

Р. О. Мишанов

ИСПОЛЬЗОВАНИЕ ОДНОСЛОЙНОГО ПЕРСЕПТРОНА ДЛЯ РЕШЕНИЯ ЗАДАЧИ КЛАССИФИКАЦИИ ЭЛЕКТРОРАДИОИЗДЕЛИЙ С ЦЕЛЬЮ ПОВЫШЕНИЯ КАЧЕСТВА И НАДЕЖНОСТИ БОРТОВОЙ АППАРАТУРЫ

R. O. Mishanov

THE APPLICATION OF SINGLE-LAYER PERCEPTRON FOR SOLVING PATTERN CLASSIFICATION TASK OF ELECTRONIC COMPONENTS IN ORDER TO IMPROVE THE QUALITY AND RELIABILITY OF ONBOARD EQUIPMENT

Аннотация. Рассматривается возможность применения однослойных перцептронов с различным количеством скрытых нейронов для классификации электрорадиоизделий на классы годных и потенциально дефектных изделий. В качестве исходных данных используются прогнозируемый (выходной) и информативные (входные) параметры микросхем. Обучение сетей проводилось с использованием программы «Deductor Academic», которая позволила определить основные параметры сети: значения синаптических весов и порогов для каждого нейрона. После обучения каждой сети были определены отклики на каждый пример обучающей выборки и сравнены с эталонными значениями. Оценка эффективности сетей проводилась по точности моделирования и классификации.

Ключевые слова: однослойный перцептрон, индивидуальное прогнозирование, классификация, электрорадиоизделие, линейно-разделимые классы, образ, скрытый нейрон, нейронная сеть, обучение нейросети.

Abstract. The article is devoted to the possibility of single-layer perceptron application with a different number of hidden neurons for classifying electronic components into classes of acceptable and potentially defective instances. The forecasted (output) and informative (input) parameters of the integrated chips are used as the initial data. Network training was carried out using the software «Deductor Academic», which allowed determining the main network parameters: the values of synaptic weights and thresholds for each neuron. After training each network, the responses to each example of training sample were determined and compared with reference values. Evaluation of the network efficiency was carried out according to the accuracy of modeling and classification.

Keywords: single-layer perceptron, individual forecasting, classification, electronic component, linearly separable classes, pattern, hidden neuron, neuron network, neuron network training.

Введение

Прогнозирование состояния электрорадиоизделий (ЭРИ) на определенный срок службы радиоэлектронных средств, устанавливаемых на борт космических аппаратов, – один из способов повышения качества и надежности сложной аппаратуры. Наиболее успешно данную задачу можно решить с помощью индивидуального прогнозирования (ИП) состояния ЭРИ, которое позволяет по характеристикам конкретного экземпляра провести прогноз состояния этого экземпляра с использованием математической модели с заранее выбранным упреждением [1]. Но не всегда модели, показавшие свою эффективность для конкретного типа ЭРИ, могут давать такой же эффект для другого типа ЭРИ. Более того, эффективность таких моделей может различаться для ЭРИ из разных партий и при разных условиях изготовления. Таким образом, поиск новых способов ИП, основанных на различных математических методах и моделях, способов отбраковки, основанных на применении диагностического неразрушающего контроля (ДНК), не теряет свою актуальность и в настоящее время.

При использовании ИП состояния изделий необходимо наличие исчерпывающей информации, включающей в себя сведения:

- о физико-химических процессах, происходящих в материалах изделия и влияющих на электрические параметры;
- влиянии условий окружающей среды на скорость протекания физико-химических процессов в структуре изделий;
- динамике изменений электрических характеристик изделий, что невозможно узнать без статистических данных об испытаниях этих изделий.

При использовании ИП целесообразно воспользоваться положениями теории распознавания образов, согласно которой каждый рассматриваемый экземпляр выборки представляет собой образ (точку, объект) в n -мерном пространстве признаков [2]. Таким образом, основной задачей классификации является разбиение совокупности таких образов в соответствии с некоторым критерием оптимальности. Задачи классификации решаемы с помощью большого количества методов и подходов, но особый интерес представляет применение искусственных нейронных сетей вследствие их нелинейности, способности адаптации при изменении параметров объектов, а также организации под решение конкретных задач [3, 4].

Одной из простейших форм искусственных нейронных сетей, успешно решающей задачу классификации линейно-разделимых множеств, является однослойный персептрон, который состоит из слоя входных данных (Input), одного скрытого слоя (Hide) и слоя выходных данных (Output). Было доказано, что если образы обучающего множества выбраны из двух линейно-разделимых классов, то алгоритм персептрона является сходящимся и образует поверхность решений в виде разделяющей гиперплоскости в гиперпространстве признаков [3].

Однослойный персептрон с одним скрытым нейроном ограничен решением задачи разделения на два класса линейно-разделимых образов. При увеличении количества скрытых нейронов возрастает количество классов, на которые можно разделить совокупность [3, 5]. Данное правило справедливо для линейно-разделимых множеств, т.е. когда классы явно выделяются и, как следствие, когда образы разных классов имеют максимальные различия признаков.

Задача классификации

В статье поставлена задача классификации выборки интегральных микросхем 765 серии с помощью трех конфигураций однослойного персептрона (рис. 1). Характеристики выборки микросхем представлены в работе [6]. Точность классификации оценивалась по вероятностным характеристикам, а также по величине ошибки отклонения от эталонных значений.

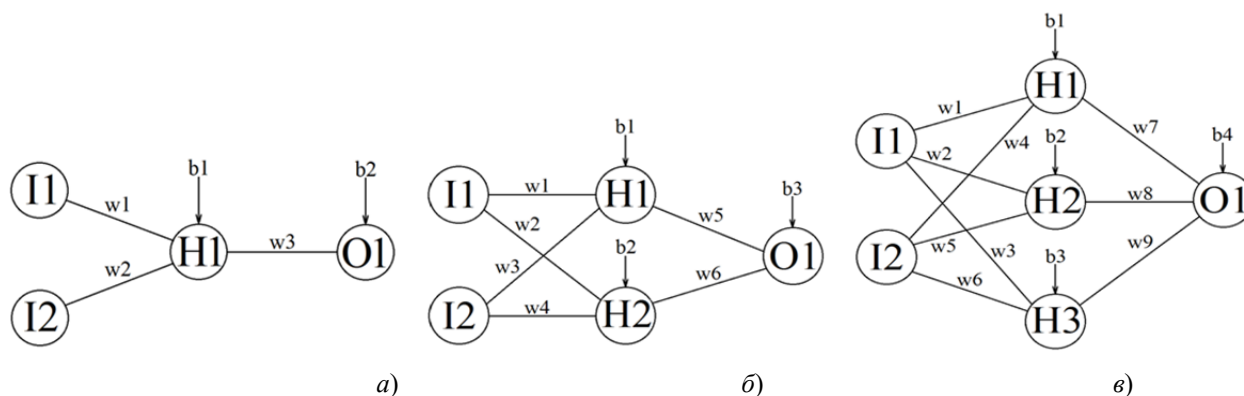


Рис. 1. Структуры однослойного персептрона:

a – с одним скрытым нейроном; *б* – с двумя скрытыми нейронами; *в* – с тремя скрытыми нейронами

В работе использовалось программное средство Deductor Academic [7]. Для обучения сети в качестве входных данных были выбраны информативные параметры X_1 и X_2 , в качестве выходных – $Y(1000)$. Обучающее множество состояло из 46 наблюдений, тестовое – из 4 наблюдений.

В качестве алгоритма обучения сети был выбран метод эластичного распространения (Resilient Propagation – Rprop) [5] с параметрами обучения, указанными на рис. 2.

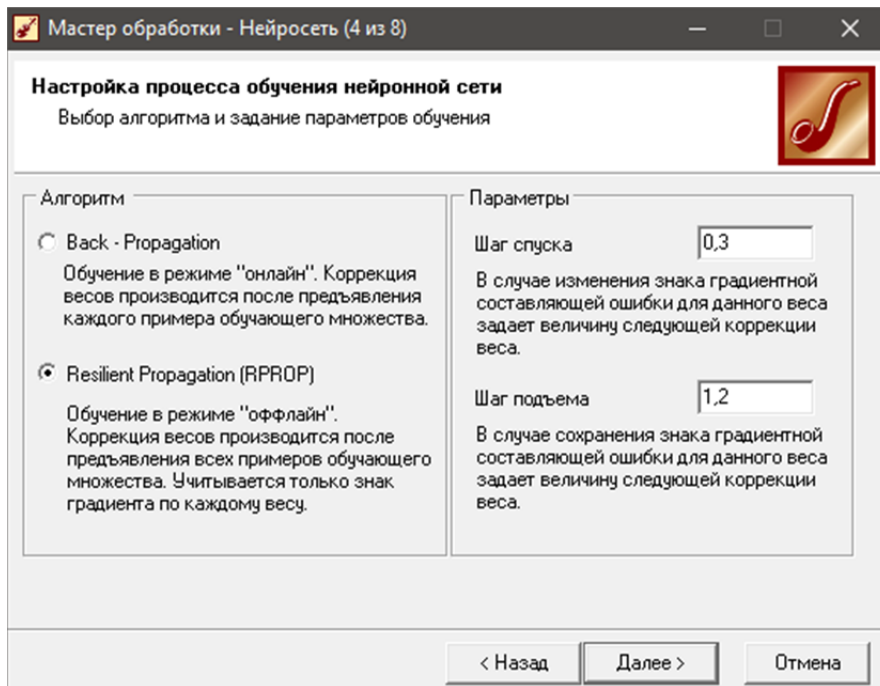


Рис. 2. Параметры обучения сети

Величина ошибки распознавания была выбрана равной 0,05. Таким образом, если отклик на выходе сети имеет различие менее 5 % с эталонным значением, то пример считается распознанным. Критерием корректного обучения сети был выбран случай, при котором все примеры обучающего и тестового множества были распознаны, а средняя ошибка принимала минимальное значение. Количество эпох обучения найдено экспериментальным путем. Для первой сети стабилизация ошибок наблюдалась на 9600 эпохе, для второй сети – на 7000 эпохе, для третьей сети – на 5500 эпохе. На рис. 3–5 показаны результаты обучения каждой из сетей.

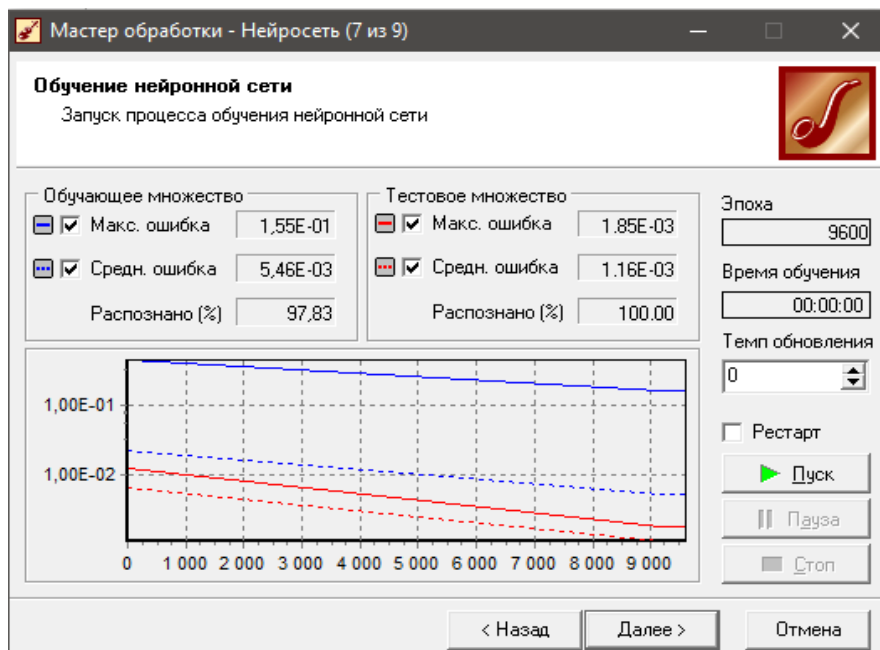


Рис. 3. Результаты обучения сети с одним скрытым нейроном

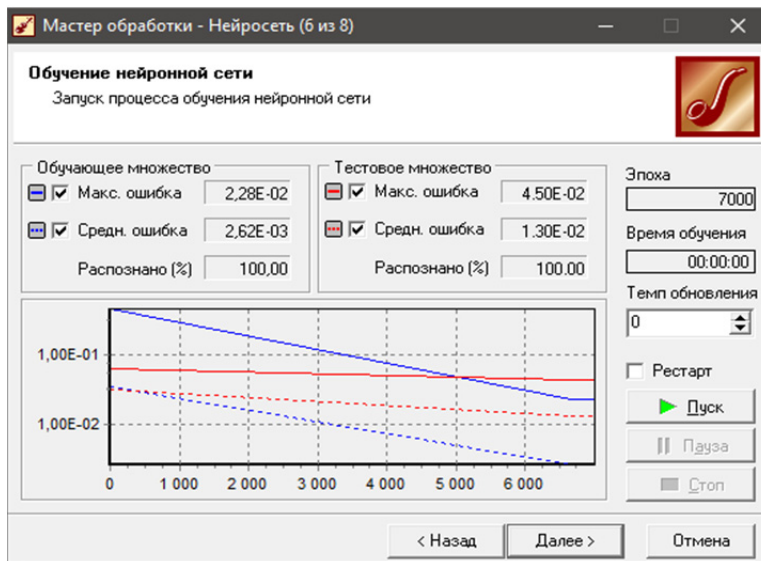


Рис. 4. Результаты обучения сети с двумя скрытыми нейронами

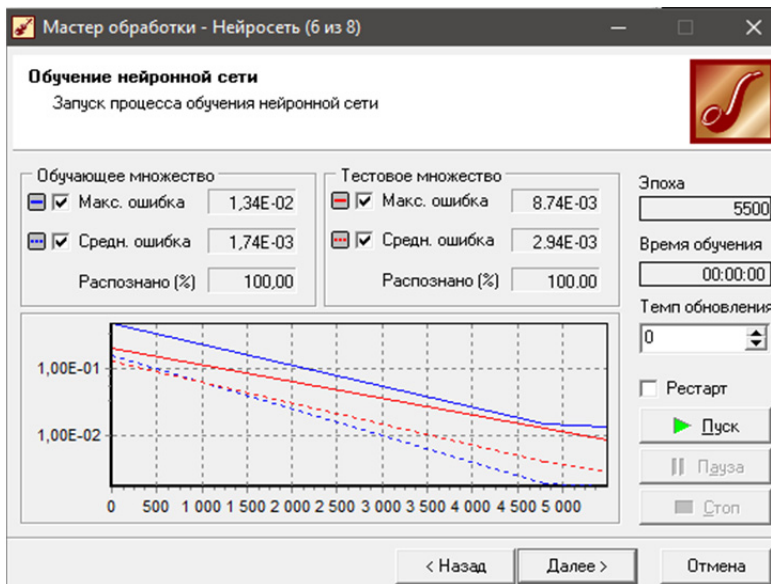


Рис. 5. Результаты обучения сети с тремя скрытыми нейронами

Результатом настройки персептрона является определение синаптических весов w и порогов b . В табл. 1 представлены результаты настройки. Результаты распознавания и классификации представлены в табл. 2. Для удобства восприятия результатов удобно пользоваться диаграммами рассеяния выходных данных, показанными на рис. 6–8.

Таблица 1

Результаты настройки параметров персептрона

Персептрон с одним скрытым нейроном				Персептрон с двумя скрытыми нейронами				Персептрон с тремя скрытыми нейронами			
w_1	-0,96	b_1	-1,683	w_1	2,207	b_1	-0,062	w_1	-17,692	b_1	5,339
w_2	0,142	b_2	4,025	w_2	7,856	b_2	-25,444	w_2	-13,439	b_2	-1,914
w_3	-24,47			w_3	-0,939	b_3	-3,795	w_3	-5,11	b_3	-1,491
				w_4	-73,143			w_4	31,879	b_4	0,087
				w_5	10,825			w_6	-0,451		
				w_6	-1,754			w_7	5,991		
								w_8	-5,759		
								w_9	-2,962		

Таблица 2

Результаты распознавания и классификации

Номер экз.	Y	K _{факт}	Сеть с 1 скр. нейроном			Сеть с 2 скр. нейронами			Сеть с 3 скр. нейронами		
			Y _{расп}	Y _{расп.ош}	K _{расп}	Y _{расп}	Y _{расп.ош}	K _{расп}	Y _{расп}	Y _{расп.ош}	K _{расп}
1	20	1	25,0777	0,001007	1	20,7943	0,000025	1	12,4156	0,002247	1
2	38	1	47,3104	0,003386	2	42,4073	0,000759	2	50,6552	0,006256	2
3	12	1	18,7031	0,001755	1	17,7296	0,001282	1	12,1728	0,000001	1
4	47	2	47,2401	0,000002	2	66,7239	0,015197	2	47,3185	0,000004	2
5	31	1	32,1992	0,000056	1	28,7806	0,000192	1	34,9675	0,000615	1
6	26	1	26,6837	0,000018	1	19,5037	0,001649	1	21,8373	0,000677	1
7	116	2	53,0848	0,154622	2	84,1787	0,039554	2	103,3356	0,006265	2
8	35	1	45,1181	0,003999	2	37,5548	0,000255	1	53,4961	0,013364	2
9	36	1	43,4806	0,002186	2	51,0094	0,0088	2	39,0726	0,000369	1
10	18	1	21,9595	0,000612	1	18,7747	0,000023	1	12,1495	0,001337	1
11	21	1	26,2044	0,001058	1	20,7099	0,000003	1	12,3031	0,002955	1
12	21	1	24,4435	0,000463	1	19,6317	0,000073	1	12,2256	0,003007	1
13	23	1	26,4425	0,000463	1	20,0722	0,000335	1	12,9042	0,003981	1
14	45	2	39,1435	0,001340	1	27,7649	0,011604	1	39,0515	0,001382	1
15	84	2	87,6945	0,000533	2	95,1455	0,004852	2	89,3558	0,00112	2
16	39	1	39,5847	0,000013	1	41,521	0,000248	2	38,3236	0,000018	1
17	37	1	45,167	0,002605	2	42,6361	0,001241	2	46,5455	0,003559	2
18	30	1	30,7557	0,000022	1	40,8925	0,004635	2	32,8148	0,00031	1
19	17	1	21,7836	0,000894	1	19,2876	0,000204	1	12,2997	0,000863	1
20	16	1	21,1191	0,001024	1	18,8366	0,000314	1	12,2251	0,000557	1
21	22	1	25,9694	0,000615	1	21,4093	0,000014	1	12,5635	0,003478	1
22	53	2	49,4902	0,000481	2	52,5162	0,000009	2	47,0936	0,001363	2
23	28	1	30,8908	0,000326	1	21,7923	0,001505	1	18,0845	0,003841	1
24	27	1	30,5982	0,000506	1	22,5854	0,000761	1	12,7505	0,007932	1
25	172	2	155,5933	0,010515	2	170,3053	0,000112	2	171,6006	0,000006	2
26	33	1	21,8392	0,004866	1	24,3342	0,002933	1	27,6497	0,001118	1
27	24	1	23,3895	0,000015	1	24,1131	0,000001	1	25,9931	0,000155	1
28	25	1	23,6477	0,000071	1	37,2858	0,005896	1	25,8218	0,000026	1
29	12	1	18,1061	0,001456	1	17,7795	0,001305	1	12,3127	0,000004	1
30	19	1	22,7211	0,000541	1	17,7797	0,000058	1	20,8732	0,000137	1
31	27	1	28,6862	0,000111	1	20,5557	0,001622	1	20,0203	0,001903	1
32	61	2	54,1228	0,001848	2	51,9014	0,003234	2	55,4601	0,001199	2
33	24	1	24,7478	0,000022	1	18,4659	0,001196	1	24,8057	0,000025	1
34	68	2	60,2658	0,002337	2	59,8528	0,002593	2	61,294	0,001757	2
35	83	2	80,4321	0,000258	2	80,6251	0,00022	2	82,9708	0,000001	2
36	29	1	26,9281	0,000168	1	22,4433	0,001679	1	28,5006	0,00001	1
37	16	1	20,8077	0,000903	1	17,5831	0,000098	1	12,3146	0,000531	1
38	34	1	39,2037	0,001058	1	43,3342	0,003403	2	36,7702	0,0003	1
39	41	2	33,6783	0,002094	1	37,5056	0,000477	1	32,8762	0,002578	1
40	44	2	43,3924	0,000014	2	40,7639	0,000409	2	45,0193	0,000041	2
41	36	1	61,7691	0,025939	2	53,4541	0,0119	2	41,7474	0,00129	2
42	27	1	28,798	0,000126	1	27,9883	0,000038	1	30,4365	0,000461	1
43	55	2	49,0704	0,001373	2	44,0402	0,004692	2	52,4507	0,000254	2
44	74	2	66,0753	0,002453	2	66,7068	0,002078	2	67,5726	0,001614	2
45	33	1	26,4806	0,001660	1	33,2456	0,000002	1	27,6128	0,001134	1
46	46	2	46,7404	0,000021	2	43,9216	0,000169	2	48,2747	0,000202	2
47	92	2	113,9586	0,018835	2	127,238	0,048505	2	106,962	0,008745	2
48	15	1	18,7131	0,000539	1	16,1656	0,000053	1	20,5126	0,001187	1
49	18	1	20,9888	0,000349	1	16,8244	0,000054	1	24,6003	0,001702	1
50	30	1	28,4408	0,000095	1	43,1078	0,006711	2	28,0708	0,000145	1

Таким образом, зная фактическую принадлежность экземпляров к классам годных и потенциально дефектных, а также класс экземпляров по распознаванию, можно оценить точность классификации по вероятностным характеристикам [8]. Кроме того, в качестве критерия выбора структуры персептрона целесообразно рассматривать величину средней ошибки распознавания, а также процент распознанных образов. Результаты представлены в табл. 3.

Таблица 3

Вероятностные характеристики разбиения выборки

Показатели		Однослойный персептрон с одним скрытым нейроном	Однослойный персептрон с двумя скрытыми нейронами	Однослойный персептрон с тремя скрытыми нейронами
Классификация				
Риск изготовителя $R_{изг}$		0,278	0,381	0,235
Риск потребителя $R_{потр}$		0,0625	0,069	0,061
Вероятность принятия ошибочного решения $P_{ош}$		0,14	0,2	0,12
Моделирование				
Обучающее множество	Распознано примеров, %	97,83	100	100
	Средняя ошибка распознавания	$5,46 \cdot 10^{-3}$	$2,62 \cdot 10^{-3}$	$1,74 \cdot 10^{-3}$
Тестовое множество	Распознано примеров, %	100	100	100
	Средняя ошибка распознавания	$1,16 \cdot 10^{-3}$	$1,3 \cdot 10^{-2}$	$2,94 \cdot 10^{-3}$

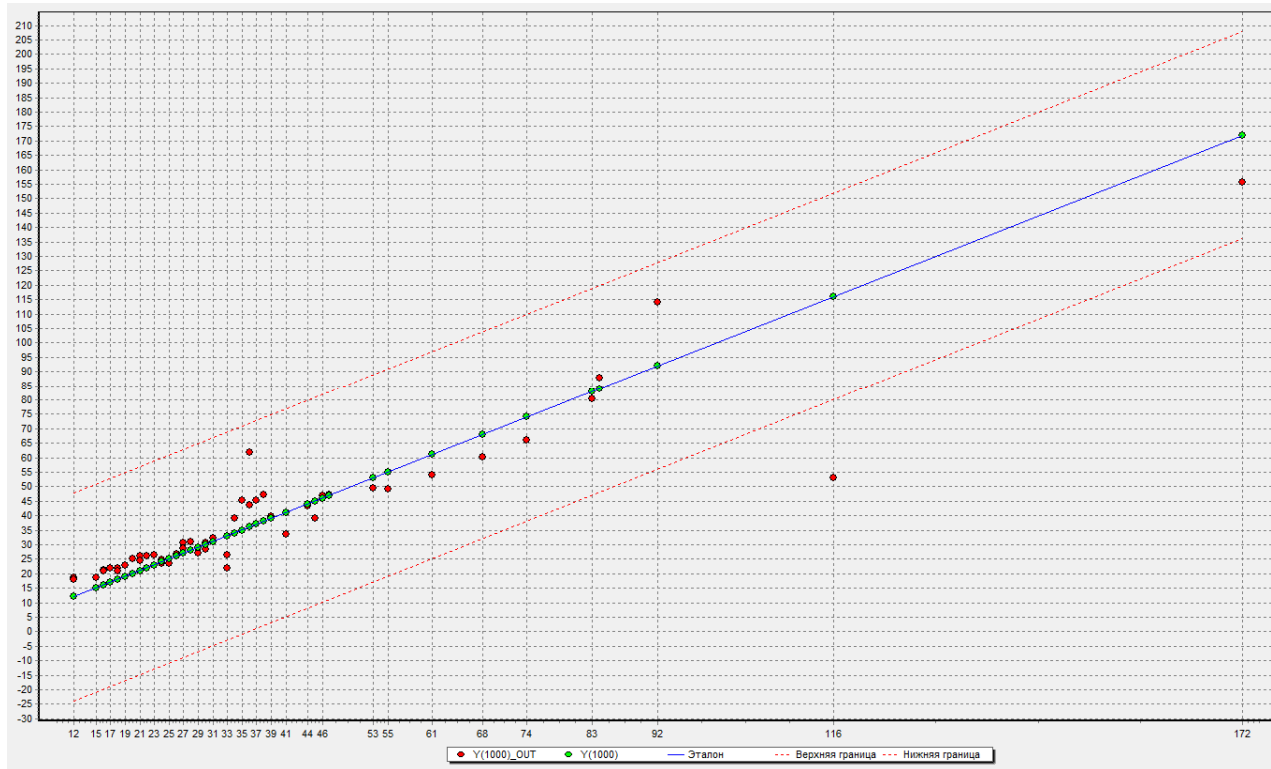


Рис. 6. Диаграмма рассеяния выходных данных по результатам обучения однослойного персептрона с одним скрытым нейроном




Рис. 7. Диаграмма рассеяния выходных данных по результатам обучения однослойного персептрона с двумя скрытыми нейронами




Рис. 8. Диаграмма рассеяния выходных данных по результатам обучения однослойного персептрона с тремя скрытыми нейронами

Заключение

По табл. 3 и при анализе диаграмм рассеяния, показанных на рис. 6–8, видно, что однослойный персептрон с одним скрытым нейроном не обеспечил высокую точность откликов, по сравне-

нию с эталонными значениями выходных данных. Кроме того, по диаграмме рассеяния видно, что одно наблюдение распознано с ошибкой более 5 %. По оценке средней ошибки распознавания обучающего множества можно сделать вывод, что однослойный персептрон с тремя скрытыми нейронами обеспечил более высокую точность разбиения по сравнению с однослойным персептроном с двумя скрытыми нейронами. При этом все примеры были распознаны с ошибкой менее 5 %. Кроме того, оценивая точность классификации, стоит отметить, что при использовании каждой структуры сети получены схожие значения риска потребителя. Однослойный персептрон с тремя скрытыми нейронами обеспечил сравнительно низкие значения риска изготовителя $P_{изг} = 0,235$ и риска принятия ошибочного решения $P_{ош} = 0,12$. Таким образом, для более качественной классификации интегральных микросхем, выбранных из партии, из которой произведена выборка, следует выбрать однослойный персептрон с тремя скрытыми нейронами.

Библиографический список

1. Пиганов, М. Н. Индивидуальное прогнозирование показателей качества элементов и компонентов микросборок / М. Н. Пиганов. – Москва : Новые технологии, 2002. – 267 с.
2. Вапник, В. Н. Теория распознавания образов / В. Н. Вапник, А. Я. Червоненкис. – Москва : Наука, 1974. – 416 с.
3. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. – Москва : Вильямс, 2006. – 1104 с.
4. Круг, П. Г. Нейронные сети и нейрокомпьютеры : учеб. пособие по курсу «Микропроцессоры» / П. Г. Круг. – Москва : Изд-во МЭИ, 2002. – 176 с.
5. Уоссермен, Ф. Нейрокомпьютерная техника: Теория и практика / Ф. Уоссермен ; пер. с англ. Ю. А. Зуева, В. А. Точенова ; под ред. А. И. Галушкина. – Москва : Мир, 1992. – 236 с.
6. Мишанов, Р. О. Методика определения набора информативных параметров для проведения индивидуального прогнозирования показателей качества и надежности радиоэлектронных средств / Р. О. Мишанов, М. Н. Пиганов // Надежность и качество сложных систем. – 2017. – № 1 (17). – С. 93–104.
7. Deductor. Руководство аналитика. Версия 5.3. – URL: https://basegroup.ru/system/files/documentation/guide_analyst_5.3.0.pdf.
8. Тюлевин, С. В. Индивидуальное прогнозирование электронных средств : учеб. пособие / С. В. Тюлевин. – Самара : Изд-во Самарского университета, 2016. – 65 с.

References

1. Piganov M. N. *Individual'noe prognozirovanie pokazateley kachestva elementov i komponentov mikrosborok* [Individual forecasting of quality indicators for elements and components of microassemblies]. Moscow: Novye tekhnologii, 2002, 267 p. [In Russian]
2. Vapnik V. N., Chervonenkis A. Ya. *Teoriya raspoznavaniya obrazov* [Pattern recognition theory]. Moscow: Nauka, 1974, 416 p. [In Russian]
3. Khaykin S. *Neyronnye seti: polnyy kurs* [Neural networks: full course]. Moscow: Vil'yams, 2006, 1104 p. [In Russian]
4. Krug P. G. *Neyronnye seti i neyrokomp'yutery: ucheb. posobie po kursu «Mikroprotsessory»* [Neural networks and Neurocomputers: tutorial on the course "Microprocessors"]. Moscow: Izd-vo MEI, 2002, 176 p. [In Russian]
5. Uossermen F. *Neyrokomp'yuternaya tekhnika: Teoriya i praktika* [Neurocomputer technology: Theory and practice]; transl. from Engl. Yu. A. Zuev, V. A. Tochenov. Moscow: Mir, 1992, 236 p. [In Russian]
6. Mishanov R. O., Piganov M. N. *Nadezhnost' i kachestvo slozhnykh system* [Reliability and quality of complex systems]. 2017, no. 1 (17), pp. 93–104. [In Russian]
7. *Deductor. Rukovodstvo analitika. Versiya 5.3* [Deductor. Analyst's guide. Version 5.3]. Available at: https://basegroup.ru/system/files/documentation/guide_analyst_5.3.0.pdf. [In Russian]
8. Tyulevin S. V. *Individual'noe prognozirovanie elektronnykh sredstv: ucheb. posobie* [Individual forecasting of electronic means: tutorial]. Samara: Izd-vo Samarskogo universiteta, 2016, 65 p. [In Russian]

Мишанов Роман Олегович

кандидат технических наук, ассистент,
кафедра конструирования и технологии
электронных систем и устройств,
Самарский национальный исследовательский
университет имени академика С. П. Королёва
(Россия, г. Самара, Московское шоссе, 34)
E-mail: kipres@ssau.ru

Mishanov Roman Olegovich

candidate of technical sciences, assistant,
sub-department of design and technology
electronic systems and devices,
Samara University
(34 Moskovskoe highway, Samara, Russia)

Образец цитирования:

Мишанов, Р. О. Использование однослойного персептрона для решения задачи классификации электрорадиоизделий с целью повышения качества и надежности бортовой аппаратуры / Р. О. Мишанов // Надежность и качество сложных систем. – 2020. – № 2 (30). – С. 106–114. – DOI 10.21685/2307-4205-2020-2-11.