



DOI: <https://doi.org/10.30898/1684-1719.2022.6.8>

УДК: 621.396.96

ДЕТЕКТИРОВАНИЕ ОБЪЕКТОВ ВОЕННОЙ ТЕХНИКИ С ИСПОЛЬЗОВАНИЕМ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ НА РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЯХ, СФОРМИРОВАННЫХ В УСЛОВИЯХ ШУМОВЫХ ПОМЕХ

И.Ф. Купряшкин

**Военный учебно-научный центр Военно-воздушных сил «Военно-воздушная академия
имени профессора Н.Е. Жуковского и Ю.А. Гагарина» (г. Воронеж)
394064, Воронеж, ул. Старых Большевиков, д. 64**

Статья поступила в редакцию 6 мая 2022 г.

Аннотация. Приведено описание детектора отметок объектов на радиолокационных изображениях, реализующего обнаружение локальных неоднородностей с помощью алгоритма CFAR с их последующей двухальтернативной классификацией («объект» или «фон») глубокой сверточной нейронной сетью. С использованием данных набора MSTAR показано, что в случае однородного фона работу детектора можно считать удовлетворительной при отношении сигнал/помеха на изображении 5 дБ и более, и полностью сорванной при отношении сигнал/помеха менее минус 5 дБ

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

Автор для переписки: Купряшкин Иван Федорович, ifk78@mail.ru

Введение

Сочетание непрерывного улучшения пространственного разрешения и помехоустойчивости с качественным скачком эффективности систем автоматического дешифрирования радиолокационных изображений (РЛИ) за счет применения технологий глубокого обучения [1-6] делает системы видовой радиолокационной разведки весьма ценным источником разведывательных сведений и одновременно – весьма сложным объектом с точки зрения эффективного радиопротиводействия.

Из анализа известных работ следует, что все более широкое применение в разнообразных задачах автоматической обработки РЛИ, и, в первую очередь, в задачах автоматического поиска и классификации отметок объектов, находят глубокие сверточные нейронные сети (ГСНС) [7-26].

Однако в них практически не отражены результаты исследований эффективности автоматического поиска объектов с помощью ГСНС на РЛИ, сформированных в условиях преднамеренных помех. При этом, судя по тенденции к все более широкому использованию ГСНС, получение таких оценок в интересах уточнения требований к средствам радиопротиводействия авиационным и космическим РЛС является актуальной задачей.

В связи с этим целью работы является изучение возможностей глубоких сверточных нейронных сетей по поиску и классификации объектов военной техники на радиолокационных изображениях, сформированных в условиях преднамеренных активных шумовых помех.

Традиционная последовательность идентификации объектов на РЛИ включает в себя выделение областей интереса (ROI – Regions Of Interest), т.е. локальных неоднородностей, с последующим решением задачи классификации в их пределах [6, 27, 28].

Развитие детекторов объектов на основе ГСНС в основном направлено на поиск решений, обеспечивающих высокую скорость работы при приемлемом качестве результатов поиска и классификации. На сегодняшний день широкое применение находят такие архитектуры, как Fast-R-CNN, Faster-R-CNN, YOLO,

SSD [29]. Как правило, работа этих сетей основана на использовании известных эффективных архитектур (MobileNet, Inception, Resnet, Inception-ResNet, VGG), а их различия состоят в используемых подходах к формированию областей интереса, подавлению не-максимумов и др. [24-26, 29-33]. В ряде работ приводятся результаты применения подобных сетей в задаче поиска и классификации объектов на РЛИ [23-26].

Тем не менее, исходя из целей настоящего исследования, состоящих не в разработке архитектуры быстродействующего детектора, а в изучении возможностей ГСНС по обнаружению объектов на зашумленных изображениях вообще, целесообразным является применение более наглядного алгоритма поиска. В простейшем случае фрагменты общего РЛИ, последовательно выделяемые с помощью алгоритма типа CFAR [6, 27-28], могут подаваться на вход ГСНС, решающей задачу бинарной классификации («объект» или «фон»).

1. Характеристика и порядок подготовки обучающих и тестовых наборов данных

В качестве исходных данных используется набор Moving and Stationary Target Acquisition and Recognition (MSTAR) [34], являющийся базовым для создания и изучения алгоритмов распознавания отметок объектов на РЛИ. Открытая часть набора включает РЛИ десяти образцов военной техники X-диапазона с разрешением около 0,3 м. Примеры РЛИ объектов набора и их фотографии приведены на рис. 1.




Рис. 1. Оптические и радиолокационные изображения объектов набора MSTAR

Из всех имеющихся изображений объектов сформированы обучающий, проверочный и тестовой наборы объемом 2000, 813 и 2502 изображения соответственно. Изображения обучающего и проверочного наборов соответствуют съемке с углом визирования 17 градусов, тестового набора – 15 градусов.

Каждое РЛИ представлено в форме массива комплексных отсчетов \dot{I} . На начальном этапе формируется маска отсчетов отметки объекта как

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

где пороговое значение $I_0 = I_{\phi_n}$ определяется как значение n -го элемента упорядоченной по возрастанию векторизированной выборки фоновых отсчетов

$I_{\phi_{(i-1)N_l+j}} = |\dot{I}_{ij}|$ из области РЛИ, 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 \mathbf{I} соответственно.

В качестве такой области принимаются участки РЛИ с интервалами индексов $i \in [1; N_r]$, $j \in [1; N_\phi]$ и $i \in [1; N_r]$, $j \in [N_l - N_\phi + 1; N_\phi]$ (заштрихованные области на рис. 2). Индекс n определяется как $n = \text{int}\{2pN_rN_\phi\}$, где $p \in [0;1]$ примерно соответствует вероятности превышения порога I_0 амплитудой фонового отсчета.

Далее осуществляется поэлементное перемножение маски с исходным изображением, т.е. формируется комплексное изображение $\tilde{\mathbf{I}}$ с нулевыми отсчетами в фоновой области

$$\tilde{I}_{ij} = I_{ij}M_{ij}. \quad (2)$$

Так как при отсутствии фона исходная размерность изображений набора MSTAR от 128×128 отсчетов и более является избыточной, осуществляется ее понижение как

$$\tilde{I}_{ij} = \tilde{I}_{i+\text{int}\{N_r/2-N/2\}, j+\text{int}\{N_l/2-N/2\}}, \quad (3)$$

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




Рис. 2. Области фоновых отсчетов

В работе [10] уже проводилась оценка точности классификации объектов по зашумленным изображениям набора MSTAR сверточной сетью. Однако при этом собственно «зашумление» состояло в искажении некоторого количества пикселей изображения, выраженного в процентном соотношении к их общему количеству. Такой подход не учитывает специфику формирования преднамеренных помех и обработки принимаемых сигналов в РЛС [6].

В общем случае результатом воздействия прицельной по частоте квазинепрерывной шумовой помехи является повышение среднего фонового уровня в пределах РЛИ (рис. 3). При этом пространственные корреляционные свойства шума будут практически совпадать с корреляционными свойствами сигнального («незашумленного») РЛИ [6], и в пределах участка, сопоставимого по площади с отметкой отдельного объекта, его можно полагать стационарным.




Рис. 3. Пример изображения радиолокационного изображения, сформированного при отсутствии (а) и наличии (б) внешней шумовой помехи

Формируемое помеховое изображение представляет собой матрицу комплексных некоррелированных значений $\dot{\eta} = \eta_c + j\eta_s$ размерностью $N \times N$, при этом распределение элементов матриц действительной η_c и мнимой η_s частей соответствует гауссовскому с нулевым средним и единичной дисперсией.

Для обеспечения соответствия корреляционных характеристик сигнального и помехового изображений над матрицами \tilde{I} и $\dot{\eta}$ осуществляется процедура пространственной фильтрации

$$\tilde{I}_{ij} = \sum_{m=1}^N \sum_{n=1}^N \tilde{I}_{mn} G(m-i, n-j); \quad \tilde{\eta}_{ij} = \sum_{m=1}^N \sum_{n=1}^N \dot{\eta}_{mn} G(m-i, n-j), \quad (4)$$

где $G(m, n) = \exp\left(-\frac{m^2 + n^2}{2}\right)$.

В результате (4) автокорреляционные пики помехового и сигнального изображений характеризуются практически одинаковой формой и шириной, что

обычно и имеет место в результате обработки аддитивной смеси прицельной по частоте шумовой помехи и эхосигнала поверхности в процессе синтеза РЛИ [6].

Над полученной матрицей помехового изображения осуществляется операция приведения к единичной средней дисперсии

$$\bar{\eta}_{ij} = \frac{\tilde{\eta}_{ij}}{\sqrt{D\{\tilde{\eta}\}}}, \quad (5)$$

где $D\{\tilde{\eta}\}$ – оценка дисперсии элементов матрицы $\tilde{\eta}$ после фильтрации (4).

Далее осуществляется поэлементное суммирование комплексных сигнального и помехового изображений с последующим определением их абсолютных значений

$$I_{ij} = \left| \tilde{I}_{ij} + k_n \bar{\eta}_{ij} \right|, \quad (6)$$

где $k_n = \tilde{m}q\sqrt{\frac{2}{\pi}}$; q – требуемое отношение помеха/сигнал на РЛИ; \tilde{m} – оценка среднего значения амплитуд ненулевых отсчетов сигнального изображения \tilde{I} после фильтрации (4).

На заключительном этапе изображение (6) преобразуется в целочисленный 8-битный формат в соответствии с правилом

$$I_{ij} = \begin{cases} \bar{I}_{ij}, & \bar{I}_{ij} \leq 2^8 \\ 2^8, & \bar{I}_{ij} > 2^8 \end{cases}, \quad (7)$$

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

Примеры изображений гаубицы 2С1 «Гвоздика», сформированных при $q = -20; -15; -10; -5; 0; 5; 10; 15; 20$ дБ, приведены на рис. 4.




Рис. 4. Примеры изображений гаубицы 2С1 «Гвоздика» при различном отношении помеха/сигнал

Для формирования наборов изображений класса «фон» используются комплексные изображения участков местности (угол визирования при съемке 15 градусов, разрешение 0,3 м), также входящие в открытую часть базы MSTAR. Обучающий и тестовый наборы включают по 50 изображений участков местности, примеры которых, отличающиеся степенью однородности, показаны на рис. 5.




Рис. 5. Примеры фоновых изображений из наборов

Каждый фрагмент фонового изображения с размерностью 44×44 отсчетов формируется путем случайного выбора одного из пятидесяти фоновых изображений и задания случайного смещения верхнего левого угла фрагмента в его пределах. Далее выделенный массив преобразуется в 8-битный целочисленный формат в соответствии с (7). Объемы обучающего, проверочного и тестового наборов класса «фон» также составили 2000, 813 и 2502 изображений соответственно. Примеры фрагментов изображений этого класса приведены на рис. 6.




Рис. 6. Примеры фрагментов фоновых изображений

Формирование наборов зашумленных изображений класса «фон» осуществляется без этапа пороговой обработки в соответствии с выражениями (4)-(6) при $q = -20; -15; -10; -5; 0; 5; 10; 15; 20$ дБ. Особенностью является использование оценки среднего уровня отметок объектов при задании среднего уровня шумовой помехи на фоновых изображениях (6).

2. Архитектура и результаты обучения ГСНС С-CNN

Разработка и обучение сети осуществлялось с использованием библиотеки глубокого обучения Keras [35] и фреймворка TensorFlow 2.0 [36]. Архитектура сети включает четыре пары сверточных слоев (Convolution Layers) с 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 на 4096 входов и 256 выходов, слой 50-процентного прореживания (Dropout) и выходной слой с 2 выходами по числу классов («объект» и «фон»). В качестве функции активации используется кусочно-линейная (ReLU). Размерность входного изображения составляет 128×128 . Для описанной архитектуры количество настраиваемых параметров сети составляет $2'223'082$. Архитектура описанной сети, для которой далее в работе принято обозначение С-CNN (Custom CNN), показана на рис. 7.

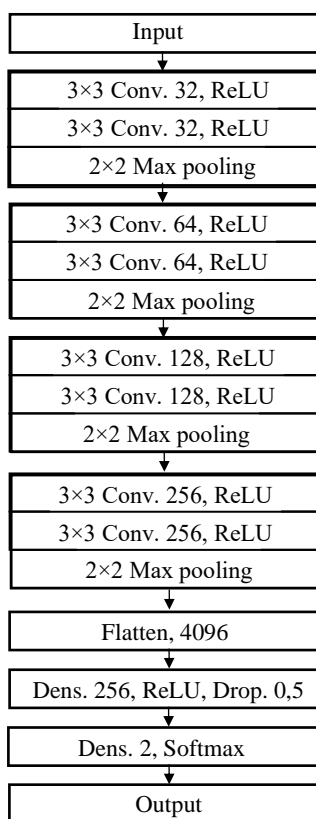


Рис. 7. Архитектура сети C-CNN

При обучении используется алгоритм Adam с параметром скорости обучения 10^{-4} , функцией потерь является перекрестная энтропия [36]. Перед подачей на вход сети целочисленные значения диапазона $[0; 255]$ преобразуются в вещественные диапазона $[0; 1]$ путем деления на 255.

С целью проверки возможности расширения диапазона отношений помеха/сигнал, в пределах которого качество работы сети существенно не снижается, также сформированы обучающий, проверочный и тестовый наборы из 12000, 4878 и 15012 изображений соответственно. Наборы для объектов и фонов включают случайное количество изображений с отношениями помеха/сигнал -40 , -20 , -15 , -10 , -5 и 0 дБ.

Значения точности классификации на всех наборах приведены в таблице 1. Из их анализа следует вывод, что при превышении помехой среднего уровня отметки объекта на 15 дБ и более двухальтернативная классификация сводится к простому угадыванию (точность около 50%). При $q = 5$ дБ и менее точность классификации остается достаточно высокой (95,53%) для вывода о работоспособности сети.

Таблица 1. Точность двухальтернативной классификации

Обучающий набор	Тестовый набор (отношение помеха/сигнал)								
	-20	-15	-10	-5	0	5	10	15	20
-20	99,67	99,61	59,27	50,40	50,00	49,97	50,06	50,00	50,02
-15	98,05	98,83	99,27	80,16	51,62	50,00	50,02	50,04	50,00
-10	98,79	99,05	99,37	86,31	54,80	50,02	49,95	49,91	49,97
-5	93,56	96,37	98,21	99,23	84,07	54,82	50,24	50,00	49,93
0	84,13	86,85	91,64	95,69	98,35	81,45	54,76	50,26	49,97
5	67,58	68,36	74,61	86,19	94,37	95,53	69,81	52,60	50,56
10	70,71	70,63	72,47	77,68	84,75	89,20	78,86	61,67	53,88
15	49,95	50,04	49,95	49,95	50,02	50,04	49,93	50,04	50,08
20	34,97	33,41	30,01	25,34	25,38	36,31	47,74	50,68	50,23
-40...0	99,39	99,19	99,03	98,99	99,03	79,92	53,62	50,24	49,93

Как видно из таблицы 1, сети, обученные на наборах данных с фиксированными отношениями помеха/сигнал, демонстрируют ухудшение точности не только при увеличении, но и при уменьшении его значения на тестовом наборе. При этом более высокую чувствительность в этом отношении демонстрируют сети, обученные на наборах с меньшими значениями отношения помеха/сигнал (-20 и -15 дБ). Сеть, обученная на расширенном наборе данных (-40...0 дБ), показала более высокую устойчивость. Так, при $q \leq 0$ дБ она демонстрирует практически те же значения точности классификации (отличия составляют десятые доли процента).

3. Результаты поиска отметок объектов на РЛИ с использованием ГСНС S-CNN в условиях шумовых помех

Для проверки эффективности ГСНС в задаче поиска отметок объектов на РЛИ сформировано тестовое однородное фоновое изображение, включающее 48 отметок объектов различных классов. Размерность матрицы фонового изображения \mathbf{I}_ϕ составляет 1478×1784 комплексных отсчетов, амплитуды

которых распределены по закону Вейбулла $w(x, a, b) = \frac{b}{a} \left(\frac{x}{a}\right)^{b-1} \exp\left\{-\left(\frac{x}{a}\right)^b\right\}$

с параметрами $a = 0,025$ и $b = 0,75$, а фазы – равномерно на интервале $[-\pi; \pi]$.

В пределах тестового изображения размещаются отсчеты отметок объектов и их радиолокационных теней в соответствии с правилом

$$I_{\phi_{ij}} = \begin{cases} I_{ij}, & M_{ij} = 1 \\ 0, & T_{ij} = 1 \\ I_{\phi_{ij}}, & M_{ij} = 0 \vee T_{ij} = 0 \end{cases}, \quad (8)$$

где M_{ij} – элементы маски отсчетов отметки объекта, определяемые в соответствии с (6); T_{ij} – элементы маски отсчетов радиолокационной тени объекта, определяемые как

$$T_{ij} = \begin{cases} 1, & |I_{ij}| < I_T \\ 0, & |I_{ij}| > I_T \end{cases}, \quad (9)$$

где пороговое значение I_T определяется как значение n -го элемента вектора, представляющего собой упорядоченный по убыванию амплитуд одномерный массив отсчетов отдельного изображения объекта (с фоном и тенью, т.е. исходного изображения из набора MSTAR без предварительной пороговой обработки). Значение индекса определяется в соответствии с правилом $n = \text{int}\{pN_r N_l\}$, где $p \in [0;1]$ приблизительно соответствует вероятности непревышения порога I_T амплитудой отсчета изображения. Далее над амплитудным изображением осуществляется операция пространственной фильтрации (4). Вид тестового изображения при $p = 0,85$ показан на рис. 8.




Рис. 8. Вид тестового изображения и примеры трех отметок объектов

Тестовые изображения при различных отношениях помеха/сигнал (q от минус 20 до 15 дБ с шагом 5 дБ) формируются путем выполнения операций (4)-(6), где в качестве отсчетов сигнального изображения используются отсчеты фонового изображения $\hat{\mathbf{I}}_{\phi}$, сформированные в соответствии с (8), а размерность исходного помехового изображения $\hat{\eta}$ составляет 1478×1784 . Примеры фрагментов тестовых изображений при различном отношении помеха/сигнал приведены на рис. 9.

Процесс детектирования отметок включает обнаружение областей интереса с помощью алгоритма CFAR с их последующей подачей на вход сети C-CNN, обученной при соответствующем отношении помеха/сигнал.




Рис. 9. Фрагменты тестового изображения при различном отношении помеха/сигнал: *a* – минус 20 дБ; *б* – минус 15 дБ; *в* – минус 10 дБ; *г* – минус 5 дБ; *д* – 0 дБ; *е* – 5 дБ; *ж* – 10 дБ; *з* – 15 дБ

Область фоновых отсчетов CFAR-детектора представляет собой прямоугольную рамку с шириной $N_C = 10$ отсчетов, размерность тестируемой области составляет 44×44 отсчета. Принятие решения о наличии области интереса осуществляется в соответствии с правилом

$$\sum_{i=1}^N \sum_{j=1}^N |I_{i+i_m, j+j_k}| \geq I_C, \quad (10)$$

где $N = 44$; $i_m = N_C + \Delta_C m$ и $j_k = N_C + \Delta_C k$ – номер строки и столбца верхнего левого угла рамки детектора на m, k -м шаге; Δ_C – шаг перемещения

рамки детектора; $m = \overline{1, N_M}$; $N_M = \text{int} \left\{ \frac{N_r - 2N_C}{\Delta_C} \right\}$; $k = \overline{1, N_K}$;

$N_K = \text{int} \left\{ \frac{N_l - 2N_C}{\Delta_C} \right\}$; $N_r = 1478$ и $N_l = 1784$ – количество строк и столбцов

тестового изображения соответственно; I_C – пороговое значение.

Пороговое значение I_C для каждого положения рамки детектора определяется путем решения уравнения вида

$$\frac{1}{\sigma_C \sqrt{2\pi}} \int_{I_C}^{\infty} \exp\left\{-\frac{(x - m_C)^2}{2\sigma_C^2}\right\} dx = F_{лм}, \quad (11)$$

где $F_{лм}$ – вероятность ложной тревоги.

Уравнение (16) записано с учетом того, что сумма амплитуд $N^2 = 1936$ области фоновых отсчетов распределена по закону, близкому к нормальному со средним значением $m_C = N^2 M\{\mathbf{I}_\phi\}$ и дисперсией $\sigma_C^2 = N^2 (1 + 4\pi) D\{\mathbf{I}_\phi\}$, где $M\{\mathbf{I}_\phi\}$ и $D\{\mathbf{I}_\phi\}$ – оценки среднего значения и дисперсии амплитуд в области фоновых отсчетов. Множитель $(1 + 4\pi)$ обусловлен тем, что в результате пространственной фильтрации тестового изображения двумерным гауссовским фильтром фоновые отсчеты становятся коррелированными, и дисперсия их суммы не является простой суммой дисперсий отдельных отсчетов, а определяется как

$$\sigma_C^2 = N^2 D\{\mathbf{I}_\phi\} \left(1 + 2 \sum_{m=1}^N \sum_{n=1}^N G(m, n)\right), \quad (12)$$

а, с учетом того, что $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \exp\left\{-\frac{1}{2}(x^2 + y^2)\right\} dx dy = 2\pi$, – как

$$\sigma_C^2 = N^2 (1 + 4\pi) D\{\mathbf{I}_\phi\}. \quad (13)$$

При выполнении условия (10) тестируемая область (область внутри рамки детектора) подается на вход сети С-CNN, и в случае, если значение точности классификации превышает 0,5 для класса «объект», принимается решение о его обнаружении.

Результаты детектирования объектов на тестовом изображении при $\Delta_C = 4$, $q = -20$ дБ и $F_{лм} = 10^{-4}$ приведены на рис. 10. На рис. 10а приведены результаты работы CFAR-детектора и сети С-CNN, включающие 539 обнаружений, показанных ограничивающими рамками (ОР), то есть так называемыми bounding box'ами. Это связано с малым шагом перемещения рамки детектора $\Delta_C = 4$, обуславливающим попадание в нее одного и того же объекта

несколько раз. В результате применения алгоритма NMS (non-maximum supression) для каждого объекта фиксируется только одно обнаружение с максимальной вероятностью его отнесения нейронной сетью к классу «объект» (рис. 10б). Итоговое количество обнаружений составило 42, то есть 7 объектов пропущено. Ложные обнаружения отсутствуют.




Рис. 10. Результаты детектирования при отношении помеха/сигнал минус 20 дБ: *а* – результаты детектирования (CFAR+C-CNN); *б* – результаты детектирования после подавления не-максимумов (CFAR+C-CNN+NMS)

Алгоритм NMS реализован следующим образом. На начальном этапе осуществляется расчет расстояний между каждой ОР и всеми остальными. Далее ОР, расстояние между которыми не превышает N отсчетов, объединяются в группы, каждая из которых предположительно соответствует одному объекту. На заключительном этапе в каждой группе оставляется только одна ОР, для которой вероятность принадлежности классу «объект», определенная ГСНС, является наибольшей.

На рис. 11 показаны результаты детектирования для тестовых изображений с отношением помеха/сигнал $q = -15; -5; 5$ дБ. При отношениях помеха/сигнал 10 и 15 дБ отметки объектов не обнаруживались.

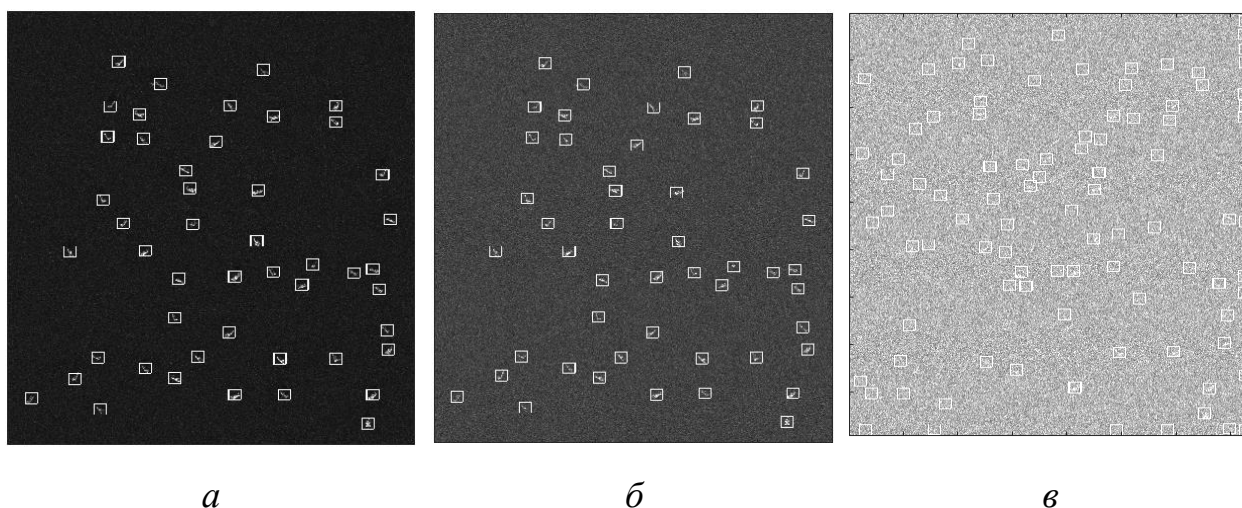


Рис. 11. Результаты детектирования (CFAR+C-CNN+NMS) при отношении помеха/сигнал: *а* – минус 15 дБ; *б* – минус 5 дБ; *в* – 5 дБ

В таблице 2 приведены результаты работы детектора при вероятности ложной тревоги $F_{лт} = 10^{-6}$ и различном отношении помеха/сигнал на обучающих наборах и тестовых изображениях (полужирным шрифтом выделены результаты детектирования при одинаковых отношениях помеха/сигнал). Заштрихованные ячейки соответствуют результатам работы детектора без пропусков целей, но при наличии ложных тревог. Ячейки, заштрихованные наиболее темным тоном, – полностью корректным результатам, когда одновременно обнаружены все 48 объектов при отсутствии пропусков и ложных обнаружений.

Из данных, приведенных в таблице 2, следует, что наиболее устойчивую работу показали сети, обученные на наборах с отношением помеха/сигнал в диапазоне от $q = -15$ до $q = -5$ дБ, причем сеть, обученная при $q = -5$ дБ, продемонстрировала безошибочную работу на тестовых изображениях с q от -20 до -10 дБ, а при $q = -5$ дБ на тестовом изображении пропустила только 3 (10%) объекта при отсутствии ложных обнаружений. Наиболее сбалансированные результаты работы продемонстрировал детектор с сетью, обученной на наборе с различным отношением помеха/сигнал $q = -40 \dots 0$ дБ (при малых q на тестовом изображении количество ложных тревог не превышает одной-двух).

Таблица 2. Результаты детектирования при различном отношении помеха/сигнал и вероятности ложной тревоги 10^{-6}

Отношение помеха/сигнал обучающего набора	Отношение помеха/сигнал на тестовом изображении	Количество обнаружений (CFAR+C-CNN)	Количество обнаружений (CFAR+C-CNN+NMS)	Количество пропусков	Количество ложных обнаружений
-15	-20	1971	48 (100%)	0 (0%)	0
	-15	1485	48 (100%)	0 (0%)	0
	-10	492	31 (64,6%)	17 (35,4%)	0
-10	-20	1863	48 (100%)	0 (0%)	0
	-15	1507	48 (100%)	0 (0%)	0
	-10	469	41 (85,4%)	7 (14,6%)	0
-5	-20	2324	48 (100%)	0 (0%)	0
	-15	2289	48 (100%)	0 (0%)	0
	-10	2019	48 (100%)	0 (0%)	0
	-5	1080	45 (93,8%)	3 (6,2%)	0
0	-20	1765	48 (100%)	0 (0%)	7
	-15	2203	48 (100%)	0 (0%)	5
	-10	2101	48 (100%)	0 (0%)	0
	-5	1893	48 (100%)	0 (0%)	0
	0	813	43 (89,6%)	5 (10,4%)	0
5	-20	100	11 (22,9%)	37 (77,1%)	33
	-15	241	23 (47,9%)	25 (52,1%)	19
	-10	1538	48 (100%)	0 (0%)	3
	-5	2146	48 (100%)	0 (0%)	1
	0	1008	44 (91,7%)	4 (8,3%)	0
	5	28	9 (18,8%)	39 (81,2%)	0
-40...0	-20	1836	48 (100%)	0 (0%)	1
	-15	1892	48 (100%)	0 (0%)	2
	-10	1795	48 (100%)	0 (0%)	0
	-5	1516	48 (100%)	0 (0%)	0
	0	636	39 (81,2%)	9 (18,8%)	0

Увеличение отношения помеха/сигнал на тестовом изображении приводит к увеличению числа пропусков целей при отсутствии ложных тревог. Это свидетельствует о пропуске отметок CFAR-детектором еще до подачи тестируемых областей изображения на вход нейросети. При малых q на тестовых изображениях (-20 и -15 дБ) детекторы с сетями, обученными на зашумленных наборах (при 0 и 5 дБ), генерируют ложные обнаружения, что

объясняется ошибками работы уже нейронной сети. В целом, из полученных результатов следует, что на однородном фоне при отношении помеха/сигнал на тестовом изображении не более -5 дБ работу детектора можно считать удовлетворительной, а при 5 дБ и более – сорванной.

Практический вывод состоит в том, что работу детектора целесообразно предварять оценкой степени зашумленности изображения, и, исходя из ее результатов, осуществлять загрузку наиболее подходящего набора весов сети S-CNN. В случае, если проведение этой оценки невозможно, наиболее целесообразно использование детектора с сетью, обученной на расширенном наборе.

Сформулированные выводы получены на основе анализа результатов работы детектора по тестовым изображениям с однородным фоном. Реальные же фоны (рис. 5) характеризуются существенной неоднородностью, способной привести к значительному увеличению количества ложных обнаружений. На рис. 12 и 13 показаны результаты работы детектора по РЛИ реальной местности при $F_{лт} = 10^{-6}$ и увеличенном до $0,9$ пороговом значении точности классификации «объект/фон» нейросетью для уменьшения количества ложных тревог. В обоих случаях использовалась сеть, обученная на расширенном наборе данных. На рис. 12а и 13а приведены полные изображения, 12б и 13б – увеличенные фрагменты, иллюстрирующие участки фона, ошибочно классифицированные как объекты. Очевидно, что количество ложных обнаружений существенно больше в неоднородных областях изображений. При этом как объекты могут классифицироваться как отдельные деревья, так и элементы искусственных сооружений (рис. 13).




Рис. 12. Полное изображение (а) и увеличенный фрагмент (б)
(1 ложная тревога)

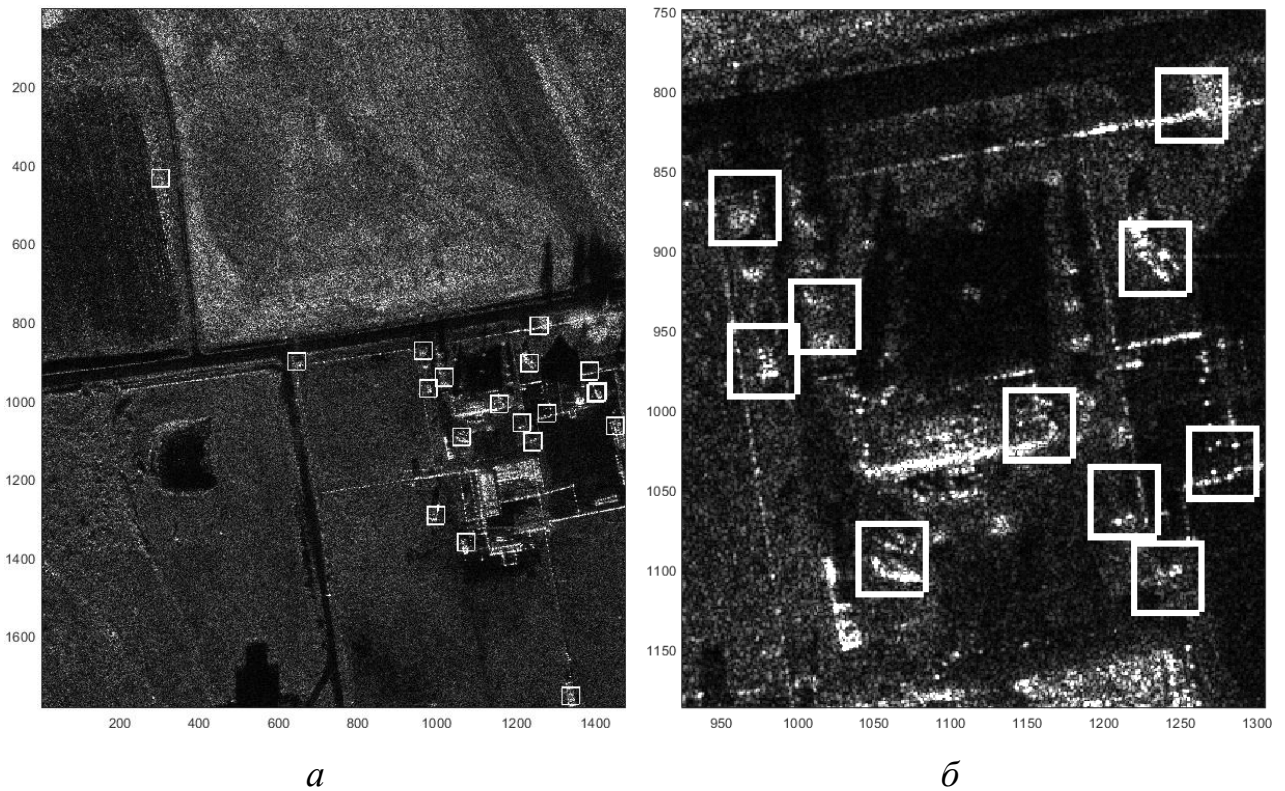


Рис. 13. Полное изображение (а) и увеличенный фрагмент (б)
(19 ложных тревог)

Заключение

Применение ГСНС в задаче бинарной классификации РЛИ объектов военной техники продемонстрировало высокую точность, максимальное достигнутое значение в беспомеховой обстановке составило 99,67%.

Одним из end-to-end-вариантов решения задачи поиска объектов на РЛИ является использование детектора, выделение областей интереса в котором выполняется алгоритмом типа CFAR, а отнесение этих областей к одному из классов («объект» или «фон») – с помощью предварительно обученной ГСНС. Общий результат состоит в том, что на однородном фоне при отношении помеха/сигнал на тестовом изображении не более минус 5 дБ работу детектора можно считать удовлетворительной, а при 5 дБ и более – сорванной. Существенному повышению устойчивости сети к изменению уровня помехи способствует обучение на наборах, включающих изображения с различными отношениями помеха/сигнал. Точность классификации при этом снижается незначительно (не более единиц процентов).

В случае неоднородного фона, когда на РЛИ присутствуют отметки деревьев, искусственные сооружения и т.п., даже в беспомеховой обстановке работа описанного детектора характеризуется значительным количеством ложных тревог. Снижение их количества возможно за счет селекции выделенных областей интереса с использованием дополнительных критериев перед их подачей на вход ГСНС, или за счет увеличения объема выборки объектов класса «фон» при обучении нейросети

Автор для переписки: Купряшкин Иван Федорович, ifk78@mail.ru

Литература

1. Alzubaidi L., Zhang J., Humaidi A.J., Al-Dujaili A., Duan Y., Al-Shamma O., Santamaria J., Fadhel M.A., Al-Amidie M., Farhan L. Review Of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions. *Journal of Big Data*. 2021. V.8. №53. <https://doi.org/10.1186/s40537-021-00444-8>
2. Rawat W., Wang Z. Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation*. 2017. V.29. P.2352-2449. https://doi.org/10.1162/neco_a_00990
3. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей. *Вестник ЮУрГУ. Серия «Вычислительная математика и информатика»*. 2017. Т.6. №3. С.28-59. <https://doi.org/10.14529/cmse170303>
4. Zhu X., Montazeri S., Ali M., Hua Yu., Wang Yu., Mou L., Shi Yi., Xu F., Bamler R. Deep Learning Meets SAR. *ArXiv*. 2020. <https://arxiv.org/abs/2006.10027>
5. Купряшкин И.Ф., Лихачев В.П., Рязанцев Л.Б. *Малогабаритные многофункциональные РЛС с непрерывным частотно-модулированным излучением*. Москва, Радиотехника. 2020. 279 с.
6. Купряшкин И.Ф., Лихачев В.П. *Космическая радиолокационная съемка земной поверхности в условиях помех*. Воронеж, Научная книга. 2014. 460 с.
7. Wang H., Chen S., Xu F., Jin Y.-Q. Application of Deep-Learning Algorithms to MSTAR data. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. 2015. P.3743-3745. <https://doi.org/10.1109/IGARSS.2015.7326637>
8. 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. V.54. №8. P.4806-4817. <https://doi.org/10.1109/TGRS.2016.2551720>
9. Anas H., Majdoulayne H., Chaimae A., Nabil S.M. Deep Learning for SAR Image Classification. *Intelligent Systems and Applications*. 2020. P.890-898. https://doi.org/10.1007/978-3-030-29516-5_67

10. Chen S., Wang H. SAR Target Recognition Based on Deep Learning. *International Conference on Data Science and Advanced Analytics (DSAA)*. 2014. P.541-547. <https://doi.org/10.1109/DSAA.2014.7058124>
11. Coman C., Thaens R. A Deep Learning SAR Target Classification Experiment on MSTAR Dataset. *2018 19th International Radar Symposium (IRS)*. 2018. P.1-6. <https://doi.org/10.23919/IRS.2018.8448048>
12. Furukawa H. Deep Learning for End-to-End Automatic Target Recognition from Synthetic Aperture Radar Imagery. *ArXiv*. 2018. <https://arxiv.org/abs/1801.08558>
13. 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, 98430M*. 14 May 2016. <https://doi.org/10.1117/12.2225934>
14. Wang Z., Xu X. Efficient deep convolutional neural networks using CReLU for ATR with limited SAR images. *The Journal of Engineering*. 2019. V.2019. №21. P.7615-7618. <https://doi.org/10.1049/joe.2019.0567>
15. Wilmanski M., Kreucher C., Lauer J. Modern Approaches in Deep Learning for SAR ATR. *Proc. SPIE 9843, Algorithms for Synthetic Aperture Radar Imagery XXIII, 98430N*. 14 May 2016. <https://doi.org/10.1117/12.2220290>
16. Xie Yi., Dai W., Hu Z., Liu Yi., Li C., Pu X. A Novel Convolutional Neural Network Architecture for SAR Target Recognition. *Journal of Sensors*. 2019. <https://doi.org/10.1155/2019/1246548>
17. Xinyan F., Weigang Z. Research on SAR Image Target Recognition Based on Convolutional Neural Network. *Journal of Physics: Conference Series*. 2019. V.1213. №4. <https://doi.org/10.1088/1742-6596/1213/4/042019>
18. Zhai J., Dong G., Chen F., Xie X., Qi C., Li L. A Deep Learning Fusion Recognition Method Based On SAR Image Data. *2018 International Conference on Identification, Information and Knowledge in the Internet of Things. Procedia Computer Science*. 2019. V.147. P.533-541. <https://doi.org/10.1016/j.procs.2019.01.229>

19. 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. V.11. P.809-824. <https://doi.org/10.1007/s12559-018-9563-z>
20. Malmgren-Hansen, D., Engholm, R., Østergaard Pedersen, M. Training Convolutional Neural Networks for Translational Invariance on SAR ATR. *Proceedings of EUSAR 2016: 11th European Conference on Synthetic Aperture Radar*. 2016. P.459-462.
21. Бородинов А.А., Мясников В.В. Сравнение алгоритмов классификации радарных изображений при различных методах предобработки на примере базы MSTAR. *Сборник трудов IV международной конференции и молодежной школы «Информационные технологии и нанотехнологии» (ИТНТ-2018)*. Самара, Новая техника. 2018. С.586-594.
22. Биленко С. В., Чередеев К. Ю., Зограбян М. К. Перспективы использования глубоких нейронных сетей в радиолокации. *Вопросы радиоэлектроники*. 2017. №1. С.57-63.
23. Казачков Е.А., Матюгин С.Н., Попов И.В., Шаронов В.В. Обнаружение и классификация малоразмерных объектов на изображениях, полученных радиолокационными станциями с синтезированной апертурой. *Вестник Концерна ВКО «Алмаз – Антей»*. 2018. №1. С.93-99.
24. Chang Y.-L., Anagaw A., Chang L., Wang Y.-C., Hsiao C.-Y., Lee W.-H. Ship Detection Based on YOLOv2 for SAR Imagery. *Remote Sensing*. 2019. V.11. P.786. <https://doi.org/10.3390/rs11070786>
25. Cui Z., Tang C., Cao Z., Liu N. D-ATR for SAR Images Based on Deep Neural Networks. *Remote Sensing*. 2019. V.11. P.906. <https://doi.org/10.3390/rs11080906>
26. Чорбаа Н.А., Ле Ань Ту, Толстой И.М. Сравнительный анализ методов детектирования объектов на радиолокационных изображениях при помощи нейронных сетей. *Научный результат. Информационные технологии*. 2020. Т.5. №4. С.15-25. <https://doi.org/10.18413/2518-1092-2020-5-4-0-3>

27. El-Darymli Kh., McGuire P., Power D., Moloney C. Target Detection in SAR Imagery: a state-of-the-art-survey. *Journal of Applied Remote Sensing*. 2013. V.7. <https://doi.org/10.1117/1.JRS.7.071598>
28. Blacknell D., Vignaud L. ATR of Ground Targets: Fundamentals and Key Challenges. Radar Automatic Target Recognition and Non-Cooperative Target Recognition. P.5-36. <https://doi.org/10.1049/PBRA033E>
29. Сирота А.А., Митрофанова Е.Ю., Милованова А.И. Анализ алгоритмов поиска объектов на изображениях с использованием различных модификаций сверточных нейронных сетей. *Вестник ВГУ, Серия «Системный анализ и информационные технологии»*. 2019. №3. С.123-137. <https://doi.org/10.17308/sait.2019.3/1313>
30. Береснев А.П., Зоев И.В., Марков Н.Г. Исследование сверточных нейронных сетей класса YOLO для мобильных систем детектирования объектов на изображениях. *GraphiCon 2018 Компьютерное зрение*. 2018. С.196-199.
31. Chen L., Zhou L., Liu J. Aircraft Recognition from Remote Sensing Images Based on Machine Vision. *Journal of Information Processing Systems*. 2020. V.16. № 4. P.795-808. <https://doi.org/10.3745/JIPS.02.0136>
32. Воронов С.В., Мухометзянов Р.Н., Воронов И.В., Шрамов В.А. Обнаружение и распознавание дорожных знаков в реальном времени на мобильных устройствах. *Автоматизация процессов управления*. 2018. №2 (52). С.105-111.
33. Ерохин Д.Ю., Ершов М.Д. Современные сверточные нейронные сети для обнаружения и распознавания объектов. *Цифровая обработка сигналов*. 2018. №3. С.64-69.
34. Kechagias-Stamatis O., Aouf N. Automatic Target Recognition on Synthetic Aperture Radar Imagery: A Survey. *ArXiv*. 2021. <https://arxiv.org/abs/2007.02106>
35. Шолле Ф. *Глубокое обучение на Python*. Санкт-Петербург, Питер. 2018. 400 с.
36. Николенко С., Кадурин А., Архангельская Е. *Глубокое обучение*. Санкт-Петербург, Питер. 2018. 480 с.

Для цитирования:

Купряшкин И.Ф. Детектирование объектов военной техники с использованием сверточной нейронной сети на радиолокационных изображениях, сформированных в условиях шумовых помех. *Журнал радиоэлектроники* [электронный журнал]. 2022. №6. <https://doi.org/10.30898/1684-1719.2022.6.8>