

Оригинальная статья / Original Paper

DOI 10.15826/urej.2022.6.3.005

УДК 621.312.01(076)

## Сравнительный анализ классических методов и методов машинного обучения при решении задач классификации радиолокационных изображений

Л. Г. Доросинский ✉, С. С. Иванов

Уральский федеральный университет имени первого Президента России  
Б. Н. Ельцина, Россия, 620002, г. Екатеринбург, Мира, 19

✉ l.g.dorosinskiy@urfu.ru

### Аннотация

Сложившаяся в последние годы массовая тенденция использовать глубокое машинное обучение, искусственные нейронные сети и методы искусственного интеллекта при решении самых разных задач, как научных исследований, так и производственных проблем, приводит к существенным методологическим неточностям, а именно, использованию сложных, трудоемких и очень объемных алгоритмических процедур в то время, как задача может быть решена несоизмеримо более простыми и компактными методами без потерь в эффективности. Для этого необходимо воспользоваться широко распространенными и хорошо известными методами, в том числе классическими, параметрическими, непараметрическими, настроенными на задачу. Машинное обучение безусловно носит универсальный характер, в чем и заключается его ценность, но не учитывает особенности конкретной проблемы, заменяя обучением тот этап, который традиционные методы призваны восполнить умелой настройкой на конкретную проблему.

В работе рассмотрены два метода, один из которых основан на классическом методе максимального правдоподобия с оптимальной оценкой неизвестных параметров распределений отдельных отсчетов флуктуирующего изображения (входного массива данных), а другой – на глубоком машинном обучении, классификации радиолокационных изображений для конкретной задачи распознавания трех классов пространственно-распределенных целей, отличающихся своими размерами.

### Ключевые слова

информационные технологии, аппаратное и программное обеспечение, радиолокатор с синтезированной апертурой, метод максимального правдоподобия, искусственные нейронные сети

### Для цитирования

Доросинский Л. Г., Иванов С. С. Сравнительный анализ классических методов и методов машинного обучения при решении задач классификации радиолокационных изображений. *Ural Radio Engineering Journal*. 2022;6(3):310–323. DOI: 10.15826/urej.2022.6.3.005.

## Comparative analysis of classical methods and machine learning methods in solving problems of radar image classification

L. G. Dorosinskiy ✉, S. S. Ivanov

Ural Federal University named after the first President of Russia B.N. Yeltsin,  
19 Mira Srt., Ekaterinburg, 620002, Russia

✉ l.g.dorosinskiy@urfu.ru

### Abstract

The mass trend that has developed in recent years to use deep machine learning, artificial neural networks and artificial intelligence methods in solving a variety of tasks, both scientific research and production problems, leads to significant methodological inaccuracies, namely, the use of complex, time-consuming and very voluminous algorithmic procedures while the problem can be solved by incomparably uncomplicated and more compact methods without loss in efficiency. To do this, it is necessary to use widely used and well-known methods, including classical, parametric, nonparametric, customized to the task. Machine learning is certainly universal in nature, which is its value, but it does not take into account peculiarities of a specific problem, replacing with learning the stage that traditional methods are designed to fill with skillful adjustment to a specific problem.

The paper considers two methods, one of which is based on the classical maximum likelihood method with optimal estimation of unknown parameters of the distributions of individual samples of the fluctuating image (input data array), and the other on deep machine learning, classification of radar images of a specific task of recognizing three classes of spatially distributed targets that differ in their sizes.

### Keywords

information technologies, hardware and software, synthetic aperture radar, maximum likelihood method, artificial neural networks

### For citation

Dorosinskiy L. G., Ivanov S.S. Comparative analysis of classical methods and machine learning methods in solving problems of radar image classification. *Ural Radio Engineering Journal*. 2022;6(3):310–323. (In Russ.) DOI: 10.15826/urej.2022.6.3.005.

### Введение

Сложившаяся в последние годы массовая тенденция использовать глубокое машинное обучение, искусственные нейронные сети и методы искусственного интеллекта (все эти три термина, по мнению авторов, легко заменяются друг на друга) [1] при решении самых разных задач приводит, на наш взгляд, к существенным методологическим неточностям. Многие исследователи пытаются использовать сложные, трудоемкие и далеко не всегда

адекватные содержанию решаемых задач алгоритмические процедуры в то время, как задача может быть решена несоизмеримо более простыми и компактными методами без потерь в эффективности. Для этого зачастую достаточно воспользоваться широко распространенными и хорошо известными методами, в том числе классическими, параметрическими, непараметрическими, настроенными на задачу. Машинное обучение безусловно носит универсальный характер, в чем и заключается его ценность, но не учитывает особенности конкретной проблемы, заменяя обучением тот этап, который традиционные методы призваны восполнить умелой настройкой на конкретную проблему.

### **Цель исследования и научная новизна**

Научная новизна работы заключается в том, что в ней впервые исследуются возможности использования глубокого машинного обучения для решения задач классификации радиолокационных изображений (РЛИ) пространственно-распределенных объектов, отличающихся своими размерами и интенсивностью флуктуаций отраженного сигнала.

В отличие от традиционных задач машинного зрения (распознавание фрагментов текста, фотографий лиц, номеров автомобилей и т. п.) в данной работе предлагается впервые публикуемый сравнительный анализ разных методов решения широко распространенной в практических приложениях задачи классификации сильно флуктуирующих (и поэтому далеко не всегда легко поддающихся распознаванию) радиолокационных изображений, формируемых в авиационных и космических системах мониторинга земной/водной поверхности [2].

### **Материал и методы исследования**

При проектировании современных радиолокационных систем космического мониторинга земной поверхности требуется создание системы распознавания и классификации пространственно-распределенных объектов (ПРО). Такая система помогает в решении многих задач анализа радиолокационных изображений наблюдаемой местности, таких как оценка площади лесных пожаров, определение морских волнений, обнаружение незаконных свалок и несанкционированного строительства, определение характера и размеров различных объектов на изображении и т. д.

В работе рассмотрены два метода решения задачи классификации РЛИ для конкретной задачи распознавания трех классов ПРО (малая, средняя, большая), первый из которых осно-

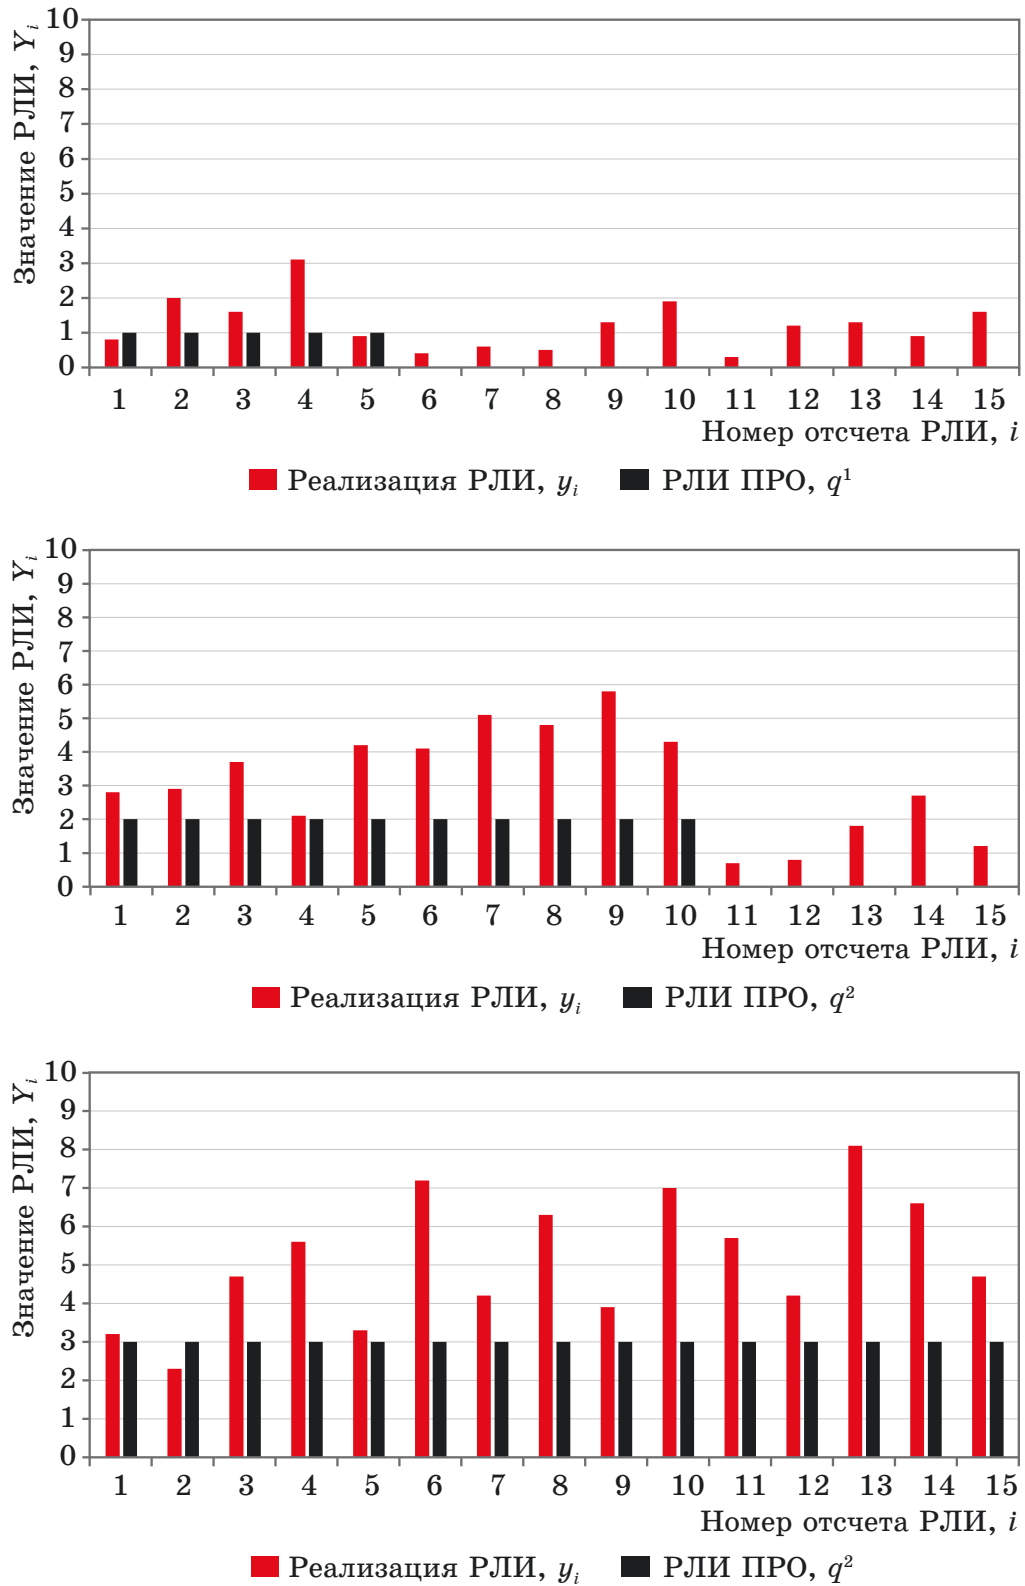
ван на методе максимального правдоподобия [3], а второй – на глубоком машинном обучении [4].

Авторы отдают себе отчет в том, что обсуждаемая проблема является весьма скромной на фоне всего многообразия практических задач классификации радиолокационных изображений, тем не менее поставленная им цель продемонстрировать необходимость детального анализа применяемых методов исследования, зачастую отдавая предпочтение хорошо изученным традиционным методам, не бросаясь сломя голову применять сложные и далеко не всегда оправданные технологии.

Критерием эффективности сравниваемых методов служат общепринятые показатели: вероятность правильной классификации; количество обучающих выборок для получения результата, близкого к асимптотическому; объем необходимой памяти; количество операций, выполняемых тем или иным алгоритмами.

### **Радиолокационные изображения**

Важнейшим преимуществом радиолокационного обзора местности над оптическим является возможность наблюдения поверхности земли независимо от метеорологических условий и времени суток. С помощью метода искусственного синтезирования антенны потенциальные характеристики разрешающей способности радиолокационной станции (РЛС) приближаются к оптическим средствам наблюдения [5]. Сущность метода заключается в излучении когерентных зондирующих сигналов РЛС, установленной на летательном аппарате (ЛА), движущемся по прямолинейной траектории полета, их запоминании и когерентном сложении. Данные РЛС также имеют возможность реализации высокой линейной разрешающей способности. Сами РЛИ формируются при следующих предположениях. Радиолокатор с синтезированной апертурой (РСА) перемещается по прямолинейной траектории, использует импульсный широкополосный зондирующий сигнал, причем отсчеты РЛИ различных каналов дальности могут считаться статистически независимыми. Весь участок поверхности, попадающий в один канал дальности, разбит на отдельные элементарные участки, состоящие, в свою очередь, из большого числа элементарных отражателей. Сигнал, отраженный от такого участка, представляет собой нормальный случайный процесс с нулевым математическим ожиданием и дисперсией, которая зависит от целого ряда параметров, в первую очередь, от типа объекта, его индивидуальных особенностей, а также условий наблюдения. После предварительной обработки полученных сигналов РЛИ представляет собой вектор независимых случайных чисел, распределенных по экспоненциальному закону [6].



**Рис. 1.** Пример идеальных (черные столбики) и реальных (красные) РЛИ ( $M = 5, 10, 15$ ;  $q_i^k = 1, 2, 3$ )

**Fig. 1.** Example of ideal (black bars) and real (red) RLI ( $M = 5, 10, 15$ ;  $q_i^k = 1, 2, 3$ )

Сравнительный анализ методов распознавания (классического и глубокого машинного обучения) был выполнен на примере классификации трех одномерных, полученных в одном канале дальности, радиолокационных изображений, формируемых РЛС с синтезированной апертурой [3]. Изображения представляли собой флуктуирующую последовательность дискретных отсчетов  $y_i$ , распределенных по экспоненциальному закону, причем часть отсчетов имела один параметр –  $\sigma^k$   $k = 1, 2, 3$  (принадлежность к  $k$ -му наблюдаемому объекту), а оставшаяся часть – отличающийся параметр  $\sigma_\Phi$  (принадлежность к фону). Пример «портретов» трех ПРО и одной из возможных выборочных случайных реализаций названных портретов в конкретном наблюдении показан на рис. 1. На верхнем фрагменте рисунка РЛИ «малой» ПРО занимает пять элементов (пикселей)  $M = 5$ , на среднем –  $M = 10$  («средняя» ПРО) и на нижнем –  $M = 15$  («большая» ПРО). Идеальные «портреты» показаны в виде черных столбиков. Соответствующие им выборочные значения – красными.

Среднеквадратические отклонения – параметры экспоненциального распределения имеют следующие значения (отношения сигнал/фон  $q^1 = \sigma^1/\sigma_\Phi = 1$ ;  $q^2 = \sigma^2/\sigma_\Phi = 2$ ;  $q^3 = \sigma^3/\sigma_\Phi = 3$ . Названные параметры исходных данных приведены в табл. 1.

Таблица 1. Параметры распределения

Table 1. Distribution Parameters

Число отсчетов РЛИ, принадлежащих ПРО (M)	5	10	15
Отношение сигнал/фон ( $q$ )	1	2	3

### Алгоритмы классификации

Классический алгоритм определения размеров предполагает вычисление отношения правдоподобия [6]:

$$L(y_i/k) = \prod_{i=1}^N W(y_i/k) = \prod_{i=1}^{M_k} \frac{1}{\sigma_i^k} e^{-\frac{y_i}{\sigma_i^k}} \prod_{i=M_k+1}^N \frac{1}{\sigma_\Phi} e^{-\frac{y_i}{\sigma_\Phi}}, \quad (1)$$

где  $y_i$  –  $i$ -й отсчет РЛИ;  $M_k$  – предполагаемый размер объекта;  $N$  – количество отсчетов РЛИ;  $\sigma_k$  – параметр плотности распределения  $i$ -го отсчета цели при условии наблюдения объекта  $k$ -го размера;  $\sigma_\Phi$  – параметр плотности распределения фона.

После несложных преобразований алгоритм определения размера (1) принимает вид

$$K = \arg \max (\ln L(y_i/k)), \quad (2)$$

где

$$\ln L(y_i/k) = \sum_{i=1}^{M_k} \left( \frac{q_i^k - 1}{q_i^k} \frac{y_i}{\sigma_\Phi} - \ln q_i^k \right), \quad q_i^k = \frac{\sigma_i^k}{\sigma_\Phi}.$$



Задача распознавания усложняется, если нам заранее неизвестен параметр  $\sigma_k$ , однако его можно оценить предварительно по «рабочеподобным» выборкам (разумеется, следует располагать названными выборками на этапе «обучения» алгоритма). Отыскание неизвестного параметра осуществляется также методом максимального правдоподобия. Названная оценка по сути является аналогом процедуры обучения нейронной сети, использование которой для решения обсуждаемой задачи приведено ниже.

Эту же задачу решим с помощью нейронной сети [7]. Выбор типа сети и ее конфигурации представляет собой отдельную задачу, решенную в [6]. В настоящее время не существует регулярных методов подбора типа сети и ее конфигурации для решения задачи распознавания пространственно-распределенных целей с различными статистическими характеристиками, что вынуждает исследователя в каждом конкретном случае подбирать тип и конфигурацию сети методами статистического моделирования. В нашем случае мы провели сравнительный анализ следующих сетей: многослойный персептрон, радиальная базисная функция, вероятностная нейронная сеть, обобщенная регрессионная нейронная сеть, самоорганизующаяся сеть Кохонена, линейная сеть, сеть главных компонент [8; 9].

Для выбора наиболее эффективной сети и для тестирования различных алгоритмов классификации требуется наличие примеров (образов) самих РЛИ. В сети Интернет можно найти различные базы данных с изображениями, в той или иной степени соответствующих решаемой задаче, однако данные базы ограничены и не позволят проводить эксперименты с различными параметрами и размерами целей. В этой ситуации более надежным является создание своей базы, легко управляемой в зависимости от особенностей решаемой задачи. Для решения данной проблемы необходимо разработать настраиваемый генератор РЛИ, с помощью которого можно будет легко создавать РЛИ трех видов, как того требует поставленная задача. Пример такого РЛИ был показан на рис. 1.

РЛИ ПРО представляет собой вектор случайных независимых отсчетов, распределенных экспоненциально. Данный факт позволяет нам превратить задачу генерации РЛИ в задачу генерации случайных экспоненциально распределенных чисел.

Для проверки правильности получаемых распределений плотности вероятностей генерируемых чисел построим гистограммы формируемых распределений и сравним с теоретическими плотностями вероятностей. На рис. 2, 3 изображены гистограммы для отдельных отсчетов РЛИ.




Рис. 2. Гистограмма нормального распределения  $\mu = 0$ ;  $\sigma = 3$

Fig. 2. Histogram of the normal distribution  $\mu = 0$ ;  $\sigma = 3$

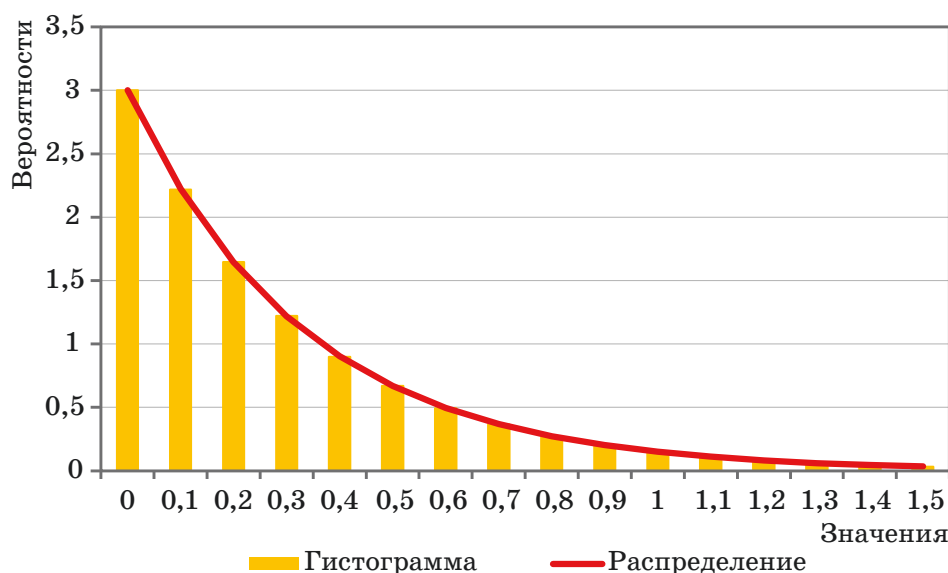


Рис. 3. Гистограмма экспоненциального распределения  $\sigma = 3$

Fig. 3. Histogram of exponential distribution  $\sigma = 3$

Сравнительный анализ названных выше типов нейронных сетей [10], обучение которых производилось на базе выборок независимых случайных потоков, отличающихся числом и интенсивностью сигнальных отсчетов, показал преимущество вероятностной нейронной сети, у которой выходы можно интерпретировать как оценки вероятностей того, что элемент принадлежит некоторому классу, и сеть фактически учится оценивать функцию плотности вероятности. Число ошибочных решений было меньше, чем у ближайшей по эффективности сравниваемой сети на 6,8 %.



Для сравнительного анализа классического метода и метода, основанного на машинном обучении, воспользуемся методом моделирования Монте-Карло. Мерой качества того или иного алгоритмов будет являться матрица ошибок, состоящей из вероятностей принять решение в пользу  $i$ -го класса ПРЦ при правильном  $k$ -м:  $p(i/k)$ :

$$\begin{pmatrix} P(1/1) & P(2/1) & P(3/1) \\ P(1/2) & P(2/2) & P(3/2) \\ P(1/3) & P(2/3) & P(3/3) \end{pmatrix}. \quad (3)$$

Для анализа примем размеры целей  $M_k = 5, 10, 15$ , а  $q_i^k = \text{const}$ , для каждого отдельного класса, причем  $q_i^1 = 5$ ,  $q_i^2 = 10$ ,  $q_i^3 = 15$ . Количество выборок  $N = 100$ . Матрица ошибок при использовании классического алгоритма определяется следующим выражением:

$$\begin{pmatrix} 1 & 0 & 0 \\ 0,01 & 0,99 & 0 \\ 0 & 0 & 1 \end{pmatrix}. \quad (4)$$

Из (4) следует, что алгоритм отлично работает при достаточно больших и отличающихся значениях  $q_i^k$ . При уменьшении отличий между ПРО по интенсивности отраженных сигналов ( $q_i^1 = 1$ ,  $q_i^2 = 2$ ,  $q_i^3 = 3$ ) матрица ошибок имеет вид:

$$\begin{pmatrix} 0,87 & 0,13 & 0 \\ 0,14 & 0,81 & 0,05 \\ 0 & 0,1 & 0,9 \end{pmatrix}. \quad (5)$$

Задача распознавания усложняется, если нам заранее неизвестен параметр  $\sigma$ , однако его можно оценить предварительно по «рабочеподобным» выборкам (разумеется, следует располагать названными выборками на этапе «обучения» алгоритма).

При числе обучающих выборок  $N = 15$ , размерах ПРО:  $M = 5, 10, 15$ , отношениях сигнал/фон:  $q_i^k = 1, 2, 3$  эффективность классификации определяется выражением:


$$\begin{pmatrix} 0,87 & 0,13 & 0 \\ 0,14 & 0,81 & 0,05 \\ 0 & 0,1 & 0,9 \end{pmatrix}. \quad (6)$$

Другим инструментом для распознавания ПРЦ, как было отмечено выше, являются нейронные сети [1; 7]. Для распознавания радиолокационных изображений была использована вероятностная нейронная сеть, состоящая из трех слоев, имеющая преимущество по выходным вероятностным характеристикам для распознаваемых ПРО. Промежуточный слой содержит 500

нейронов, функция активации нейрона – сигмоидальная/оптимизатор обучения – adam. Число обучающих выборок равно 100. Матрица ошибок имеет вид:


$$\begin{pmatrix} 0,995 & 0,005 & 0 \\ 0,01 & 0,989 & 0,001 \\ 0 & 0,011 & 0,989 \end{pmatrix}. \quad (7)$$

Графики зависимости вероятности ошибки от числа обучающих выборок приведены на рис. 4 и 5. На графике красным цветом обозначены результаты, полученные нейронной сетью, зеленым – метод максимального правдоподобия.



**Рис. 4.** График зависимости вероятности ошибки от числа обучающих выборок  $N$  ( $M = 5, 10, 15$ ;  $q_i^k = 5, 10, 15$ )

**Fig. 4.** Graph of the error probability dependence on the number of training samples  $N$  ( $M = 5, 10, 15$ ;  $q_i^k = 5, 10, 15$ )



**Рис. 5.** График зависимости вероятности ошибки от числа обучающих выборок  $N$  ( $M = 5, 10, 15$ ;  $q_i^k = 1, 2, 3$ )

**Fig. 5.** Graph of the error probability dependence on the number of training samples  $N$  ( $M = 5, 10, 15$ ;  $q_i^k = 1, 2, 3$ )

При таких условиях нейронная сеть работает хуже, чем метод максимального правдоподобия, если число выборок меньше 20. При увеличении количества обучающих выборок нейронная сеть практически не уступает методу максимального правдоподобия.

### Результаты исследования

Проведенное сравнение двух методов принятия решений о классе РЛИ говорит в пользу классического метода максимального правдоподобия даже при неизвестных параметрах задачи, что требует использования параметрического алгоритма, использующего «обучение с учителем». В этом нет ничего удивительного, так как метод максимального правдоподобия использует априорную информацию о статистических характеристиках сигналов, в то время как названная информация недоступна нейронной сети, которой, что поделать, приходится «учиться».

Проведем сравнение двух описанных выше алгоритмов по памяти и быстродействию на этапах обучения и распознавания. Сложность обучения по памяти для нейронной сети –  $O(n)$ , где  $n$  – количество обучающих выборок, т. к. нейронной сети нужно держать все обучающие выборки в процессе обучения в памяти. Для метода максимального правдоподобия сложность составляет  $O(1)$ , так как можно удалить из памяти выборку сразу после обучения по ней. Сложность распознавания по памяти для алгоритмов одинакова –  $O(1)$ , другими словами, требуется хранить в памяти только одну выборку. Однако хранение параметров метода максимального правдоподобия требует  $M_1 + M_2 + M_3$  чисел с плавающей точкой, где  $M_1, M_2, M_3$  – размеры распознаваемых объектов. Для  $M_1 = 5, M_2 = 10, M_3 = 15$  нужно будет держать в памяти 30 чисел с плавающей точкой. Для нейронной сети этот показатель гораздо выше, так как нейронная сеть требует хранения всех связей нейронов. В данном примере в памяти будет держаться  $15 \cdot 500 + 500 \cdot 3 = 9000$  чисел с плавающей точкой. То есть хранение такой простой нейронной сети требует в 300 раз больше памяти, чем хранение параметров метода максимального правдоподобия. С увеличением сложности нейронной сети (добавлением новых слоев) это число будет только расти.

Сравним данные методы по числу операций. Во время обучения методу максимального правдоподобия требуется производить только операции сложения, в то время как нейронной сети требуется производить сложные (для быстродействия) операции взятия градиента функции и операции матричного ум-

ножения. Сравним время обучения в зависимости от числа обучающих выборок.

При 1000 обучающих выборок нейронная сеть совершает в 15 раз больше операций. При распознавании число операций и время выполнения для обоих методов примерно одинаково с небольшим перевесом у метода максимального правдоподобия.

Таким образом, в случае сильно флуктуирующих, с одной стороны, но сравнительно простых по конфигурации пространственно-распределенных объектов, с другой – применение глубокого машинного обучения как минимум не приводит к повышению эффективности классификации по сравнению с классическими алгоритмами.

## Выводы

При решении задач классификации объектов по отраженным от них сигналам, подверженным значительным искажениям в форме мультипликативных флуктуаций с известными статистическими характеристиками, прежде чем использовать методы машинного обучения, автор настоятельно рекомендует применить классические алгоритмы, основанные на статистических различиях принимаемых сигналов.

Как показано в данной статье, лучшая из исследованных нейронная сеть при самых благоприятных условиях дает результаты, не уступающие классическому алгоритму, только в асимптотике, проигрывая ему до 2–3 раз по вероятности правильно классификации при ограниченном числе обучающих выборок (менее 10). Поскольку в реальных условиях применения исследуемых алгоритмов в авиационных и космических системах мониторинга земной/водной поверхностей рассчитывать на значительное число образов пространственно-распределенных объектов не приходится, автор считает объективно аргументированным использование классического алгоритма максимального правдоподобия при его параметрическом воплощении – применении обучения с учителем для оценки неизвестных параметров: интенсивностей сигнальных отсчетов.

В этом случае может оказаться, что, несколько не уступая в эффективности, метод максимального правдоподобия работает в десятки раз быстрее и занимает в сотни раз меньше памяти.

Последний вывод связан с тем, что характер флуктуаций, по крайней мере, вид распределения априори известен с точностью до параметров и подтверждается на практике. В случае значительной априорной неопределенности нейронная сеть может и должна оказаться более эффективной.

## Список литературы

1. Бишоп К. М. *Распознавание образов и машинное обучение*. М.; СПб.: Диалектика; 2020. 962 с.
2. Костяшкин Л. Н., Никифоров М. Б. (ред.). *Обработка изображений в авиационных системах технического зрения*. М.: Физматлит; 2016. 238 с.
3. Rossi R. J. *Mathematical statistics: An introduction to logical inference based on likelihood*. New York: John Wiley & Sons; 2018. 448 p. Available at: <https://www.wiley.com/en-us/9781118771167>
4. Траск Э. *Грокаем глубокое обучение*. СПб.: Питер; 2019. 352 с.
5. Сколник М. И. (ред.). *Справочник по радиолокации*. М.: Техносфера; 2014. 672 с.
6. Доросинский Л. Г., Виноградова Н. С., Иванов О. Ю. *Обработка радиолокационных изображений*. М.: Издательский дом «Академии Естествознания»; 2021. 334 с. <https://doi.org/10.17513/np.503>
7. Бруссард М. *Искусственный интеллект. Пределы возможного*. М.: Альпина; 2020. 361 с.
8. Тархов Д. А. *Нейронные сети. Модели и алгоритмы*. М.: Радиотехника; 2005. 256 с.
9. Хайкин С. *Нейронные сети*. 2-е изд. М.: Издательский дом «Вильямс»; 2006. 1104 с.
10. Доросинский Л. Г., Виноградова Н. С. *Теория и практика обработки сигналов в многопозиционных космических РСА*. М.: Издательский дом «Академии Естествознания»; 2020. 271 с. Режим доступа: <http://hdl.handle.net/10995/94603>

## References

1. Bishop K. M. *Pattern recognition and machine learning*. Moscow; St. Petersburg: Dialectics; 2020. 962 p. (In Russ.)
2. Kostyashkin L. N., Nikiforov M. B. (eds). *Image processing in aviation vision systems*. Moscow: Fizmatlit; 2016. 238 p.
3. Rossi R. J. *Mathematical statistics: An introduction to logical inference based on likelihood*. New York: John Wiley & Sons; 2018. 448 p. Available at: <https://www.wiley.com/en-us/9781118771167>
4. Trask A. *Grok deep learning*. St. Petersburg: Peter; 2019. 352 p. (In Russ.)
5. Skolnik M. I. (ed.) *Handbook of Radar*. Moscow: Tekhnosfera; 2014. 672 p. (In Russ.)
6. Dorosinskiy L. G., Vinogradova N. S., Ivanov O. Yu. *Radar image processing*. Moscow: Akademiya Estestvoznaniya; 2021. 334 p. (In Russ.)
7. Broussard M. *Artificial intelligence. The limits of the possible*. Moscow: Alpina; 2020. 261 p. (In Russ.)
8. Tarkhov D. A. *Neural networks. Models and algorithms*. Moscow: Radiotekhnika; 2005. 256 p. (In Russ.)

9. Khaykin S. *Neural networks*. Moscow: Williams; 2006. 1104 p. (In Russ.)

10. Dorosinskiy L.G., Vinogradova N.S. *Theory and practice of signal processing in multi-position space RSA*. Moscow: Akademiya Estestvoznaniya; 2020. 271 p. (In Russ.) Available at: <http://hdl.handle.net/10995/94603>

### **Информация об авторах**

**Доросинский Леонид Григорьевич**, доктор технических наук, профессор Уральского федерального университета, г. Екатеринбург, Россия

**Иванов Сергей Сергеевич**, магистрант Уральского федерального университета, г. Екатеринбург, Россия

### **Information about the authors**

**Leonid G. Dorosinskiy**, Doctor of Technical Sciences, Professor of the Department of Radio Electronics and Telecommunications, Institute of Radio Electronics and Information Technologies – RTF Ural Federal University named after the first President of Russia B.N. Yeltsin, Ekaterinburg, Russia.

**Sergey S. Ivanov**, Master's student of Radio Electronics and Telecommunications, Institute of Radio Electronics and Information Technologies – RTF Ural Federal University named after the first President of Russia B.N. Yeltsin, Ekaterinburg, Russia.

[Поступила](#) / Received: 22.09.2022

[Принята в печать](#) / Accepted: 30.09.2022