

Анализ классификационных признаков объектов военной техники набора MSTAR, выявляемых глубокой сверточной нейронной сетью в процессе обучения

И. Ф. Купряшкин

Военный учебно-научный центр военно-воздушных сил "Военно-воздушная академия
им. профессора Н. Е. Жуковского и Ю. А. Гагарина", Воронеж, Россия

✉ ifk78@mail.ru

Аннотация

Введение. Одним из наиболее эффективных инструментов для решения задачи классификации отметок объектов на радиолокационных изображениях являются нейронные сети. Однако процесс принятия ими решения непрозрачен, в связи с чем определение классификационных признаков объектов, вносящих существенный вклад в результат работы сети, – актуальная задача, составляющая часть общей проблемы "объяснимого искусственного интеллекта".

Цель работы. Определение классификационных признаков объектов военной техники, выявляемых глубокой сверточной нейронной сетью в процессе обучения.

Материалы и методы. Обучение и тестирование нейронной сети осуществлено с использованием фреймворков Keras и Tensorflow 2.0. В качестве датасета использована открытая часть набора радиолокационных изображений MSTAR. Для определения классификационных признаков использован метод GradCAM.

Результаты. В случае изображений с неподавленным фоном собственно отметка объекта вносит определяющий вклад в результат классификации только для 58 % изображений, для 6 % результат в основном обусловлен радиолокационной тенью объекта, а для 25 % – фоном местности. Для 11 % изображений наиболее выраженный классификационный признак установить не удалось. Для изображений с подавленным фоном результат классификации обусловлен распределением яркости в пределах отметки примерно в 60 % случаев, а ее контуром – в 40 % случаев.

Заключение. Особенность набора MSTAR в том, что каждый класс представлен набором изображений одного и того же реального объекта при различных ракурсах съемки. Следствием этого являются локальные особенности фона, не заметные для человека, уникальные для каждого класса объектов и способные внести определяющий вклад в результат обучения нейронной сети. Показано, что подавление фона и снижение размерности изображений устраняет этот эффект. Из полученных результатов также следует целесообразность проведения дальнейших исследований возможностей методов ХАИ применительно к современным нейросетевым детекторам и датасетам радиолокационных изображений.

Ключевые слова: глубокая сверточная нейронная сеть, радиолокационное изображение, классификационный признак

Для цитирования: Купряшкин И. Ф. Анализ классификационных признаков объектов военной техники набора MSTAR, выявляемых глубокой сверточной нейронной сетью в процессе обучения // Изв. вузов России. Радиоэлектроника. 2025. Т. 28, № 2. С. 45–56.

doi: 10.32603/1993-8985-2025-28-2-45-56

Конфликт интересов. Автор заявляет об отсутствии конфликта интересов.

Статья поступила в редакцию 24.10.2024; принята к публикации после рецензирования 16.03.2025; опубликована онлайн 30.04.2025



Analysis of MSTAR Object Classification Features Extracted by a Deep Convolutional Neural Network

Ivan F. Kupryashkin

Military Educational and Scientific Center of the Air Force
"N. E. Zhukovsky and Yu. A. Gagarin Air Force Academy", Voronezh, Russia

✉ ifk78@mail.ru

Abstract

Introduction. Deep convolutional neural networks are effective tools for classifying objects on radar images; however, their decision-making process is not transparent. This makes the determination of classification features of objects that affect the entire network operation a relevant research task. Such a study contributes to the field of explainable AI (XAI).

Aim. Determination of the classification features of military objects, detected by a deep convolutional neural network during training.

Materials and methods. The convolutional neural network was designed, trained, and tested using Keras and Tensorflow 2.0 libraries on the open part of the MSTAR dataset. The GradCAM method was used to visualize and determine the classification features of objects in the dataset.

Results. When using MSTAR images with an unsuppressed background, the object itself makes a significant contribution to the classification result only for 58 % of the images. For 6 % of the images, the classification result is determined by the object radar shadow, and for 25 % of images – by the background. For 11 % of the images, the most significant classification feature could not be established. For images with a suppressed background, in 60 and 40 % of the cases, brightness distribution and the object contour, respectively, made the main contribution to the classification result.

Conclusion. In the MSTAR dataset, each class of objects is represented by a set of radar images of the same real object from different view angles. This determines local background features, invisible to humans and unique to each class of objects. These features have a significant effect of the training outcome of the neural network. This effect can be eliminated by suppressing the background and reducing the image dimensionality. The obtained results also suggest the feasibility of further research into the XAI capabilities in relation to modern neural detectors and radar image datasets.

Keywords: deep convolutional neural network, radar image, classification feature

For citation: Kupryashkin I. F. Analysis of MSTAR Object Classification Features Extracted by a Deep Convolutional Neural Network. Journal of the Russian Universities. Radioelectronics. 2025, vol. 28, no. 2, pp. 45–56.
doi: 10.32603/1993-8985-2025-28-2-45-56

Conflict of interest. The author declares no conflicts of interest.

Submitted 24.10.2024; accepted 16.03.2025; published online 30.04.2025

Введение. Современные нейросетевые решения вызывают значительный интерес у разработчиков систем автоматического дешифрирования радиолокационных изображений (РЛИ) благодаря высоким результатам, демонстрируемым ими при решении задач поиска и классификации отметок объектов, сегментации изображений, подавления спекл-шума и др. [1–7].

Несмотря на это, неясное понимание процесса принятия решения, непрозрачность рабо-

ты нейронных сетей, их уязвимость к adversarial-атакам являются существенным препятствием на пути внедрения нейросетевых технологий в ряде областей [8]. Все это – часть более общей проблемы "объяснимого искусственного интеллекта" (XAI – eXplainable AI) [8], причем решения, принимаемые нейронными сетями, считаются самыми точными и одновременно – самыми непрозрачными по сравнению с остальными алгоритмами машинного обуче-

ния. На сегодняшний день существует ряд систем ХАИ от IBM, Microsoft, Google и др., включающих различные инструменты исследования и визуализации процесса и результатов работы нейросетей.

Однако в случае РЛИ необходимо отметить относительно малое количество публикаций, посвященных вопросам применения методов ХАИ к нейросетевым классификаторам или детекторам [9–12]. Учитывая недостаточную изученность этого направления, представляется целесообразным провести исследование хотя бы на примере простой глубокой сверточной нейронной сети (ГСНС). Безусловно, на практике при поиске объектов на крупномасштабных снимках в "чистом" виде они не применяются, так как уже несколько лет существуют быстродействующие решения, основанные на более продвинутых архитектурах [3–7]. Однако учитывая неочевидный характер работы нейронных сетей, особенно со сложной архитектурой, и сложность проблемы ХАИ в целом, более рациональным представляется проведение исследования по принципу "от простого к сложному", т. е. изучение на начальном этапе более простого и интуитивно понятного инструмента – ГСНС.

Что касается выбора данных, то на сегодняшний день в открытом доступе существует достаточно большое количество наборов РЛИ земной и морской поверхности, предназначенных для обучения и тестирования нейросетевых детекторов с целью их дальнейшего практического использования. Многие из них, в силу относительной доступности снимков и простоты разметки, являются наборами изображений судов на морской поверхности (HRSID, LS-SSDD, OpenSARShip, SAR-Ship и др.), сформированными на основе космической съемки такими РЛС, как Radarsat-2, Sentinel-1, TerraSAR-X, Gaofen-3 [7]. Следует также выделить крупный набор SARDet-100K, скомпилированный из других датасетов, в том числе и некоторых из перечисленных выше, и включающий 116 598 изображений, на которых представлены 245 653 объекта шести классов: танк, самолет, корабль, автомобиль, мост и гавань [13]. Однако в случае настолько сильно отличающихся размерами и формой объектов, как

танк, мост или гавань, определение классификационных признаков не представляет особого интереса. Более важным представляется изучение особенностей, выделяемых нейросетями в случае классификации объектов, близких по виду своих отметок. Например, объектов различных типов, но принадлежащих к какому-то общему классу (самолеты, объекты авто- и бронетехники, морские суда с сопоставимым водоизмещением и т. п.). Кроме того, общая черта перечисленных наборов – их формирование из РЛИ, имеющихся в открытом доступе и полученных с использованием различных датчиков, в различное время, в различных частотных диапазонах и с различным разрешением [7]. С одной стороны, это снижает риск переобучения детектора и способствует достижению его инвариантности к условиям формирования РЛИ и типу РЛС, но, с другой стороны, существенно затрудняет определение тонких отличий изображений объектов близких классов. Последнее особенно важно в случаях, когда датасет формируется в интересах обучения нейросетевых систем обработки высокодетальных снимков РЛС конкретного диапазона длин волн или даже типа.

В связи с изложенным целесообразно использовать широко известную открытую часть базового набора MSTAR (Moving and Stationary Target Acquisition and Recognition) [14]. Он включает РЛИ X-диапазона десяти образцов военной и специальной техники и отличается от большинства более современных наборов (например, OGSOD или SIVED [7]) качественной сбалансированностью, полным охватом азимутальных ракурсов съемки объектов с угловым шагом до двух градусов и высоким разрешением порядка 0.3 м. Такое высокое пространственное разрешение особенно важно, так как именно к этому уровню сегодня приблизились передовые космические системы радиолокационной съемки (Umbra, Capella, Iceye). Все это следствие изначальной цели его создания как банка высокодетальных радиолокационных отметок военной техники для исследования возможностей существующих и отработки новых алгоритмических решений по их детектированию, классификации и др. Несмотря на то, что с момента формирования этого набо-




Рис. 1. Количество публикаций по вопросам распознавания объектов на РЛИ по годам (2015–2024)

Fig. 1. Number of publications on the SAR ATR issues by year (2015–2024)

ра прошло уже почти 30 лет, на сегодняшний день в открытом доступе до сих пор отсутствуют банки РЛИ военной техники, сопоставимые по детальности и диапазону пространственных условий съемки с набором MSTAR. На рис. 1 приведена диаграмма [15], иллюстрирующая динамику роста по годам общего количества статей, посвященных вопросам распознавания объектов на РЛИ, и в том числе статей, в которых обсуждаемые решения так или иначе используют набор MSTAR.

В случае ГСНС, предназначенных для обработки изображений, часто применяется визуализация шаблонов максимальной активации фильтров сверточных слоев [16, 17], или так называемых карт активации классов (Class Activation Map – CAM), или тепловых карт, наглядно показывающих, какие области изображения в наибольшей степени повлияли на решение, принятое сетью [9–12, 17, 18].

В связи с этим представляет интерес дальнейшее изучение особенностей набора MSTAR методом GradCAM с целью определения классификационных признаков изображений объектов военной техники, выявляемых ГСНС в процессе обучения.

Методы. В качестве исходных данных использован набор MSTAR, из всех имеющихся изображений которого сформированы обучающий, проверочный и тестовый наборы, сведения об объемах (количестве изображений) которых приведены в табл. 1 [19]. Изображения объектов обучающих и проверочных наборов получены при съемке с углом визирования 17° , тестовых наборов – 15° .

Общее количество изображений обучающего, проверочного и тестового наборов составляет 1923, 891 и 2503 соответственно. В первом случае фон на изображениях не подавлялся, размерность изображений объектов, различная

Табл. 1. Объемы обучающих, проверочных и тестовых наборов

Tab. 1. Volumes of training, validation and test sets

Набор	Объекты									
	2C1	БМП-2	D7	T-62	БРДМ-2	БТР-60	БТР-70	T-72	Зил-131	ЗСУ-23-4
Обучающий	209	163	200	200	209	179	163	200	200	200
Проверочный	90	70	99	99	89	77	70	79	99	99
Тестовый	274	195	274	273	274	195	196	274	274	274




Рис. 2. Радиолокационные изображения объектов набора MSTAR

Fig. 2. Radar images of MSTAR dataset objects

в исходном наборе для разных классов и составляющая от 128×128 пикселей и более, приводилась к одинаковой для всех классов (120×120 пикселей) за счет "обрезки" изображений по краям. Изображения представлены в форме массивов комплексных отсчетов, поэтому предварительная обработка каждого из них включает преобразование в целочисленный 8-битный формат и нормировку по максимальному значению.

Примеры полученных радиолокационных изображений объектов приведены на рис. 2.

Разработка и обучение сети осуществлялись с использованием библиотеки глубокого обучения Keras [17] и фреймворка TensorFlow 2.0. Архитектура сети показана на рис. 3, общее количество ее настраиваемых параметров составляет 9 729 258. В качестве оптимизатора применяется алгоритм Adam с параметром скорости обучения 10^{-4} , в качестве функции потерь – перекрестная энтропия. Обучение осуществляется в течение двухсот эпох, и его общее время с использованием GPU (GeForce GTX1650) составляет около 15 мин, т. е. по 4...5 с на эпоху. В качестве дополнительного приема предотвращения переобучения применяется расширение данных посредством смещения каждого изображения по вертикали и горизонтали на случайное число пикселей от одного до пяти.

В [19] было показано, что фон местности, на которой расположены объекты, способен весьма существенно повлиять на результат ра-



Рис. 3. Архитектура нейронной сети

Fig. 3. Neural network architecture

боты нейронной сети. Так, ГСНС способна правильно классифицировать практически 50 % изображений даже в том случае, когда отметки собственно объектов и их радиолокационных теней полностью режектированы [19]. В связи с этим обучение и анализ осуществлялись для двух типов наборов изображений – с неподавленным фоном (рис. 2) и с подавленным фоном и пониженной до 44×44 пикселей размерностью (рис. 4). Подавление фона осуществлялось методом пороговой обработки, как описано в [19].




Рис. 4. Примеры изображений набора MSTAR с подавленным фоном

Fig. 4. MSTAR images with suppressed background

По результатам классификации изображений тестового набора с неподавленным фоном достигнутая точность составила 95.71 %, с подавленным фоном и пониженной размерностью – 97.2 %.

Следует отметить, что задача исследования – достигнуть не максимально возможной, а всего лишь достаточно хорошей точности сети для последующего анализа работы. Поэтому использовалась классическая архитектура VGG-типа [17, 20], а тщательный подбор гиперпараметров, направленный на повышение точности классификации, не проводился.

После обучения изображения тестового набора поочередно подавались на вход сети для определения их тепловых карт методом GradCAM [17, 18]. Метод GradCAM предполагает вычисление градиентов для класса, к которому сеть отнесла изображение, по отношению к последнему сверточному слою, усреднение градиентов для каждой карты признаков на выходе этого слоя, перемножение средних градиентов с картами признаков и суммирование результатов перемножения. RGB-отсчеты полученной тепловой карты с весом 0.4 суммировались с соответствующими отсчетами тестового изображения. Так как исходное тестовое изображение является 8-битным одноканальным, т. е. представлено в градациях серого, перед суммированием с тепловой картой оно преобразовывалось в трехканальное RGB-изображение с одинаковыми интенсивностями пикселей в каждом цветовом канале.

Результаты. Из результатов, полученных для набора изображений с неподавленным фоном, следует, что основными классификационными признаками могут являться распределение интенсивности отсчетов в пределах отметки объекта, т. е. собственно ее вид, очертания радиолокационной тени объекта, а в значительном числе случаев – фон окружающей местности. Для отдельных изображений полученные тепловые карты являются однородными, что не позволило установить наиболее существенные классификационные признаки в этих случаях.

На рис. 5 приведены примеры тепловых карт изображений объектов для случаев, когда наибольший вклад в решение сети о классе объекта внес фон местности.

На рис. 6 представлены примеры изображений в случаях, когда определяющим признаком для сети является вид радиолокационной тени объекта. При этом информативным может быть как сам участок тени, так и ее контур (БРДМ-2, ЗиЛ-131). В случае бульдозера D7 изображения, на которых тепловая карта соответствовала бы его тени, отсутствуют. Объекты данного класса вообще заметно отличаются от всех остальных характерным видом и размерами отметки, поэтому, скорее всего, сети просто незачем "учиться" использовать дополнительные фоновые признаки.

На рис. 7 приведены примеры изображений для случаев, когда существенный вклад в решение сети внесла собственно отметка объекта.




Рис. 5. Примеры тепловых карт изображений, для которых наиболее существенным классификационным признаком явился фон местности
Fig. 5. Heatmaps of images, for which the terrain background was the most significant classification feature




Рис. 6. Примеры тепловых карт изображений, для которых наиболее существенным классификационным признаком являлась радиолокационная тень объекта
Fig. 6. Heatmaps of images, for which the object shadow was the most significant classification feature

Кроме того, на рис. 8 приведены примеры неверно классифицированных изображений объектов. По их виду невозможно однозначно определить причину ошибочного результата, так как используются все классификационные признаки (вид отметки, тень и окружающий фон).

Распределение изображений тестового набора по наиболее выраженным классификационным признакам приведено в табл. 2. Эти оценки не лишены определенного субъективизма, так как не во всех случаях можно однозначно выделить конкретный доминирующий классификационный признак. Например, в ряде

случаев отметка и самого объекта, и его радиолокационной тени совместно вносят заметный вклад в решение сети.

Из данных табл. 2 следует, что собственно отметка объекта вносила основной вклад в 57.5 % изображений, т. е. всего лишь чуть больше, чем в половине случаев. Это приблизительно соответствует результату, полученному в [19], когда даже при полностью режестрированных отметках объектов точность классификации изображений составила не около 10 %, как этого можно было бы ожидать при 10 классах, а 50.72 %.




Рис. 7. Примеры тепловых карт изображений, для которых наиболее существенным классификационным признаком явился собственно вид отметки объекта

Fig. 7. Heatmaps of images, for which the object itself was the most significant classification feature




Рис. 8. Примеры тепловых карт ошибочно классифицированных изображений

Fig. 8. Heatmaps for misclassified images

Табл. 2. Распределение изображений тестового набора по наиболее выраженным классификационным признакам
Tab. 2. Distribution of test set images according to the most significant classification features

Наиболее выраженный классификационный признак	2С1	БМП-2	БРДМ-2	БТР-60	БТР-70	Д7	Т-62	Т-72	Зил-131	ЗСУ-23-4	Всего	Доля от общего объема тестового набора (2503), %
Отметка	150	155	43	96	36	260	179	194	76	251	1440	57.5
Тень	18	11	1	9	18	–	43	29	2	18	149	6.0
Фон	100	27	230	67	29	14	14	36	97	2	616	24.6
Не установлен	6	2	–	23	113	–	37	15	99	3	298	11.9
Всего	274	195	274	195	196	274	273	274	274	274	2503	100




Рис. 9. Примеры тепловых карт изображений объектов набора MSTAR с подавленным фоном

Fig. 9. Heatmaps of MSTAR images with suppressed background

Аналогичным образом осуществлялся расчет тепловых карт для тестового набора изображений с подавленным фоном и сниженной размерностью. Из анализа их вида следует, что основным классификационным признаком в

этом случае является или распределение интенсивности отсчетов в пределах самой отметки (примерно 60 % изображений), или вид ее контура (около 40 % изображений). Примеры изображений приведены на рис. 9, характери-

Табл. 3. Распределение изображений тестового набора с подавленным фоном по наиболее выраженным классификационным признакам

Tab. 3. Distribution of test set images with suppressed background according to the most significant classification features

Наиболее выраженный классификационный признак	2C1	БМП-2	БРДМ-2	БТР-60	БТР-70	D7	T-62	T-72	Зил-131	ЗСУ-23-4	Всего	Доля от общего объема тестового набора (500), %
Отметка	39	5	15	45	27	29	46	26	27	42	301	60.2
Контур	11	45	35	5	23	21	4	24	23	8	188	39.8
Всего	50	50	50	50	50	50	50	50	50	50	500	100

стика их распределения по наиболее выраженным классификационным признакам – в табл. 3.

Заключение. В ходе обучения классификации РЛИ объектов военной техники ГСНС ожидаемо демонстрирует характерную для нейросетей вообще "склонность" к переобучению, т. е. использованию всех скрытых закономерностей в данных, даже если они не имеют прямого отношения к решаемой задаче. В случае широко используемого базового набора MSTAR в роли такой закономерности часто выступают практически незаметные особенности фона местности, на которой расположены объекты того или иного класса (до 25 % изображений тестового набора). Также необходимо отметить, что в отдельных случаях (около 6 % изображений) определяющую роль для результата классификации играет радиолокационная тень объекта. Тем не менее, основным классификационным признаком остается распределение интенсивности в пределах отметки (около 58 % изображений от общего объема тестового набора).

Подавление фона и снижение размерности ("обрезка") изображений позволили исключить влияние местности и тени на результат работы сети. Установлено, что в этом случае примерно для 60 % изображений определяющим признаком явилось распределение интенсивности в пределах отметки, а для 40 % – вид ее контура. Определить более конкретно, какие устойчивые к поворотам особенности отметок объектов каждого класса являются информативными для сети, с помощью метода GradCAM не удалось. Скорее всего, это объективно обусловлено довольно близким сходством вида отметок объектов разных классов (за исключением D7 и ЗСУ-23-4), а также характерным для РЛИ спекл-шумом.

Приблизительно для 11 % изображений тестового набора метод GradCAM не позволил

сформировать информативные тепловые карты, что оставляет работу сети в значительной степени непрозрачной. Таким образом, даже в случае такого сбалансированного, продолжительно используемого и хорошо изученного набора, как MSTAR, требуется повышенное внимание к устранению скрытых закономерностей в данных перед их подачей на вход нейронной сети. В качестве рекомендации по предварительной подготовке изображений набора MSTAR предлагается включение процедуры подавления фона местности и снижение их размерности (с минимальной для отдельных классов 128×128 до одинаковой для всех классов 44×44).

Так как в статье рассмотрена только ГСНС с классической архитектурой VGG-типа, полученные результаты в части процентных соотношений вклада того или иного признака в результат классификации при использовании других, более современных архитектур (трансформеров, диффузионных моделей и др.), могут измениться. Оценки этих вкладов, очевидно, изменятся и в случае использования наборов РЛИ объектов другого класса (например, морских судов, самолетов, зданий и сооружений), или РЛИ с более низким разрешением, или полученных в другом частотном диапазоне.

В любом случае, из рассмотренного примера следует, что применение к РЛИ даже такого базового метода XAI, как GradCAM, позволяет уточнить особенности принятия решения нейронной сетью и на их основе сформулировать рекомендации по предварительной подготовке данных. Безусловно, значительный интерес представляет дальнейшее изучение возможностей и других методов XAI (SHAP, LIME, CEM и др.) по объяснению решений нейросетей, в том числе на более объемных и разнообразных наборах данных и для передовых современных архитектур.

Список литературы

1. Deep Learning Meets SAR / X. Zhu, S. Montazeri, M. Ali, Yu. Hua, Yu. Wang, L. Mou, Yi. Shi, F. Xu, R. Bamler. URL: <https://arxiv.org/abs/2006.10027> (дата обращения 10.03.2025).
2. Deep Learning for SAR Image Classification / H. Anas, H. Majdoulayne, A. Chaimae, S. M. Nabil // Intelligent Systems and Applications. IntelliSys 2019. Advances in Intelligent Systems and Computing. Vol. 1037. Cham: Springer, 2020. P. 890–898. doi: 10.1007/978-3-030-29516-5_67
3. Deep Learning for SAR Ship Detection: Past, Present and Future / J. Li, C. Xu, H. Su, L. Gao, T. Wang // Remote Sensing. 2022. Vol. 14, iss. 11. Art. № 2712. doi: 10.3390/rs14112712
4. Target Detection and Recognition in Synthetic Aperture Radar Images Using YOLO Deep Learning Methods / Wu T.-D., Wang H.-F., Hsu P.-H., Tiong K.-K., Chang L.-C., Chang C.-H. // Intern. Conf. on Consumer Electronics, PingTung, Taiwan, 17–19 July 2023. IEEE, 2023. P. 593–594. doi: 10.1109/ICCE-Taiwan58799.2023.10226736
5. Yu C., Shin Y. SMEP-DETR: Transformer-Based Ship Detection for SAR Imagery with Multi-Edge Enhancement and Parallel Dilated Convolutions // Remote Sensing. 2025. Vol. 17, iss. 6. Art. № 953. doi: 10.3390/rs17060953
6. A Ship Detection Method via Redesigned FCOS in Large-Scale SAR Images / M. Zhu, G. Hu, H. Zhou, S. Wang, Z. Feng, S. Yue // Remote Sensing. 2022. Vol. 14, iss. 5. Art. № 1153. doi: 10.3390/rs14051153
7. SARATR-X: A Foundation Model for Synthetic Aperture Radar Images Target Recognition / W. Li, W. Yang, Y. Hou, L. Liu, X. Li, X. Li. URL: <https://arxiv.org/html/2405.09365v1> (дата обращения 10.03.2025).
8. Мишра П. Объяснимые модели искусственного интеллекта на Python. Модель искусственного интеллекта. Объяснения с использованием библиотек, расширений и фреймворков на основе языка Python. М.: ДМК Пресс, 2022. 298 с.
9. Self-Matching CAM: A Novel Accurate Visual Explanation of CNNs for SAR Image Interpretation / Z. Feng, M. Zhu, L. Stankovic, H. Ji // Remote Sensing. 2021. Vol. 13, iss. 9. Art. № 1772. doi: 10.3390/rs13091772
10. LIME-Based Data Selection Method for SAR Images Generation Using GAN / M. Zhu, B. Zang, L. Ding, T. Lei, Z. Feng, J. Fan // Remote Sensing. 2022. Vol. 14, iss. 1. Art. № 204. doi: 10.3390/rs14010204
11. Fein-Ashley J., Kannan R., Prasanna V. Studying the Effects of Self-Attention on SAR Automatic Target Recognition. URL: <https://arxiv.org/abs/2409.00473> (дата обращения 10.03.2025).
12. Taufique A. M. N., Nagananda N., Savakis A. Visualization of Deep Transfer Learning in SAR Imagery. URL: <https://arxiv.org/abs/2103.11061> (дата обращения 10.03.2025).
13. SARDet-100K: Towards Open-Source Benchmark and ToolKit for Large-Scale SAR Object Detection / Y. Li, X. Li, W. Li, Q. Hou, L. Liu, M.-M. Cheng, J. Yang. URL: <https://arxiv.org/abs/2403.06534> (дата обращения 10.03.2025).
14. Kechagias-Stamatis O., Aouf N. Automatic Target Recognition on Synthetic Aperture Radar Imagery: A Survey. URL: <https://arxiv.org/abs/2007.02106> (дата обращения 10.03.2025).
15. NUDT4MSTAR: A New Dataset and Benchmark Towards SAR Target Recognition in the Wild / Y. Liu, W. Li, L. Liu, J. Zhou, X. Xiong, B. Peng, Y. Song, W. Yang, T. Liu, Z. Liu, X. Li. URL: <https://arxiv.org/abs/2501.13354> (дата обращения 10.03.2025).
16. Купряшкин И. Ф., Мазин А. С. Визуализация шаблонов максимальной активации фильтров сверточной нейронной сети в задаче классификации зашумленных радиолокационных изображений объектов // Цифровая обработка сигналов. 2021. № 4. С. 42–47.
17. Шолле Ф. Глубокое обучение на Python. СПб.: Питер, 2018. 400 с.
18. Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization / R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, D. Batra. URL: <https://arxiv.org/abs/1610.02391> (дата обращения 10.03.2025).
19. Купряшкин И. Ф. Сравнительные результаты точности классификации радиолокационных изображений объектов набора MSTAR сверточными нейронными сетями с различными архитектурами // Журн. радиоэлектроники. 2021. № 11. С. 1–27. doi: 10.30898/1684-1719.2021.11.14
20. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. URL: <https://arxiv.org/abs/1409.1556> (дата обращения 10.03.2025).

Информация об авторе

Купряшкин Иван Федорович – доктор технических наук (2017), доцент (2011), начальник кафедры боевого применения средств РЭБ (с воздушно-космическими системами управления и наводящимся оружием) Военного учебно-научного центра военно-воздушных сил "Военно-воздушная академия им. профессора Н. Е. Жуковского и Ю. А. Гагарина". Автор более 100 научных публикаций. Сфера научных интересов – радиолокационные системы; системы радиоэлектронного противодействия радиолокационным системам. Адрес: Военный учебно-научный центр военно-воздушных сил "Военно-воздушная академия им. профессора Н. Е. Жуковского и Ю. А. Гагарина", ул. Старых Большевиков, д. 54 А, Воронеж, 394064, Россия E-mail: ifk78@mail.ru

References

1. Zhu X., Montazeri S., Ali M., Hua Yu., Wang Yu., Mou L., Shi Yi., Xu F., Bamler R. Deep Learning Meets SAR. Available at: <https://arxiv.org/abs/2006.10027> (accessed 10.03.2025).
2. Anas H., Majdoulayne H., Chaimae A., Nabil S. M. Deep Learning for SAR Image Classification. Intelligent Systems and Applications. IntelliSys 2019. Advances in Intelligent Systems and Computing. Vol. 1037. Cham, Springer, 2020, pp. 890–898. doi: 10.1007/978-3-030-29516-5_67
3. Li J., Xu C., Su H., Gao L., Wang T. Deep Learning for SAR Ship Detection: Past, Present and Future. Remote Sensing. 2022, vol. 14, iss. 11, art. no. 2712. doi: 10.3390/rs14112712
4. Wu T.-D., Wang H.-F., Hsu P.-H., Tiong K.-K., Chang L.-C., Chang C.-H. Target Detection and Recognition in Synthetic Aperture Radar Images Using YOLO Deep Learning Methods. Intern. Conf. on Consumer Electronics, PingTung, Taiwan, 17–19 July 2023. IEEE, 2023, pp. 593–594. doi: 10.1109/ICCE-Taiwan58799.2023.10226736
5. Yu C., Shin Y. SMEP-DETR: Transformer-Based Ship Detection for SAR Imagery with Multi-Edge Enhancement and Parallel Dilated Convolutions. Remote Sensing. 2025, vol. 17, iss. 6, art. no. 953. doi: 10.3390/rs17060953
6. Zhu M., Hu G., Zhou H., Wang S., Feng Z., Yue S. A Ship Detection Method via Redesigned FCOS in Large-Scale SAR Images. Remote Sensing. 2022, vol. 14, iss. 5, art. no. 1153. doi: 10.3390/rs14051153
7. Li W., Yang W., Hou Y., Liu L., Liu X., Li X. SARATR-X: A Foundation Model for Synthetic Aperture Radar Images Target Recognition. Available at: <https://arxiv.org/html/2405.09365v1> (accessed 10.03.2025).
8. Mishra P. *Ob'yasnimyye modeli iskusstvennogo intellekta na Python. Model' iskusstvennogo intellekta. Ob'yasneniya s ispol'zovaniyem bibliotek, rasshireniy i freymvorkov na osnove yazyka Python* [Practical Explainable AI Using Python: Artificial Intelligence Model Explanations Using Python-based Libraries, Extensions, and Frameworks]. Moscow, DMK Press, 2022, 298 p. (In Russ.)
9. Feng Z., Zhu M., Stankovic L., Ji H. Self-Matching CAM: A Novel Accurate Visual Explanation of CNNs for SAR Image Interpretation. Remote Sensing. 2021, vol. 13, iss. 9, art. no. 1772. doi: 10.3390/rs13091772
10. Zhu M., Zang B., Ding L., Lei T., Feng Z., Fan J. LIME-Based Data Selection Method for SAR Images Generation Using GAN. Remote Sensing. 2022, vol. 14, iss. 1, art. no. 204. doi: 10.3390/rs14010204
11. Fein-Ashley J., Kannan R., Prasanna V. Studying the Effects of Self-Attention on SAR Automatic Target Recognition. Available at: <https://arxiv.org/abs/2409.00473> (accessed 10.03.2025).
12. Taufique A. M. N., Nagananda N., Savakis A. Visualization of Deep Transfer Learning in SAR Imagery. Available at: <https://arxiv.org/abs/2103.11061> (accessed 10.03.2025).
13. Li Y., Li X., Li W., Hou Q., Liu L., Cheng M.-M., Yang J. SARDet-100K: Towards Open-Source Benchmark and ToolKit for Large-Scale SAR Object Detection. Available at: <https://arxiv.org/abs/2403.06534> (accessed 10.03.2025).
14. Kechagias-Stamatis O., Aouf N. Automatic Target Recognition on Synthetic Aperture Radar Imagery: A Survey. Available at: <https://arxiv.org/abs/2007.02106> (accessed 10.03.2025).
15. Liu Y., Li W., Liu L., Zhou J., Xiong X., Peng B., Song Y., Yang W., Liu T., Liu Z., Li X. NUDT4MSTAR: A New Dataset and Benchmark Towards SAR Target Recognition in the Wild. Available at: <https://arxiv.org/abs/2501.13354> (accessed 10.03.2025).
16. Kupryashkin I. F., Mazin A. S. Visualization of Convolutional Neural Network Patterns in the Noisy Radar Images Classification Problem. Digital Signal Processing. 2021, no. 4, pp. 42–47. (In Russ.)
17. Chollet F. Deep Learning with Python. Shelter Island, Manning Publications, 2017, 384 p.
18. Selvaraju R. R., Cogswell M., Das A., Vedantam R., Parikh D., Batra D. Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization. Available at: <https://arxiv.org/abs/1610.02391> (accessed 24.10.2024).
19. Kupryashkin I. F. Comparative Results of the Classification Accuracy of MSTAR Dataset Radar Images by Convolutional Neural Networks with Different Architectures. J. of Radio Electronics. 2021, no. 11, pp. 1–27. (In Russ.) doi: 10.30898/1684-1719.2021.11.14
20. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. Available at: <https://arxiv.org/abs/1409.1556> (accessed 24.10.2024).

Information about the author

Ivan F. Kupryashkin, Dr Sci. (Eng.) (2017), Associate Professor (2011), Head of the Department of Combat Use of Electronic Warfare Systems (with Aerospace Control Systems and Guided Weapons) of Military Educational and Scientific Center of the Air Force "N.E. Zhukovsky and Y.A. Gagarin Air Force Academy". The author of more than 100 publications. Area of expertise: radar systems; systems of radio-electronic counteraction to radar. Address: Military Educational and Scientific Center of the Air Force "N. E. Zhukovsky and Yu. A. Gagarin Air Force Academy", 54 A, Starykh Bolshevikov St., Voronezh 394064, Russia
E-mail: ifk78@mail.ru