

УДК 621.396.96

DOI 10.34822/1999-7604-2020-1-69-76

ПОВЫШЕНИЕ ДОСТОВЕРНОСТИ НЕЙРОСЕТЕВОЙ КЛАССИФИКАЦИИ РАДИОЛОКАЦИОННЫХ ОБЪЕКТОВ

Д. В. Маршаков

Донской государственный технический университет, Ростов-на-Дону, Россия

E-mail: daniil_marshakov@mail.ru

Распознавание типов радиолокационных объектов по сигнальным признакам с целью отслеживания их перемещений в заданной области является важной задачей обеспечения безопасности воздушного движения. Один из эффективных инструментов решения этой задачи – применение искусственных нейронных сетей.

В данной работе предложен способ статистической оценки результатов нейросетевой классификации радиолокационно-отслеживаемых динамических объектов, основанный на статистической проверке гипотез. Оценка осуществляется посредством сравнения выборочной средней всего распределения выходных результатов нейронной сети, полученных по результатам серии наблюдений за объектами, с усредненным пороговым значением меры сходства ее выходных сигналов, принятой в качестве гипотетической генеральной средней. Проведенные экспериментальные исследования предложенных решений на примере классификации одиночных объектов двух типов по их доплеровским портретам в условиях значительных помех подтверждают повышение достоверности нейросетевой классификации в среднем до 8 %.

Рассмотренный подход может быть применим как в независимых нейросетевых системах классификации или селекции радиолокационно-обнаруживаемых объектов, так и в составе комплексных систем поддержки принятия решений существующих или перспективных радиолокационных станций.

Ключевые слова: радиолокация, спектральный портрет, сигнальные признаки, классификация, искусственная нейронная сеть, достоверность.

RELIABILITY IMPROVEMENT OF NEURAL NETWORK CLASSIFICATION FOR RADAR OBJECTS

D. V. Marshakov

Don State Technical University, Rostov-on-Don, Russia

E-mail: daniil_marshakov@mail.ru

The recognition of types of radar objects by signal characteristics to track their movements in a given area is an important task for ensuring air traffic security. One of the effective tools for solving this problem is the artificial neural networks.

The paper proposes the method for the statistical evaluation of the results of a neural network classification for radar-tracked dynamic objects based on the statistical hypothesis testing. The estimation is carried out by comparing the sample mean of the entire distribution of the results output of the neural network. The results are obtained from a series of observations over objects, with the averaged threshold value of similarity of its output signals, adopted as a hypothetical general average. The increase in the reliability of the neural network classification for a mean of 8% is confirmed during experimental studies of the proposed solutions on the example of the classification of single objects of two types with their Doppler portraits under conditions of significant noise.

The considered method can be used in an independent neural network classification or selection system for radar-detectable objects and as part of integrated decision support systems for existing or prospective radar stations.

Keywords: radiolocation, spectral portrait, signal characteristics, classification, artificial neural network, reliability.

Введение. В современных условиях проблемы радиолокационной разведки и контроля воздушного пространства многократно возросли в силу имеющихся фактов воздушно-го терроризма, несанкционированного использования воздушного пространства, в том числе частными летательными аппаратами [1–3]. В связи с этим задача распознавания и классификации радиолокационно-обнаруживаемых воздушных объектов вызывает повышенный интерес среди разработчиков систем управления воздушным движением и противовоздушной обороны.

Реализация методов распознавания и классификации радиолокационных объектов определяется видом применяемых зондирующих сигналов и способами их обработки. В качестве признаков пространства могут выступать сигнальные признаки, содержащиеся в структуре отраженных сигналов, а также статистические траекторные и поведенческие признаки, заложенные в параметрах и особенностях движения отслеживаемого объекта.

Одним из наиболее информативных сигнальных признаков распознавания динамического объекта является его доплеровский портрет, или доплеровский спектр [4–7]. Спектр формируется за счет изменения частоты отраженного от движущихся частей объекта радиосигнала, максимальные мощности составляющих которого обусловлены отражением от корпуса объекта. При изменении скорости, направления движения происходит сдвиг спектральных составляющих по оси частот, их расширение или сужение. Достоинствами этих признаков являются простота их векторного представления, а также отсутствие необходимости доработки существующих радиолокационных станций для реализации режимов их формирования. При этом основная сложность их применения состоит в непрерывном изменении во времени отраженного от отслеживаемого объекта сигнала (эхо-сигнала) при изменении его ориентации в пространстве, изменении работы двигателей, скорости движения и т. п., что влечет за собой необходимость учета множества совместных многомерно распределенных, динамичных во времени величин.

Кроме того, спектральные портреты малоразмерных или значительно удаленных от системы радиолокации объектов могут быть сильно зашумлены, в связи с этим традиционные методы классификации объектов по признакам данного рода сталкиваются с рядом трудностей. Одними из эффективных инструментов решения этой задачи являются искусственные нейронные сети (далее – ИНС) [7–10], обладающие возможностями обучения на экспериментальном материале, адаптации к изменениям внешних условий и параллельной обработки многомерных зашумленных данных. Существенным достоинством нейросетевых методов распознавания является отсутствие необходимости заблаговременного выявления законов распределения и числовых характеристик используемых признаков, что делает наиболее целесообразным их применение в решении задач классификации объектов на основе радиолокационной информации.

Принцип нейросетевого распознавания образов. Задача распознавания образов сводится к классификации и идентификации типов объектов, характеризуемых конечным набором отдельных свойств и признаков, представленных в виде входного вектора фиксированной длины. Построение правил нейросетевой классификации заключается в поиске функций, описывающих разделение параметрического пространства на соответствующие классам объектов области. Принадлежность входного вектора к одному из M -классов определяется исходя из максимального значения вектора выходных сигналов $Y = [y_1, \dots, y_M]^T$ нейронной сети [11–14]. Представителем распознанного класса признается наиболее активный нейрон: $y_k = \max(Y)$, $k = \overline{1, M}$, где M – число выходных нейронов, определяющее количество классов распознавания.

Недостатком такой интерпретации выходных результатов ИНС является отсутствие оценки уровней активности выходных нейронов. Между тем в условиях ограниченной точности измерения параметров объектов, сильной зашумленности исходного сигнала, перемещения объектов признаки распознаваемого объекта могут изменяться случайным образом. Вследствие этого входной образ может оказаться близким граничным значениям двух или более классов, что не позволяет оценить с высокой достоверностью выходной результат ИНС и ведет к снижению качества распознавания нейронной сетью.

Одним из способов частичного устранения этого недостатка является применение радиально-базисных нейронных сетей [15–16]. Данный способ позволяет определить степень вероятной принадлежности к некоторому классу, однако применим только для нейронных сетей с точно известной функцией распределения значений выходных данных, в то время как на практике статистики выходных данных описываются заранее неизвестными законами распределения. Другим решением может служить применение вероятностных нейронных сетей [17], в которых для аппроксимации неизвестных плотностей вероятностей по обучающим выборкам используются ядерные функции Парзена, позволяющие решить задачу оценки плотности вероятности по имеющимся данным, однако для реализации требующие использования достаточно большого объема памяти для хранения всех обучающих выборок. Известен метод [18] оценки достоверности выходных результатов многослойных ИНС, основанный на вычислении евклидова расстояния между фактическим выходным вектором ИНС, характеризующим класс распознаваемого объекта, и множеством эталонных векторов, задающих на этапе обучения априорно известные классы. Данный метод позволяет оценить выходной результат классификации в зависимости от величины «активности» каждого из выходов нейронной сети, однако не учитывает динамику наблюдений.

Интересным представляется подход, предложенный в [19], в котором рассмотрена возможность применения к задаче нейросетевого распознавания образов методов математической статистики, что в аспекте радиолокационного распознавания позволило бы учесть последовательность наблюдений. Такой способ подразумевает проведение серии наблюдений за подаваемыми на вход ИНС векторами и формируемыми на выходе заключениями и исследованием распределения случайной величины по классам с последующей статистической проверкой гипотез.

В этом случае при N последовательных наблюдениях за каждым динамически изменяемым входным образом на выходе нейронной сети будет сформировано множество из N наблюдаемых выходных векторов $Y = \{Y_l\}$, $l = \overline{1, N}$, где $Y_l = \{y_{k,l}\}$ – выходной вектор ИНС для l -го наблюдения.

Такой подход может быть применим к задачам радиолокационного распознавания в условиях статического шума или пространственного перемещения объекта с целью повышения достоверности распознавания.

Постановка задачи. Качественно задача классификации радиолокационно-обнаруженных объектов сводится к принятию решения по измеренным значениям признаков наблюдаемых объектов о том, какой именно из этих объектов относится к интересующему классу при известных отличиях между значениями признаков объектов различных классов и составе конкретной выборки.

На практике эффективность классификации характеризуется условными вероятностями ошибочных (ложных) решений различного вида – вероятностью появления ошибки первого рода, состоящей в отвержении правильного класса и влекущей за собой возникновение «ложной тревоги», и ошибки второго рода, сводящейся к пропуску классифицируемого объекта вследствие принятия неправильного класса. Однако применительно к задаче оценки достоверности классификации, в силу необходимости определения в некоторой группе объектов единственного из них, который относится к интересующему классу, решение определяется вероятностью правильной классификации объекта, если все остальные решения являются ошибочными. Отсюда следует, что вероятность правильной и ошибочной классификации в сумме равна единице, и при этом не имеет значения, какой именно из ложных объектов классификации принимается истинным, а «ложная тревога» означает одновременно его пропуск. Таким образом, в качестве показателя достоверности классификации целесообразно рассматривать вероятность ω правильной классификации, которую можно определить согласно выражению:

$$\omega = \frac{\Omega_{\text{пр}}}{\Omega} \cdot 100 \%, \quad (1)$$

где $\Omega_{\text{пр}}$ – число успешно классифицированных объектов;
 Ω – общее число проведенных классификаций.

Целью данной работы является повышение достоверности нейросетевой классификации радиолокационно-обнаруженных объектов. Для достижения цели предлагается применение статистической оценки формируемых на выходе нейросетевого классификатора решений при заданных сведениях об отслеживаемом объекте классификации – наличии объекта либо отсутствии классификационных признаков.

Методика статистической оценки результатов нейросетевой классификации. Для статистической оценки выходных результатов ИНС предлагается применение статистической проверки гипотез, а именно сравнения выборочной средней всего распределения выходных результатов ИНС с некоторой гипотетической генеральной средней. По результатам сравнения формируется решение на основании значимого или незначимого различия средней вычисленной величины и гипотетической идеальной.

По N независимым наблюдениям над выходными векторами ИНС, являющимися результатом классификации отслеживаемого объекта, может быть определено некоторое среднее a_0 значение признака генеральной совокупности, принимаемое за гипотетическое.

Гипотетическое среднее может быть получено исходя из анализа разрешающей способности δ нейросетевого классификатора [19], определяющей степень сходства полученных на выходе ИНС решений, которая может быть соотнесена с разностью максимальных значений сигналов нейронов выходного слоя:

$$\delta_l = \max_1(Y_l) - \max_2(Y_l),$$

где $\max_1(Y_l)$ и $\max_2(Y_l)$ – первый и второй максимумы наблюдаемого выходного вектора для l -го наблюдения соответственно.

Минимальное значение разрешающей способности соответствует трудноразличимым изображениям, и в зависимости от его величины возможно определение некоторого порога меры сходства выходных сигналов, по величине разницы с которым определяется качество проведенной классификации. На основании проведенных наблюдений формируется усредненное пороговое значение разрешающей способности, принимаемое за гипотетическое генеральное среднее:

$$a_0 = \frac{1}{N} \sum_{l=1}^N \max_1(Y_l) - \max_2(Y_l),$$

где Y_l – выходной вектор ИНС l -го наблюдения; $l = \overline{1, N}$.

Выборочной средней является среднее арифметическое всех значений выборки для каждого k -го выхода ИНС:

$$\overline{y_{k,l}} = \frac{1}{N} \sum_{l=1}^N y_{k,l}, \quad k = \overline{1, M}, \quad l = \overline{1, N}.$$

В зависимости от количества наблюдений (объема выборки выходных результатов ИНС) возможно определение дисперсии генеральной совокупности. Так, при большом объеме выборки $N > 30$ можно получить достаточно хорошую оценку дисперсии, однако такое количество наблюдений требует увеличения времени наблюдения за радиолокационным объектом, что практически не всегда возможно. При малом объеме выборки $N < 30$ дисперсия генеральной совокупности остается неизвестной, и для расчетов применяется исправленная дисперсия. Такой подход представляется наиболее целесообразным в целях повышения оперативности проведения классификации.

Проверка основной гипотезы $H_0 : a = a_0$ о равенстве неизвестной генеральной средней a гипотетическому значению a_0 при конкурирующей гипотезе $H_1 : a < a_0$ при заданном

уровне значимости α осуществляется на основе наблюдаемого значения статистического критерия для каждого l -го, $l = 1, N$, наблюдения, вычисляемого как:

$$T_{\text{набл}}^l = \frac{(\overline{y_{k,l}} - a_0) \sqrt{N}}{s_k},$$

где $\overline{y_{k,l}}$ – выборочная средняя по каждому k -му выходу ИНС, $k = \overline{1, M}$;

s_k – исправленное среднее квадратичное отклонение для каждого k -го выхода ИНС.

Значение критической точки $t_{\text{пр.кр.}}(\alpha; d)$ определяется согласно уровню значимости α критических точек распределения Стьюдента и числу степеней свободы $d = (N - 1)$. В случае, если $T_{\text{набл}}^l > -t_{\text{пр.кр.}}$, нет оснований отвергнуть основную гипотезу, иначе принимается конкурирующая гипотеза.

Подтверждение гипотезы о генеральной средней статистического распределения на k -м выходе ИНС означает, что среднее значение всех заключений ИНС будет превышать принятое в качестве порогового значение разрешающей способности ИНС.

Моделирование и оценка эффективности. Практическое применение и оценку эффективности описанного подхода рассмотрим на примере нейросетевой классификации радиолокационно-обнаруженных объектов двух типов. Исходными данными являлись экспериментально полученные результаты широкополосного зондирования для двух отслеживаемых одиночных объектов, сведенные к статистическому набору спектров эхо-сигналов, представленному в виде поверхности доплеровских сдвигов частоты (рис.). Объект № 1 и объект № 2 содержали 118 и 52 временных отчета соответственно. Каждый вектор спектрального портрета включал в себя 175 значений и для удобства последующей обработки был масштабирован в интервал $[0, 1]$ и перенесен в среду математического моделирования MATLAB.




Рисунок. Наборы спектров отраженного от отслеживаемого объекта сигнала: а) объекта № 1; б) объекта № 2

Примечание: данные получены автором в ходе совместных исследований с АО «КБ «Связь».

Формирование матриц для обучения нейросетевого классификатора осуществлялось согласно предложенной в [20] методике, на основании которой была обеспечена стационарность анализируемых спектральных портретов, применяемых в качестве входных данных нейронной сети, с подавлением гребня, сформированного лучом подсвета, проходящего через все задержки исследуемых поверхностей. При этом исходные данные были разделены на обучающие (60 %) и проверочные (40 %) наборы векторов.

В качестве нейросетевой модели была определена многослойная ИНС прямого распространения с 175 входами, числом нейронов скрытого слоя, принятым 8, и числом нейронов выходного слоя, соответствующим количеству классифицируемых объектов, т. е. равным 2. Для нейронов скрытого и выходного слоя применялись сигмоидальные униполярные функции активации. Обучение ИНС проводилось методом обратного распространения ошибки с применением алгоритма Левенберга – Марквардта, обеспечивающим максимальное быстродействие.

Для оценки эффективности классификации в условиях, имитирующих высокий уровень помех, набор проверочных векторов был подвергнут зашумлению сигналами случайной величины со среднеквадратичным отклонением, равным 0,6.

В качестве показателя достоверности классификации применялось количество $\Omega_{\text{пр}}$ успешно классифицированных объектов и соотношение (1). При этом сравнительный анализ проверок между классическим методом, предусматривающим признание распознанного класса по наиболее активному нейрону выходного слоя, и описанным статистическим подходом проходил для $N = 5$ и $N = 10$ последовательных наблюдений. Для $N = 5$ наблюдений было проведено 10 экспериментов, для $N = 10$ наблюдений – 5 экспериментов, в силу ограниченного количества входных данных для объекта № 2, для которого в проверочные наборы были включены зашумленные векторы из обучающего множества. Оценка выходных результатов ИНС с применением статистического метода осуществлялась при уровне значимости $\alpha = 0,05$.

Поскольку каждая генерируемая ИНС в зависимости от первоначально инициализируемых значений своих весовых коэффициентов и последующей процедуры обучения является уникальным объектом исследований, в целях общности проводимых экспериментов при заданных первоначальных условиях были проведены испытания с разными обученными ИНС, по исходу которых отмечена устойчивая тенденция результатов классификации.

Результаты одного из испытаний представлены в табл. 1 и 2.

Таблица 1

Оценка вероятности правильной классификации для $N = 5$ наблюдений

№ эксперимента	Объект № 1		Объект № 2	
	$\Omega_{\text{пр}}$ классический метод	$\Omega_{\text{пр}}$ статистический метод	$\Omega_{\text{пр}}$ классический метод	$\Omega_{\text{пр}}$ статистический метод
1	3/5	1/1	4/5	1/1
2	5/5	1/1	4/5	1/1
3	4/5	1/1	5/5	1/1
4	4/5	1/1	5/5	1/1
5	5/5	1/1	5/5	1/1
6	5/5	1/1	4/5	1/1
7	5/5	1/1	5/5	1/1
8	3/5	0/2	5/5	1/1
9	3/5	1/1	5/5	1/1
10	5/5	1/1	5/5	1/1
ω	84 %	90 %	94 %	100 %

Примечание: данные получены автором в ходе проведения экспериментов.

Таблица 2

Оценка вероятности правильной классификации для $N = 10$ наблюдений

№ эксперимента	Объект № 1		Объект № 2	
	$\Omega_{\text{пр}}$ классический метод	$\Omega_{\text{пр}}$ статистический метод	$\Omega_{\text{пр}}$ классический метод	$\Omega_{\text{пр}}$ статистический метод
1	8/10	1/1	8/10	1/1
2	8/10	1/1	10/10	1/1
3	10/10	1/1	9/10	1/1

Окончание табл. 2

№ эксперимента	Объект № 1		Объект № 2	
	$\Omega_{\text{пр}}$ классический метод	$\Omega_{\text{пр}}$ статистический метод	$\Omega_{\text{пр}}$ классический метод	$\Omega_{\text{пр}}$ статистический метод
4	8/10	1/1	10/10	1/1
5	8/10	1/1	10/10	1/1
ω	84 %	100 %	94 %	100 %

Примечание: данные получены автором в ходе проведения экспериментов.

Результаты проведенного моделирования задачи нейросетевой классификации радиолокационно-обнаруженных объектов по доплеровским спектрам, полученным на основе натурального эксперимента, позволяют сделать вывод об эффективности применения статистической оценки формируемых на выходе нейросетевого классификатора решений. При этом статистический подход позволяет повысить в среднем на 8 % достоверность проводимой классификации.

Выводы. Рассмотренный в работе способ статистической оценки выходных результатов нейросетевого классификатора радиолокационно-обнаруженных объектов учитывает динамику наблюдений за отслеживаемым радиолокационным объектом и не создает противоречивых суждений при оценке качества классификации. Применение данной методики в условиях зашумления или искажения признаков распознавания позволяет обеспечить повышение достоверности проводимой классификации до 8 %.

Достоинством данного подхода является учет величины уровней активности выходных нейронов ИНС при формировании основной гипотезы, недостатком – увеличение времени наблюдения за радиолокационным объектом.

Полученные результаты могут быть использованы как в независимых нейросетевых системах классификации или селекции радиолокационно-обнаруженных объектов, так и в составе комплексных систем поддержки принятия решений существующих или перспективных радиолокационных станций.

Перспективной представляется разработка методов вероятностной оценки степени принадлежности отслеживаемого объекта к выявленному классу.

Литература

1. Бердышев В. П., Помазуев О. Н., Савельев А. Н., Смолкин М. А., Копылов В. А., Лой В. В. Распознавание классов и типов воздушных объектов по двумерным радиолокационным изображениям в обзорной РЛС // Журн. СФУ. Техника и технологии. 2019. Т. 12, № 1. С. 18–29.
2. Воробьев Е. Н. Исследование сигнальных признаков распознавания малых БПЛА в полуактивной РЛС // Вест. Новгород. гос. ун-та. Технич. науки. 2019. № 4. С. 72–77.
3. Казачков Е. А., Матюгин С. Н., Попов И. В., Шаронов В. В. Обнаружение и классификация малоразмерных объектов на изображениях, полученных радиолокационными станциями с синтезированной апертурой // Вестн. Концерна ВКО «Алмаз-Антей». 2018. № 1. С. 93–99.
4. Molchanov P., Egiazarian K., Astola J., Harmanny R. I. A., Wit J. J. M. Classification of Small UAVs and Birds by Micro-Doppler Signatures // Proceedings of the 10th European Radar Conference, Nuremberg, Germany, 9-11 October 2013. IEEE, 2013. P. 172–175.
5. Романенко А. В. Формирование доплеровских портретов воздушных объектов с использованием метода сверхразрешения // Журн. радиоэлектроники. 2015. № 3. С. 4.
6. Онищенко В. С., Шевченко В. Н. Корреляционный метод классификации подвижных объектов по их спектральным портретам в системах скрытой локации // Радиолокация и радиосвязь: сб. тр. XI Всероссийской науч.-технич. конф., Москва, 27–29 ноября 2017 г. М. : ИРЭ им. В. А. Котельникова РАН, 2017. С. 236–240.

7. Сафонов А. В., Митрофанов Д. Г., Прохоркин А. Г. Нейросетевое распознавание летательных аппаратов по экспериментально сформированным доплеровским спектрам // *Нейрокомпьютеры: разработка, применение*. 2009. № 10. С. 57–62.
8. Brooks D., Schwander O., Barbaresco F., Schneider J.-Y., Cord M. Temporal Deep Learning for Drone Micro-Doppler Classification // *Proceedings of the 19th International Radar Symposium (IRS 2018)*, Bonn, Germany, 20–22 June 2018. IEEE, 2018. P. 874–883.
9. Карабаев Б. С. Распознавание летательных аппаратов при помощи нейросетевых технологий // *Новости науки Казахстана*. 2017. № 1. С. 31–42.
10. Баронин А. М., Демин Д. А. Применение нейронных сетей в современных РЛС // *DSPA: Вопросы применения цифровой обработки сигналов*. 2017. Т. 7, № 4. С. 205–210.
11. Rajaguru H., Prabhakar S. K. An Approach to Classification of Oral Cancer Using Softmax Discriminant Classifier // *Proceedings of the 2nd International Conference on Communication and Electronics Systems (ICCES)*, Coimbatore, India, 19–20 October, 2017. IEEE, 2017. P. 420–423.
12. Bayar V., Efe M. Ö. Detection of Smart Phone Position on User Using Artificial Neural Network Classifier // *Proceedings of the 26th Signal Processing and Communications Applications Conference (SIU)*, Izmir, Turkey, 2–5 May, 2018. IEEE, 2018. P. 345–348.
13. Coşkun M., Uçar A., Yildirim Ö., Demir Y. Face Recognition Based on Convolutional Neural Network // *Proceedings of the International Conference on Modern Electrical and Energy Systems (MEES)*, Kremenchuk, Ukraine, 15–17 November, 2017. IEEE, 2017. P. 376–379.
14. Wu Y., Liy J., Kongy Y., Fu Y. Deep Convolutional Neural Network with Independent Softmax for Large Scale Face Recognition // *Proceedings of the 24th ACM International Conference on Multimedia*, Amsterdam, Netherlands, 15–19 October, 2016. Association for Computing Machinery, 2016. P. 1063–1067.
15. Качайкин Е. И., Иванов А. И., Безяев А. В., Перфилов К. А. Оценка достоверности нейросетевой автоматизированной экспертизы авторства рукописного почерка // *Вопр. кибербезопасности*. 2015. № 2. С. 43–48.
16. Urgun D., Singh C. Multi Label RBF Classification Method for Composite System Reliability Evaluation // *Proceedings of the International Conference on Probabilistic Methods Applied to Power Systems (PMAAPS)*, Boise, Idaho, USA, 24–28 June, 2018. IEEE. P. 692–696.
17. Savchenko A. V. Statistical Recognition of a Set of Patterns Using Novel Probability Neural Network // *International Workshop on Artificial Neural Networks and Pattern Recognition, Lecture Notes in Computer Science*. 2012. Vol. 7477. P. 93–103.
18. Marshakov D. V., Galushka V. V., Fathi V. A., Fathi D. V. Evaluation of Neural Network Output Results Reliability in Pattern Recognition // *Proceedings of the Third International Scientific Conference “Intelligent Information Technologies for Industry” (ITI’18)*. P. 503–510.
19. Загинайло М. В., Маршаков Д. В. Статистическая оценка выходных результатов искусственной нейронной сети при задаче распознавания образов // *ИНФОКОМ-2018 : тр. СКФ МТУСИ по результатам XI Междунар. науч.-практич. конф, Ростов-на-Дону, 19–20 апреля 2018*. Ростов н/Д: ПЦ «Университет» СКФ МТУСИ, 2018. С. 137–140.
20. Иванов С. А., Маршаков Д. В. Методика представления входных векторов для нейросетевого классификатора радиолокационно-обнаруживаемых объектов // *Системный анализ, управление и обработка информации : тр. VIII Междунар. науч. конф., с. Дивноморское, 8–13 октября 2017, Т. 1*. Ростов н/Д: ДГТУ, 2017. С. 137–140.