

DOI 10.15826/urej.2024.8.1.004

УДК 621/312/01(076)

Исследование методов классификации надводных кораблей по размерам, определяемым по их радиолокационным изображениям

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 определения размеров, занимаемых радиолокационным изображением (РЛИ) пространственно-распределенной цели (ПРЦ) на двумерной растровой картинке наблюдаемого участка земной (водной) поверхности, формируемой космическим радиолокатором с синтезированной апертурой, актуальна в самых различных задачах космического мониторинга. В данной работе названная проблема решается применительно к определению размеров РЛИ надводных кораблей на фоне отражений от морской поверхности.

В качестве моделей РЛИ используются как феноменологические, так и реальные, основанные на базе SSDD. Принятие решения о размерах НК производится как классическими (параметрическими и непараметрическими) алгоритмами, так и алгоритмами, основанными на машинном обучении с использованием искусственных нейронных сетей. Приведены результаты сравнительного анализа названных алгоритмов.

Ключевые слова: пространственно-распределенная цель, радиолокационное изображение, распознавание, отношение сигнал/шум, нейронная сеть

Для цитирования: Доросинский Л. Г., Виноградова Н. С. Исследование методов классификации надводных кораблей по размерам, определяемым по их радиолокационным изображениям. *Ural Radio Engineering Journal*. 2024;8(1):85–109. DOI: 10.15826/urej.2024.8.1.004.

Investigation of Methods of Classifying Surface Ships by Size, Determined by Their Radar Images

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 problem of determining the dimensions occupied by a spatially distributed target (SDT) in a two-dimensional raster image of the observed area of the Earth's (water) surface, formed by a spaceborne synthetic aperture radar (SAR), is relevant in various space monitoring tasks. In this work, this problem is addressed specifically in the context of determining the dimensions of SDT of surface ships against reflections from the sea surface.

Both phenomenological and real models based on SSDD database are used as SAR images. Decision-making regarding the dimensions of surface ships is performed using classical (parametric and non-parametric) algorithms as well as machine learning algorithms leveraging artificial neural networks. The results of the comparative analysis of these algorithms are presented.

Keywords: Spatially Distributed Target, Radar Image, Pattern Recognition, Signal-to-Noise Ratio (SNR), Neural Network

For citation: Dorosinskiy L. G., Vinogradova N. S. Investigation of methods of classifying surface ships by size, determined by their radar images. *Ural Radio Engineering Journal*. 2024;8(1):85–109 (In Russ.) DOI: 10.15826/urej.2024.8.1.004

1. Введение. Описание исходных данных

Прежде чем перейти к исследованию методов классификации пространственно-распределенных целей (ПРЦ) по их радиолокационным изображениям (РЛИ), выполним анализ существующих баз данных о РЛИ надводных кораблей (НК). Названные РЛИ будут служить в дальнейшем основой сравнительного анализа алгоритмов классификации.

В работе будут использованы РЛИ двух типов: растровые изображения, сформированные алгоритмически на основе феноменологических моделей сигналов, принимаемых бортовой РЛС, и реальные РЛИ НК, заимствованные из базы SSDD, которая представляет собой набор различных изображений НК, используемых для тестирования и оценки алгоритмов и моделей

машинного обучения. Все изображения содержат две области: область, занимаемую изображением ПРЦ, и область, содержащую фон (отражения от водной поверхности).

Сегодня в мире существует более 12 тысяч различных НК военного назначения, выполняющих различные задачи, такие как охрана водного пространства и флота, воздушная оборона, высадка войск, техники и грузов на берег и другие. Длина НК варьируется от нескольких десятков до сотен метров, ширина НК меняется от нескольких метров до десятков метров, осадка и водоизмещение определяют вместимость судна и наравне с используемыми при строительстве материалами и формой НК влияют на численное значение эффективной поверхности рассеяния (ЭПР). Перечень военных НК приведен в таблице 1 [1–6], из которой следует, что НК могут быть условно поделены на три класса: длиной менее 100 м, от 100 м до 200 м и более 300 м (табл. 2).

1.1. Формирование модельных изображений

В качестве модельных изображений, лежащих в основе последующих исследований, использованы РЛИ, отсчетами которых являются мгновенные значения мощности на выходе устройства первичной обработки, распределенные по экспоненциальному закону см. стр. 4 [7], где параметр распределения σ пропорционален значению ЭПР элемента разрешения ПРЦ или фона.

$$p(y) = \frac{1}{2\sigma^2} e^{-\frac{y}{2\sigma^2}}, \quad (1)$$

Такая модель плотности вероятности отсчета РЛИ соответствует нормальному распределению отраженных сигналов от элемента поверхности (элемента разрешения), состоящих из двух квадратурных составляющих, каждая из которых имеет нулевое математическое ожидание и дисперсию σ^2 ,

Таблица 1. Типовые характеристики надводных кораблей
Table 1. Typical Characteristics of Surface Ships

Тип корабля	Типовые размеры, м	Типовая осадка, м	Типовое водоизмещение, т	Количество
Авианосец	340 × 50	11	100 000	40
Аviso	200 × 30	6	30 000	30
Артиллерийский корабль	130 × 20	6	6 000	70

Окончание табл. 1

Тип корабля	Типовые размеры, м	Типовая осадка, м	Типовое водоизмещение, т	Количество
Боевой катер	28 × 7	2	300	2500
Большие десантные корабли	180 × 25	7	30 000	60
Десантный катер	22 × 7	2	200	2000
Крейсер	200 × 20	8	15 000	200
Корвет	90 × 12	4	2000	150
Малый десантный корабль	35 × 8	2	300	1500
Малый патрульный корабль	60 × 8	3	4 000	3000
Ракетный катер	30 × 7	2	300	500
Ракетный крейсер	200 × 14	6	15 000	70
Ракетный корабль	110 × 17	4	10 000	800
Средний десантный корабль	100 × 17	6	10 000	100
Сторожевой корабль	90 × 14	4	15 000	700
Торпедный катер	30 × 6	2	200	200
Универсальные десантные корабли	210 × 25	7	35 000	100
Фрегат	130 × 17	6	4 000	300
Эсминец	170 × 18	6	8 000	300

Площадь НК на РЛИ аппроксимирована эллипсом:

$$f(x, y) = \left(\frac{x}{a}\right)^2 + \left(\frac{y}{b}\right)^2, \quad (2)$$

где a — большая полуось эллипса, задаваемая в соответствии с параметрами НК, b — малая полуось эллипса, численное значение которой составляет приблизительно 15 % от большой полуоси, что соответствует данным табл. 1. Отсчеты РЛИ внутри эллипса имеют экспоненциальное распределение с параметром σ , вне эллипса названный параметр принят равным 1.

Таблица 2. Обобщенные характеристики категорий надводных кораблей
Table 2. Generalized Characteristics of Surface Ship Categories

Категория НК	Средняя длина, м	Среднее пространственное разрешение	Средняя частота, %	Номенклатура
Большие (L)	350	35	0,5	Авианосцы
Средние (M)	150	15	18	Авизо, артиллерийский корабли, большие десантные корабли, крейсера, ракетный крейсера, ракетные корабли, средние десантные корабли, универсальные десантные корабли, фрегаты, эсминцы
Малые (S)	50	5	81,5	Боевые катера, десантные катера, корветы, малые десантные корабли, малые патрульные корабли, ракетные катера, сторожевые корабли, торпедный катер

1.2. РЛИ из SSDD

База данных SSDD (SAR Ship Detection Dataset) представляет собой открытый [8] набор РЛИ НК различного типа [9, 10]. Создание этой базы обусловлено потребностью исследователей и разработчиков алгоритмов обработки сигналов бортовых РЛС в наличии набора данных, который может быть использован для проведения исследований в области глубокого обучения для задач распознавания НК на РЛИ.

База SSDD содержит 28 296 фрагментов РЛИ, полученных с помощью космических аппаратов RadarSat-2, TerraSAR-X и Sentinel-1, пространственное разрешение которых варьируется от 1 до 15 м. Около 20 % сцен приходится на прибрежные зоны, и около 80 % РЛИ представляют собой радиолокационные изображения НК, полученные в открытом море [11]. Характерные размеры сторон изображений составляют 500×500 и могут изменяться от 214 до 668 пикселей по ширине и от 160 до 526 пикселей

по высоте. Размеры НК на изображении варьируются от 4,4 до 393,3 м, однако большая часть РЛИ относится к сравнительно небольшим судам, и в целом распределение НК по размерам соответствует данным из табл. 2. РЛИ НК могут иметь произвольный угол поворота и располагаться в произвольном месте кадра.

Выбор базы SSDD в настоящей работе обусловлен следующими факторами:

1. База SSDD является единственной среди аналогичных (на сегодняшний момент в открытом доступе представлены также базы LS-SSDD-v1.0, SAR-Ship-Dataset и HRSID), включающей РЛИ НК при разном пространственном разрешении.

2. База SSDD выложена в открытый доступ самой первой (базы LS-SSDD-v1.0, SAR-Ship-Dataset и HRSID появились как минимум на 1,5 года позже). Поэтому больше половины работ, посвященных исследованию методов классификации НК, используют именно эту базу, что позволяет адекватно сопоставлять различные методы классификации [10].

3. База SSDD содержит РЛИ разнообразных НК, полученные в широко варьирующихся условиях (местность съемки, времена года, погодные условия), что позволяет проводить наиболее комплексный и полный анализ с применением различных алгоритмов распознавания.

Для настоящей работы отобрано 15 фрагментов РЛИ, содержащих образы НК класса L, и 3 304 фрагментов РЛИ — класса M, 14 713 фрагментов РЛИ — класса S. Примеры изображений НК различных классов приведены на рис. 1.

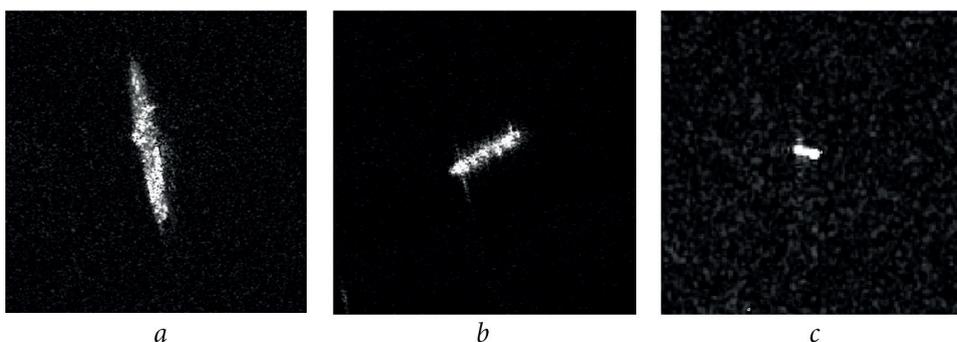


Рис. 1. Примеры объектов базы SSDD:
a — НК класса L; *b* — НК класса M; *c* — НК класса S

Fig. 1. Examples of objects from the SSDD database:
a — Surface ship of class L; *b* — Surface ship of class M; *c* — Surface ship of class S

Классификация НК по их РЛИ производится при условии, что их наблюдение производится под одинаковым ракурсом. Подробно оптимальный алгоритм классификации рассмотрен в [11, 12]. Наблюдаемое РЛИ сравнивается с возможными шаблонами (масками) альтернативных НК, которые выбираются из памяти под теми же ракурсами. Поэтому задача сведена к одномерной. Проблема неточного определения ракурса требует отдельного рассмотрения и выходит за рамки настоящей работы.

2. Байесовский классификатор в задаче определения типа ПРЦ

Байесовский классификатор (БК) основан на оценках апостериорных вероятностей принадлежности РЛИ к одному из возможных классов, взвешенных с учетом функций риска.

Поскольку плотности вероятностей отсчетов мощности анализируемой вектор-строки распределены по экспоненциальному закону, функция правдоподобия имеет вид*:

$$W_k(y) = \frac{\prod_{i=\frac{n-I(k)}{2}+1}^{\frac{n+I(k)}{2}} \frac{1}{\sigma_1^2} e^{-\frac{y_i}{2\sigma_1^2}}}{\prod_{i=\frac{n-I(k)}{2}+1}^{\frac{n+I(k)}{2}} \frac{1}{\sigma_0^2} e^{-\frac{y_i}{2\sigma_0^2}}}, \quad (3)$$

где σ_0 и σ_1 — значения ЭПР, характеризующие свойства подстилающей поверхности в пределах фона и цели соответственно, n — размер вектор-строки, $I(k)$ — размер цели, $k = S, M, L$.

После взятия логарифма от выражения (3) получаем:

$$\ln(W_k) = \left(\frac{1}{\sigma_0^2} - \frac{1}{\sigma_1^2} \right) \sum_{i=\frac{n-I(k)}{2}+1}^{\frac{n+I(k)}{2}} (x_i) - I(k) \ln \left(\frac{\sigma_1^2}{\sigma_0^2} \right). \quad (4)$$

где $x_i = y_i/2\sigma_0^2$

* Формула (3) получена в предположении о том, что РЛИ НК расположено в центре наблюдаемого кадра. Задача центрирования требует специального рассмотрения. В данной работе основное внимание уделено сравнению алгоритмов без учета таких деталей, как центрирование и оценка ракурса.

В результате элементарных преобразований имеем:

$$\ln(W_k) = \sum_{i=\frac{n-I(k)}{2}+1}^{\frac{n+I(k)}{2}} (x_i) - \left(\frac{I(k)\ln(q)}{q-1} q \right), \quad q = \frac{\sigma_1^2}{\sigma_0^2}. \quad (5)$$

Решение будет принято в пользу класса k с максимальным значением выражения (5):

$$\hat{K} = \arg \max_{k=1:K} \{ \ln(W_k) \}. \quad (6)$$

Таким образом, задача классификации сводится к суммированию элементов центральной вектор-строки в пределах каждого из априори возможных размеров ПРЦ при условии известного значения отношения сигнал/шум.

Матрица классификации для различных отношений сигнал/шум, полученная на основе БК при объеме тестовой выборки в 10 000 элементов, приведена в табл. 3.

Анализ данных в табл. 3 демонстрирует высокую точность классификатора даже при сравнительно невысоких значениях отношения сигнал/шум. При снижении величины q сохраняется высокая точность для классов S и L, однако уменьшается вероятность правильного распознавания ПРЦ среднего размера.

Таблица 3. Матрицы классификации при распознавании типа ПРЦ при использовании БК для различных значений отношения сигнал/шум

Table 3. Classification matrices for SDT type recognition using Bayesian classifier for various SNR values

	$q = 1,5$			$q = 3$			$q = 5$		
	S	M	L	S	M	L	S	M	L
S	83,4	14,3	3,0	99,9	0,2	0,0	100,0	0,0	0,0
M	12,6	75,3	9,9	0,1	99,7	0,1	0,0	100,0	0,0
L	4,0	10,4	87,1	0,0	0,1	99,9	0,0	0,0	100,0

Таким образом, при полностью известных априори характеристиках ПРЦ БК показывает высокую эффективность распознавания типа цели в сочетании с высокой производительностью и способностью работать с большими объемами данных. Блок-схема алгоритма БК представлена на рис. 2. Разумеется, получение таких хороших результатов связано как с большим априорным отличием в размерах, так и априори известным отношением сигнал/шум.

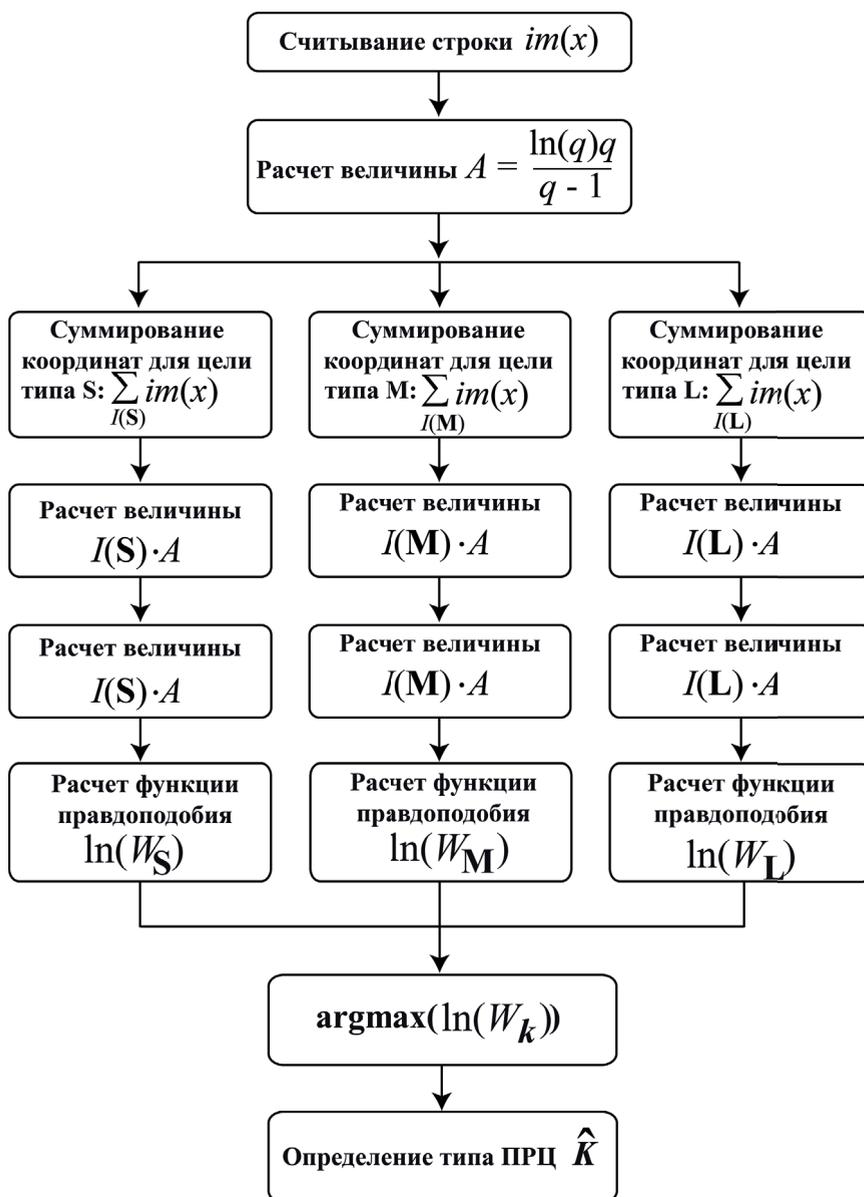


Рис. 2. Блок-схема алгоритма определения типа ПРЦ с помощью байесовского классификатора

Fig. 2. Block diagram of the PRS type determination algorithm using Bayesian classifier

3. Параметрические методы в задаче определения типа ПРЦ

В случае, если априорные данные о распознаваемых классах известны, байесовский классификатор является оптимальным по критерию минимума среднего риска. Если же отношение сигнал/шум неизвестно (что справедливо практически для любых реальных задач), то перед применением алгоритма (6) необходимо оценить величину q . С учетом предположения об известных координатах центра ПРЦ и ее ориентации в кадре будем оценивать отношение сигнал/шум по методу максимального правдоподобия. При экспоненциальном распределении отсчетов названная оценка определяется с помощью известного выражения [13]:

$$\hat{q} = \sum_{\frac{(n-1)}{2}}^{\frac{(n-1)}{2}+4} (x_i) / 9. * \quad (7)$$

Оценка отношения сигнал/шум подставляется в формулу (5) вместо известной величины q . При тех же условиях моделирования получаем матрицы верных и ошибочных решений, представленные в табл. 4.

Таблица 4. Матрицы классификации при распознавании типа ПРЦ при использовании БК ОД для различных значений отношения сигнал/шум
Table 4. Classification matrices for SDT type recognition using Bayesian classifier with point estimation of variance for various SNR values

$q = 5$			$q = 10$			$q = 15$					
S	M	L	S	M	L	S	M	L			
S	100,0	38,7	29,0	S	100,0	7,3	2,9	S	100,0	2,2	0,4
M	0,0	61,3	38,8	M	6,3	92,7	6,6	M	2,1	97,8	1,4
L	0,0	0,0	54,2	L	0,0	0,0	90,5	L	0,0	0,0	98,2

Следующий анализируемый метод основан на формировании в качестве признаков классификации вектора достаточных статистик [12]. Каждая компонента вектора — суть сумма отсчетов в пределах области, априори занимаемой малой, средней и большой целями. При этом получаем совокупность векторов для ПРЦ каждого из возможных размеров. Оценка типа ПРЦ может быть найдена по минимуму расстояния от текущей выборки

* Число 9 — то минимальное число отсчетов РЛИ, при котором алгоритм классификации НК по размерам можно считать работоспособным. А именно оценка вероятности правильной классификации, полученная методом статистического моделирования, больше 0,8.

до совокупности выборок, полученных от каждого класса целей на этапе обучения, или по методу k ближайших соседей (рис. 3).

$$\hat{K} = \arg \min_{k=1:K} \{D_k^2\}. \tag{8}$$

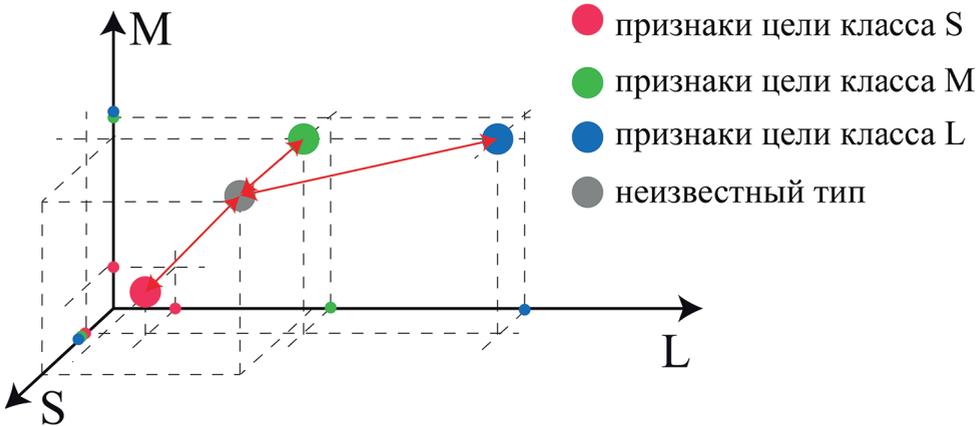


Рис. 3. К объяснению непараметрического метода, основанного на подсчете сумм отсчетов в пределах известных масок

Fig. 3. Explanation of the non-parametric method based on summing counts within known masks

Предложенный метод наименьших расстояний (НР) протестирован на примере обучающей выборки объемом 100 элементов при аналогичных условиях, результаты для различных значений отношения сигнал/шум представлены в табл. 5.

Как видно из данных таблицы, результаты применения метода НР для небольших значений отношения сигнал/шум оказываются более точными в сравнении с методами БК и БК ОД.

Таблица 5. Матрицы классификации при распознавании типа ПРЦ при использовании НР для различных значений отношения сигнал/шум

Table 5. Classification matrices for SDT type recognition using minimum distance method for various SNR values

$q = 5$				$q = 10$			$q = 20$				
	S	M	L	S	M	L	S	M	L		
S	82,4	0,5	0,0	S	97,4	1,1	0,0	S	99,2	2,2	0,0
M	17,6	96,8	2,3	M	2,6	98,1	0,8	M	0,8	97,4	0,6
L	0,0	2,7	97,7	L	0,0	0,8	99,2	L	0,0	0,4	99,4

Далее рассмотрим зависимость точности алгоритма НР от размера обучающей выборки для различных отношений сигнал/шум. Зависимости оценок вероятностей правильной классификации от размера обучающей выборки, полученные методом статистического моделирования, приведены на рис. 4.

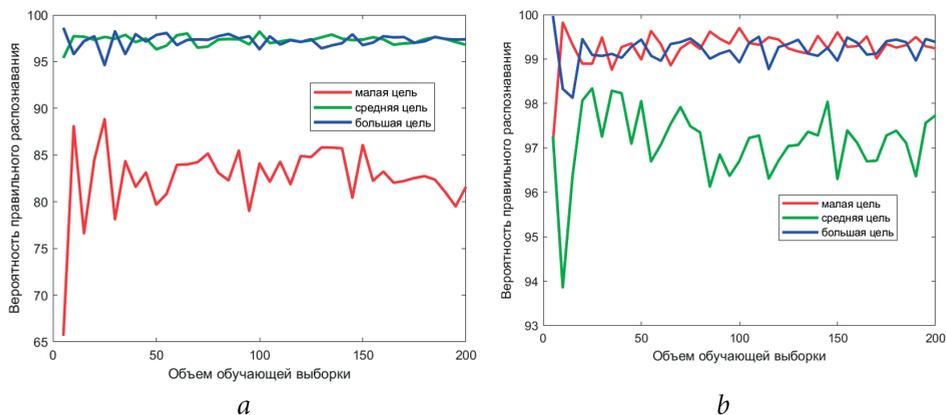


Рис. 4. Зависимость вероятности правильного распознавания типа цели при использовании метода с подсчетом сумм элементов НР от отношения сигнал/шум: красная линия — ПРЦ класса S, зеленая линия — ПРЦ класса M, синяя линия — ПРЦ класса L: $a - q = 5$; $b - q = 10$

Fig. 4. Probability of correctly recognizing the target type using the sum-counting minimum distance method elements as a function of signal-to-noise ratio: line (1) — S-class SDT, line (2) — M-class SDT, line (3) — L-class SDT. a) $q = 5$; b) $q = 10$

Из показателей графиков следует, что стабильные значения точности распознавания (математические ожидания и дисперсии оценок практически неизменны) могут быть достигнуты при объеме обучающей выборки, содержащей 30 элементов. При этом оценка точности распознавания малой цели при низких значениях сигнал/шум не превышает 83 % при росте объема обучающей выборки. Точность классификации выше 95 % не может быть достигнута даже при объеме обучающей выборки, приближающейся к значению 10^6 (что практически эквивалентно ситуации с известным отношением сигнал/шум). Блок схема алгоритма наименьших расстояний приведена на рис. 5.

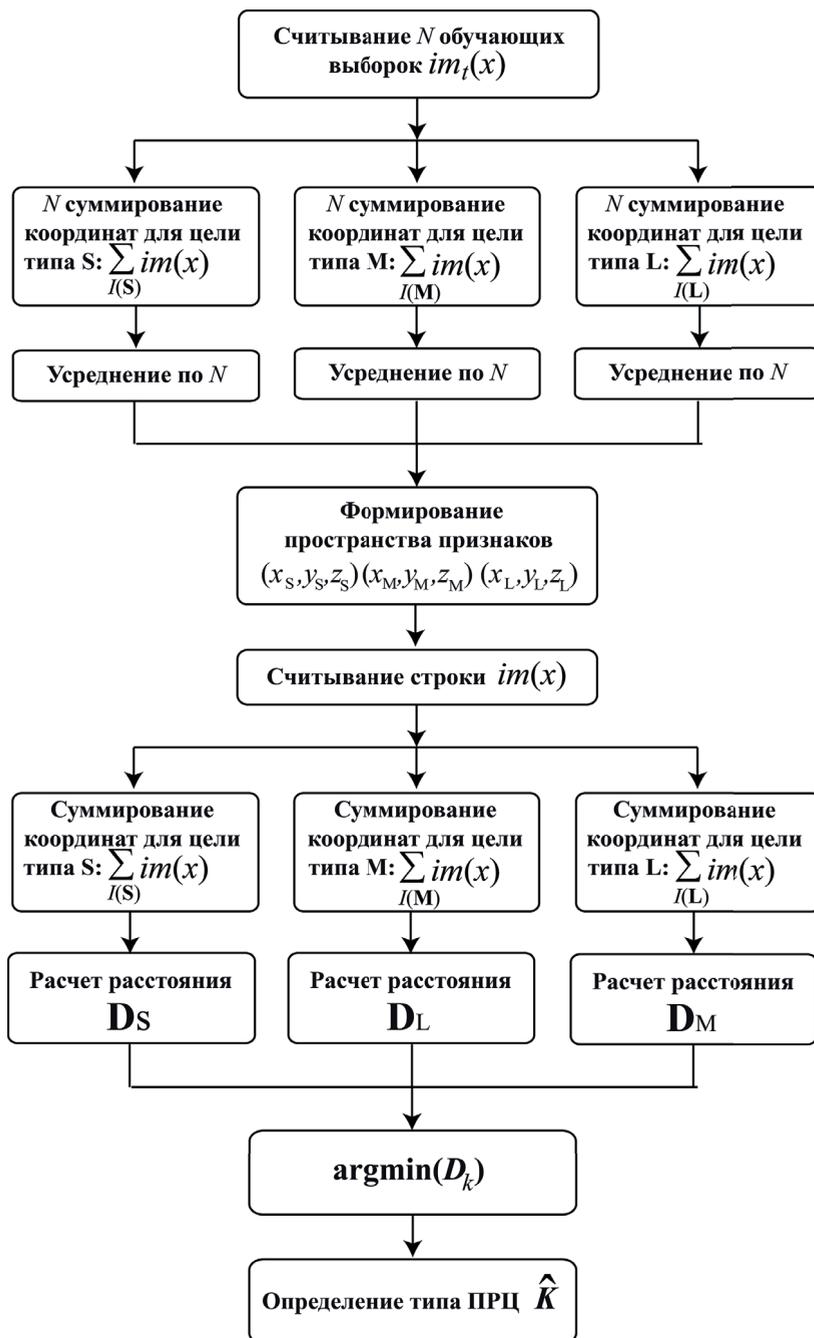


Рис. 5. Блок-схема алгоритма определения типа ПРЦ с помощью метода наименьших расстояний

Fig. 5. Block diagram of the PRS type determination algorithm using the minimum distance method

4. Искусственные нейронные сети (ИНС)

в задаче определения типа ПРЦ по оценке ее размеров

В настоящей работе использовано два типа ИНС: сверточная нейронная сеть (CNN) и полносвязная нейронная сеть (FFNN) [14].

Полносвязная нейронная сеть (FFNN) представляет собой один из самых простых типов архитектуры ИНС. В FCNN каждый узел, за исключением входного и выходного, работает одновременно как вход и как выход. Эти узлы организованы в скрытый слой нейронов, и каждый нейрон в этом слое связан со всеми нейронами в предыдущем слое. Входные сигналы умножаются на веса, которые настраиваются в процессе обучения и далее передаются на нейроны. При этом каждый нейрон имеет порог активации, который определяет, когда он активируется и передает свой выход. Архитектура FFNN, использованная для определения типа ПРЦ на основе вектор-строки, представлена на рис. 6.



Рис. 6. Архитектура полносвязной нейронной сети в задаче определения типа ПРЦ, представленной центральной вектор-строкой

Fig. 6. Architecture of a fully connected neural network in the PRS type determination task represented by a central vector row

Рассмотрим подробнее отдельные элементы архитектуры FFNN. Слой «1» предназначен для считывания анализируемой последовательности, в данном случае размер входных данных устанавливается равным 101, т. е. каждый элемент входных данных является одномерной последовательностью длиной 101, каждая из которых имеет один признак (класс S, M или L). Как и для сверточных нейронных сетей, на этом слое может применяться различная модификация динамического диапазона считываемых последовательностей, в данном случае наилучшая сходимость и обучаемость ИНС достигнута при использовании пакетной нормализации [13].

Слой «2» (слой «4») предназначен для формирования связей между входной последовательностью и нейронами, ответственными за формирование заданных классов. В данном случае использована двухкаскадная

архитектура, при этом на слое «2» присутствуют 64 нейрона, на слое «4» — три нейрона, каждый из которых соответствует одному из трех распознаваемых типов ПРЦ. Между полносвязными слоями помещен слой «3», представляющий собой функцию активации, выполняющую следующую пороговую обработку:

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (9)$$

На первом этапе выполнено обучение обеих типов ИНС на данных с фиксированными параметрами (отношение сигнал/шум и размер целей), некоторые характеристики полученных ИНС приведены в табл. 6, где V — максимальный объем выборки каждого класса с учетом дообучения, η — коэффициент скорости обучения, Acc — точности классификации, полученная на тестовых данных, CPU — процессорное время обучения.

Таблица 6. Параметры обучения ИНС для задачи определения типа ПРЦ на основе вектор-строки с фиксированными параметрами
Table 6. ANN training parameters for SDT type determination based on a fixed vector row

q		$a = \{10\ 40\ 70\}$				$a = \{25\ 40\ 55\}$			
		Объем выборки	η	Acc, %	CPU, с	Объем выборки	η	Acc, %	CPU, с
1,3	FFNN	—							
	CNN	1 800	10^{-5}	62,8	39	—			
1,5	FFNN	1 200	10^{-4}	67,1	9,6	—			
	CNN	1 500	10^{-4}	73,4	24	—			
2	FFNN	800	10^{-4}	87,6	4,0	1 500	10^{-4}	82,4	8,3
	CNN	1 300	10^{-4}	88,1	19,8	1 600	10^{-4}	82,5	27,1
3	FFNN	600	10^{-3}	97,0	2,3	1 100	10^{-3}	90,7	6,2
	CNN	1 000	10^{-3}	99,3	16,1	1 200	10^{-3}	95,6	21,2
5	FFNN	500	10^{-3}	99,0	0,8	800	10^{-3}	98,3	3,9
	CNN	800	10^{-3}	99,9	10,9	1 000	10^{-3}	99,4	17,8
10	FFNN	300	10^{-2}	99,8	0,6	450	10^{-2}	98,8	2,2
	CNN	500	10^{-2}	100,0	6,3	800	10^{-3}	100,0	12,4
15	FFNN	200	10^{-2}	100,0	0,3	300	10^{-2}	100,0	0,7
	CNN	300	10^{-2}	100,0	3,4	500	10^{-2}	100,0	6,6
20	FFNN	100	10^{-2}	100,0	0,2	150	10^{-2}	100,0	0,3
	CNN	200	10^{-2}	100,0	2,2	400	10^{-2}	100,0	3,4

Окончание табл. 6

q		$a = \{10\ 40\ 70\}$				$a = \{25\ 40\ 55\}$			
		Объем выборки	η	Acc, %	CPU, с	Объем выборки	η	Acc, %	CPU, с
25	FFNN	50	10^{-2}	100,0	0,1	50	10^{-2}	100,0	0,2
	CNN	200	10^{-2}	100,0	1,1	300	10^{-2}	100,0	1,8

Как следует из данных таблицы, без применения аугментации данных обучение ИНС на выборках с низким значением сигнал/шум оказалось принципиально невозможным, в частности CNN при разнице размеров в числе отсчетов 30 не может быть обучена при величине $q < 1,3$ и при разнице в размерах $15 - q < 2$. Также CNN оказались значительно более ресурсоемким инструментом в сравнении с FFNN, причем затрачиваемое процессорное время и требования к минимальному размеру обучающей выборки увеличиваются как с уменьшением отношения сигнал/шум, так и уменьшением отличий в размерах распознаваемых ПРЦ.

На втором этапе обучение обеих типов ИНС осуществлялось методом файн-тюнинга — сначала на различные значения отношения сигнал/шум в диапазоне от 1,1 до 100, затем на возможные колебания в разнице размеров целей, начиная с разницы в размерах 30 отсчетов и заканчивая 2, т. е. размеры малой, средней и большой ПРЦ составляли соответственно 38, 40 и 42. Параметры обеих итоговых ИНС приведены в табл. 7, где C — значение функции потерь, RAM — объем оперативной памяти.

Таблица 7. Итоговые параметры обучения ИНС для задачи определения типа ПРЦ на основе вектор-строки

Table 7. Final ANN training parameters for SDT type determination based on a fixed vector row

Тип ИНС	Гиперпараметры обучения				CPU, с	RAM, Мб
	Объем выборки	η	C	Acc, %		
FFNN	1 500	10^{-3}	0,07	99,6	15	52
CNN	2 500	10^{-7}	0,07	98,5	376	221

Из данных таблицы следует, что применение аугментации в процессе обучения обеих типов ИНС позволяет существенно увеличить точность обучения даже с учетом выборок, построенных при величине $q = 1,1$. При достижении приблизительно эквивалентной точности и одинаковых функций потерь процесс обучения общей CNN требует значительно больше оперативной памяти в сравнении с FFNN, что объясняется более сложной архитектурой CNN с большим числом слоев, необходимостью извлечения

пространственных признаков из данных, что требует дополнительных вычислений, а также применением сверточных операций к входным данным.

CNN работают с локальными областями входных изображений, и каждый нейрон в сверточном слое соединен только с небольшой частью входных данных, что приводит к большому числу связей и активаций во время обучения. В случае FFNN каждый нейрон в слое полносвязной сети соединен со всеми нейронами предыдущего слоя, что означает меньшее потребление оперативной памяти по сравнению с CNN.

Матрицы классификации, полученные для обоих типов архитектуры ИНС при различных значениях отношения сигнал/шум, представлены в табл. 8.

Из данных таблицы следует, что для ИНС типа CNN, как и для байесовского классификатора, характерно небольшое снижение точности при распознавании ПРЦ среднего размера, тогда как для FFNN вероятность правильного распознавания увеличивается при увеличении размеров цели. Также следует отметить, что точность распознавания сети FFNN несколько уступает CNN, что объясняется большей специализацией сверточных слоев на выявление пространственных особенностей в данных. Однако вследствие того, что процесс обучения сети типа FFNN является несравнимо менее затратным, целесообразно оставить этот тип архитектуры для дальнейших исследований.

Таблица 8. Матрицы классификации при распознавании типа ПРЦ при использовании FFNN и CNN

Table 8. Classification matrices for SDT type recognition using FFNN and CNN

Тип ИНС	$q = 5$			$q = 10$			$q = 20$					
	S	M	L	S	M	L	S	M	L			
CNN	S	99,6	1,3	0,0	S	100,0	0,0	0,0	S	100,0	0,0	0,0
	M	0,3	98,3	0,3	M	0,0	99,9	0,0	M	0,0	100,0	0,0
	L	0,1	0,4	99,7	L	0,0	0,1	100,0	L	0,0	0,0	100,0
FFNN	S	91,7	2,2	0,6	S	98,6	0,4	0,2	S	99,8	0,2	0,2
	M	3,5	97,4	0,1	M	0,9	99,6	0,0	M	0,2	99,8	0,0
	L	4,8	0,4	99,1	L	0,5	0,0	99,8	L	0,0	0,0	99,8

5. Результаты и обсуждение

Рассмотрим результаты анализа эффективности классификации РЛИ НК различными методами, а именно: байесовский классификатор (БК), байесовский классификатор с оценкой дисперсии (БК ОД), метод наименьших расстояний (НР), полносвязные нейронные сети (FFNN) и сверточные нейронные сети (CNN).

На первом этапе проанализированы возможности применения алгоритмов с полностью известными априори параметрами — отношением сигнал/шум q и размерами целей a . Размеры целей считаются неизменными и различаются в первом случае на 30 отсчетов, во втором — на 15, при этом значения размеров ПРЦ составляют, соответственно, 10, 40 и 70 отсчетов (что соответствует разрешающей способности порядка 5 м) и 25, 40 и 55 отсчетов (что соответствует разрешающей способности порядка 2,5 м). Поскольку все сведения о свойствах ПРЦ известны, то методы БК ОД и НР на данном этапе не применялись, в качестве конкурирующих алгоритмов использованы ИНС типа CNN и FFNN, обученные на наборах данных с фиксированными параметрами. Результаты представлены на рис. 7.

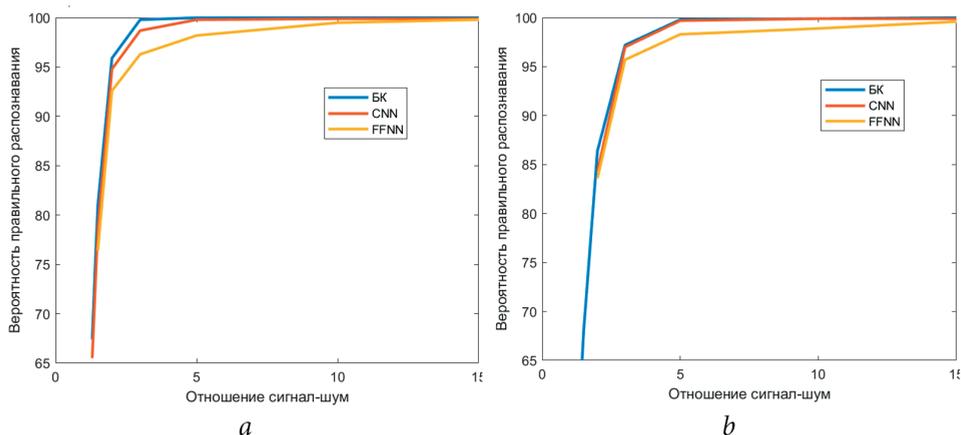


Рис. 7. Вероятность правильного распознавания типа ПРЦ:
 a — $a = \{10\ 40\ 70\}$; b — $a = \{25\ 40\ 55\}$

Fig. 7. Probability of correctly recognizing the SDT type
 a) $a = \{10\ 40\ 70\}$; b) $a = \{25\ 40\ 55\}$.

Байесовский классификатор при полностью известной априорной информации о распознаваемых классах показывает более высокую точность распознавания в сравнении с ИНС. В случае, если размеры целей различаются на 30 отсчетов, БК обеспечивает точность распознавания выше 95 % при значении $q = 2$, если же размеры целей различаются на 15 отсчетов,

то минимально необходимое значение сигнал/шум составят 2,5. В аналогичных условиях сеть CNN может обеспечить точность распознавания не менее 95 % при значении $q = 2,8$, сеть FFNN — при значении $q = 3$.

На следующем этапе рассмотрена эффективность БК в случае, когда отношение сигнал/шум известно с некоторой погрешностью Δq . В качестве конкурирующих алгоритмов использованы как ИНС, обученные на фиксированном наборе данных, так и ИНС, обученные на всем возможном диапазоне отношений сигнал/шум. Зависимости вероятности правильного распознавания от величины Δq при отличии размеров целей на 30 отсчетов для двух значений отношения сигнал/шум показаны на рис. 8.

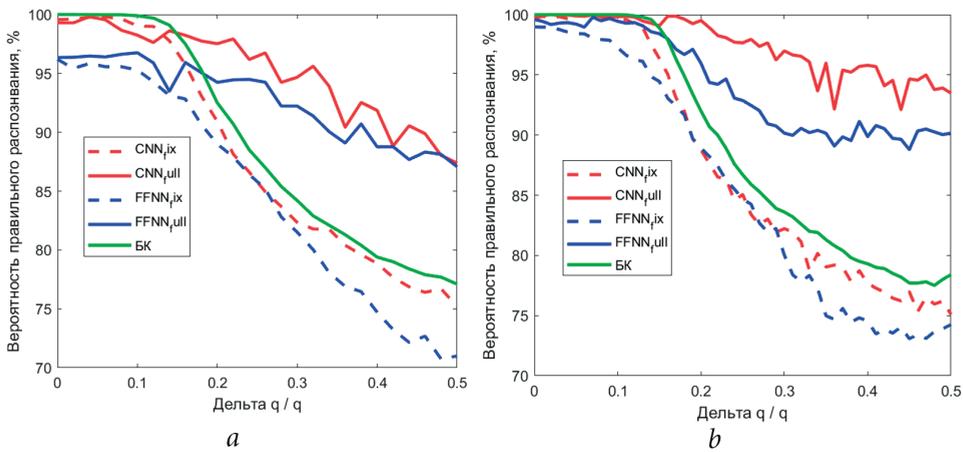


Рис. 8. Вероятность правильного распознавания типа ПРЦ от величины погрешности определения отношения сигнал/шум Δq : а — $q = 5$; б — $q = 10$

Fig. 8. Probability of correctly recognizing the SDT type depending on SNR measurement error Δq : а) $q = 5$; б) $q = 10$

Как следует из приведенных зависимостей, точность распознавания с использованием БК составляет более 95 % только в том случае, когда отношение сигнал/шум известно с ошибкой не более 15 %.

ИНС, обученные на выборках с фиксированным отношением сигнал/шум, ведут себя аналогичным образом, тогда как ИНС, обученные на всем диапазоне величин q , показывают приемлемую точность распознавания и при больших значениях погрешности Δq .

Применение БК становится неэффективным даже в том случае, когда размеры ПРЦ известны точно, но отношение сигнал/шум известно с погрешностью, превышающей 15 %.

При неизвестном отношении сигнал/шум БК не работает. Поэтому проанализируем сравнительную точность классификации для двух ИНС, БК ОД и НР. Результаты для двух типов размеров ПРЦ приведены на рис. 9.

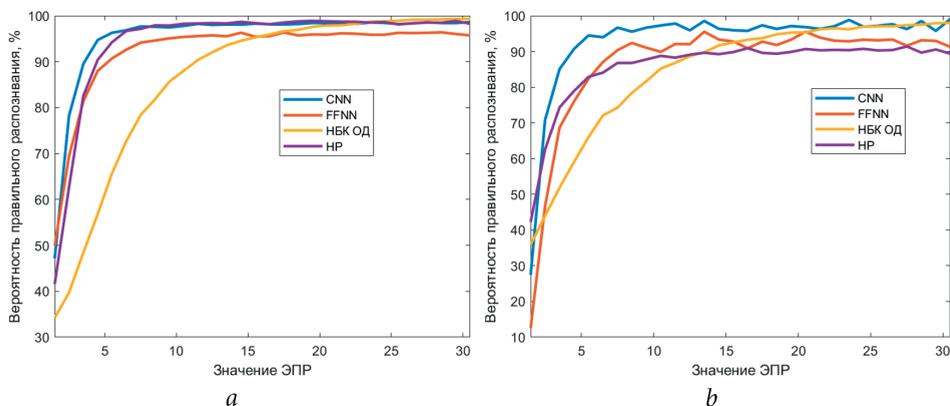


Рис. 9. Вероятность правильного распознавания типа ПРЦ от величины сигнал/шум:
 $a — a = \{10\ 40\ 70\}$; $b — a = \{25\ 40\ 55\}$

Fig. 9. Probability of correctly recognizing the SDT type depending on SNR: a) $a = \{10\ 40\ 70\}$; b) $a = \{25\ 40\ 55\}$

Наиболее высокая точность в условиях сильного шума может быть получена с помощью CNN.

Для анализа степени влияния различий в размерах ПРЦ определена вероятность правильного распознавания для наборов ПРЦ с последовательно уменьшающимися отличиями в размерах с $\{10, 40, 70\}$ ($\Delta a = 30$) по $\{38\ 40\ 42\}$ ($\Delta a = 2$). Результаты для различных фиксированных значений отношения сигнал/шум приведены на рис. 10.

БК обеспечивают точность распознавания не ниже 97,5 % при разнице размеров в 4 отчета при $q = 5$ и 6 отсчетов при $q = 10$, при меньших различиях в размерах наблюдается резкий рост ошибки определения «малых» целей.

Несмотря на дополнительное «дообучение», CNN показывает точность распознавания не менее 95 % только до разницы в размерах в 22 отсчета, что соответствует размеру малой цели в 18 отсчетов и размеру большой — в 62. Наиболее устойчивыми к изменениям размеров ПРЦ оказалась сеть FFNN, показывающая точность не менее 95 % на всем анализируемом интервале.

Как следует из приведенных выше зависимостей, для всех методов с ростом угла поворота точность распознавания снижается, что обусловлено деформацией величины большой полуоси в рамках наблюдаемой век-

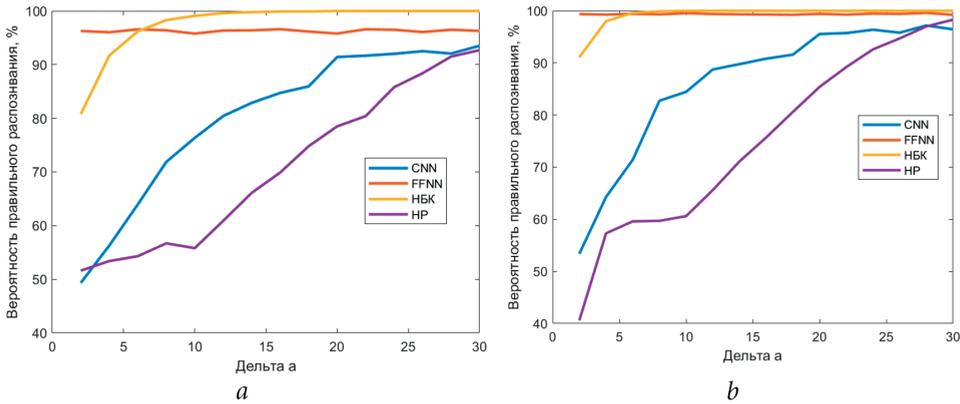


Рис. 10. Вероятность правильного распознавания типа ПРЦ от различия в размерах распознаваемых целей Δa : $a - q = 5$; $b - q = 10$

Fig. 10. Probability of correctly recognizing the SDT type depending on the difference in the sizes of recognized targets Δa : a) $q = 5$; b) $q = 10$

тор-строки и, как следствие, смещением классов. Наиболее устойчивыми методами оказались CNN, сохраняющие точность не ниже 95 % вплоть до значений колебаний размеров ПРЦ до 4 отсчетов, аналогичные результаты при низком уровне шума показывают FFNN. БК сохраняет высокую точность распознавания в случае, если размеры ПРЦ изменяются не более чем на 2 отсчета. Следует отметить, что ошибка определения ракурса до 10° приводит к изменению размеров даже крупных целей не более чем на 1 отсчет, поэтому при соблюдении рассмотренных выше условий для решения задачи распознавания типа ПРЦ в условиях, когда их размеры известны с некоторой погрешностью, могут быть использованы как классические методы, так и ИНС.

Результаты анализа влияния вариаций размеров ПРЦ приведены на рис. 11.

6. Заключение

В целом по анализу задачи определения типа ПРЦ можно сделать следующие выводы:

1. В условиях, когда отношение сигнал/шум известно с точностью до 15 %, байесовский классификатор показывает наилучшие результаты.
2. При необходимости определения типа цели в случае, когда наименьшая ПРЦ занимает менее 11 отсчетов и на кадре присутствует интенсивный шум, следует использовать ИНС.

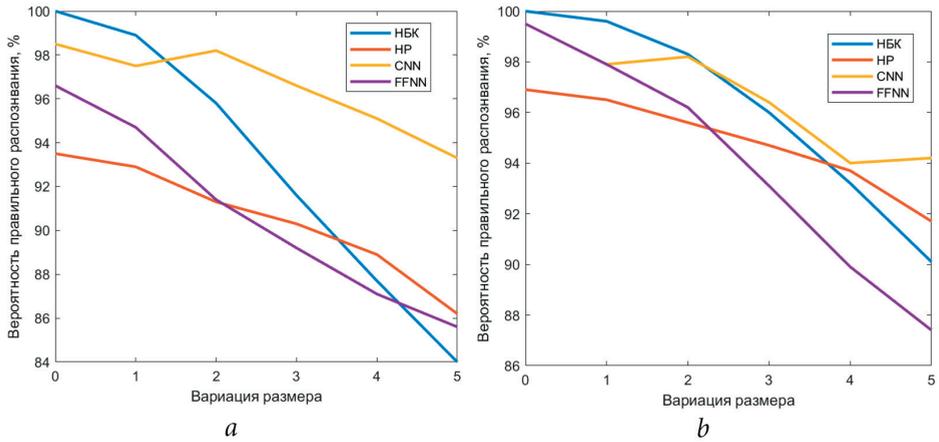


Рис. 11. Вероятность правильного распознавания типа ПРЦ зависимости от различия в размерах распознаваемых целей Δa : а — $q = 5$; б — $q = 10$

Fig. 11. Probability of correctly recognizing the SDT type depending on the difference in the sizes of recognized targets Δa : а) $q=5$; б) $q=10$

3. Если размеры наблюдаемых ПРЦ различаются не более, чем на 2 отсчета, то для распознавания их типов могут быть использованы как классические подходы, так и ИНС с архитектурой FFNN.

Список литературы

1. Артемьев А. М. *Военно-морской словарь*. М.: Военное издательство; 1990. 511 с.
2. *Корабел.ру*. URL: <https://www.korabel.ru/fleet/index2.html> (дата обращения: 15.01.2024).
3. *MIL Press Flot*. URL: <https://flot.com/nowadays/strength/surfaceships/#24> (дата обращения: 16 09 2023).
4. Дмитриев В. В., ред. *Морской энциклопедический словарь*. В 3 т. Ленинград: Судостроение; 1991. Т. 1. 504 с.
5. *NavSource Photo Archives*. URL: <http://www.navsource.org/archives/10/15idx.htm> (дата обращения: 17.01.2024).
6. *Энциклопедия военной техники*. URL: <https://war-book.ru/xxi-vek/flot-ww4/> (дата обращения: 18.01.2024).
7. Кондратенков Г. С., Потехин В. А., Реутов А. П., Феоктистов Ю. А. *Радиолокационные станции обзора Земли*. М.: Радио и связь; 1983. 272 с.
8. Zhang T., ed. *Official-SSDD*. URL: <https://github.com/TianwenZhang0825/Official-SSDD> (дата обращения: 17.01.2024).

9. 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.
10. Zhang T. SAR Ship Detection Dataset (SSDD): Official Release and Comprehensive Data Analysis. *Remote Sensing*. 2021;13(18):3690–3690. DOI: 10.3390/rs13183690
11. Доросинский Л. Г. *Оптимальная обработка радиолокационных изображений*. М.: Издательский дом Академии естествознания; 2017. 212 с.
12. Доросинский Л. Г., Виноградова Н. С. *Обработка сигналов от пространственно-распределенных целей*: монография. М.: Издательский дом Академии естествознания; 2023. 348 с. DOI: 10.17513/np.560
13. Ван Трис Г. *Теория обнаружения, оценок и модуляции*. В 4 т. Пер. с англ. под ред. В. И. Тихонова. М.: Советское радио; 1972. Т. 1. 744 с.
14. Hunter H., Graber H. Comparison of Feed Forward Neural Networks and Convolutional Neural Networks for SAR Automatic Target Recognition. *12th European Conference on Synthetic Aperture Radar (EUSAR 2018)*. 04–07 June 2018. Aachen, Germany. IEEE; 2018. Pp. 1–6.

References

1. Artemyev A. M. *Voенно-морской` slovar`* [Naval Dictionary]. Moscow: Voенное izdatel'stvo [Military Publishing]; 1990. 511 p. (In Russ.)
2. *Korabel.ru*. URL: <https://www.korabel.ru/fleet/index2.html> (accessed: January 15, 2024). (In Russ.)
3. *MIL Press Flot*. URL: <https://flot.com/nowadays/strength/surfaceships/#24> (accessed: September 16, 2023). (In Russ.)
4. Dmitriev V. V., ed. *Morskoi entsiklopedicheski slovar`* [Marine encyclopedic dictionary]. In 3 volumes. Leningrad: Sudostroenie [Shipbuilding]; 1991. Vol. 1. 504 p. (In Russ.)
5. *NavSource Photo Archives*. URL: <http://www.navsource.org/archives/10/15idx.htm> (accessed: January 17, 2024).
6. *Entsiklopediya voенnoi tekhniki* [Encyclopedia of military equipment]. URL: <https://war-book.ru/xxi-vek/flot-ww4/> (accessed: January 18, 2024). (In Russ.)
7. Kondratenkov G. S., Potehin V. A., Reutov A. P., Feoktistov Yu. A. *Radiolokatsionnye stantsii obzora Zemli* [Earth survey radars]. Moscow: Radio i svyaz' [Radio and communications]; 1983. 272 p. (In Russ.)
8. Zhang T., ed. *Official-SSDD*. URL: <https://github.com/TianwenZhang0825/Official-SSDD> (accessed: January 17, 2024).
9. 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/BIGSARDATA.2017.8124934.
10. Zhang T. SAR Ship Detection Dataset (SSDD): Official Release and Comprehensive Data Analysis. *Remote Sensing*. 2021;13(18):3690–3690. DOI: 10.3390/rs13183690
11. Dorosinskii L. G. *Optimal'naya obrabotka radiolokatsionnykh izobrazhenii* [Optimal processing of radar images]. Moscow: Izdatel'skii dom Akademii Estestvoznaniya [Publishing House of the Academy of Natural Sciences]; 2017. 212 p. (In Russ.)
12. Dorosinskii L. G., Vinogradova N. S. *Obrabotka signalov ot prostranstvenno-rasprostranennykh tselei: monografiya* [Signal Processing from Spatially Distributed Targets]. Moscow: Izdatel'skii dom Akademii Estestvoznaniya Estestvoznaniya [Publishing House of the Academy of Natural Sciences]; 2023. 348 p. DOI: 10.17513/np.560 (In Russ.)
13. Van Tris G. *Teoriia obnaruzheniia, ocenok i moduliatcii* [Theory of detection, estimation and modulation]. In 4 volumes. Moscow: Sovetskoe radio [Soviet radio]; 1972. Vol. 1. 744 p. (In Russ.)
14. Hunter H., Graber H. Comparison of Feed Forward Neural Networks and Convolutional Neural Networks for SAR Automatic Target Recognition. *12th European Conference on Synthetic Aperture Radar (EUSAR 2018)*. 04–07 June 2018. Aachen, Germany. IEEE; 2018. Pp. 1–6.

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, Russian Federation.

Nina S. Vinogradova, 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, Russian Federation.

Поступила / Received: 01.02.2024

Принята в печать / Accepted: 20.03.2024