 3743–3745. DOI: 10.1109/IGARSS.2015.7326637.
12. Wu Y., Kirillov A., Massa F., Lo W. Y., Girshick R. Detectron2. 2019. <https://github.com/facebookresearch/detectron2> (accessed 20.10.2023).

A harmonization technique for radar images obtained from various synthetic aperture radars to form a composite dataset for training a neural network

B. S. Savchenko

*Moscow Institute of Physics and Technology
Dolgoprudny 141700, Moscow Region, Russia
E-mail: savchenko.bs@phystech.edu
JSC Racurs, Moscow 129366, Russia*

Research in the field of detection and classification of artificial objects in radar images obtained by synthetic aperture radars is one of the most promising due to the objective properties of radar data. The use of well-known correlation algorithms for object detection and classification shows limited effectiveness when working on a wide range of classes. The use of neural network algorithms, which have proven themselves well in solving a number of similar optical imaging problems, is hampered by the lack of a high-quality training sample and the specific features of radar images. The available sets of training radar data for a number of classes of interest can be obtained in a different frequency range relative to the data that are planned to be processed. The aim of the work is to confirm the possibility of joint training of a neural network on mixed radar data obtained in several frequency ranges. The paper proposes a method for forming a single training dataset consisting of real data obtained in different sensing ranges and in various combinations of polarizations. The proposed technique consists of successive stages of geometric and radiometric correction of radar images, as well as their normalization, which makes it possible to ensure the consistency of radar images of the training dataset. To confirm the effectiveness of the technique an experiment on training a neural network on raw combined data and on data that had been preprocessed in accordance with the proposed methodology was performed. The experiment showed significant improvements in the performance of the neural network while training on data that was prepared according to the proposed methodology.

Keywords: synthetic aperture radar, composite dataset, neural network, object recognition, detection and classification

Accepted: 07.02.2024

DOI: 10.21046/2070-7401-2024-21-1-135-145

References

1. Antonov I. K., Detkov A. N., Nitsak D. A., Tonkikh A. N., Tsvetkov O. E., *Vozdushnaya razvedka. Avtomatizirovannoe deshifrirovaniye radiolokatsionnykh izobrazhenii* (Aerial reconnaissance. Automated decoding of radar images), Moscow: Radiotechnics, 2021, 296 p. (in Russian).
2. Verba V. S., Neronsky L. B., Osipov I. G., Turuk V. E., *Radiolokatsionnye sistemy zemleobzora kosmicheskogo bazirovaniya* (Space-borne Earth Surveillance Radar Systems), Moscow: Radiotechnics, 2010, 680 p. (in Russian).

3. Vyukov N. A., Elizavetin I. V., Savchenko B. S., Sobolev A. V. (2020a), Development of methods for detecting objects in images obtained by space radars with synthesized antenna aperture, *19th Intern. Conf. "Aviation and Cosmonautics"*, Moscow: Pen, 2020, pp. 488–489 (in Russian).
4. Vyukov N. A., Elizavetin I. V., Savchenko B. S., Sobolev A. V. (2020b), Methods for detecting artificial objects in images obtained by space-based radars, *Proc. 63rd All-Russian Scientific Conf. MIPT, Aerospace technologies*, Moscow: MIPT, 2020, pp. 18–19 (in Russian).
5. Turuk V. E., Verba V. S., Golovanova M. V. et al., Strizh SAR for small Condor-E satellites, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2017, Vol. 14, No. 5, pp. 69–83 (in Russian), DOI: 10.21046/2070-7401-2017-14-5-69-83.
6. Camus B., Barbu C. L., Monteux E., Robust SAR ATR on MSTAR with Deep Learning Models trained on Full Synthetic MOCEM data, *arXiv preprint, arXiv:2206.07352*, 2022, DOI: 10.48550/arXiv.2206.07352.
7. Hui J. *MAP (Mean Average Precision) for Object Detection*, 2018, <https://jonathan-hui.medium.com/map-mean-average-precision-for-object-detection-45c121a31173> (accessed 2.03.2023).
8. Inkawhich N., Inkawhich M. J., Davis E. K. et al., Bridging a gap in SAR-ATR: Training on fully synthetic and testing on measured data, *IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, Vol. 14, pp. 2942–2955, DOI: 10.1109/JSTARS.2021.3059991.
9. Lin T. Y., Dollár P., Girshick R. et al., Feature pyramid networks for object detection *Proc. IEEE Conf. Computer Vision and Pattern Recognition*, 2017, pp. 2117–2125, DOI: 10.48550/arXiv.1612.03144.
10. Liu Z., Luo S., Wang Y., Mix MSTAR: A Synthetic Benchmark Dataset for Multi-Class Rotation Vehicle Detection in Large-Scale SAR Images, *Remote Sensing*, 2023, Vol. 15, No. 18, Article 4558, DOI: 10.3390/rs15184558.
11. Wang H., Chen S., Xu F., Jin Y. Q., Application of deep-learning algorithms to MSTAR data, *2015 IEEE Intern. Geoscience and Remote Sensing Symp. (IGARSS)*, 2015, pp. 3743–3745, DOI: 10.1109/IGARSS.2015.7326637.
12. Wu Y., Kirillov A., Massa F., Lo W. Y., Girshick R., *Detectron2*, 2019, <https://github.com/facebookresearch/detectron2> (accessed 20.10.2023).