

DOI 10.15826/urej.2024.8.1.003

УДК 621/312/01(076)

Современное состояние проблемы распознавания радиолокационных изображений надводных кораблей средствами космического мониторинга

Л. Г. Доросинский✉, Н. С. Виноградова

Уральский федеральный университет имени первого Президента России Б. Н. Ельцина, 620002, Российская Федерация, г. Екатеринбург, ул. Мира, 32

✉ l.g.dorosinskiy@urfu.ru

Аннотация. Проблема синтеза и анализа алгоритмов обработки радиолокационных изображений пространственно-распределенных целей, полученных средствами космического мониторинга, была и остается одной из наиболее значимых как с теоретических, так и практических позиций для обеспечения безопасности мореплавания, контроля за незаконной добычей рыбы, мониторинга и управления кризисными ситуациями, такими как естественные бедствия, миграционные потоки и другие.

Одним из наиболее распространенных приложений названной проблемы является распознавание надводных кораблей, которому и посвящен данный обзор, выполненный по иностранным источникам.

В связи с этим предлагаемый обзор, содержащий достаточно подробный анализ современных методов решения названной задачи, предложенных широким кругом авторов в последние десятилетия, будет полезен создателям и исследователям средств космического наблюдения за состоянием морской поверхности.

Ключевые слова: пространственно-распределенная цель, надводный корабль, радиолокационное изображение, обнаружение, распознавание, отношение сигнал/шум, разрешающая способность.

Для цитирования: Доросинский Л. Г., Виноградова Н. С. Современное состояние проблемы распознавания радиолокационных изображений надводных кораблей средствами космического мониторинга. *Ural Radio Engineering Journal*. 2024;8(1):55–84. DOI: 10.15826/urej.2024.8.1.003.

State of the Art of Radar Images Recognition of Surface Ships by Means of Space Monitoring

L. G. Dorosinskiy✉, **N. S. Vinogradova**

Ural Federal University named after the first President of Russia B. N. Yeltsin,
32 Mira Str., Ekaterinburg, 620002, Russian Federation

✉ l.g.dorosinskiy@urfu.ru

Abstract. The issue of synthesizing and analyzing algorithms of processing radar images of spatially distributed targets, obtained through space monitoring tools, remains one of the most significant both theoretically and practically. This is particularly crucial for ensuring maritime safety, monitoring illegal fishing activities, and managing crisis situations such as natural disasters and migration flows.

One of the most common applications of this problem is the recognition of surface ships, to which this review is devoted. The review is performed using foreign materials.

Thus, the proposed review, which includes a detailed analysis of contemporary methods addressing the mentioned challenges, proposed by a wide range of authors over the past decades, will be valuable for developers and researchers in the field of space observation of marine surface conditions.

Keywords: Spatially Distributed Target, Surface Ship, Radar Image, Detection, Pattern Recognition, Signal-to-Noise Ratio (SNR), Range Resolution Half Width

For citation: Dorosinskiy L. G., Vinogradova N. S. State of the art of radar images recognition of surface ships by means of space monitoring. *Ural Radio Engineering Journal*. 2024;8(1):55–84 (In Russ.) DOI: 10.15826/urej.2024.8.1.003

Список сокращений

ACM — Active Contour Model

CFAR — Constant False Alarm Rate

CNN — Convolutional Neural Network

CSM — Cross-Sectional Method

RF — Random Forest

SD — Saliency Detector

SVM — Support Vector Machine

SSDD — SAR Ship Detection Dataset

ИНС — искусственные нейронные сети

НК — надводные корабли

ПРЦ — пространственно-распределенная цель

РЛИ — радиолокационные изображения

Введение

Обнаружение и распознавание таких пространственно-распределенных целей (ПРЦ), как надводные корабли (НК), космическими средствами наблюдения представляют собой приоритетные задачи в области глобального мониторинга и имеют целый ряд важных практических применений. Среди них можно выделить следующие:

1. Безопасность мореплавания: автоматическое распознавание кораблей дает возможность заблаговременно обнаруживать другие суда и определять траектории их движения, что позволяет снизить вероятность столкновений и других аварий на море.

2. Контроль за незаконной добычей рыбы: автоматическое распознавание водного транспорта может использоваться для контроля за незаконными промыслами рыбы, что способствует сохранению рыбных ресурсов и экологии водных биоресурсов.

3. Борьба с контрабандой: распознавание типов кораблей может помочь выявлять суда, занятые контрабандой наркотиков, оружия и других запрещенных товаров.

4. Гражданская защита: распознавание морских судов может быть использовано в качестве инструмента для мониторинга и управления кризисными ситуациями, такими как естественные бедствия, миграционные потоки и другие.

5. Очевидным представляется использование данных наблюдения водных поверхностей для решения задач разведки и целеуказания.

В настоящее время изображения кораблей могут быть получены в различных спектральных диапазонах, однако решающую роль играют именно радиолокационные изображения (РЛИ), имеющие ряд преимуществ по сравнению с оптическими: независимость от условий освещения, времени суток и погодных условий. Применение сверхширокополосных сигналов и принципа искусственного синтеза апертуры позволяет достичь разрешения, практически не уступающего оптическим снимкам.

Следует отметить, что важным компонентом систем распознавания НК является автоматическая идентификационная система (AIS), обеспечивающая дополнительную информацию о кораблях и помогающая повысить качество классификации. AIS представляет собой систему, используемую

на судах для обмена информацией о своем положении, курсе, скорости и других характеристиках соседних судов и наземных станций. Эта информация передается через радиоканалы и может быть принята другими судами и наземными станциями для мониторинга движения судов, предотвращения столкновений и обеспечения безопасности на море. Интеграция данных от системы AIS с системами распознавания надводных кораблей на РЛИ позволяет значительно повысить эффективность классификации, в частности информация от AIS может использоваться для подтверждения и уточнения обнаруженных кораблей на радиолокационных изображениях. Названная информация позволяет идентифицировать корабли, которые могут быть не видны на РЛИ. Методы распознавания, интегрирующие данные от системы AIS, как правило, имеют преимущество в точности и достоверности классификации, поскольку они могут использовать дополнительную, в том числе не радиолокационную, информацию о кораблях для принятия решений.

Однако важно также учитывать другие аспекты, такие как производительность и надежность системы, а также ее способность адаптироваться к различным ситуациям на море. Использование AIS в задаче распознавания НК на РЛИ имеет ряд ограничений, важнейшим из которых является тот факт, что данные от системы AIS могут быть недоступны в некоторых областях моря, особенно в удаленных или малонаселенных районах, что ограничивает применимость системы AIS для распознавания кораблей при такой их локации. Данные от системы AIS могут быть неполными или содержать ошибки, такие как неправильное идентификационное или географическое положение судна, что затрудняет точное сопоставление данных AIS с РЛИ. Также система AIS может сталкиваться с ложными сигналами и помехами, которые могут быть вызваны различными причинами, включая неправильное функционирование оборудования или международные нормы передачи данных. Необходимо отметить, что интеграция данных от системы AIS с РЛИ требует более сложной обработки и сопоставления данных. Учитывая эти сложности, необходимо разработать специализированные методы и алгоритмы, которые могли бы эффективно распознавать тип НК на РЛИ независимо от системы AIS и обеспечить высокую точность и эффективность распознавания.

Анализ теории и практики использования AIS в совокупности с космическим мониторингом, на наш взгляд, заслуживает отдельного внимания и не рассматривается в данном обзоре.

Основные методы распознавания пространственно-распределенных целей

Методы распознавания пространственно-распределенных целей могут быть разделены на три основных класса: классические, параметрические и непараметрические, отличающиеся степенью априорной неопределенности относительно статистических характеристик случайных сигналов, отраженных от ПРЦ.

Классические методы предполагают распределения вероятностей отдельных отсчетов РЛИ полностью известными, параметрические — известными с точностью до параметров, требующих оценки в процессе решения задачи распознавания, и непараметрические, когда распределения неизвестны до получения радиолокационных изображений.

К классическим методам можно отнести метод минимального среднего риска, метод идеального наблюдателя и т. п.

Примерами параметрических методов могут служить метод наивного Байеса, минимизация взаимной корреляционной функции, минимизация расстояния Махаланобиса, метод опорных векторов, метод разреженных представлений и другие.

Непараметрические методы не опираются на предварительно заданные модели распределений вероятностей, а используют их статистические оценки. В частности, к непараметрическим относятся: метод k -ближайших соседей, «случайный лес», модель АСМ, искусственные нейронные сети (ИНС) и другие.

Обобщенные характеристики методов, наиболее часто используемых в задачах распознавания РЛИ, представлены на рис. 1 [1–50]. При практической реализации каждый метод может иметь свои особенности и требования к данным, поэтому оценка и выбор конкретного метода распознавания ПРЦ должны быть основаны на анализе поставленной задачи, особенностях распознаваемого объекта, а также на доступных вычислительных ресурсах и времени принятия решений [1, 2, 51–53]. Среди методов, дающих наиболее высокую точность распознавания, следует отметить метод опорных векторов, метод АСМ, метод «случайный лес» и искусственные нейронные сети (ИНС), при использовании которых точность распознавания в ряде случаев достигает 99 % и выше [4–6, 9, 16, 28, 44, 47, 54–57].

Одной из основных трудностей распознавания РЛИ является тот факт, что распределение яркостей отдельных элементов РЛИ не является нормальным (достаточно часто эти распределения можно аппроксимировать с помощью гамма-распределения). Получение РЛИ осуществляется при боковом обзоре, что искажает образы целей и вызывает появление радио-

локационных теней, причем эти эффекты являются анизотропными, что приводит к значительным различиям в изображениях одной и той же цели, полученных при наблюдении с разных ракурсов. Еще одной особенностью РЛИ является наличие мультипликативного спекл-шума [1, 5, 9, 58]. В РЛИ могут присутствовать другие эффекты, например эффекты доплеровского сдвига и сжатия, которые могут исказить действительные размеры ПРЦ и вносить дополнительную сложность их распознавания.

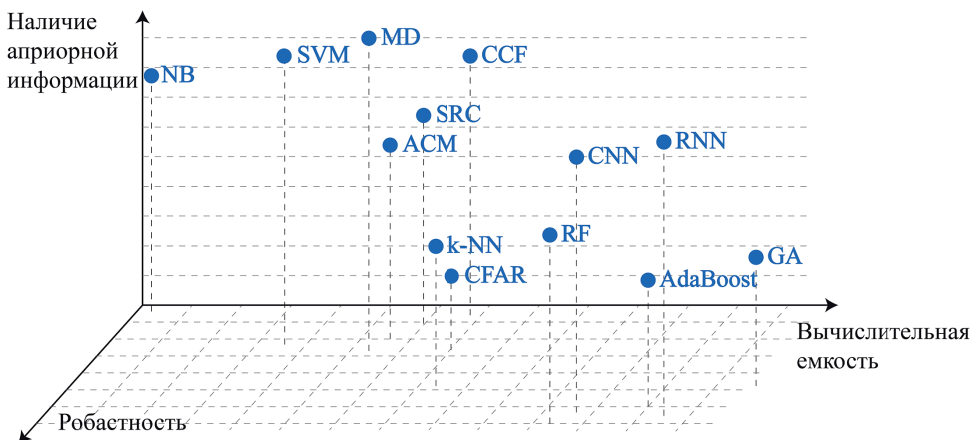


Рис. 1. Обобщенные характеристики различных методов распознавания образов на РЛИ (NB – наивный Байес, CCF – взаимная корреляционная функция, MD – расстояние Махаланобиса, SVM – метод опорных векторов, SRC – метод разреженных представлений, ACM – модель активного контура, CFAR – постоянная вероятность ложных тревог, k -NN – метод k -ближайших соседей, RF – метод «случайный лес», CNN – сверточные нейронные сети, RNN – рекуррентные нейронные сети, GA – генетический алгоритм)*

Fig. 1. Generalized characteristics of various pattern recognition methods in SAR imagery (NB – Naive Bayes, CCF – Cross Correlation Function, MD – Mahalanobis Distance, SVM – Support Vector Machine, SRC – Sparse Representation-based Classification, ACM – Active Contour Model, CFAR – Constant False Alarm Rate, k -NN – k -Nearest Neighbors method, RF – Random Forests, CNN – Convolutional Neural Networks, RNN – Recurrent Neural Networks, GA – Genetic Algorithm)

В задаче распознавания РЛИ надводных кораблей особое место занимает использование признаков, связанных с геометрическими характе-

* Под термином «робастность» понимается условная работоспособность метода при наличии искажений и помех, другими словами сохранение функционала при изменяющихся условиях наблюдения. Аналогично под вычислительной емкостью подразумевается способность компьютерной системы обрабатывать данные, в том числе скорость обработки, объем памяти, мощность вычислительных ресурсов и эффективность алгоритмов.

ристиками объектов, такими как длина, ширина, площадь и ориентация. Это связано с тем, что форма судна является одним из информативных признаков, по которым можно с высокой точностью определить его тип.

Следует отметить большое количество работ, посвященных распознаванию РЛИ НК, что делает задачу обзора литературы особенно важной для того, чтобы выделить и обосновать содержание нерешенных проблем.

Используемые авторами методы отличаются разнообразием алгоритмов, варьирующихся по требованиям к априорной информации, точности и вычислительным ресурсам. В простейшем случае обнаружение НК может быть основано на использовании взаимной корреляционной функции, позволяющей выполнять сопоставление между наблюдаемым РЛИ и набором эталонов. Для борьбы со спекл-шумом перед вычислением взаимной корреляционной функции применяются различные способы, улучшающие характеристики РЛИ: морфологическая фильтрация, адаптивная пороговая обработка [54, 59], метод оконных функций (windowing) [60], использование дешифровочных признаков, основанных на расчете значений яркости отдельных отсчетов РЛИ, контраста и среднеквадратического отклонения значений яркости [61] в рамках отдельных областей РЛИ. Дополнительно к традиционному анализу РЛИ могут применяться спектральный анализ, вейвлет-преобразование и другие методы [34, 62].

Алгоритмы распознавания НК, основанные на использовании взаимной корреляционной функции, при благоприятных условиях наблюдения обеспечивают вероятность правильного распознавания отдельных типов НК до 95 % и выше [34, 59, 61]. Скорость обработки РЛИ при использовании взаимной корреляционной функции несколько выше по сравнению с иными методами, однако необходимость тщательной настройки различных дополнительных параметров, в частности выбор подходящей формы оконной функции может усложнять применение этого метода в реальных условиях.

Еще одна группа методов обнаружения НК основана на применении многопороговой сегментации РЛИ, использующей серию пороговых значений для разбиения исходного изображения на различные области, относящиеся либо к фону, либо к интересующим наблюдателя объектам. Выбор и настройка пороговых значений могут осуществляться либо вручную на основе анализа точечных оценок различных характерных участков РЛИ, либо автоматически путем анализа гистограмм отдельных участков РЛИ, либо путем множественной проверки статистических гипотез [63, 64]. Как правило, из-за наличия шумов результат сегментации РЛИ содержит

разрывы яркости контуров и иные дефекты, осложняющие процедуру определения площадей и координат найденных объектов.

Для повышения эффективности классификации применяется морфологическая или сглаживающая фильтрация [63, 64]. Методы распознавания, основанные на многопороговой сегментации, позволяют достичь вероятности правильной классификации НК, превышающей 90 % и достигающей в отдельных случаях 96 % [64]. Однако эта группа методов является вычислительно трудоемкой из-за необходимости применения операции пороговой сегментации многократно для каждого порогового значения, что особенно сказывается при обработке изображений большого размера с большим количеством пороговых значений. Кроме того, при ручном выборе пороговых значений может потребоваться время на анализ гистограмм или точечных оценок, что также замедляет процесс принятия решения.

Различные методы автоматического выбора пороговых значений помогают ускорить процесс распознавания [63]. Так, при сегментации РЛИ наиболее широкое применение получили два подхода: расчет энтропии изображения и алгоритм Оцу. При использовании первого подхода пороговое значение устанавливается таким образом, чтобы энтропия всего изображения принимала максимально возможное значение [65, 66]. В основе алгоритма Оцу лежит максимизация межклассовой дисперсии и минимизация внутриклассовой дисперсии, на основании чего и устанавливается порог яркости [67]. Алгоритм Оцу и анализ энтропии изображения позволяют достичь ускорения обработки РЛИ в несколько раз [67, 68].

Развитием многопороговой сегментации изображений является использование модели активного контура (АСМ). Процедура сегментации сводится к минимизации функционала энергии, за счет чего происходит деформация активного контура таким образом, чтобы он оптимальным образом соответствовал границам выделяемых кластеров. Применительно к РЛИ метод АСМ требует дополнительных модификаций, поскольку такому типу изображений свойственны высокий уровень шумов и неоднородность яркости объектов. В качестве примера таких модификаций можно привести регуляризацию расстояния в процессе оптимизации [35], генетический алгоритм для подбора оптимальных значений параметров контура, сглаживающие пространственные и морфологические фильтры [70], нелокальную оценку градиента изображения [35].

Дополнительным преимуществом метода АСМ является возможность учета геометрической формы конкретных моделей НК, что позволяет дополнительно повысить точность распознавания до 95 % и выше [69].

Одним из самых распространенных методов по обнаружению НК на РЛИ является адаптивный алгоритм постоянной вероятности ложных тревог (CFAR). Алгоритм оценивает минимальное пороговое значение мощности, при котором сигнал считается относящимся к цели, при этом величина порога должна поддерживать постоянную ошибку ложных тревог с учетом изменчивости уровня шума в радиолокационных сигналах.

Для применения алгоритма CFAR к двумерным сигналам требуется некоторая модификация классического алгоритма. Применительно к РЛИ распространены два подхода. Первый подход основан на предварительном выделении границ участков изображения, например с использованием оператора Собеля в сочетании с различными приемами сглаживания фрагментов РЛИ [36, 37] или методов предварительной сегментации [12, 70]. Это позволяет выделить области, соответствующие расположению цели, и упростить дальнейшие вычисления. Затем на границах полученных областей вычисляется условная плотность вероятности отсчетов РЛИ для двух окрестностей и определяется пороговое значение. Для оценки параметров используемых распределений могут применяться различные методы, например метод Парзенковского окна [36, 37]. В конечном итоге применяются морфологическая фильтрация [36, 37] и кластеризация исходных РЛИ [70].

Второй подход основан на двухпараметрическом методе CFAR, который рассчитывает два статистических параметра в пределах концентрических окон элемента изображения [13, 71–73].

Алгоритм CFAR показывает высокую эффективность в обнаружении целей на радиолокационных изображениях, демонстрируя точность распознавания НК до 90 % и выше при вероятности ложных тревог порядка 10^{-6} [12, 36, 70, 72]. Достоинством алгоритма является возможность не только выполнения процедуры распознавания целей, но и выявления и анализа природы ошибок.

В частности, исследование распределения ложных срабатываний и пропусков, их пространственного распределения на изображении и зависимостей от различных параметров позволяет получить информацию о типичных и нетипичных ситуациях, которые приводят к росту ошибок [13].

Скорость обработки РЛИ при использовании алгоритма CFAR является сравнительно высокой. Реализация CFAR может быть оптимизирована для сокращения времени выполнения процедуры распознавания. Некоторые методы оптимизации включают использование эффективных алгоритмических структур данных, параллельных вычислений на многоядерных процессорах или графических процессорах (GPU), а также применение

различных практик снижения размерности или предварительной обработки данных [12, 71].

Увеличение точности работы алгоритма CFAR с сохранением низкого уровня ошибок ложного срабатывания может быть достигнуто путем комбинирования со сверточными нейронными сетями [74, 75]. Для предварительного выделения РЛИ потенциальных кораблей выполняется алгоритм CFAR, после чего для более точного распознавания и классификации типов кораблей применяется ИНС. Такой прием позволяет увеличить точность распознавания НК для РЛИ с высоким пространственным разрешением практически до 100 % [74], однако существенно увеличивает время реализации за счет подготовки обучающих выборок нужного объема.

Как и при использовании взаимной корреляционной функции, дополнительно в процессе классификации может быть задействован спектральный анализ, основанный, например, на вейвлет-преобразовании [76, 77] или Фурье-преобразовании [78, 79]. Такой подход повышает робастность алгоритма CFAR, поскольку частотные компоненты сигнала могут быть более различимыми, чем амплитудные значения в пространственной области [76, 78]. Использование частотного анализа позволяет снизить вычислительную сложность алгоритма CFAR, так как операции в частотной или масштабной областях могут быть выполнены более эффективно и быстро, особенно при использовании оптимизированных алгоритмов и структур данных [77–79]. Однако у алгоритма CFAR есть ряд недостатков, среди важнейших из которых следует отметить высокую чувствительность к уровню шума, низкую точность определения формы обнаруживаемого объекта, что может негативно сказываться на точности распознавания РЛИ, полученных не с круговых орбит.

Вторым по распространенности методом распознавания кораблей на водной поверхности является метод SD (Saliency Detector), основанный на предположении, что распознаваемые на изображении объекты обладают определенными уникальными характеристиками, которые отличают их от окружающего фона и иных объектов. Эти характеристики могут быть связаны с интенсивностью отраженного сигнала, текстурой, формой или другими свойствами образов кораблей. Один из наиболее распространенных вариантов метода SD основан на использовании статистических свойств данных, таких как среднее значение интенсивности, контраст, дисперсия, ковариационная матрица, угол поляризации и другие характеристики [80–83].

Процесс детектирования включает несколько этапов: вначале выполняется фильтрация и нормализация интенсивности РЛИ. Далее вычисля-

ются различные статистические характеристики элементов изображения, после чего выполняется сравнение статистических свойств данных между фоновыми областями и областями, которые предположительно содержат НК. Для этого применяются статистические метрики, например расстояние Бхаттачария [81] или метод SKDE* [83].

Результатом реализации является специальное изображение, называемое картой салиентности, на которой в дальнейшем размечаются области, предположительно содержащие НК. В такой форме метод SD представляет собой алгоритм классификации данных без учителя, тем не менее на низкодетальных РЛИ с его помощью возможно обнаружить до 95 % НК [80]. Вариацией метода SD является сочетание полученных карт салиентности с каким-либо классификатором, таким как ИНС [84–87], метод опорных векторов [80] и другими [89]. Такое комбинирование позволяет упростить процесс обнаружения судов, поскольку внимание сосредоточено только на выделенных областях РЛИ, что может значительно сократить вычислительную нагрузку и повысить эффективность обнаружения. Благодаря учету дополнительных признаков и контекстной информации такой подход позволяет повысить точность распознавания до 98 % [87, 89].

Метод SD может быть комбинирован с алгоритмом, основанном на модели АСМ, статистических свойствах разрывов яркости на РЛИ и последующей идентификации этих разрывов с контурами выделяемых объектов (метод CSM).

В этом случае осуществляется использование пороговых значений для отбрасывания контуров-кандидатов с низкой интенсивностью сигнала или низкой степенью согласованности, что позволяет удалить из рассмотрения области, которые не являются значимыми либо не относятся к целевым объектам [90, 91], что позволяет достигать точности до 95 % даже на высокодетальных РЛИ, при этом, подобно алгоритму CFAR, возможна последующая дифференциация полученных ошибок [90, 91].

Следует отметить, что скорость реализации метода CSM является одной из самых высоких среди прочих групп методов, предназначенных для распознавания образов на РЛИ.

Экспериментальные результаты показывают, что применение эволюционных алгоритмов [92] обеспечивает устойчивость по отношению к специфическим шумам на РЛИ, причем по сравнению с другими методами

* SKDE (Spatial Kernel Density Estimation) — метод классификации изображений, основанный на ядерной оценке плотности при моделировании распределения признаков в пространственном контексте, что позволяет учитывать положение отдельных пикселей на изображении при их классификации.

предложенный имеет более высокую скорость обнаружения и более низкую скорость ложных срабатываний.

Альтернативой подхода, используемого в методе АСМ, является аппроксимация контура, соответствующего НК, с помощью кривой сплайна, состоящей из сегментов, где каждый сегмент представляет собой полином определенной степени [93]. Для каждого сегмента кривой сплайна вычисляется кривизна, которая является мерой изменения направления контура и позволяет оценить его изгибы и изломы. Затем с использованием вычисленных значений кривизны определяется карта салиентности для каждого из контуров. После этого применяется пороговая обработка для выделения образов кораблей на основе полученной карты салиентности, пороговое значение устанавливается исходя из величины значений ошибок ложного срабатывания. Такой подход позволяет эффективно обнаруживать морские суда при значениях ошибки ложного срабатывания порядка 10^{-6} на высокодетальных РЛИ даже на неоднородных водных поверхностях [93].

Одним из наиболее быстрых и простых в реализации методов распознавания образов является байесовский классификатор. Особенности метода является необходимость полного учета априорных вероятностей распределения отсчетов РЛИ и возможность обновлять классификацию по мере получения новых данных, что позволяет адаптировать классификатор к изменяющимся условиям и быстро вносить корректировки в алгоритм распознавания. Для принятия решения о наличии или отсутствии РЛИ корабля используется пороговая обработка, при этом величина порога рассчитывается на основе вероятностных оценок, которые определяются в процессе обучения или анализа изображений [8, 94].

Для улучшения точности распознавания и производительности классификатора могут использоваться дополнительные приемы, такие как применение весовых коэффициентов для различных признаков, применение частотной и пространственной фильтрации, а также применение различных методов аугментации элементов обучающей выборки, например «mixup». Подобные способы позволяют достигнуть точности распознавания на РЛИ среднего пространственного разрешения до 97 % [8], кроме того, преимуществом использования байесовского классификатора является возможность анализа ошибок классификации (ложная тревога и пропуск цели), что позволяет оперативно вносить изменения в алгоритм распознавания, либо в набор используемых признаков.

Однако, как и у любого метода, у байесовского классификатора есть свои ограничения. В частности, он может быть чувствителен к выбору параметров модели распределения или выбросам отдельных значений. Кроме

того, метод показывает невысокую эффективность при работе с большим количеством признаков, что особенно принципиально для РЛИ с высоким пространственным разрешением.

Частично эта проблема может быть снята путем сочетания байесовского классификатора с методом SD, что позволяет увеличить точность правильного распознавания до 98 % [95]. Важно отметить, что ошибка распознавания РЛИ НК может быть существенно снижена при сочетании байесовского классификатора и сверточных нейронных сетей. При этом байесовский классификатор используется для извлечения признаков из РЛИ, которые затем подаются на вход ИНС для последующей классификации. В этом случае точность распознавания может достигать 99 % для различных типов кораблей, однако такой подход сильно замедляет обработку данных и требует значительно большего объема обучающей выборки [39, 40, 96, 97].

В последние десятилетия стали широко распространены алгоритмы распознавания РЛИ, основанные на методах машинного обучения, что отчасти связано с увеличением вычислительной мощности современных компьютеров. Это сделало возможным эффективно обрабатывать существенные объемы данных и применять сложные алгоритмы обучения на больших наборах данных. В настоящее время модели машинного обучения могут учитывать более сложные характеристики кораблей и адаптироваться к разнообразным условиям окружающей среды, что приводит к более точному и надежному обнаружению и распознаванию ПРЦ. Применительно к задаче распознавания НК чаще всего применяются три группы алгоритмов машинного обучения: метод опорных векторов, метод «случайный лес» и сверточные нейронные сети.

Метод опорных векторов (SVM) основан на поиске гиперплоскости в многомерном пространстве признаков таким образом, чтобы расстояние между различными классами данных было бы максимальным. Задача оптимизации в методе SVM сводится к поиску такого вектора весов и смещения, которые определяют положение и зачастую форму гиперплоскости [41, 42, 49, 98, 99]. Метод SVM предполагает анализ распознаваемых образов и извлечение признаков, которые отличают НК от прочих объектов. Наиболее распространенными признаками являются статистические характеристики, текстура, форма объектов [98], а также информация о поляризации [41].

Для повышения робастности алгоритма перед применением метода опорных векторов исходные РЛИ, как правило, подвергаются пространственной фильтрации [41]. На основе собранных данных об отдельных образцах РЛИ происходит дальнейшее обучение классификатора, заключающееся

в оптимизации параметров модели, после чего выполняется построение оптимальной разделяющей гиперплоскости. Метод SVM является мощным инструментом для классификации сложных и нелинейных данных, что делает его привлекательным для обнаружения различных типов кораблей даже на высоко детальных РЛИ с точностью не ниже 94 % [41, 42].

В целом метод опорных векторов является надежным классификатором, демонстрирующим хорошую обобщающую способность и эффективную работу с большим количеством признаков. Между тем метод SVM является достаточно трудоемким алгоритмом [99], несмотря на то, что предварительное обучение классификатора и использование весовых коэффициентов отдельных признаков позволяет увеличить производительность на несколько десятков процентов [41, 42]. При недостаточном количестве обучающих данных или неправильном подборе параметров высока вероятность переобучения исходной модели, а большой набор характеристик применительно к задаче распознавания кораблей на РЛИ не является главным преимуществом.

Еще один метод — «случайный лес» (RF) — основан на ансамбле множества деревьев решений, где каждое дерево строится на основе случайной выборки из обучающих векторов. При создании каждого дерева также случайно выбирается некоторое количество признаков из общего набора, при этом каждое дерево в ансамбле работает независимо, и окончательное решение принимается путем голосования — тот класс, за который проголосовало наибольшее количество деревьев, становится окончательным классом для данного изображения [43, 99, 100].

Применительно к задаче распознавания образов на РЛИ метод «случайный лес» используется существенно чаще, чем классический алгоритм «дерево решений», поскольку благодаря использованию большого количества деревьев в ансамбле обеспечивает лучшую обобщающую способность, так как он учитывает различные комбинации признаков и уменьшает вероятность переобучения.

Зачастую перед применением метода RF исходное РЛИ целесообразно подвергать сглаживающей фильтрации, что уменьшает шумы и, соответственно, несколько увеличивает вероятность правильного распознавания [100]. В качестве используемых признаков могут выступать текстурные характеристики, геометрические параметры кораблей, а также различные статистические характеристики фрагментов РЛИ, содержавшие образы НК. Дополнительно к таким классическим признакам в методе «случайный лес» могут быть учтены геометрические координаты, когерентность изображений и поляризация снимков [43, 99].

После излечения признаков осуществляется обучение модели RF на подготовленных данных. В каждом дереве решений, на каждом узле, выбирается случайное подмножество признаков для разбиения данных на два поддерева. После обучения классификатора каждое дерево решений в ансамбле выдает свой прогноз, и результаты объединяются путем голосования. Метод «случайный лес» позволяет обеспечить точность обнаружения и распознавания до 91 % [43] и подходит для задач с высокой размерностью данных и большим количеством признаков, а его способность к обработке нелинейных отношений между признаками и классами в целом делает его эффективным инструментом в обнаружении различных объектов на РЛИ.

Однако обучение классификатора в методе «случайный лес» может быть весьма затратным по времени, особенно при работе с большими объемами данных, хотя и отмечается его сравнительно более высокая производительность в сравнении с ИНС или методом опорных векторов [99, 100]. Итоговое решение в методе «случайный лес» основано на голосовании всех деревьев, что затрудняет его интерпретацию по сравнению с рассмотренными выше подходами, где каждый шаг принятия решения может быть легко проанализирован.

Наконец, наиболее распространенным способом реализации решения задачи распознавания кораблей на РЛИ с применением методов машинного обучения в последние годы являются сверточные нейронные сети (CNN). В основе этого подхода лежит идея чередования двух типов слоев: сверточных и субдискретизирующих, при этом на вход каждого из нейронов подается лишь определенный фрагмент исходного изображения, что позволяет сохранить топологию изображения внутри архитектуры сети [44, 45, 57, 99, 101–103].

Фрагменты изображения поэлементно перемножаются на ядро свертки, при этом полученный результат суммируется и записывается в соответствующую позицию выходного изображения. Такой подход сохраняет инвариантность процедуры распознавания относительно операций сдвига, поворота и масштабирования, позволяя выявлять все более крупные и обобщенные структуры изображения.

Концепция разделяемых весов в CNN-сетях предполагает использование ограниченного набора весов для существенного количества связей, что позволяет, с одной стороны, снизить требования к вычислительным ресурсам, с другой — уменьшить количество настраиваемых параметров. Субдискретизация слоев заключается в уменьшении пространственной размерности изображения по мере углубления сети, а чередование слоев обеспечивает формирование карты признаков, полученной на основе атри-

бутивных данных предыдущего слоя, за счет чего достигается процедура распознавания сложных иерархических связей.

В качестве метода вычисления градиента, используемого при обновлении весов нейронной сети, как правило, применяется метод обратного распространения ошибки. Функция активации нейрона в общем случае может быть произвольной, однако чаще всего используются нелинейные функции, например функция гиперболического тангенса или радиальная базисная функция. Применительно к РЛИ, в виду наличия интенсивного шума и, как правило, недостаточно большого объема обучающей выборки, с целью предотвращения эффектов переобучения и улучшения обобщающей способности сети в процессе обучения также применяется регуляризация, например L1 и L2 регуляризация, Data Augmentation или регуляризация Фишера [102].

Расширением традиционной CNN, предназначенной для работы с изображениями в целом, включая классификацию и сегментацию, является тип архитектуры ИНС R-CNN, предназначенный для задачи объектного обнаружения на изображениях. Основная идея R-CNN заключается в том, чтобы сначала выделить области изображения, которые, вероятно, содержат интересующие наблюдателя объекты, после чего каждая из областей обрабатывается независимо с использованием сверточной нейронной сети для извлечения признаков, которые передаются на полносвязанные слои для последующей классификации и определения границ объектов.

В начале своего использования архитектура R-CNN была относительно громоздкой и требовала значительных вычислительных ресурсов для обработки изображений, поскольку все области, потенциально содержащие распознаваемый объект, обрабатывались независимо, что приводило к дублированию вычислений для перекрывающихся областей. В последующем была предложена серия оптимизаций, позволяющих ускорить обработку изображений. Так, архитектура Faster R-CNN основана на интеграции областей с потенциальными образами распознаваемых объектов непосредственно в исходную нейронную сеть, что значительно сокращает время обработки [46, 47, 104, 105].

Еще одним способом модификации сверточной нейронной сети является сеть Grid CNN [103].

Благодаря адаптивности и многоуровневой иерархии используемых слоев и инвариантности к таким преобразованиям, как масштабирование, сдвиги и поворот использование CNN в сочетании с различными приемами, такими как мягкое квантование значений весов, признаки Хаара, адаптивные формы сверточного фильтра и другими, в задаче распознавания

НК на РЛИ позволяет достичь впечатляющих результатов с точностью распознавания до 98 % и выше [44, 47, 57].

Процедура автоматического извлечения разнообразных признаков позволяет сети самостоятельно выявлять характерные особенности кораблей на РЛИ, концентрируясь на самых неочевидных деталях. Однако, несмотря на многочисленные преимущества, у сверточных нейронных сетей есть и некоторые недостатки, из которых важнейшим является вычислительная сложность используемых алгоритмов, требующая значительных вычислительных ресурсов для обучения и работы, что ограничивает использование CNN для мобильных устройств и различных встроенных систем даже в настоящее время.

Для ускорения работы ИНС в задачах распознавания НК на РЛИ используется мягкое квантование, позволяющее обрабатывать ограниченный набор значений с меньшим количеством битов [101], перенос обучения [104] или различные модификации архитектуры CNN [46, 103, 105]. Однако, во-первых, подавляющее большинство авторов отмечает общее увеличение скорости обработки в пределах от единиц процентов по двух десятков процентов [46, 101, 104, 105], во-вторых, все приведенные модификации протестированы на ограниченном наборе данных, в роли которого, как правило, выступает база SSDD [104–107] с изображениями сравнительно небольших водных судов.

CNN требуют значительного объема размеченных данных для обучения, особенно при решении задач в изменяющихся условиях, при этом сбор и разметка большого количества фрагментов РЛИ с образами кораблей является затруднительным и трудоемким процессом [57, 102]. Еще одним существенным недостатком любого типа ИНС является неопределенность интерпретации: практически всегда принимаемые ими решения невозможно формализовать. В случае обучения на ограниченном наборе данных CNN не всегда достаточно обобщается на новые условия или новые типы кораблей, что может привести к ошибкам и ложным срабатываниям при работе на неизвестных данных [45]. Кроме того, если водных судов на изображениях меньше по сравнению с другими объектами или фоном, то CNN может испытывать трудности в обучении и распознавании таких редких классов.

Нельзя не отметить существование метода, основанного не на распознавании НК как таковых, а на исследовании следов, оставляемых ими на водной поверхности. Этот след может быть обнаружен на РЛИ и использован для определения наличия и местоположения судна. Существует два подхода в решении задачи обнаружения волновых следов на РЛИ. Во-первых, мож-

но использовать преобразование Радона, Радона — Фурье, вейвлет-преобразование [107–112] для выделения линейных структур и обнаружения характерных паттернов следов на изображении. Это сравнительно быстрые и простые в реализации алгоритмы, способные достаточно точно выделять необходимые структуры на РЛИ даже в условиях низкой контрастности, однако существенным недостатком такого подхода является сравнительно высокие значения ошибок ложных срабатываний. Во-вторых, для автоматического обнаружения следов и последующей классификации судов дополнительно к упомянутым типам преобразований можно использовать алгоритмы машинного обучения, такие как метод опорных векторов, метод разреженных представлений или ИНС [110–115].

Названный метод является вычислительно более трудоемким, но дает существенно более высокую точность распознавания, показывая на отдельных данных точность распознавания до 95 % [113–115], а также может дополнять методы, рассмотренные выше. Основным преимуществом метода, основанного на поиске и анализе волнового следа, является возможность обнаружения судов в условиях, когда они не видны непосредственно на изображении, например из-за плохой погоды или наличия затененных зон.

Анализ работ, посвященных различным методам обнаружения и распознавания НК на РЛИ, позволяет сделать следующие выводы:

1. Существует большое количество алгоритмов распознавания НК, работоспособных в заданных конкретных условиях без сравнительного анализа названных алгоритмов и практических рекомендаций по выбору того или иного алгоритма в зависимости от условий его применения. Оценка надежности используемых алгоритмов не опирается на единую универсальную методику. В большинстве работ производится оценка точности на тестовых данных, но аналитические исследования возможностей данных методов, как правило, отсутствуют. Выбор оптимального подхода зачастую осуществляется на основе сравнения с конкурирующими алгоритмами, без учета аналитических преимуществ каждого из методов.

2. Работы, содержащие анализ точности используемых алгоритмов, как правило, опираются на расчет ошибок ложного срабатывания и ошибок пропуска, а также различные зависимости, полученные из них. Однако современные задачи распознавания образов, в том числе НК, выходят за пределы простого бинарного анализа результатов и требуют более гибкого инструмента для оценки потенциальных возможностей используемых алгоритмов.

3. Из анализа литературы следует, что при выборе конкретного метода распознавания НК необходимо искать баланс между точностью получае-

мых результатов и скоростью обработки, причем замедление процедуры обнаружения и распознавания объекта может быть обусловлено как подготовкой и анализом исходных данных, так и самим вычислительным процессом. С учетом расширения области применения радиолокационных методов дистанционного зондирования в практических задачах поиска и идентификации НК вопрос оперативности получения результатов становится особенно актуальным. Несмотря на то, что глубокие методы обучения позволяют достигать высокой точности при распознавании объектов на РЛИ, приближающейся к 99 %, часто операторы не могут позволить себе затратить достаточное время на должную подготовку исходных данных.

4. Многие из существующих исследований в области распознавания РЛИ НК включают экспериментальные разделы, посвященные применению алгоритмов к узкому типу анализируемых объектов, в роли которых выступают либо образы, полученные с конкретного спутника, либо корабли базы данных SSDD, чьи геометрические, яркостные и структурные параметры довольно специфичны. Поскольку реальные образы РЛИ НК могут иметь значительную вариативность, можно предположить, что представленные в работах алгоритмы могут быть узконаправленными даже в рамках одной сцены.

5. За исключением задач по обнаружению НК, основанных на разновременных РЛИ одной и той же сцены, существующие исследования в основном ориентированы на методы, предназначенные для обработки отдельных кадров. Однако современное развитие космических технологий включает активное использование сетей малых спутников. Этот подход предоставляет значительные возможности для расширения потенциала в области распознавания образов, и современные методы обработки РЛИ должны быть адаптированы к изменяющимся условиям.

Из анализа опубликованных работ следует, что необходимо разрабатывать универсальные подходы, адаптированные к полноте и достоверности исходных данных: классические при достаточной априорной информации о РЛИ НК, параметрические при достоверной информации о видах распределений отраженных сигналов и непараметрические, основанные на использовании ИНС, при отсутствии возможностей обобщения априорной информации и необходимости строить алгоритм классификации, опирающийся на ограниченный набор отдельных РЛИ НК, полученных в конкретных условиях. Особую значимость имеет формулирование практических рекомендаций об использовании классических алгоритмов или ИНС в конкретных условиях.

Список литературы / References

1. Kechagias-Stamatis O., Aouf N. Automatic Target Recognition On Synthetic Aperture Radar Imagery: A Survey. *IEEE Aerospace and Electronic Systems Magazine*. 2021;36(3):56–81. DOI: 10.1109/MAES.2021.3049857.
2. Dong G., Kuang G., Wang N., Zhao L., Lu J. SAR Target Recognition via Joint Sparse Representation of Monogenic Signal. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2015;8(7):3316–3328. DOI: 10.1109/JSTARS.2015.2436694
3. Bolourchi P., Moradi M., Demirel H., Uysal S. Random Forest Feature Selection for SAR-ATR. *2018 UKSim-AMSS 20th International Conference on Modelling and Simulation*. 27–29 March 2018. Cambridge, UK. IEEE; 2018. Pp. 91–96. DOI 10.1109/UKSim.2018.00028
4. Zhao Q., Brennan V., Xu D., Wang Zh. Synthetic Aperture Radar Automatic Target Recognition with Three Strategies of Learning and Representation. *Optical Engineering*. 2000;39(5):1230–1244. DOI: 10.1117/1.602495
5. Wang Y., Han P., Lu X., Wu R., Huang Ji. The performance comparison of Adaboost and SVM applied to SAR ATR. *2006 CIE International Conference on Radar*. 6–19 October 2006. Shanghai, China. IEEE; 2007. Pp. 1–4. DOI: 10.1109/ICR.2006.343515
6. Chen Ch., Huang K., Gao G. Small-Target Detection between SAR Images Based on Statistical Modeling of Log-Ratio Operator. *Sensors*. 2019;19(6):1431–1440. DOI: 10.3390/s19061431
7. Huang P., Qiu W. A robust decision fusion strategy for SAR target recognition. *Remote Sensing Letters*. 2019;9(6):507–514. DOI: 10.1080/2150704X.2018.1444287
8. Song S., Xu B., Li Z., Yang J. Ship Detection in SAR Imagery via Variational Bayesian Inference. *IEEE Geoscience and Remote Sensing Letters*. 2016;13(3):319–323. DOI: 10.1109/LGRS.2015.2510378
9. Liu H., Li Sh. Decision fusion of sparse representation and support vector machine for SAR image target recognition. *Neurocomputing*. 2013;113:97–104. DOI: 10.1016/j.neucom.2013.01.033
10. Bolourchi P., Moradi M., Demirel H., Uysal S. Improved SAR target recognition by selecting moment methods based on Fisher score. *Signal, Image and Video Processing*. 2020;14:39–47. DOI: 10.1007/s11760-019-01521-5
11. Touzi R., Lopes A., Bousquet P. A Statistical and Geometrical Edge Detector for SAR Images. *IEEE transactions on geoscience and remote sensing*. 1988;26(6):764–773. DOI: 10.1109/36.7708
12. Dai H., Du L., Wang Y., Wang Z. Modified CFAR Algorithm Based on Object Proposals for Ship Target Detection in SAR Images. *IEEE Geoscience and Remote Sensing Letters*. 2016;13(12):1925–1929. DOI: 10.1109/LGRS.2016.2618604

13. Raj N., Sethunadh R., Aparna P.R. Object detection in SAR image based on bandlet transform. *Journal of Visual Communication and Image Representation*. 2016;40(A):376–383. DOI: 10.1016/j.jvcir.2016.07.010
14. Gao G., Liu L., Zhao L., Shi G., Kuang G. An adaptive and fast CFAR algorithm based on automatic censoring for target detection in high-resolution SAR images. *IEEE transactions on geoscience and remote sensing*. 2009;47(6):1685–1697. DOI: 10.1109/TGRS.2008.2006504
15. Kaplan L. M., Murenzi R. Evaluation of CFAR and texture based target detection statistics on SAR imagery. In: *Proceedings of the 1998 IEEE International Conference on Acoustics, Speech and Signal Processing*. 15 May 1998. Seattle, WA, USA. IEEE; 2002. Pp. 2141–2144. DOI: 10.1109/ICASSP.1998.681569
16. Wang R., Chen J.-W., Wang Y., Jiao L., Wang M. SAR Image Change Detection via Spatial Metric Learning With an Improved Mahalanobis Distance. *IEEE Geoscience and Remote Sensing Letters*. 2020;17(1):77–81. DOI: 10.1109/LGRS.2019
17. Song S., Xu B., Yang J. SAR Target Recognition via Supervised Discriminative Dictionary Learning and Sparse Representation of the SAR-HOG Feature. *Remote Sensing*. 2016;8(8):686. DOI: 10.3390/rs8080683
18. Zhao Q., Principe J.C. Support Vector Machines For Synthetic Aperture Radar Automatic Target Recognition. *IEEE Transactions on Aerospace and Electronic Systems*. 2001;37(2):643–654. DOI: 10.1109/7.937475
19. Nicoli L. P., Anagnostopoulos G. C. Shape-based recognition of targets in Synthetic Aperture Radar images using elliptical Fourier Descriptors. In: *Proceedings of SPIE*. Vol. 6967. *Automatic Target Recognition XVIII*. 19–20 March 2008. Orlando, Florida, USA. SPIE; 2008. Pp. 148–159. DOI: 10.1117/12.777806
20. Ruiz P., Mateos J., Camps-Valls G., Molina R. Bayesian Active Remote Sensing Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*. 2014;52(4):2186–2196. DOI: 10.1109/TGRS.2013.2258468
21. Wei Y., Jiao L., Liu F., Yang S., Wu Q., Sanga G. Fast DDL Classification for SAR Images with $L(1, \inf)$ Constraint. *IEEE Access*. 2019;7:68991–69006. DOI: 10.1109/ACCESS.2019.2918352
22. Waske B. M., Waske B. Classifier ensembles for land cover mapping using multitemporal SAR imagery. *Journal of Photogrammetry and Remote Sensing*. 2009;64(5):450–457. DOI: 10.1016/j.isprsjprs.2009.01.003
23. Tongyuan Z., Yang W., Dai D., Sun H. Polarimetric SAR Image Classification Using Multifeatures Combination and Extremely Randomized Clustering Forests. *EURASIP journal on advances in signal processing*. 2010;2:1–9. DOI: 10.1155/2010/465612
24. Zhu Zh., Woodcock C.E., Rogan J., Kellndorfer J. Assessment of spectral, polarimetric, temporal, and spatial dimensions for urban and peri-urban land cover classifica-

- tion using Landsat and SAR data. *Remote Sensing of Environment*. 2011;117:72–82. DOI: 10.1016/j.rse.2011.07.020
25. Topouzelis K., Psyllos A. Oil spill feature selection and classification using decision tree forest on SAR image data. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2012;68:135–143. DOI: 10.1016/j.isprsjprs.2012.01.005
26. Du T., Li L. SAR Automatic Target Recognition Based on Attribute Scattering Center Model and Discriminative Dictionary Learning. *IEEE Sensors Journal*. 2019;19(2):4598–4611. DOI: 10.1109/JSEN.2019.2901050
27. Tian Z., Wang L., Zhan R., Hu J., Zhang J. Classification via weighted kernel CNN: application to SAR target recognition. *International Journal of Remote Sensing*. 2018;39(23):9249–9268. DOI: 10.1080/01431161.2018.1531317
28. Lv J., Liu Y. Data Augmentation Based on Attributed Scattering Centers to Train Robust CNN for SAR ATR. *IEEE Access*. 2019;7:25459–25473. DOI: 10.1109/ACCESS.2019.2900522
29. Wang L., Xu X., Dong H., Gui R., Yang R., Pu F. Exploring Convolutional Lstm for Polarsar Image Classification. *IGARSS 2018–2018 IEEE International Geoscience and Remote Sensing Symposium*. 22–27 July 2018. Valencia, Spain. IEEE; 2018. Pp. 8452–8455. DOI: 10.1109/IGARSS.2018.8518517
30. Ji X. X., Zhang G. Adaptive boosting for SAR automatic target recognition. *IEEE Transactions on Aerospace and Electronic Systems*. 2007;43(1):112–125. DOI: 10.1109/TAES.2007.357120
31. Min R., Quan H., Cui Z., Cao Z., Pi Y, Xu Z. SAR Target Detection Using AdaBoost via GPU Acceleration. *IGARSS 2019–2019 IEEE International Geoscience and Remote Sensing Symposium*. July 28 — August 2 2019. Yokohama, Japan. IEEE; 2019. Pp. 1180–1183. DOI: 10.1109/IGARSS.2019.8899296
32. Wen X. B., Zhang H., Jiang Z. T. Multiscale Unsupervised Segmentation of SAR Imagery Using the Genetic Algorithm. *Sensors*. 2008;8(3):1704–1711. DOI: 10.3390/s8031704
33. Bhanu B., Lin Y. Genetic algorithm based feature selection for target detection in SAR images. *Image and Vision Computing*. 2003; 21(7):591–608. DOI: 10.1016/S0262-8856(03)00057-X
34. Marino A., Sanjuan-Ferrer M.J., Hajnsek I., Ouchi K. Ship detectors exploiting spectral analysis of SAR images. *2014 IEEE Geoscience and Remote Sensing Symposium*. 13–18 July 2014. Quebec City, QC, Canada. IEEE; 2014. Pp. 978–981. DOI: 10.1109/IGARSS.2014.6946590
35. Zhang X., Xiong B., Dong G., Kuang G. Ship Segmentation in SAR Images by Improved Nonlocal Active Contour Model. *Sensors*. 2018;18(12):420–434. DOI: 10.3390/s18124220

36. Leng X., Ji K., Yang K., Zou H. A Bilateral CFAR Algorithm for Ship Detection in SAR Images. *IEEE Geoscience and Remote Sensing Letters*. 2015;12(7):1536–1540. DOI: 10.1109/LGRS.2015.2412174
37. Gao G. A Parzen-Window-Kernel-Based CFAR Algorithm for Ship Detection in SAR Images. *IEEE Geoscience and Remote Sensing Letters*. 2011;8(3):557–561. DOI: 10.1109/LGRS.2010.2090492
38. Bisceglie M., Galdi C. CFAR detection of extended objects in high resolution SAR images. *IEEE Transactions on Geoscience and Remote Sensing*. 2005;43(4):833–843. DOI: 10.1109/TGRS.2004.843190
39. Ji K., Xing X., Chen W., Zou H., Chen Ju. Ship classification in TerraSAR-X SAR images based on classifier combination. *2013 IEEE International Geoscience and Remote Sensing Symposium — IGARSS*. 21–26 July 2013. Melbourne, VIC, Australia. IEEE; 2014. Pp. 2589–2592. DOI: 10.1109/IGARSS.2013.6723352
40. Osman H. M., Blostein S. D. New cost function for backpropagation neural networks with application to SAR imagery classification. In: *Proceedings of SPIE — The International Society for Optical Engineering*. Vol. 3718. Automatic Target Recognition IX. 24 August 1999. Society of Photo Optical; 1999. DOI: 10.1117/12.359941
41. Xiong W., Yongli X., Libo Y., Yaqi C. A New Ship Target Detection Algorithm based on SVM in High Resolution SAR Images. *Remote Sensing Technology and Application*. 2018;33(1):119–127. DOI: 10.1145/3133264.3133273
42. Ji K., Leng X., Wang H., Zhou S., Zou H. Ship detection using weighted SVM and M–CHI decomposition in compact polarimetric SAR imagery. *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. 23–28 July 2017. Fort Worth, TX, USA. IEEE; 2017. Pp. 890–893. DOI: 10.1109/IGARSS.2017.8127095
43. Snapir B., Waine T. W., Biermann L. Maritime Vessel Classification to Monitor Fisheries with SAR: Demonstration in the North Sea. *Remote Sensing*. 2019;11(3):353. DOI: 10.3390/rs11030353
44. Yang R., Pan Z., Jia X., Zhang L., Deng Y. A Novel CNN-Based Detector for Ship Detection Based on Rotatable Bounding Box in SAR Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2021;14:1938–1958. DOI: 10.1109/JSTARS.2021.3049851
45. Yang R., Wang G., Pan Z., Lu H., Zhang H., X. Jia A Novel False Alarm Suppression Method for CNN-Based SAR Ship Detector. *IEEE Geoscience and Remote Sensing Letters*. 2021;18(8):1401–1405. DOI: 10.1109/LGRS.2020.2999506
46. Lin Z., Ji K., Leng X., Kuang G. Squeeze and Excitation Rank Faster R-CNN for Ship Detection in SAR Images. *IEEE Geoscience and Remote Sensing Letters*. 2019;16(5):751–755. DOI: 10.1109/LGRS.2018.2882551
47. Ke X., Zhang X., Zhang T., Shi J., Wei S. SAR Ship Detection Based on an Improved Faster R-CNN Using Deformable Convolution. *2021 IEEE International Geoscience*

- and Remote Sensing Symposium IGARSS*. 11–16 July 2021. Brussels, Belgium. IEEE; 2021. Pp. 3565–3568. DOI: 10.1109/IGARSS47720.2021.9554697
48. Dong G., Kuang G. Target Recognition in SAR Images via Classification on Riemannian Manifolds. *IEEE Geoscience and remote sensing letters*. 2015;12(1):199–203. DOI: 10.1109/LGRS.2014.2332076
49. Yan F., Mei W., Chunqin Zh. SAR Image Target Recognition Based on Hu Invariant Moments and SVM. In: *Proceedings of the Fifth International Conference on Information Assurance and Security*. 18–20 August 2009. Xi'an, China. IEEE; 2009. Pp. 585–588. DOI: 10.1109/IAS.2009.289
50. Lu Z., Jiang G., Guan Yu., Wang Q., Wu Ji. A SAR Target Recognition Method Based on Decision Fusion of Multiple Features and Classifiers. *Scientific Programming*. 2021. Art. ID 1258219. DOI: 10.1155/2021/1258219
51. Fiscella B., Giancaspro A., Nirchio F., Pavese P., Trivero P. Oil spill detection using marine SAR images. *International Journal of Remote Sensing*. 2000;21(18):3561–3566. DOI: 10.1080/014311600750037589
52. Mountrakis G., Im Ju., Ogole C. Support vector machines in remote sensing: A review. *Journal of Photogrammetry and Remote Sensing*. 2010;66(3):247–259. DOI: 10.1016/j.isprsjprs.2010.11.001
53. Parikh H., Patel S., Patel V. Classification of SAR and PolSAR images using deep learning: a review. *International Journal of Image and Data Fusion*. 2020;11(1):1–32. DOI: 10.1080/19479832.2019.1655489
54. Gierull C. H. Demystifying the Capability of Sublook Correlation Techniques for Vessel Detection in SAR Imagery. *IEEE Transactions on Geoscience and Remote Sensing*. 2019;57(4): 2031–2042. DOI: 10.1109/TGRS.2018.2870716
55. Ding B., Wen G., Huang X., Ma C., Yang X. Target Recognition in Synthetic Aperture Radar Images via Matching of Attributed Scattering Centers. *IEEE Journal of selected topics in applied Earth observations and remote sensing*. 2017;10(7):3334–3347. DOI: 10.1109/JSTARS.2017.2671919
56. Tanase R., Datcu M., Raducanu D. A Convolutional deep belief network for polarimetric SAR data feature extraction. *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. 10–15 July 2016. Beijing, China. IEEE; 2016. Pp. 7545–7548. DOI: 10.1109/IGARSS.2016.7730968.
57. Ai J., Tian R., Luo Q., Jin J., Tang B. Multi-Scale Rotation-Invariant Haar-Like Feature Integrated CNN-Based Ship Detection Algorithm of Multiple-Target Environment in SAR Imagery. *IEEE Transactions on Geoscience and Remote Sensing*. 2019;57(12):10070–10087. DOI: 10.1109/TGRS.2019.2931308
58. Yuan X., Tang T., Xiang D., Li Y., Su Y. Target recognition in SAR imagery based on local gradient ratio pattern. *International Journal of Remote Sensing*. 2014;35(3):857–870. DOI: 10.1080/01431161.2013.873150

59. Ouchi K., Tamaki S., Yaguchi H., Iehara M. Ship Detection Based on Coherence Images Derived From Cross Correlation of Multilook SAR Images. *IEEE Geoscience and remote sensing letters*. 2004;1(3):184–187. DOI: 10.1109/LGRS.2004.827462
60. Iehara M., Ouchi K., Takami I., Morimura K., Kumano Sh. Detection of ships using cross-correlation of split-look SAR images. *IGARSS 2001. Scanning the Present and Resolving the Future. Proceedings. IEEE 2001 International Geoscience and Remote Sensing Symposium*. 9–13 July 2001. Sydney, NSW, Australia. IEEE; 2001. Vol. 4. Pp. 1807–1809. DOI: 10.1109/IGARSS.2001.977078
61. Wei J., Zhang J., Huang G., Zhao Z. On the Use of Cross-Correlation between Volume Scattering and Helix Scattering from Polarimetric SAR Data for the Improvement of Ship Detection. *Remote Sensing*. 2016;8(74):1–16. DOI: 10.3390/rs8010074
62. Marino A., Sanjuan-Ferrer M.J., Hajnsek I., Ouchi K. Ship Detection with Spectral Analysis of Synthetic Aperture Radar: A Comparison of New and Well-Known Algorithms. *Remote sensing*. 2015;7:5416–5439. DOI: 10.3390/rs70505416
63. Wang R., Shao S., An M., Li J., Wang S., Xu X. Soft Thresholding Attention Network for Adaptive Feature Denoising in SAR Ship Detection. *IEEE Access*. 2021;9:29090–29105. DOI: 10.1109/ACCESS.2021.3059033
64. Liu C., Yang J., Zheng, J., Nie X. An Unsupervised Port Detection Method in Polarimetric SAR Images Based on Three-Component Decomposition and Multi-Scale Thresholding Segmentation. *Remote Sensing*. 2022;14(1):205. DOI: 10.3390/rs14010205
65. Chen X., Wang C. Ship Detection for Complex Background SAR Images Based on a Multiscale Variance Weighted Image Entropy Method. *IEEE Geoscience and Remote Sensing Letters*. 2017;14(2):184–187. DOI: 10.1109/LGRS.2016.2633548
66. Huo W., Huang Y., Pei J., Zhang Q., Gu Q., Yang J. Ship Detection from Ocean SAR Image Based on Local Contrast Variance Weighted Information Entropy. *Sensors*. 2018;18(4):1196. DOI: 10.3390/s18041196
67. Messina M., Greco M., Fabbrini L., Pinelli G. Modified Otsu's algorithm: A new computationally efficient ship detection algorithm for SAR images. *2012 Tyrrhenian Workshop on Advances in Radar and Remote Sensing (TyWRRS)*. 12–14 September 2012. Naples, Italy. IEEE; 2012. Pp. 262–266. DOI: 10.1109/TyWRRS.2012.6381140
68. Lang H., Xi Yu., Zhang X. Ship Detection in High-Resolution SAR Images by Clustering Spatially Enhanced Pixel Descriptor. *IEEE Transactions on Geoscience and Remote Sensing*. 2019;57(8):5407–5423. DOI: 10.1109/TGRS.2019.2899337
69. Proia N. and Pagé V. Characterization of a Bayesian Ship Detection Method in Optical Satellite Images. *IEEE Geoscience and Remote Sensing Letters*. 2010;7(2):226–230. DOI: 10.1109/LGRS.2009.2031826

70. Pappas O., Achim A., Bull D. Superpixel-Level CFAR Detectors for Ship Detection in SAR Imagery. *IEEE Geoscience and Remote Sensing Letters*. 2018;15(9):1397–1401. DOI: 10.1109/LGRS.2018.2838263
71. Wang C., Bi F., Zhang W., Chen L. An Intensity-Space Domain CFAR Method for Ship Detection in HR SAR Images. *IEEE Geoscience and Remote Sensing Letters*. 2017;14(4):529–533. DOI: 10.1109/LGRS.2017.2654450
72. Wang C., Bi F., Zhang W., Chen L. An Improved Iterative Censoring Scheme for CFAR Ship Detection With SAR Imagery. *IEEE Transactions on Geoscience and Remote Sensing*. 2014;52(8):4585–4595. DOI: 10.1109/LGRS.2017.2654450
73. Ai J., Qi X., Yu W., Deng Y., Liu F., Shi L. A New CFAR Ship Detection Algorithm Based on 2-D Joint Log-Normal Distribution in SAR Images. *IEEE Geoscience and Remote Sensing Letters*. 2010;7(4):806–810. DOI: 10.1109/LGRS.2010.2048697
74. Xiao Q., Cheng Yu., Xiao M., Zhang Ju., Hongji Sh., Niu L., et al. Improved region convolutional neural network for ship detection in multiresolution synthetic aperture radar images. *Concurrency and Computation Practice and Experience*. 2020;32(22):1–10. DOI: 10.1002/cpe.5820
75. Kang M., Leng X., Lin Z., Ji K. A modified faster R-CNN based on CFAR algorithm for SAR ship detection. *2017 International Workshop on Remote Sensing with Intelligent Processing (RSIP)*. 18–21 May 2017. Shanghai, China. IEEE; 2017. Pp. 1–4. DOI: 10.1109/RSIP.2017.7958815
76. Stagliano D., Lupidi A., Berizzi F. Ship detection from SAR images based on CFAR and wavelet transform. *2012 Tyrrhenian Workshop on Advances in Radar and Remote Sensing (TyWRRS)*. 12–14 September 2012. Naples, Italy. IEEE; 2012. DOI: 10.1109/TyWRRS.2012.6381102
77. Schwegmann C. P., Kleynhans W., Salmon B. P., Mdakane L. A CA-CFAR and localized wavelet ship detector for Sentinel-1 imagery. *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. 26–31 July 2015. Milan, Italy. IEEE; 2015. Pp. 3707–3710. DOI: 10.1109/IGARSS.2015.7326628
78. Ma B., Yang H., Yang J. Ship Detection in Spaceborne SAR Images under Radio Interference Environment Based on CFAR. *Electronics*. 2022;11(24):4135. DOI: 10.3390/electronics11244135
79. Wang C., Liao M., Li X. Ship Detection in SAR Image Based on the Alpha-stable. *Sensors*. 2008;8(8):4948–4960. DOI: 10.3390/s8084948
80. Cui X.-C., Su Y., Chen S.-W. A Saliency Detector for Polarimetric SAR Ship Detection Using Similarity Test. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2019;12(9):3423–3433. DOI: 10.1109/JSTARS.2019.2925833
81. Cheng J., Xiang D., Tang J., Zheng Y., Guan D.; Du B. Inshore Ship Detection in Large-Scale SAR Images Based on Saliency Enhancement and Bhattacharyya-like Distance. *Remote Sensing*. 2022;14(12):2832. DOI: 10.3390/rs14122832

82. Han L., Liu D., Guan D. Ship detection in SAR images by saliency analysis of multi-scale superpixels. *Remote Sensing Letters*. 2022;13(7):708–715. DOI: 10.1080/2150704X.2022.2068988
83. Liang Y., Sun K., Zeng Y., Li G., Xing M. An Adaptive Hierarchical Detection Method for Ship Targets in High-Resolution SAR Images. *Remote Sensing*. 2020;12(2):303. DOI: 10.3390/rs12020303
84. Zhang C., Liu P., Wang H., Jin Y. Saliency-Based Centernet for Ship Detection in SAR. *IGARSS 2022–2022 IEEE International Geoscience and Remote Sensing Symposium*. 17–22 July 2022. Kuala Lumpur, Malaysia. IEEE; 2022. Pp. 1552–1555. DOI: 10.1109/IGARSS46834.2022.9883396
85. Xu Ch., Yin Ch., Wang D., Han W. Fast ship detection combining visual saliency and a cascade CNN in SAR images. *IET Radar, Sonar and Navigation*. 2020;14(12):1879–1887. DOI: 10.1049/iet-rsn.2020.0113
86. Zhang P., Luo H., Ju M., He M., Chang Z., Hui B. Brain-Inspired Fast Saliency-Based Filtering Algorithm for Ship Detection in High-Resolution SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*. 2022;60:1–9. DOI: 10.1109/TGRS.2021.3053257
87. Liu Y., Zhang M.-H., Xu P., Guo Z. SAR ship detection using sea-land segmentation-based convolutional neural network. *2017 International Workshop on Remote Sensing with Intelligent Processing (RSIP)*. 18–21 May 2017. Shanghai, China. IEEE; 2017. Pp. 1–4. DOI: 10.1109/RSIP.2017.7958806
88. Nie T., He B., Bi G., Zhang Y., Wang W. A Method of Ship Detection under Complex Background. *International Journal of Geo-Information*. 2017;6(6):159. DOI: 10.3390/ijgi6060159
89. Hu, J., Zhi, X., Zhang, W., Ren, L., & Bruzzone, L. Salient Ship Detection via Background Prior and Foreground Constraint in Remote Sensing Images. *Remote Sensing*. 2020;12(20):3370. DOI: 10.3390/rs12203370
90. Hu J., Zhi X., Zhang W., Ren L., Bruzzone L. New Hierarchical Saliency Filtering for Fast Ship Detection in High-Resolution SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*. 2017;55(1):351–362. DOI: 10.1109/TGRS.2016.2606481
91. Li N., Pan X., Yang L., Huang Z., Wu Z., Zheng G. Adaptive CFAR Method for SAR Ship Detection Using Intensity and Texture Feature Fusion Attention Contrast Mechanism. *Sensors*. 2022;22(21):8116. DOI: 10.3390/s22218116
92. Li N., Pan X., Yang L., Huang Zh., Wu Zh., Zheng G. Inshore Ship Detection Based on Level Set Method and Visual Saliency for SAR Images. *Sensors*. 2018;18(11):3877. DOI: 10.3390/s18113877
93. Yang M., Guo C., Zhong H., Yin H. A Curvature-Based Saliency Method for Ship Detection in SAR Images. *IEEE Geoscience and Remote Sensing Letters*. 2021;18(9):1590–1594. DOI: 10.1109/LGRS.2020.3005197

94. Song S., Xu B., Yang J. Ship Detection in Polarimetric SAR Images via Variational Bayesian Inference. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2017;10(6):2819–2829. DOI: 10.1109/JSTARS.2017.2687473
95. Wang Z., Du L., Su H. Target Detection via Bayesian-Morphological Saliency in High-Resolution SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*. 2017;55(10):5455–5466. DOI: 10.1109/TGRS.2017.2707672
96. Yang R., Pan Zh., Jia X., Zhang L., Deng Yu. Ship detection in SAR images based on Bayesian classifier and improved data augmentation. *IEEE International Geoscience and Remote Sensing Symposium*. 28 July — 2 August 2019. Yokohama, Japan. IEEE; 2019.
97. Kim K., Hong S., Choi B., Kim E. Probabilistic Ship Detection and Classification Using Deep Learning. *Applied Sciences*. 2018;8(6):936. DOI: 10.3390/app8060936
98. Su X., Yang G., Sang H. Ship Detection in Polarimetric SAR Based on Support Vector Machine. *Research Journal of Applied Sciences, Engineering and Technology*. 2012;4(18):3448–3454.
99. Baek W.-K., Jung H.-S. Performance Comparison of Oil Spill and Ship Classification from X-Band Dual- and Single-Polarized SAR Image Using Support Vector Machine, Random Forest, and Deep Neural Network. *Remote Sensing*. 2021;13(16):3203. DOI: 10.3390/rs13163203
100. Wang Y., Rajesh G., Mercilin Raajini X., Kritika N., Kavinkumar A., Shah Syed Bilal H. Machine Learning-based Ship Detection and Tracking Using Satellite Images for Maritime Surveillance. *Journal of Ambient Intelligence and Smart Environments*. 2021;13(5):361–371. DOI: 10.3233/AIS-210610
101. Yang X., Zhang J., Chen C., Yang D. An Efficient and Lightweight CNN Model With Soft Quantification for Ship Detection in SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*. 2022;60:1–13. DOI: 10.1109/TGRS.2022.3186155.
102. He J., Wang Y., Liu H. Ship Classification in Medium-Resolution SAR Images via Densely Connected Triplet CNNs Integrating Fisher Discrimination Regularized Metric Learning. *IEEE Transactions on Geoscience and Remote Sensing*. 2021;59(4):3022–3039. DOI: 10.1109/TGRS.2020.3009284
103. Zhang T., Zhang X. High-Speed Ship Detection in SAR Images Based on a Grid Convolutional Neural Network. *Remote Sensing*. 2019;11(10):1206. DOI: 10.3390/rs11101206
104. Li J., Qu C., Shao J. Ship detection in SAR images based on an improved faster R-CNN. 2017 SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA). 13–14 November 2017. Beijing, China. IEEE; 2017. Pp. 1–6. DOI: 10.1109/BIGSAR DATA.2017.8124934.

105. Li Y., Zhang S., Wang W. -Q. A Lightweight Faster R-CNN for Ship Detection in SAR Images. *IEEE Geoscience and Remote Sensing Letters*. 2022;19:1–5. DOI: 10.1109/LGRS.2020.3038901.
106. Zhang T., Zhang X., Li J., Xu X., Wang B., Zhan X., et al. SAR Ship Detection Dataset (SSDD): Official Release and Comprehensive Data Analysis. *Remote Sensing*. 2021;13(18):3690. DOI: 10.3390/rs13183690
107. Courmontagne P. An improvement of ship wake detection based on the radon transform. *Signal Processing*. 2005;85(8):1634–1654. DOI: 10.1016/j.sigpro.2005.02.013
108. Copeland A. C., Ravichandran G., Trivedi M. M. Localized Radon Transform-Based Detection of Ship Wakes in SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*. 1995;33(1):35–45. DOI: 10.1109/36.368224.
109. Tello M., Lopez-Martinez C., Mallorqui J. J. Novel Algorithm for Ship Detection in SAR Imagery Based on the Wavelet Transform. *IEEE Geoscience and Remote Sensing Letters*. 2005;2(2):201–205. DOI: 10.1109/LGRS.2005.845033
110. Tings B., Pleskachevsky A., Velotto D., Jacobsen S. Extension of Ship Wake Detectability Model for Non-Linear Influences of Parameters Using Satellite Based X-Band Synthetic Aperture Radar. *Remote Sensing*. 2019;11(5):563. DOI: 10.3390/rs11050563
111. Xue F., Jin W., Qiu S., Yang Ji. Rethinking automatic ship wake detection: state-of-the-art CNN-based wake detection via optical images. *IEEE Transactions on Geoscience and Remote Sensing*. 2022;60:1–22. DOI: 10.1109/TGRS.2021.3128989
112. Gao C., Tao R., Kang X. Weak Target Detection in the Presence of Sea Clutter Using Radon-Fractional Fourier Transform Cancellation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2021;14:5818–5830. DOI: 10.1109/JSTARS.2021.3078723
113. Graziano M. D. Preliminary Results of Ship Detection Technique by Wake Pattern Recognition in SAR Images. *Remote Sensing*. 2020;12(18):2869. DOI: 10.3390/rs12182869
114. Karakuş O., Rizaev I., Achim A. Ship Wake Detection in SAR Images via Sparse Regularization. *IEEE Transactions on Geoscience and Remote Sensing*. 2019;58(3):1665–1677. DOI: 10.1109/TGRS.2019.2947360
115. Hwang J.-I., Jung H.-S. Automatic Ship Detection Using the Artificial Neural Network and Support Vector Machine from X-Band Sar Satellite Images. *Remote Sensing*. 2018;10(11):1799–1817. DOI: 10.3390/rs10111799

Информация об авторах

Доросинский Леонид Григорьевич, доктор технических наук, профессор, заслуженный работник высшей школы РФ, почетный радист. Директор департамента радиоэлектроники и связи. Уральский федеральный университет

имени первого Президента России Б. Н. Ельцина, Екатеринбург, Российская Федерация.

Виноградова Нина Сергеевна старший преподаватель, зам. директора департамента радиоэлектроники и связи. Уральский федеральный университет имени первого Президента России Б. Н. Ельцина, Екатеринбург, Российская Федерация.

Information about the authors

Leonid G. Dorosinsky. Dr. Tech. Sciences, Professor, Honored Worker of the Higher School of Russian Federation. Head of the Department of Radioelectronics and Telecommunications, Institute of Radioelectronics and Information Technologies, Ural Federal University, Ekaterinburg, Russia.

Nina S. Vinogradova. Graduated from the Faculty of Physics of Gorky Ural State University (2009), Master of Physics. Nowadays she works as a Senior Lecturer and a Subhead of the Department of Radioelectronics and Communication, Institute of Radioelectronics and IT, Ural federal university, Ekaterinburg, Russia.

Поступила / Received: 01.02.2024

Принята в печать / Accepted: 01.03.2024