

Радиолокация и радионавигация

УДК 621.396.96

Оригинальная статья

<https://doi.org/10.32603/1993-8985-2022-25-1-36-46>

Влияние разрешающей способности радиолокационных изображений военной техники на точность их классификации глубокой сверточной нейронной сетью

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. Сегодня в качестве одного из наиболее перспективных инструментов для решения задачи классификации малоразмерных объектов на радиолокационных изображениях рассматриваются глубокие сверточные нейронные сети. Несмотря на это, в известных работах отсутствуют результаты системного исследования зависимости точности классификации, достигаемой сверточными нейросетями, от такой важной характеристики изображения, как его разрешающая способность.

Цель работы. Определение зависимости точности классификации объектов военной техники глубокой сверточной нейронной сетью от разрешающей способности их радиолокационных изображений.

Материалы и методы. Проектирование восьмислойной сверточной нейронной сети, ее обучение и тестирование осуществлено с использованием библиотеки глубокого обучения Keras и фреймворка Tensorflow 2.0. Для обучения и тестирования использована открытая часть стандартного набора радиолокационных изображений объектов военной техники десяти классов Moving and Stationary Target Acquisition and Recognition. Исходные значения весовых коэффициентов сетей MobileNetV1 и Xception, использованных для сравнительной оценки достигаемой точности классификации, получены по результатам обучения на наборе Imagenet.

Результаты. Точность классификации объектов военной техники быстро снижается с ухудшением разрешающей способности и составляет 97.91, 90.22, 79.13, 52.2 и 23.68 % при разрешении 0.3, 0.6, 0.9, 1.5 и 3 м соответственно. Показано, что использование предобученных сетей с архитектурами MobileNetV1 и Xception не приводит к улучшению точности классификации по сравнению с простой сетью VGG-типа.

Заключение. Эффективное распознавание объектов военной техники при разрешении, хуже чем 1 м, практически невозможно. Точность классификации, демонстрируемая глубокой нейронной сетью, существенно зависит от различия разрешающей способности изображений обучающего и тестового наборов. Значительному повышению устойчивости точности классификации к изменению разрешения способствует обучение на наборе изображений с различным разрешением.

Ключевые слова: глубокая сверточная нейронная сеть, радиолокационное изображение, точность классификации

Для цитирования: Купряшкин И. Ф. Влияние разрешающей способности радиолокационных изображений военной техники на точность их классификации глубокой сверточной нейронной сетью // Изв. вузов России. Радиоэлектроника. 2022. Т. 25, № 1. С. 36–46. doi: 10.32603/1993-8985-2022-25-1-36-46

Конфликт интересов. Автор заявляет об отсутствии конфликта интересов.

Статья поступила в редакцию 24.12.2021; принята к публикации после рецензирования 26.01.2022; опубликована онлайн 28.02.2022

Impact of the Radar Image Resolution of Military Objects on the Accuracy of their Classification 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 considered as one of the most promising tools for classifying small-sized objects on radar images. However, no systemic study has been reported so far on the dependence between the classification accuracy achieved by convolutional neural networks and such an important image characteristic as resolution.

Aim. Determination of a dependence between of the accuracy of classifying military objects by a deep convolutional neural network and the resolution of their radar images.

Materials and methods. An eight-layer convolutional neural network was designed, trained and tested using the Keras library and Tensorflow 2.0 framework. For training and testing, the open part of the standard MSTAR dataset comprising ten classes of military objects radar images was used. The initial weight values of the MobileNetV1 and Xception networks used for a comparative assessment of the achieved classification accuracy were obtained from the training results on the Imagenet.

Results. The accuracy of classifying military objects decreases rapidly along with a deterioration in resolution, amounting to 97.91, 90.22, 79.13, 52.2 and 23.68 % at a resolution of 0.3, 0.6, 0.9, 1.5 and 3 m, respectively. It is shown that the use of pre-trained MobileNetV1 and Xception networks does not lead to an improvement in the classification accuracy compared to a simple VGG-type network.

Conclusion. Effective recognition of military objects at a resolution worse than one meter is practically impossible. The classification accuracy of deep neural networks depends significantly on the difference in the image resolution of the training and test sets. A significant increase in the resistance of the classification accuracy to changes in the resolution can be achieved by training on a set of images with different resolutions.

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

For citation: Kupryashkin I. F. Impact of the Radar Image Resolution of Military Objects on the Accuracy of their Classification by a Deep Convolutional Neural Network. Journal of the Russian Universities. Radioelectronics. 2022, vol. 25, no. 1, pp. 36–46. doi: 10.32603/1993-8985-2022-25-1-36-46

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

Submitted 24.12.2021; accepted 26.01.2022; published online 28.02.2022

Введение. В настоящее время глубокие сверточные нейронные сети (ГСНС) являются одним из наиболее перспективных инструментов для решения задач поиска и классификации объектов на радиолокационных изображениях (РЛИ) [1–13]. Это обусловлено тем, что результаты сравнения точности классификации объектов с помощью алгоритмов, рассматриваемых как традиционные (K-ближайших соседей (K-Neighbor)), опорных векторов (SVM), множества решающих деревьев (Random Forest, AdaBoost, CART и др.) и алгоритмов, построенных на основе ГСНС, демонстрируют уверенное преимущество последних даже при отсутствии предобработки изображений [2], [14–16], а также их меньшую чувстви-

тельность к случайным смещениям или поворотам изображения.

Несмотря на значительный объем уже выполненных исследований в этой сравнительно новой области, в известных публикациях практически не отражены вопросы влияния изменения разрешающей способности РЛИ на результаты работы ГСНС. В то же время естественно ожидать, что ГСНС, обученная классифицировать объекты при одном разрешении, может решать эту задачу гораздо хуже при его изменении даже при аналогичных пространственных условиях радиолокационной съемки и для тех же самых объектов.

В связи с этим целью работы является определение зависимости точности классификации объ-

ектов глубокой сверточной нейронной сетью от разрешения их радиолокационных изображений.

Методы. В качестве исходных данных использован набор MSTAR (Moving and Stationary Target Acquisition and Recognition) [17], являющийся базовым для создания и изучения алгоритмов распознавания объектов на РЛИ. Используемая в описываемой работе открытая часть набора MSTAR включает РЛИ десяти образцов военной техники, полученные по результатам съемки РЛС Х-диапазона. Заявленное исходное разрешение составляет около 0.3 м. Примеры оптических и радиолокационных изображений объектов набора MSTAR приведены на рис. 1.

Из всех имеющихся изображений сформированы обучающий, проверочный и тестовый набо-

ры, сведения об объемах (количестве изображений) которых приведены в табл. 1. Изображения объектов обучающих и проверочных наборов получены при съемке с углом визирования 17°, тестовых наборов – 15°. При разработке и исследовании алгоритмов распознавания объектов на РЛИ на базе набора MSTAR подобное распределение близко соответствует стандартному, которое в иностранной литературе обозначается как SOC (Standard Operating Conditions) [3].

Общее количество изображений обучающего, проверочного и тестового наборов составляет 1923, 891 и 2503 соответственно.

Каждое изображение представлено в форме массива комплексных отсчетов \dot{I} , причем его размерность для разных классов объектов раз-




Рис. 1. Оптические и радиолокационные изображения объектов набора MSTAR

Fig. 1. Optical and radar images of MSTAR objects

Табл. 1. Характеристики обучающих, проверочных и тестовых наборов

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

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

лична. Для исключения влияния фона местности вычисленные амплитуды отсчетов исходных комплексных изображений сравниваются с порогом

$$I_{ij} = \begin{cases} \dot{I}_{ij}, & |\dot{I}_{ij}| \geq I_0; \\ 0, & |\dot{I}_{ij}| < I_0, \end{cases} \quad (1)$$

где порог $I_0 = I_{\Phi_n}$ определяется как значение n -го элемента упорядоченной по возрастанию выборки фоновых отсчетов $I_{\Phi_{(i-1)N_l+j}} = |\dot{I}_{ij}|$ из области изображения, заведомо не включающей отсчеты отметки объекта и его радиолокационной тени; $i \in [1; N_r]$, $j \in [1; N_l]$; N_r и N_l – количество строк и столбцов массива \dot{I} соответственно.

В качестве такой области принимаются участки изображения с интервалами индексов $i \in [1; N_r]$, $j \in [1; N_\Phi]$ и $i \in [1; N_r]$, $j \in [N_l - N_\Phi + 1; N_l]$ (заштрихованные области на рис. 2). Значение индекса определяется в соответствии с правилом




Рис. 2. Области фоновых отсчетов
Fig. 2. Areas of background samples

$n = \text{int}\{2pN_rN_\Phi\}$, где N_Φ – количество столбцов массива \dot{I} , выделяемых при формировании выборки фоновых отсчетов; $p \in [0; 1]$ – вероятность превышения порога I_0 амплитудой фоновых отсчета, т. е. вероятность ложной тревоги.

Так как при отсутствии фона исходная размерность изображений от 128×128 отсчетов и более с точки зрения классификации объектов является избыточной, на следующем этапе подготовки данных она понижается до 44×44 за счет осуществления операции вида

$$\dot{I}_{ij} = \dot{I}_{i+\text{int}\{N_r/2-N/2\}, j+\text{int}\{N_l/2-N/2\}}, \quad (2)$$

где $i = \overline{1, N}$ и $j = \overline{1, N}$ при $N = 44$.

Результат пороговой обработки (1) и понижения размерности (2) комплексного изображения преобразуется в целочисленный 8-битный формат в соответствии с правилом

$$I_{ij} = \begin{cases} \bar{I}_{ij}, & \bar{I}_{ij} \leq 2^8; \\ 2^8, & \bar{I}_{ij} > 2^8, \end{cases}$$

где $\bar{I}_{ij} = \text{int}\left\{2^9 \times \frac{|\dot{I}_{ij}| - I_{\min}}{I_{\max}}\right\}$; I_{\min} и I_{\max} – минимальная и максимальная амплитуды отсчетов массива \dot{I} соответственно.

Перед подачей на вход нейронной сети целочисленные значения диапазона $[0; 255]$ преобразуются в вещественные диапазона $[0; 1]$ делением на 255.

Примеры изображений подготовленного набора при $N_\Phi = 30$ и $p = 0.01$ приведены на рис. 3.




Рис. 3. Примеры изображений набора данных с подавленными фоновыми отсчетами

Fig. 3. Examples of images with suppressed background pixels

Разработка и обучение сети осуществлялись с использованием библиотеки глубокого обучения Keras [18] и фреймворка TensorFlow 2.0 [19].

Архитектура сети, для которой далее в статье принято обозначение C-CNN (Custom CNN), показана на рис. 4 и включает последовательности четырех пар сверточных слоев (Convolution Layers) с одинаковыми ядрами 3×3 и единичным шагом свертки. После каждой пары включены слои подвыборки (MaxPooling) 2×2 . Первая пара сверточных слоев включает по 32 фильтра, вторая – по 64, третья – по 128 и четвертая – по 256. Полносвязный классификатор включает входной слой (Dense) на 4096 входов и 256 выходов, слой 50-процентного прореживания (Dropout) и выходной слой с 10 выходами по числу классов. В качестве функции активации сверточных слоев и входного слоя классификатора используется кусочно-линейная (ReLU). Для описанной архитектуры количество настраиваемых параметров сети составляет 2 223 082.

При обучении используется адаптивный алгоритм Adam с параметром скорости обучения 10^{-4} (по умолчанию это значение составляет 10^{-3}),

обучение осуществляется в течение двухсот эпох. В качестве функции потерь применена перекрестная энтропия [19]. Общее время обучения с использованием GPU (GeForce GTX1660SUPER) составляет около 25 мин, т. е. примерно по 7 с на эпоху. В качестве дополнительного приема предотвращения переобучения применяется расширение данных (augmentation) смещением каждого изображения по вертикали и горизонтали на случайное число пикселей от одного до пяти и двукратной подачей обучающего набора на вход сети в течение каждой эпохи. По результатам классификации изображений тестового набора сеть C-CNN показала точность 97.91 %, т. е. неверно классифицировала 52 изображения из 2503.

При выборе архитектуры сети осуществлялся перебор различных вариантов сочетания гиперпараметров (количества и размерности сверточных слоев, типов функций активации, включение слоев пакетной нормализации (BatchNormalization), слоев прореживания (Dropout) на различных этапах и др.), а также сравнение скорости и качества обучения при различных способах инициализации весов, типах и параметрах оптимизаторов (Adam, RMSProp, Adadelta). В целом, к заметному улучшению точности классификации включение дополнительных слоев или этапов обработки не привело.

Несмотря на то, что сеть C-CNN представляет собой классическую сверточную сеть VGG-типа [20], достигнутая точность классификации 97.91 % довольно высока. Тем не менее, на сегодняшний день существует значительное разнообразие более сложных архитектур, включающих bottleneck-слои (сети типа Inception), residual-блоки (сети типа ResNet), а также ряд других решений и их сочетаний.

Как правило, эти сети обучают и тестируют на наборе данных цветных изображений ImageNet, используемом в проекте ImageNet Large Scale Visual Recognition Challenge (ILSVRC), в рамках которого различные программные продукты ежегодно соревнуются в классификации и распознавании объектов и сцен в базе данных ImageNet¹.

Для проверки того, повлияет ли существенным образом выбор архитектуры сети на результаты классификации изображений с разным раз-

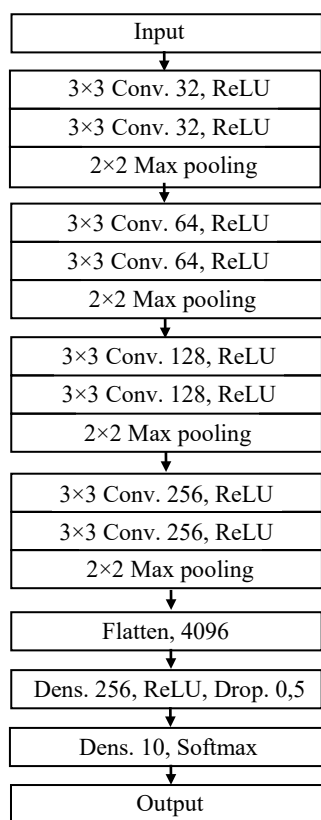


Рис. 4. Архитектура сети C-CNN
Fig. 4. C-CNN network architecture

¹ По состоянию на декабрь 2021 г. первенство в соревновании ILSVRC удерживает сеть CoAtNet-7 более чем с двумя миллиардами настраиваемых параметров.

решением, с использованием техники переноса обучения (Transfer Learning) [18, 21] дополнительно дообучены сети Xception [22] и MobileNetV1 [23]. Полносвязные классификаторы этих сетей заменены на собственные, включающие входной полносвязный слой на 512 выходов, слой 50 %-го прореживания и выходной полносвязный слой на 10 выходов по числу классов. При дообучении использован оптимизатор Adam с параметром скорости обучения 10^{-5} . С целью обеспечения равных условий обучения и корректности последующего сравнения результатов входные изображения перед подачей на вход сетей (C-CNN в том числе) приведены к размерности 128×128 , так как она является минимальной для сети Xception. Наилучшая точность на тестовом наборе для сети на основе архитектуры Xception составляет 97.36 %, MobileNetV1 – 96.47 %.

В целом, использование предобученных сетей с большим количеством слоев и более сложной архитектурой при исходном разрешении РЛИ около 0.3 м заметного улучшения точности не дало.

Подготовка наборов РЛИ с ухудшенным разрешением осуществляется фильтрацией изображений после пороговой обработки (1) и снижения их размерности (2) как

$$I_{ij} = \sum_{m=1}^N \sum_{n=1}^N |I_{mn}| G(m-i, n-j),$$

где $G(m, n) = \exp\left[-\frac{(m^2 + n^2)}{2k_r^2}\right]$; k_r – коэффициент, характеризующий, во сколько раз в результате фильтрации ухудшается разрешение изображения.




Рис. 5. Сечения нормированной автокорреляционной функции изображения при различных k_r

Fig. 5. Image normalized autocorrelation function cross sections at different k_r

В качестве меры разрешающей способности принята ширина автокорреляционной функции изображения по уровню 0.5 от максимума. На рис. 5 показаны сечения нормированной автокорреляционной функции одного и того же изображения по одной из координат, иллюстрирующие ее расширение при $k_r = 1, 2, 3, 5$ и 10.

Примеры изображений объектов с исходным разрешением 0.3 м и с ухудшенным в 2 (0.6 м), 3 (0.9 м), 5 (1.5 м) и 10 (3 м) раз показаны на рис. 6.

Обучение сетей C-CNN, MobileNetV1 и Xception проведено в течение 200, 150 и 100 эпох соответственно. Параметр скорости обучения оптимизатора Adam принимался равным 10^{-4} в случае C-CNN и 10^{-5} – в случаях MobileNetV1 и Xception. Зависимости, иллюстрирующие процесс обучения сети C-CNN на различных наборах изображений, приведены на рис. 7.




Рис. 6. Примеры изображений наборов с различным разрешением

Fig. 6. Examples of image sets with different resolutions

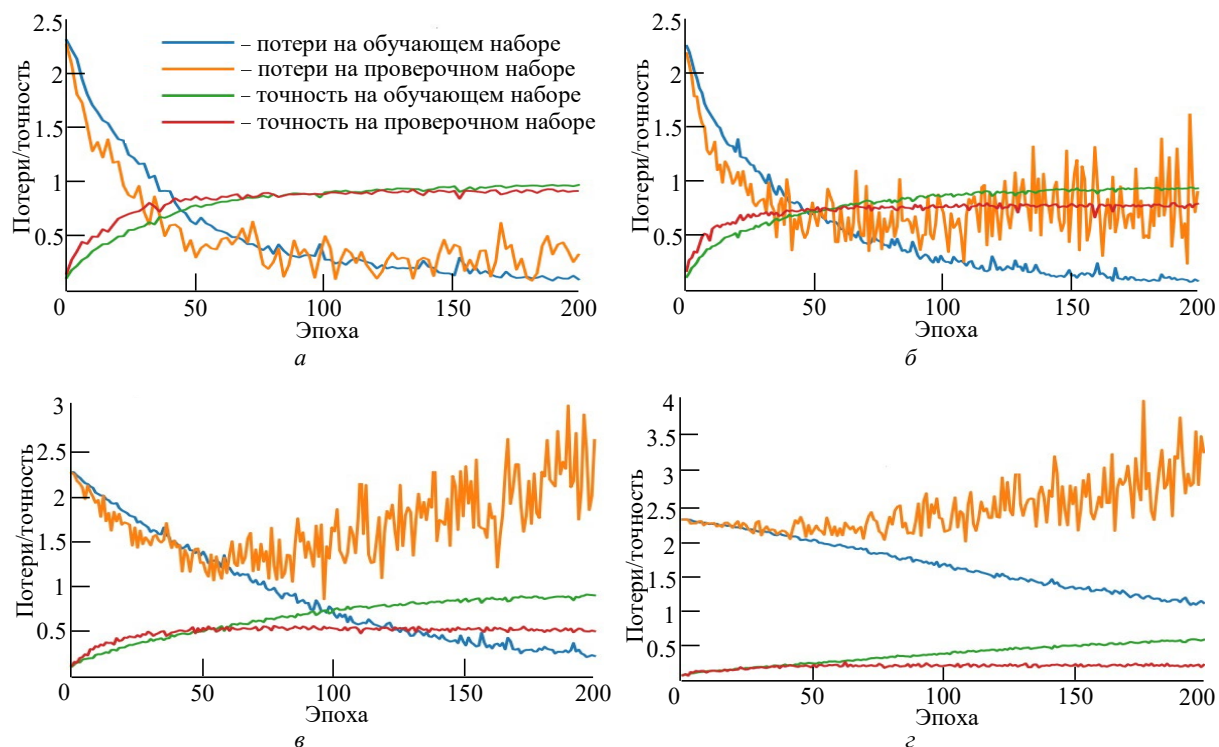


Рис. 7. Характеристики процесса обучения сети C-CNN при различном разрешении изображений:

$a - k_r = 2$; $b - k_r = 3$; $v - k_r = 5$; $z - k_r = 10$

Fig. 7. Characteristics of the C-CNN network training process at different image resolution:

$a - k_r = 2$; $b - k_r = 3$; $v - k_r = 5$; $z - k_r = 10$

Результаты. Характерной чертой является все более раннее проявление признаков переобучения сети по мере ухудшения разрешения набора данных (прекращение роста точности и рост потерь на проверочном наборе при непрерывных улучшении точности и снижении потерь на обучающем). Наилучшие точности на тестовом наборе продемонстрировали сети C-CNN с весами, настроенными на 172-й ($k_r = 2$; 89.82 %), 141-й ($k_r = 3$; 79.13 %), 129-й ($k_r = 5$; 52.2 %) и 113-й ($k_r = 10$; 23.68 %) эпохах. Сеть MobileNetV1 показала наилучшие точности на 126-й ($k_r = 2$; 90.22 %), 95-й ($k_r = 3$; 66.07 %), 145-й ($k_r = 5$; 40.83 %) и 113-й ($k_r = 150$; 20.99 %) эпохах, сеть Xception – на 33-й ($k_r = 2$; 86.54 %), 95-й ($k_r = 3$; 69.47 %), 94-й ($k_r = 5$; 44.91 %) и 100-й ($k_r = 10$; 21.59 %) эпохах соответственно.

Сравнительная диаграмма достигнутой максимальной точности классификации при различной разрешающей способности приведена на рис. 8.

Полные результаты, включающие тестирование всех сетей на всех наборах с различным разрешением, приведены в табл. 2.




Рис. 8. Сравнительная диаграмма точности классификации при различной разрешающей способности

Fig. 8. Comparative diagram of classification accuracy at different resolution

Результаты тестирования сетей в форме графических зависимостей приведены на рис. 9, $a-v$. Из их анализа следует, что чувствительность к изменению разрешения тестового набора является максимальной для сетей, обученных на наборах с высоким разрешением, и снижается по мере его ухудшения с одновременным падением точности.

С целью анализа возможности расширения диапазона разрешений изображений, эффективно классифицируемых сетью C-CNN, были сформированы обучающий, проверочный и тестовый наборы из 4063, 1904 и 5249 изображений соответственно. Наборы изображений каждого класса

Табл. 2. Результаты тестирования сетей на наборах с различным разрешением

Tab. 2. Results of network testing on image sets with different resolutions

Разрешение обучающего набора, м	Разрешение тестового набора, м				
	0.3	0.6	0.9	1.5	3
C-CNN					
0.3	97.91 %	13.22 %	10.93 %	10.93 %	10.97 %
0.6	14.34 %	89.82 %	31.61 %	13.9 %	11.54 %
0.9	16.39 %	52 %	79.13 %	19.27 %	10.86 %
1.5	21.43 %	28.73 %	37.62 %	52.2 %	10.69 %
3	12.62 %	15.3 %	15.18 %	16.27 %	23.68 %
MobileNetV1					
0.3	96.47 %	17.63 %	14.02 %	11.86 %	8.61 %
0.6	16.38 %	90.22 %	39.3 %	19.51 %	12.02 %
0.9	11.06 %	36.05 %	66.07 %	23.88 %	12.5 %
1.5	12.1 %	20.75 %	31.61 %	40.83 %	12.46 %
3	11.26 %	11.26 %	10.62 %	13.02 %	20.99 %
Xception					
0.3	97.36 %	23.92 %	15.76 %	14.46 %	10.89 %
0.6	19.51 %	86.54 %	44.99 %	18.67 %	10.77 %
0.9	11.78 %	48.19 %	69.47 %	24.32 %	11.09 %
1.5	13.54 %	23.12 %	33.77 %	44.91 %	13.14 %
3	9.13 %	10.49 %	9.86 %	12.78 %	21.59 %

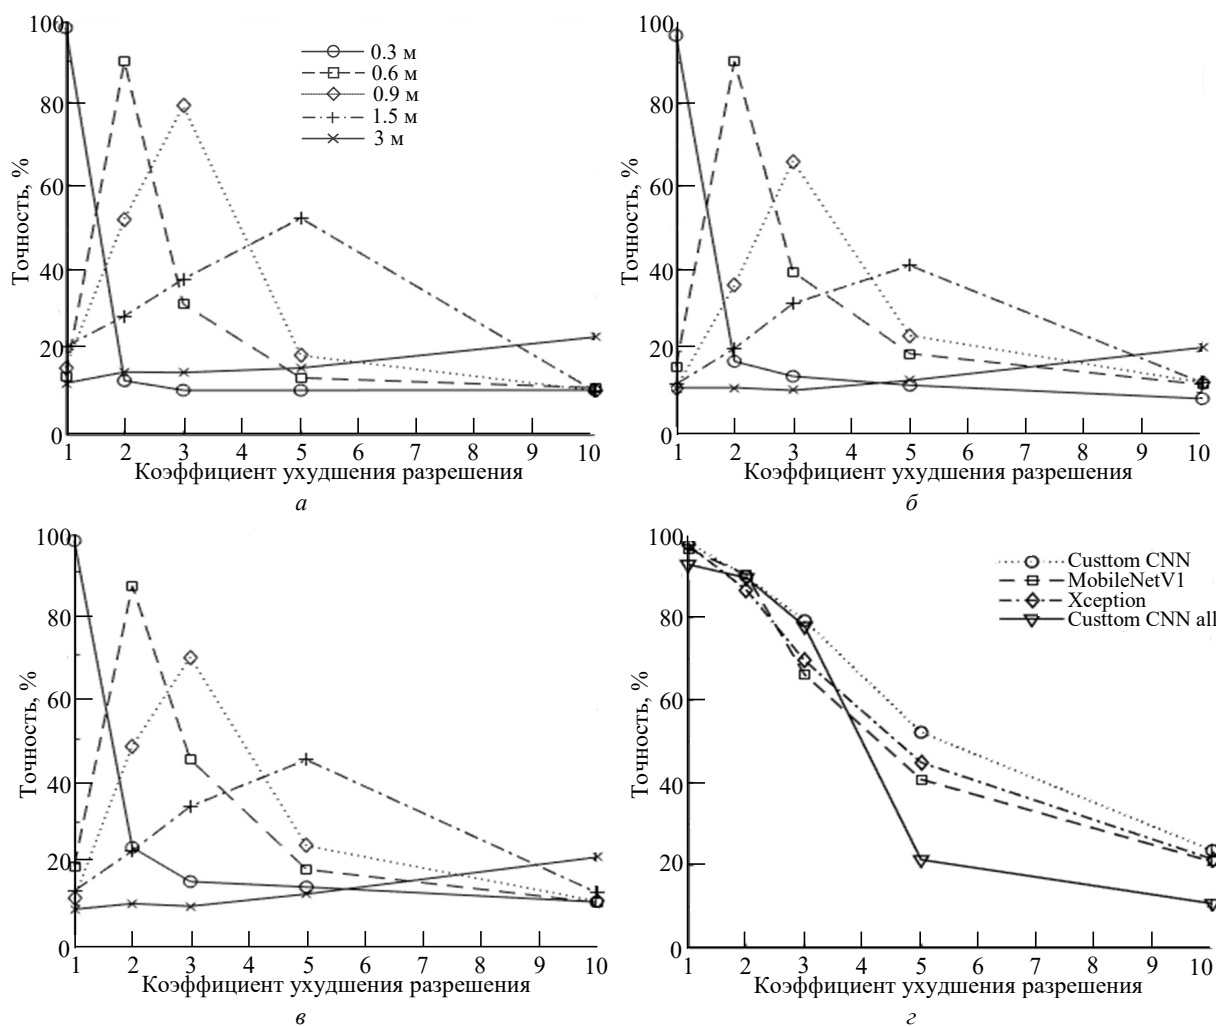


Рис. 9. Точности классификации, достигнутые на тестовых наборах с различным разрешением: а – C-CNN; б – MobileNetV1; в – Xception; г – на смешанном наборе с различным разрешением

Fig. 9. Classification accuracy on image test sets with different resolutions: а – C-CNN; б – MobileNetV1; в – Xception; г – on a mixed set with different resolutions

Табл. 3. Результаты тестирования сети C-CNN на наборах с различным разрешением

Tab. 3. Results of testing the CNN network on image sets with different resolutions

Разрешение тестового набора, м					
Случайное (0.3; 0.6; 0.9)	0.3	0.6	0.9	1.5	3
87.41	92.70	89.46	77.76	21.47	10.89

включали случайное количество изображений с исходным, ухудшенным в 2 и в 3 раза разрешением. Результаты тестирования сети C-CNN на всех наборах данных приведены в табл. 3.

На рис. 9, 2 приведены зависимости максимальных значений точности классификации, достигнутые различными сетями, от разрешающей способности радиолокационных изображений.

В целом, несмотря на некоторое ухудшение точности с 97.91 до 92.7 % при исходном разрешении, при его двух- и трехкратном ухудшении сеть продемонстрировала приблизительно те же точностные характеристики, что и сети, обученные только на соответствующих наборах данных.

Заключение. Таким образом, общим выводом является быстрое ухудшение точности распознавания объектов военной техники с ухудшением разрешающей способности их изображений.

Так, при разрешении 0.6 м наилучшая точность составила 90.22 % (MobileNetV1), 0.9 м – 79.13 % (C-CNN), 1.5 м – 52.2 % (C-CNN), 3 м – 23.68 % (C-CNN). Другими словами, эффективное распознавание объектов с точностью до типа при разрешении, хуже чем 1 м, практически невозможно даже при использовании одного из наиболее совершенных из существующих инструментов, а именно ГСНС. Существенно повысить устойчивость точности к изменению разрешения позволило обучение сети на наборе изображений с различным разрешением. Полученные оценки могут служить опорными при оценке возможностей распознавания объектов на РЛИ в целом, так как вряд ли какие-либо из существующих алгоритмов способны показать более высокие результаты по сравнению с ГСНС в обозримой перспективе.

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/pdf/2006.10027.pdf> (дата обращения 20.12.2021)
2. Application of Deep-Learning Algorithms to MSTAR Data / H. H. Wang, S. Chen, F. Xu, Y.-Q. Jin // IEEE Intern. Geoscience and Remote Sensing Symp. (IGARSS), Milan, Italy, 26–31 July 2015. IEEE, 2015. P. 3743–3745. doi: 10.1109/IGARSS.2015.7326637
3. Target Classification Using the Deep Convolutional Networks for SAR Images / S. Chen, H. Wang, F. Xu, Y.-Q. Jin // IEEE Transaction Geoscience and Remote Sensing. 2016. Vol. 54, № 8. P. 4806–4817. doi: 10.1109/TGRS.2016.2551720
4. Deep Learning for SAR Image Classification / H. Anas, H. Majdoulayne, A. Chaimae, S. M. Nabil // Intelligent Systems and Applications. Springer, Cham., 2020. P. 890–898. doi: 10.1007/978-3-030-29516-5_67
5. Chen S., Wang H. SAR Target Recognition Based on Deep Learning // Intern. Conf. on Data Science and Advanced Analytics (DSAA). Shanghai, China, 30 Oct. – 1 Nov. 2014. IEEE, 2014. P. 541–547. doi: 10.1109/DSAA.2014.7058124
6. Coman C., Thaens R. A Deep Learning SAR Target Classification Experiment on MSTAR Dataset // 19th Intern. Radar Symp. (IRS), Bonn, Germany, 20–22 June 2018. IEEE, 2018. P. 1–6. doi: 10.23919/IRS.2018.8448048
7. Furukawa H. Deep Learning for End-to-End Automatic Target Recognition from Synthetic Aperture Radar Imagery. URL: <https://arxiv.org/pdf/1801.08558.pdf> (дата обращения 20.12.2021)
8. Profeta A., Rodriguez A., Clouse H. S. Convolutional Neural Networks for Synthetic Aperture Radar Classification // Proc. SPIE 9843, Algorithms for Synthetic Aperture Radar Imagery XXIII. 2016. 98430M. doi: 10.1117/12.2225934
9. Wang Z., Xu X. Efficient deep convolutional neural networks using CReLU for ATR with limited SAR images // The J. of Engineering. 2019. Vol. 2019, № 21. P. 7615–7618. doi: 10.1049/joe.2019.0567
10. Wilmski M., Kreucher C., Lauer J. Modern Approaches in Deep Learning for SAR ATR // Proc. SPIE 9843, Algorithms for Synthetic Aperture Radar Imagery XXIII. 2016. 98430N. doi: 10.1117/12.2220290
11. A Novel Convolutional Neural Network Architecture for SAR Target Recognition / Yi. Xie, W. Dai, Z. Hu, Yi. Liu, C. Li, X. Pu // J. of Sensors. 2019. Art. 1246548. doi: 10.1155/2019/1246548
12. Xinyan F., Weigang Z. Research on SAR Image Target Recognition Based on Convolutional Neural Network // J. of Physics: Conf. Series. 2019. Ser. 1213. 042019. doi: 10.1088/1742-6596/1213/4/042019
13. A Deep Learning Fusion Recognition Method Based On SAR Image Data / J. Zhai, G. Dong, F. Chen, X. Xie, C. Qi, L. Li // Procedia Computer Science. 2019. Vol. 147. P. 533–541. doi: 10.1016/j.procs.2019.01.229
14. A New Algorithm of SAR Image Target Recognition based on Improved Deep Convolutional Neural Network / F. Gao, T. Huang, J. Sun, J. Wang, A. Hussain, E. Yang // Cognitive Computation. 2019. Vol. 11. P. 809–824. doi: 10.1007/s12559-018-9563-z

15. Malmgren-Hansen D., Engholm R., Østergaard Pedersen M. Training Convolutional Neural Net-works for Translational Invariance on SAR ATR // Proc. of EUSAR 2016: 11th European Conf. on Synthetic Aperture Radar, Hamburg, Germany, 6–9 Jun 2016. IEEE, 2016. P. 459–462.

16. Бородинов А. А., Мясников В. В. Сравнение алгоритмов классификации радарных изображений при различных методах предобработки на примере базы MSTAR // Сб. тр. IV Междунар. конф. и молодежной школы "Информационные технологии и нанотехнологии" (ИТНТ-2018). Самара: Новая техника, 2018. С. 586–594.

17. Kechagias-Stamatis O., Aouf N. Automatic Target Recognition on Synthetic Aperture Radar Imagery: A Survey. URL: <https://arxiv.org/ftp/arxiv/papers/2007/2007.02106.pdf> (дата обращения 20.12.2021)

18. Шолле Ф. Глубокое обучение на Python. СПб.:

Питер, 2018. 400 с.

19. Николенко С., Кадури А., Архангельская Е. Глубокое обучение. СПб.: Питер, 2018. 480 с.

20. Simonyan K., Zisserman A. Very Deep Convolutional Networks For Large-Scale Image Recognition. URL: <https://arxiv.org/pdf/1409.1556.pdf> (дата обращения 20.12.2021)

21. Huang Z., Pan Z., Lei B. What, Where and How to Transfer in SAR Target Recognition Based on Deep CNNs. URL: <https://arxiv.org/pdf/1906.01379.pdf> (дата обращения 20.12.2021)

22. Chollet F. Xception: Deep Learning with Depth-wise Separable Convolutions. URL: <https://arxiv.org/pdf/1610.02357.pdf> (дата обращения 20.12.2021)

23. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications / A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko. URL: <https://arxiv.org/pdf/1704.04861.pdf> (дата обращения 20.12.2021)

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. проф. 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/pdf/2006.10027.pdf> (accessed 20.12.2021)

2. Wang H. H., Chen S., Xu F., Jin Y.-Q. Application of Deep-Learning Algorithms to MSTAR. IEEE Intern. Geoscience and Remote Sensing Symp. (IGARSS), Milan, Italy, 26–31 July 2015. IEEE, 2015, pp. 3743–3745. doi: 10.1109/IGARSS.2015.7326637

3. Chen S., Wang H., Xu F., Jin Y.-Q. Target Classification Using the Deep Convolutional Networks for SAR Images. IEEE Transaction Geoscience and Remote Sensing. 2016, vol. 54, no. 8, pp. 4806–4817. doi: 10.1109/TGRS.2016.2551720

4. Anas H., Majdoulayne H., Chaimae A., Nabil S. M. Deep Learning for SAR Image. Intelligent Systems and Applications. Springer, Cham., 2020, pp. 890–898. doi: 10.1007/978-3-030-29516-5_67

5. Chen S., Wang H. SAR Target Recognition Based on Deep Learning. Intern. Conf. on Data Science and Advanced Analytics (DSAA). Shanghai, China, 30 Oct. – 1 Nov. 2014. IEEE, 2014, pp. 541–547. doi: 10.1109/DSAA.2014.7058124

6. Coman C., Thaens R. A Deep Learning SAR Target Classification Experiment on MSTAR Dataset. 19th Intern. Radar Symp. (IRS). Bonn, Germany, 20–22 June 2018. IEEE, 2018, pp. 1–6. doi: 10.23919/IRS.2018.8448048

7. Furukawa H. Deep Learning for End-to-End Automatic Target Recognition from Synthetic Aperture Radar Imagery. Available at: <https://arxiv.org/pdf/1801.08558.pdf> (accessed 20.12.2021)

8. Profeta A., Rodriguez A., Clouse H. S. Convolutional Neural Networks for Synthetic Aperture Radar Classification. Proc. SPIE 9843, Algorithms for Synthetic Aperture Radar Imagery XXIII. 2016, 98430M. doi: 10.1117/12.2225934

9. Wang Z., Xu X. Efficient Deep Convolutional Neural Networks Using CReLU for ATR with Limited SAR Images. The J. of Engineering. 2019, vol. 2019, no. 21, pp. 7615–7618. doi: 10.1049/joe.2019.0567

10. Wilmski M., Kreucher C., Lauer J. Modern Approaches in Deep Learning for SAR ATR. Proc. SPIE 9843, Algorithms for Synthetic Aperture Radar Imagery XXIII. 2016, 98430N. doi: 10.1117/12.2220290

11. Xie Yi., Dai W., Hu Z., Liu Yi., Li C., Pu X. A Novel Convolutional Neural Network Architecture for SAR Target Recognition. J. of Sensors. 2019, art. 1246548. doi: 10.1155/2019/1246548

12. Xinyan F., Weigang Z. Research on SAR Image Target Recognition Based on Convolutional Neural Network. J. of Physics: Conf. Series. 2019, ser. 1213, 042019. doi: 10.1088/1742-6596/1213/4/042019

13. Zhai J., Dong G., Chen F., Xie X., Qi C., Li L. A Deep Learning Fusion Recognition Method Based On SAR Im-

age Data. Procedia Computer Science. 2019, vol. 147, pp. 533–541. doi: 10.1016/j.procs.2019.01.229

14. Gao F., Huang T., Sun J., Wang J., Hussain A., Yang E. A New Algorithm of SAR Image Target Recognition based on Improved Deep Convolutional Neural Network. Cognitive Computation. 2019, vol. 11, pp. 809–824. doi: 10.1007/s12559-018-9563-z

15. Malmgren-Hansen D., Engholm R., Østergaard Pedersen M. Training Convolutional Neural Networks for Translational Invariance on SAR ATR. Proc. of EUSAR 2016: 11th European Conf. on Synthetic Aperture Radar, Hamburg, Germany, 6–9 Jun 2016. IEEE, 2016, pp. 459–462.

16. Borodinov A. A., Myasnikov V. V. Comparison of Radar Image Classification Algorithms for Various Pre-processing Methods Based on MSTAR Data. Proc. of the IV Intern. Conf. and Youth School "Information Technology and Nanotechnology" (ITNT-2018). Samara, New Equipment, 2018, pp. 586–594. (In Russ.)

17. Kechagias-Stamatis O., Aouf N. Automatic Target Recognition on Synthetic Aperture Radar Imagery: A Survey. Available at: <https://arxiv.org/ftp/arxiv/papers/2007/2007.02106.pdf> (accessed 20.12.2021)

18. Chollet F. Deep Learning with Python. NY, Manning, 2017, 384 p.

19. Nikolenko S., Kadurin A., Arkhangel'skaya E. *Glubokoe obuchenie* [Deep Learning]. SPb., Piter, 2018, 480 p. (In Russ.).

20. Simonyan K., Zisserman A. Very Deep Convolutional Networks For Large-Scale Image Recognition. Available at: <https://arxiv.org/pdf/1409.1556.pdf> (accessed 20.12.2021)

21. Huang Z., Pan Z., Lei B. What, Where and How to Transfer in SAR Target Recognition Based on Deep CNNs. Available at: <https://arxiv.org/pdf/1906.01379.pdf> (accessed 20.12.2021)

22. Chollet F. Xception: Deep Learning with Depth-wise Separable Convolutions. Available at: <https://arxiv.org/pdf/1610.02357.pdf> (accessed 20.12.2021).

23. Howard A.G., Zhu M., Chen B., Kalenichenko D. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. Available at: <https://arxiv.org/pdf/1704.04861.pdf> (accessed 20.12.2021)

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, Sarykh Bolshevikov Str., Voronezh 394064, Russia
E-mail: ifk78@mail.ru
