

УДК 004.8:658.562

С.С. Федін

Київський національний університет технологій і дизайну, Київ

ОБЕСПЕЧЕНИЕ ТОЧНОСТИ НЕЙРОСЕТЕВОГО ПРОГНОЗИРОВАНИЯ КАЧЕСТВА И КОНКУРЕНТОСПОСОБНОСТИ ПРОДУКЦИИ

На основе теоретических и экспериментальных исследований свойств моделей нейронных сетей типа feed forward предложен метод обеспечения точности нейросетевого прогнозирования качества продукции на примере электронных тахеометров. Разработана адаптивная модель оценки и прогнозирования конкурентоспособности электронных тахеометров по совокупности их основных метрологических характеристик с использованием технологии конкурирующих нейронных сетей.

Ключевые слова: *точность прогнозирования, нейронная сеть, качество, конкурентоспособность, адаптивная модель, электронный тахеометр.*

Введение

На этапе эксплуатации различных видов продукции, сложных технических объектов или средств измерений (СИ) актуальной задачей является прогнозирование комплексного или обобщенного показателя качества по совокупности единичных показателей или метрологических характеристик (МХ) СИ.

В работах Ю.П. Адлера [1], Д. Фуллера [2], Р.М. Трища [3] показано, что одним из основных методов комплексной оценки качества продукции является применение обобщенной функции желательности Харрингтона или ее различных модификаций. Большинство методов комплексной оценки качества могут быть отнесены к off-line методам информационной поддержки жизненного

цикла продукции и предназначены для решения задач контроля. При этом методы комплексной оценки качества, являясь инструментом многомерного анализа данных, могут быть применены для эффективного решения on-line задач прогноза и управления на основе использования адаптивных нейронных сетей (НС). Однако из-за неопределенности связанной с выбором архитектуры модели НС, видом и значением параметра функции активации нейронов и объемом обучающей выборки существует проблема обеспечения точности нейросетевого прогноза, решению которой посвящены теоретические и экспериментальные исследования работы.

Целью работы является разработка метода обеспечения точности нейросетевого прогнозирования комплексного показателя качества продукции и создание адаптивной модели оценки конкурентоспособности продукции на основе технологии конкурирующих нейронных сетей.

Формализация задачи обеспечения точности нейросетевого прогнозирования качества продукции

Теоретической основой НС являются результаты фундаментальных исследований академика А.Н. Колмогорова, посвященных представлению непрерывной функции многих переменных в виде суперпозиции непрерывных функций одного переменного [4]. Основные преимущества НС заключаются в адаптивности, способности к обучению и обобщению информации, нелинейности, распределенности и параллельности обработки информации [5].

В настоящее время среди большого разнообразия архитектур современных НС наибольшее распространение получили многослойные перцептроны или НС прямого распространения сигнала типа feed forward, представляющие собой совокупность простых процессорных элементов – нейронов, организованных слоями. Нейроны одного слоя по связям получают информацию от нейронов из предыдущего слоя, линейно или нелинейно преобразуют ее и посылают результат нейронам следующего слоя. Принцип преобразования информации в НС заключается в формировании сигнала на основе разности между взвешенной суммой входов каждого нейрона и связанным с нейроном пороговым значением. Полученный сигнал поступает на вход униполярной сигмоидной функции активации с параметром α (1):

$$S(x) = \frac{1}{1 + \exp(-\alpha x)}, \quad (1)$$

которая предназначена для формирования выходного сигнала и имеет область значений от 0 до 1 [5].

Важным свойством сигмоидной функции активации является ее непрерывность и дифференцируемость на всей области определения, что позволяет использовать при обучении НС градиентные

методы, например метод обратного распространения ошибки, известный как back-propagation of error [6]. В процессе настройки по этому алгоритму обучения, встроенному в программу моделирования НС, итерационно подстраивается всё множество весовых коэффициентов по критерию достижения назначенной точности обучения. Причем подстройка весов происходит в направлении от известного выхода последнего слоя нейронов к входному слою. Выходные значения последнего слоя нейронов сравниваются с обучающим показателем, и на основе разницы между желаемым и действительным результатом определяется значение величины, изменяющей весовые коэффициенты связей между нейронами последнего слоя с предыдущим. Затем подобная операция производится с нейронами предпоследнего слоя и в результате по НС от выхода к входу распространяется волна изменяющихся весовых коэффициентов. Обучение прекращается в том случае, когда ошибка на тестовых примерах (фактах) между обучающим и прогнозируемым значениями будет меньше заданной величины точности обучения НС. Обучение НС заключается в усилении одних связей и ослаблении других таким образом, чтобы при появлении одного и того же примера из обучающего множества модель получала более корректный ответ по отношению к выбранному критерию обучения. Используемые для разработки модели НС данные, как правило, делятся на собственно обучающее, контрольное и тестовое множества. Процесс обучения носит итерационный характер и разбивается на ряд эпох, во время каждой из которых на вход НС подаются элементы из обучающего множества. Поскольку при этом может возникнуть явление переобучения, то качество работы НС проверяется на контрольном множестве, т.е. проводится верификация модели НС¹. Тестовое множество используется для проверки достоверности результатов прогнозирования.

Если ошибки обучения и контрольные ошибки, оцениваемые на основе разности между наблюдаемыми и прогнозируемыми результатами, близки друг другу, то построенная модель нейросети обладает хорошими обобщающими способностями и может быть применена для решения задач прогнозирования качества продукции.

На точность обучения модели НС и достоверность получаемого прогноза при использовании градиентного алгоритма обучения значительное влияние оказывает значение параметра α функции активации НС (1). Для большинства практических

¹ Явление переобучения возникает в тех случаях, когда модель НС распознает выходные значения, входящие в обучающее множество, но оказывается неадекватной на этапе эксплуатации, при прогнозе или распознавании новых данных.

задач прогнозування з метою упрощення моделі НС використовується значення $\alpha = 1,0$ [5]. Различные значения параметра α изменяют крутизну сигмоидной функции (рис. 1), а также вид графика ее производной (рис. 2) и как следствие оказывают влияние на прогнозирующие свойства НС.




Рис. 1. Сигмоидная функция активации НС




Рис. 2. Производные функции активации НС

Во всех трех случаях при $\alpha = 1,0$, $\alpha = 1,5$, $\alpha = 2,0$ графики изменения производной функции активации (1) относительно переменной x имеют колоколообразную форму, а их максимум соответствует значению $x = 0$ (рис. 2). При этом значение максимума и форма кривых относительно оси симметрии различны и в значительной степени зависят от значения параметра α .

Очевидно, что для повышения точности нейросетевого прогнозирования целесообразно определить значение параметра α , при котором ошибка обучения НС будет минимальной.

Разработка метода обеспечения точности нейросетевого прогнозирования комплексного показателя качества продукции

Для прогнозирования комплексной оценки качества продукции на примере электронных тахеометров – высокоточных СИ, предназначенных для измерений угловых и линейных размеров, предлагается метод, основанный на определении обобщенных показателей качества. Обобщенный показатель оценивается как совокупность основных МХ электронных тахеометров [7]:

- неперпендикулярность оси вращения трубы к оси вращения алидады (НВО);
- максимальное влияние эксцентриситета вертикального круга на измеряемый угол (ЭВК);
- среднеквадратическая погрешность горизонтального круга (СКП ГК);
- среднеквадратическая погрешность вертикального круга (СКП ВК);
- среднеквадратическая погрешность измерения расстояний (СКП Р);
- погрешность измерения расстояний на каждый километр (ppm).

Допусковые значения МХ электронных тахеометров типа Та5 приведены в табл. 1 [8].

Таблица 1

Допусковые значения МХ электронных тахеометров типа Та5

МХ	НВО	ЭВК	СКП ГК	СКП ВК	СКП Р	ppm
Допусковые значения МХ	15"	10"	5"	5"	2 мм	2 мм

В результате поверки с использованием рабочего эталона второго разряда – автоколлимационной установки АУПНТ были определены значения основных МХ для 120-ти электронных тахеометров типа Та5. На основе полученных статистических данных была сформирована репрезентативная выборка объемом $N = 110$, предназначенная для обучения и настройки моделей НС, а также тестовая выборка объемом $N = 10$, предназначенная для проверки достоверности результатов прогноза.

В работе [8] показано, что комплексный показатель качества тахеометров можно рассчитать на основе интервальной и точечной оценок обобщенной функции желательности Харрингтона. При этом точечную среднюю оценку комплексного показателя качества электронных тахеометров можно получить аналитически по формуле (2):

$$F(x) = \frac{1 - \exp(-\exp(x)) + \exp(-\exp(-x))}{2} \quad (2)$$

Определение точечной и интервальной оценок комплексного показателя качества электронных тахеометров осуществлялось с использованием разработанного интерактивного программного модуля «Оцінка якості 1.0» (рис. 3).

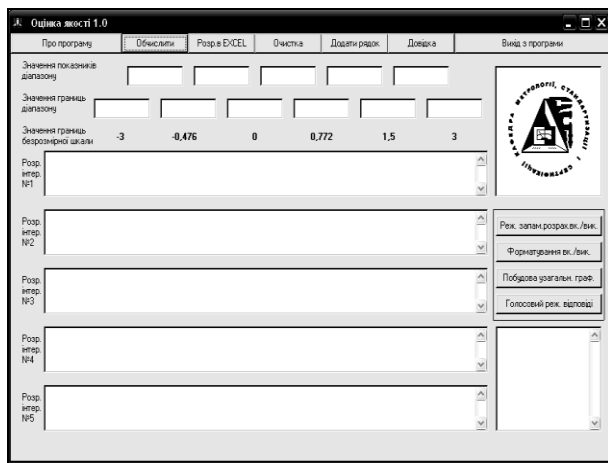


Рис.3. Інтерфейс програми «Оцінка якості 1.0»

Применение модуля позволило получить оценку комплексного показателя качества в количественной и качественной форме в соответствии с диапазонами области значений функции Харрингтона, которые характеризуют качественные категории (классы) СИ: (0 – 0,2) – «Очень плохо»; (0,2 – 0,37) – «Плохо»; (0,37 – 0,63) – «Удовлетворительно»; (0,63 – 0,8) – «Хорошо»; (0,8 – 1,0) – «Отлично».

На основе расчетов, проведенных в программе «Оцінка якості 1.0» было создано обучающее множество примеров (фактов) для настройки нейросетевой модели прогнозирования, в котором входами являлись значения 6-ти МХ, а выходом точечная оценка комплексного показателя качества тахеометров (табл. 2).

Таблица 2

Обучающее множество НС объемом N = 110 фактов

№ п/п	Фирма	НВО	ЭВК	СКП ГК	СКП ВК	СКП Р	ppm	F(x)	Класс
1	TRIMBLE	3,50	2,80	1,60	2,40	1,4	0,5	0,807	Fine
2	TRIMBLE	1,70	3,20	0,90	3,60	0,9	1,7	0,724	Well
3	TRIMBLE	1,41	1,54	1,31	2,55	1,7	1,3	0,730	Well
4	TRIMBLE	3,51	1,40	1,35	1,28	1,5	0,4	0,825	Fine
5	TRIMBLE	12,4	0,11	2,33	0,82	0,7	0,9	0,714	Well
...
46	LEICA	14,8	2,20	2,10	1,90	1,1	1,7	0,415	Satis
47	LEICA	6,50	5,03	2,64	4,26	0,9	0,7	0,693	Well
48	LEICA	4,30	0,40	1,89	4,55	1,9	0,3	0,497	Satis
49	LEICA	1,02	2,73	2,72	2,59	1,7	1,1	0,732	Well
50	LEICA	7,60	0,90	0,70	2,60	1,2	1,3	0,752	Well
...
60	SOKKIA	3,02	0,56	4,13	1,84	1,1	0,3	0,788	Well
61	SOKKIA	3,22	2,67	3,48	4,39	1,5	0,4	0,723	Well
62	SOKKIA	7,78	0,14	1,93	1,48	1,7	1,2	0,687	Well
63	SOKKIA	2,58	0,91	1,08	1,22	0,4	1,6	0,823	Fine
64	SOKKIA	1,86	0,71	2,02	1,21	1,5	0,7	0,820	Fine
...
70	NIKON	8,90	2,20	1,60	2,10	1,5	1,1	0,701	Well
71	NIKON	5,30	0,40	2,30	1,40	0,7	1,2	0,841	Fine
72	NIKON	1,20	1,10	1,20	3,20	1,6	0,4	0,806	Fine
73	NIKON	2,30	4,60	4,40	3,00	1,7	0,3	0,638	Well
74	NIKON	0,90	1,73	1,80	1,39	1,1	0,4	0,892	Fine
...
106	TOPCON	9,80	2,80	3,40	3,90	1,7	1,1	0,532	Satis
107	TOPCON	8,90	4,10	0,80	3,70	1,7	0,3	0,721	Well
108	TOPCON	6,33	0,84	2,72	4,01	1,7	0,9	0,678	Well
109	TOPCON	3,30	0,40	2,40	2,30	1,3	0,4	0,841	Fine
110	TOPCON	8,40	3,10	2,80	3,70	1,1	0,5	0,742	Well

Анализ данных табл. 2 показывает, что обучающее множество фактов содержит три класса (категории или группы) СИ, которые можно условно обозначить как Fine (Отлично), Well (Хорошо) и Satis (Удовлетворительно). Множество фактов тес-

товой выборки представлено в табл. 3.

Для нейросетевого прогнозирования комплексного показателя качества тахеометров была выдвинута гипотеза, в соответствии с которой наибольшую точность прогноза обеспечивает модель НС,

Тестовая выборка НС объемом N = 10 фактов

№ п/п	Фирма	НВО	ЭВК	СКП ГК	СКП ВК	СКП Р	ppm	F(x)	Класс
1	TRIMBLE	0,60	2,50	2,70	2,90	0,5	0,8	0,878	Fine
2	TRIMBLE	12,79	2,45	1,47	3,95	1,5	1,1	0,528	Satis
3	LEICA	1,21	1,04	0,71	1,30	0,7	1,1	0,893	Fine
4	LEICA	11,79	1,00	1,78	1,03	0,8	1,5	0,692	Well
5	SOKKIA	5,18	1,43	2,18	2,52	1,2	0,9	0,814	Fine
6	SOKKIA	2,96	1,29	1,66	1,83	1,7	1,1	0,702	Well
7	NIKON	8,14	1,29	1,15	2,32	0,5	1,1	0,816	Fine
8	NIKON	1,20	1,30	1,70	1,70	0,5	1,1	0,889	Fine
9	TOPCON	9,50	1,40	1,40	2,6	1,5	1,1	0,715	Well
10	TOPCON	2,30	4,60	4,40	3,00	1,7	1,5	0,563	Satis

реализующая наилучшее приближение функции активации к точечной средней оценке функции желательности Харрингтона. Методика вычислительного эксперимента в соответствии с данной гипотезой включала четыре этапа².

На первом этапе в соответствии с зависимостями, предложенными в работе [9] осуществляли выбор архитектуры модели двухслойной НС типа feed forward с параметром сигмоидной функции активации $\alpha = 1,0$. В результате расчетов установлено, что для обучающей выборки экспериментальных данных объемом 110 фактов минимальное и максимальное количество нейронов соответствует 4-м и 11-ти соответственно. Таким образом, в диапазоне от 4-х до 11-ти нейронов скрытого слоя было создано и протестировано 8 моделей НС. Принятие решения относительно качества полученных моделей осуществлялось на основе критерия тестирования, по которому определялось количество неправильно распознанных фактов контрольной выборки – Bad facts и показателя сходимости процесса обучения модели или числа эпох обучения – Run. Результаты экспериментальной оценки качества моделей НС с различной архитектурой представлены в табл. 4.

Анализ данных табл. 4 показывает, что наименьшее количество нераспознанных фактов и наибольшая скорость сходимости соответствуют модели № 7 с архитектурой 6:10:1, которая включает 6 входов, 10 скрытых нейронов и 1 выходной нейрон.

На втором этапе с использованием метода наименьших квадратов выполняли аппроксимацию точечной средней оценки комплексного показателя качества (2) к сигмоидной функции активации нейронной сети (1) на основе минимизации функционала (3):

$$\Psi(x, \alpha) = \left(\frac{(1 - \exp(-\exp(x)) + \exp(-\exp(-x)))/2 -}{-1/(1 + \exp(-\alpha x))} \right)^2. \quad (3)$$

² Реализацию вычислительного эксперимента осуществляли в лицензионной версии системы моделирования нейронных сетей BrainMaker Professional 3.52.

Таблица 4

Оценка качества моделей НС с различной архитектурой и параметром функции активации $\alpha = 1,0^3$

Модель	Архитектура модели	Количество нераспознанных фактов из 11 – Bad facts ⁴	Число эпох обучения модели НС – Run
1	6:4:1	3	18374
2	6:5:1	2	22480
3	6:6:1	3	1686
4	6:7:1	2	832
5	6:8:1	3	3133
6	6:9:1	3	2392
7	6:10:1	1	645
8	6:11:1	2	1062

Оптимальное значение параметра α находится на основе уравнения (4):

$$\frac{\partial \Psi(x, \alpha)}{\partial \alpha} = 0;$$

$$-2 \left(\frac{\left(\frac{(1 - \exp(-\exp(x)) + \exp(-\exp(-x)))/2 -}{-1/(1 + \exp(-\alpha x))} \right)}{(1 + \exp(-\alpha x))^2} \right) \times x \exp(-\alpha x) = 0. \quad (4)$$

С использованием универсальной системы математического моделирования MathCAD было найдено оптимальное значение параметра $\alpha = 1,42$.

Таким образом, скорректированная сигмоидная функция активации нейронов для прогнозирования точечной средней оценки комплексного показателя

³ Во избежание попадания алгоритма обучения в точку локального минимума для каждой модели НС проводилось несколько экспериментов с использованием рандомизации фактов обучающей выборки.

⁴ Объем контрольной выборки соответствовал 10% от объема обучающей выборки, т.е. 11 фактам.

качества тахеометров имеет вид (5):

$$S(x) = \frac{1}{1 + \exp(-1,42x)} \quad (5)$$

На третьем этапе, в системе моделирования нейронных сетей BrainMaker Professional были протестированы 13 моделей нейронных сетей с архитектурой 6:10:1 и различным значением параметра α (табл. 5).

Таблица 5

Результаты тестирования моделей нейронной сети с архитектурой 6:10:1

Модель	Значение параметра α	Количество нераспознанных фактов из 11 – Bad facts	Число эпох обучения модели НС – Run
1	1,00	1	1014
2	1,10	2	776
3	1,20	1	418
4	1,30	1	335
5	1,40	2	376
6	1,41	3	1465
7	1,42	0	397
8	1,43	2	559
9	1,44	1	489
10	1,50	2	1203
11	1,60	3	497
12	1,70	3	455
13	1,80	3	718

Анализ данных табл. 5 показывает, что наилучшими способностями к обобщению обладает модель № 7, что подтверждает гипотезу о повышении точности прогноза за счет наилучшего приближения функции активации НС с параметром $\alpha = 1,42$ к точечной средней оценке функции желательности Харрингтона.

На четвертом этапе осуществляли проверку качества модели НС с архитектурой 6:10:1, непосредственно по результатам прогнозирования комплексного показателя качества тахеометров с использованием тестовой выборки.

Наилучшее качество прогноза (табл. 6) оценивалось по критерию среднеквадратической ошибки (RMS-ошибки) и критерию качества прогноза Q , рассчитываемому в виде отношения стандартного отклонения ошибки прогноза (С.К.О._{о.п.}) к стандартному отклонению наблюдаемого параметра (С.К.О._{н.п.}).

Анализ данных табл. 6 подтверждает, что наилучшими прогнозирующими свойствами обладает модель № 7, для которой число нераспознанных фактов равно нулю, а значения критериев RMS-ошибки и Q являются минимальными.

Таблица 6

Результаты прогнозирования комплексного показателя качества на основе моделей с архитектурой 6:10:1 для тестовой выборки из 10 фактов

Модель	Значение параметра α	Количество нераспознанных фактов из 10 – Bad facts	RMS-ошибка (%)	Качество прогноза $Q = \frac{С.К.О._{о.п.}}{С.К.О._{н.п.}}$
1	1,00	1	3,14	0,1174
2	1,10	1	3,04	0,1400
3	1,20	0	3,05	0,1646
4	1,30	1	4,55	0,2971
5	1,40	0	3,98	0,2135
6	1,41	0	4,08	0,2190
7	1,42	0	1,74	0,0854
8	1,43	0	3,61	0,1840
9	1,44	0	4,31	0,2486
10	1,5	0	3,52	0,1770
11	1,6	0	3,47	0,2041
12	1,7	0	3,18	0,1882
13	1,8	0	4,34	0,2667

Разработка адаптивной модели прогнозирования конкурентоспособности продукции

В работе [10] было показано, что задачу прогнозирования конкурентоспособности можно решить с использованием адаптивной нейросетевой модели, разработанной на основе технологии конкурирующего обучения.

Так, в частности проведение экспериментальных исследований для оценки конкурентоспособности тахеометров осуществляли с использованием выборки однородных данных, объемом 54 факта, равномерно распределенных между ранее определенными классами Fine, Well и Satis. Для реализации метода конкурирующего обучения применяли интерактивный программный модуль Competitor системы BrainMaker Professional⁵, интерфейс которого представлен на рис. 4.

Решение задачи определения наилучшего СИ из выборки тахеометров по совокупности МХ с применением технологии конкурирующих нейронных сетей в программе BrainMaker Competitor состоит из трех этапов.

На первом этапе элементы выборки выстраиваются в ряд и попарно сравниваются, а результаты таких сравнений упорядочиваются в виде обучаю-

⁵ Competitor - это специальная программа, позволяющая выполнить рейтинговую оценку и определить наилучший объект (продукцию) из выборки или группы.

щей выборки фактов. Например, модель сравнения комплексного показателя качества для выборки из 3-х тахеометров включает $N*(N-1)/2=(3*2)/2=3$ фактов для каждого СИ и если для получения оценок используется информация, например, о 6-ти выборках, то сеть будет включать 36 фактов⁶.

На втором этапе по критерию назначенной точности настройки TOL осуществляется обучение НС.




Рис. 4. Интерфейс программного модуля BrainMaker Competitor

На третьем этапе реализуется процесс функционирования НС, который заключается в создании файла текущих фактов путем установки элементов выборки в пары таким же образом, как и во время обучения и сравнения каждой выбранной пары с парами обученной сети, с целью получения «наилучшей степени» выигрыша каждого введенного факта. Например, в рейтинге с 3-мя тахеометрами модель НС использует $3 + 2 + 1 = 6$ сравнений. Каждый тахеометр получает рейтинг по отношению к двум другим тахеометрам. Тахеометр, который «победит» в большинстве такого рода сравнений, будет идентифицирован как наилучший, т.е. наиболее конкурентоспособный по совокупности МХ. В заключение процесса функционирования НС, осуществляется сортировка полученных результатов и запись их в форме соответствия значения рейтинга каждому номеру входа модели. Пример результатов рейтинговой оценки комплексного показателя качества для выборки из трех тахеометров, каждый из которых соответствует классу Fine, Well или Satis приведен на рис. 5.

Проверка качества и достоверности полученных результатов прогнозирования заключалась в том, что вначале создавались модели НС, отличающиеся друг от друга объемом выборки обучающих примеров, и выполнялось тестирование по критерию количества нераспознанных фактов, предназначенных для прогноза (табл. 7). Затем осуществляли проверку адекватности модели НС с минимальным объемом обучающей выборки, при котором достигался наибольший процент распознавания фактов, предназначенных для тестирования и прогноза.

⁶ НС сравнивает первый элемент выборки со вторым и второй с первым. Таким образом, общее количество фактов для сравнения соответствует $18+18=36$.




Рис.5. Диалоговое окно вывода результатов рейтинговой оценки тахеометров по совокупности МХ

Таблица 7
Результат тестирования моделей конкурирующих нейронных сетей

Модель	Количество фактов обучающей выборки	Количество тестов ⁷	Общее количество нераспознанных фактов bad facts
1	12	16	5
2	18	15	3
3	24	14	1
4	30	13	1
5	36	12	0
6	42	11	0
7	60	8	0
8	84	4	0

Анализ данных табл. 7 показывает, что минимальный объем выборки, при котором число нераспознанных фактов равно нулю соответствует модели № 5 с объемом обучающей выборки равным 36 фактам⁸.

Оценку качества модели № 5 проводили методом инверсной верификации на основе 6-ти тестов с использованием зашумленных данных. Для проведения верификации из обучающей и контрольной выборок случайным образом отбирали 2 группы по 3 факта в пределах каждого класса Fine, Well и Satis. Результаты прогнозирования рейтинга, т.е. конкурентоспособности тахеометров в пределах каждого из трех классов приведены на рис. 6 – 8 и в табл. 8, 9 и 10 соответственно.




Рис. 6. Рейтинг для двух групп тахеометров класса Fine

⁷ В одном тесте содержится 3 факта, каждый из которых относится к определенному классу в соответствии со значением комплексного показателя качества тахеометров.

⁸ Обучающая выборка в классическом представлении для модели № 5 включает 18 примеров - 6 групп по 3 факта в каждой группе, а контрольная 36 примеров - 12 групп по 3 в каждой.

Таблица 8

Результаты прогнозирования рейтинга тахеометров для класса Fine

Фирма		F(x)	Рейтинг по F(x)	Рейтинг по НС
Группа 1	TRIMBLE	0,825	3	3
	TRIMBLE	0,866	2	2
	TRIMBLE	0,919	1	1
Группа 2	TRIMBLE	0,904	2	2
	TRIMBLE	0,866	1	1
	TRIMBLE	0,807	3	3




Рис. 7. Рейтинг для двух групп тахеометров класса Well

Таблица 9

Результаты прогнозирования рейтинга тахеометров для класса Well

Фирма		F(x)	Рейтинг по F(x)	Рейтинг по НС
Группа 1	TRIMBLE	0,785	2	2
	TRIMBLE	0,730	3	3
	TRIMBLE	0,793	1	1
Группа 2	TRIMBLE	0,789	1	1
	LEICA	0,718	2	2
	TRIMBLE	0,683	3	3




Рис. 8. Рейтинг для двух групп тахеометров класса Satis

Таблица 10

Результаты прогнозирования рейтинга тахеометров для класса Satis

Фирма		F(x)	Рейтинг по F(x)	Рейтинг по НС
Группа 1	LEICA	0,625	1	1
	SOKKIA	0,598	2	2
	SOKKIA	0,556	3	3
Группа 2	LEICA	0,625	1	1
	LEICA	0,415	2	2
	TOPCON	0,563	3	3

Анализ данных табл. 8, 9 и 10 показывает, что все полученные результаты прогнозирования рейтинга тахеометров на основе разработанной модели конкурирующей НС для 6-ти тестов с использованием зашумленных данных совпадают с реальными точечными средними оценками функции Харрингтона, что свидетельствует о 100%-й достоверности прогнозов. Интерфейс разработанной модели на основе обучающей выборки из 36 фактов представлен на рис. 9.

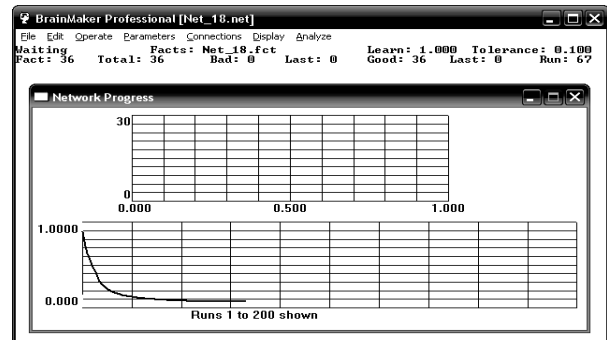


Рис. 9. Интерфейс модели конкурирующей НС с объемом выборки N=36 фактов

График (рис. 9) показывает прогресс в изменении величины RMS-ошибки при создании модели НС для диапазона точности обучения TOL от значения 1,0 до 0,1. Следует отметить, что между параметром точности обучения, числом входов модели НС и количеством фактов, т.е. объемом обучающей выборки существует принятая в теории и практических приложениях НС зависимость (6):

$$\frac{N}{n} TOL \approx 1, \tag{6}$$

где N – количество фактов обучающей выборки; n – число входов модели НС.

В соответствии с зависимостью (6) объем обучающей выборки модели НС, включающей 6 входов, т.е. 6 МХ тахеометров должен соответствовать 60-ти фактам при установленном значении TOL = 0,1. В то же время на основе анализа результатов тестирования моделей НС, полученных методом конкурирующего обучения (табл. 7) можно утверждать, что минимальный объем обучающей выборки для 6-ти входов соответствует 36-ти фактам, что в 1,667 раза меньше чем значение 60 фактов.

Таким образом, на основе результатов экспериментальных исследований в формулу (6) целесообразно ввести поправочный коэффициент $\beta = 1,667$ и представить ее в виде зависимости (7):

$$\frac{\beta N}{n} TOL \approx 1. \tag{7}$$

Введение поправочного коэффициента β позволяет сократить объем обучающей выборки моделей НС типа feed forward, предназначенных для решения задач прогнозирования качества и конкурентоспособности продукции.

Выводы

1. Предложен новый подход к обеспечению точности нейросетевого прогнозирования комплексного показателя качества продукции, основанный на приближении функции активации НС к точечной средней оценке обобщенной функции желательности Харрингтона.

2. Разработан метод обеспечения точности обучения моделей НС типа feed forward и установлено оптимальное значение параметра сигмоидной функции активации НС $\alpha = 1,42$, при ее аппроксимации к точечной средней оценке обобщенной функции желательности Харрингтона.

3. С использованием технологии конкурирующих НС разработана адаптивная модель прогнозирования конкурентоспособности продукции по комплексному показателю качества и экспериментально определено значение поправочного коэффициента β , предлагаемого впервые в формуле определения объема обучающей выборки НС в зависимости от количества входов и параметра точности обучения нейросетевой модели.

4. На основе разработанной адаптивной модели прогнозирования конкурентоспособности электронных тахеометров показано, что применение поправочного коэффициента позволяет в 1,667 раза сократить объем обучающей выборки НС и частично решает проблему «увеличения размерности выборки» характерную для большинства задач многомерного анализа статистических данных.

Список литературы

1. Адлер Ю.П. Планирование эксперимента при поиске оптимальных условий / Ю.П. Адлер, Е.В. Маркова, Ю.В. Грановский. – М.: Наука, 1976. – 280 с.
2. Fuller D. The Desirability Function: Underlying Assumptions and Applications Implications / D. Fuller, W. Scherer // IEEE Transactions. – 1998. – № 1. – P. 4016-4021.

3. Триц Р.М. Обобщенная точечная и интервальная оценки качества изготовления деталей ДВС / Р.М. Триц, Е.А. Слитюк // Восточно-Европейский журнал передовых технологий. – 2006. – № 1/2 (19). – С. 63-67.

4. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных в виде суперпозиции непрерывных функций одного переменного и сложения / А.Н. Колмогоров. – М.: ДАН СССР, 1957. – Т. 114, вып. 5. – С. 953-956.

5. Осовский С. Нейронные сети для обработки информации / С. Осовский. – М.: Финансы и статистика, 2004. – 344 с.

6. Rumelhart D.E. Learning Internal Representation by Error Propagation / D.E. Rumelhart, G.E. Hinton, R.J. Williams // D.E. Rumelhart & J.L. McClelland (eds.), Parallel Distributed Processing: Explorations in the Microstructure of Cognition, 1: Foundation., The MIT Press, Cambridge, MA. – 1986. – P. 318-364.

7. МПУ 164/01-2003 Нивелиры, теодолиты, тахеометры. Угломерная часть. Методика поверки. – К.: Укрметрестандарт, 2003. – 33 с.

8. Федін С. Комплексне оцінювання якості прецизійних засобів вимірювання геодезичного призначення / С. Федін, І. Акользін, Н. Зубрецька // Стандартизація, сертифікація, якість. – 2009. – № 3 (58). – С. 63-68.

9. Федін С.С. Обеспечение качества типовых деталей машиностроения методом нейросетевой классификации статистических законов распределения / С.С. Федін, Р.М. Триц // Восточно-Европейский журнал передовых технологий. – 2006. – № 3/2 (21). – С. 93-100.

10. Федін С.С. Використання інформаційних технологій для рейтингової оцінки успішності студентів у вищому навчальному закладі / С.С. Федін // Вісник КНУТД. Збірник наукових праць ювілейної міжнародної конференції «Інноваційні технології – майбутнє України». – К.: КНУТД, 2005. – Т. 1. – С. 119-121.

Поступила в редколлегию 17.12.2009

Рецензент: д-р. техн. наук., проф. В.В. Костицкий, Киевский национальный университет технологий и дизайна, Киев.

ЗАБЕЗПЕЧЕННЯ ТОЧНОСТІ НЕЙРОМЕРЕЖЕВОГО ПРОГНОЗУВАННЯ ЯКОСТІ ТА КОНКУРЕНТОСПРОМОЖНОСТІ ПРОДУКЦІЇ

С.С. Федін

На основі теоретичних та експериментальних досліджень властивостей моделей нейронних мереж типу feed forward запропоновано метод забезпечення точності нейромережевого прогнозування якості продукції, на прикладі електронних тахеометрів. Розроблено адаптивну модель оцінки та прогнозування конкурентоспроможності електронних тахеометрів за сукупністю їх основних метрологічних характеристик із використанням технології конкуруючих нейронних мереж.

Ключові слова: точність прогнозування, нейронна мережа, якість, конкурентоспроможність, адаптивна модель, електронний тахеометр.

PROVIDING OF EXACTNESS OF NEURAL NETWORKS FORECASTING OF QUALITY AND COMPETITIVENESS OF PRODUCTS

S.S. Fedin

On base theoretical and experimental researches characteristic of neural networks models of the type feed forward is offered method of the provision to accuracy neural forecasting of quality to product on example electronic tacheometers. It is designed adaptive model of the estimation and forecasting to competitiveness electronic tacheometers on the basis of their main metrological features with use of technologies rival neural networks.

Keywords: exactness of forecasting, neuron network, quality, competitiveness, adaptive model, electronic tacheometer.