

## РЕШЕНИЕ ЗАДАЧИ КЛАССИФИКАЦИИ ПРИ ПРИНЯТИИ УПРАВЛЕНЧЕСКИХ РЕШЕНИЙ В УСЛОВИЯХ НЕЧЁТКОСТИ ИСХОДНЫХ ДАННЫХ С ИСПОЛЬЗОВАНИЕМ ГИБРИДНОГО НЕЙРОНЕЧЁТКОГО КЛАССИФИКАТОРА

© 2014 О.П. Солдатова, А.Н. Даниленко

Самарский государственный аэрокосмический университет имени академика С.П. Королёва  
(национальный исследовательский университет)

Поступила в редакцию 17.12.2013

В статье приводятся результаты применения предложенной авторами методики проверки базы нечётких продукционных правил на непротиворечивость и полноту на примере базы нечётких продукционных правил, составленной экспертами по результатам психологического тестирования группы соискателей на профессиональную пригодность. Описаны алгоритмы проверки базы правил на непротиворечивость и полноту и исследована эффективность их применения для базы нечётких продукционных правил в модели гибридного нейронечёткого классификатора при решении задачи классификации на профессиональную пригодность специалистов.

Ключевые слова: нечёткая логика, предел полноты, база нечётких продукционных правил, гибридный нейронечёткий классификатор, алгоритм Абэ-Лена, градиентные алгоритмы обучения.

### ВВЕДЕНИЕ

Системы поддержки принятия управленческих решений зачастую работают с исходной информацией, которая является неполной, неточной или недостаточно определённой. При таких условиях задача принятия решений является слабо структурированной задачей, для решения которой практически неприменимы аналитические методы, поэтому в настоящее время широко применяются интеллектуальные методы решения подобных задач.

Особенностью задачи классификации при определении соответствия соискателя требованиям профессии, возникает необходимость обработки более сотни различных параметров, каждый из которых отличается нечёткостью информации.

В связи с данным обстоятельством, возникает необходимость применения аппарата нечёткой логики и теории нечётких множеств как эффективных подходов к решению данной проблемы. В настоящее время наблюдается тенденция к гибридизации моделей систем нечёткого логического вывода и нейросетевых моделей, которые сочетают в себе возможности представления и обработки нечётких знаний в виде базы нечётких продукционных правил, и возможности обучения на ограниченном множе-

стве примеров с последующим обобщением полученных знаний [1-6].

Основным недостатком применения баз нечётких продукционных правил являются субъективные методы, применяемые для их разработки. Если база правил составляется группой экспертов в данной предметной области, то она может содержать противоречивые правила и не обладать свойствами полноты и независимости. Следовательно, для решения данной проблемы требуется разработка методик и алгоритмов проверки базы правил на непротиворечивость, полноту и независимость.

Во многих современных работах рассматриваются алгоритмы генерации баз нечётких продукционных правил и автоматические методы проверки их на непротиворечивость и полноту, в том числе алгоритмы, основанные на нейросетевых моделях [5,7]. Авторами статьи для решения поставленной задачи предлагается использовать аппарат нечёткой логики, основанный на теории градуированных формальных систем, позволяющий определить “предел” полноты [8].

### 1. ФОРМИРОВАНИЕ БАЗЫ ПРАВИЛ

Для задачи оценки профессиональной пригодности специалиста была построена нечёткая продукционная модель классификации кандидатов по четырём классам: “не соответствует требованиям специальности”, “частично соответствует”, “в основном соответствует”, “соответствует”, которые обозначаются как  $r_1, r_2, r_3, r_4$  соответственно [9].

Солдатова Ольга Петровна, кандидат технических наук, доцент, доцент кафедры информационных систем и технологий. E-mail: op-soldatova@yandex.ru  
Даниленко Александра Николаевна, кандидат технических наук, ассистент кафедры программных систем. E-mail: danilenko.al@gmail.com

Пусть множество кандидатов описывается как:  $O = \{Ch_1, Ch_2, \dots, Ch_l, \dots, Ch_n\}$ , где  $Ch_l$  – конкретный человек.

Набор личностных характеристик, полученных в результате автоматизированного психологического тестирования [10-11], описывается множеством  $A = \{a_1, a_2, \dots, a_m\}$ .

Отношение  $\tilde{G}_i : a_i \rightarrow \tilde{A}_i$ , задаёт отображение личностной характеристики  $a_i$  на множество значений  $\tilde{A}_i \rightarrow \{\tilde{a}_{i1}, \tilde{a}_{i2}, \dots, \tilde{a}_{ij}\}$ , которые были получены при тестировании кандидатов.

Отношение  $\hat{G}_i : \tilde{a}_i \rightarrow \hat{A}_i$ , задаёт отображение значения личностной характеристики  $\tilde{a}_i$  на множество допустимых значений характеристики  $a_i$  (“проходной коридор”)  $\hat{A}_i = \{\hat{a}_{iN}, \dots, \hat{a}_{iW}\}$ , где  $\hat{a}_{iN}, \hat{a}_{iW}$  – нижняя и верхняя граница множества для значения  $\tilde{a}_i$ .

Обозначим  $\mu_{\tilde{a}_i}^{(s)}(\hat{A}_i^{(s)})$  – степень принадлежности “проходному коридору” значения  $\tilde{a}_i$  характеристики  $a_i$  в  $s$ -ом правиле вывода.

Для того, чтобы определить степень принадлежности посылки  $s$ -ого правила необходимо выполнить нечёткую операцию “И” для степеней принадлежности всех значений  $\tilde{a}_i$  (в данной методике логическое произведение интерпретируется в форме минимума).

Множество результатов  $R = \{r_1, r_2, r_3, r_4\}$  соответствует распознаваемым классам.

Множество значений заключений правил обозначим как  $\tilde{R}_s = \{\tilde{r}_1, \tilde{r}_2, \dots, \tilde{r}_3\}$ , а  $\mu_{\tilde{r}_s}(R)$  – обозначим степень принадлежности заключения  $s$ -ого правила вывода  $\tilde{r}_s$  множеству распознаваемых классов.

Заключение правил определяется нечёткой импликацией “ТО”, которая в данном случае интерпретируется как логическая сумма в виде максимума, модифицированного путем ранжирования в соответствии с экспертной оценкой.

Таким образом, база нечётких правил вывода будет иметь следующий вид:

$$\begin{aligned} & \text{Если } \tilde{a}_1^{(1)} = \hat{A}_1^{(1)} \text{ И } \tilde{a}_2^{(1)} = \hat{A}_2^{(1)} \text{ И } \dots \text{ И } \tilde{a}_i^{(1)} = \hat{A}_i^{(1)} \\ & \text{ТО } \mu_{r_1}^{(1)} = \tilde{r}_1^{(1)} \text{ И } \mu_{r_2}^{(1)} = \tilde{r}_2^{(1)} \text{ И } \mu_{r_3}^{(1)} = \tilde{r}_3^{(1)} \\ & \text{И } \mu_{r_4}^{(1)} = \tilde{r}_4^{(1)} \end{aligned} \dots$$

$$\begin{aligned} & \text{Если } \tilde{a}_1^{(s)} = \hat{A}_1^{(s)} \text{ И } \tilde{a}_2^{(s)} = \hat{A}_2^{(s)} \text{ И } \dots \text{ И } \tilde{a}_i^{(s)} = \hat{A}_i^{(s)} \\ & \text{ТО } \mu_{r_1}^{(s)} = \tilde{r}_1^{(s)} \text{ И } \mu_{r_2}^{(s)} = \tilde{r}_2^{(s)} \text{ И } \mu_{r_3}^{(s)} = \tilde{r}_3^{(s)} \\ & \text{И } \mu_{r_4}^{(s)} = \tilde{r}_4^{(s)} \end{aligned}$$

где  $s$  – номер правила.

В работе предлагается методика проверки полученной базы нечётких правил вывода на непротиворечивость и полноту в соответствии с введёнными в теории градуированных нечётких систем понятиями синтаксических и семантических выводов [11].

Градуированная формальная логическая система является непротиворечивой, если нечёткое множество синтаксических выводов любого нечёткого множества формул есть нечёткое подмножество его семантических выводов, т.е.

$C^{syn}(\tilde{A}_i)(F^{(s)}) \leq C^{sem}(\tilde{A}_i)(F^{(s)})$  верно для любого  $\tilde{A}_i \subset F$  и формулы  $F^{(s)} \in F$ , где  $F$  – база нечётких правил.

Градуированная формальная логическая система является полной, если

$C^{syn}(\tilde{A}_i)(F^{(s)}) = C^{sem}(\tilde{A}_i)(F^{(s)})$  верно для любого  $\tilde{A}_i \subset F$  и формулы  $F^{(s)} \in F$ , где  $F$  – база нечётких правил.

После экспертного оценивания специалистом было выделено 56 значимых характеристик для определения профессиональной пригодности кандидата. В зависимости от требований специальности набор личностных характеристик в значительной степени варьируется. В данной работе для построения общей базы правил был использован максимальный набор параметров, применяемых при отборе кандидатов на экстремальные профессии, к которым относятся: работники правоохранительных органов, военнослужащие, летчики, разведчики, космонавты и т.д.

База правил, составленная экспертами, для профессии лётчика состоит из 39 правил, ниже приведены некоторые из них:

П. 1: ЕСЛИ Меланхолик ТО Не подходит  
 П. 2: ЕСЛИ Депрессия >60 ИЛИ Психопатия >60 ИЛИ Психастения >60  
 ИЛИ Шизоидность >60 ТО Не подходит

...  
 П. 11: ЕСЛИ 8 < Интеллект < 10 ТО Подходит

При преобразовании экспертной базы правил в соответствии с изложенными выше обозначениями, база нечётких продукционных правил для профессии лётчика включает 62 правила следующего вида:

П.1:  
 Если  $\mu_1 = 1$  ТО  $\mu_{r_1}^{(1)} = 1$  И  $\mu_{r_2}^{(1)} = 0$  И  $\mu_{r_3}^{(1)} = 0$  И  $\mu_{r_4}^{(1)} = 0$

П. 2:  
 Если  $\mu_2 > 60$  ТО  $\mu_{r_1}^{(1)} = 1$  И  $\mu_{r_2}^{(1)} = 0$  И  $\mu_{r_3}^{(1)} = 0$  И  $\mu_{r_4}^{(1)} = 0$

...  
 П. 11:

Если  $\mu_{11} = 1$  ТО  $\mu_{r_1}^{(1)} = 0$  И  $\mu_{r_2}^{(1)} = 0$  И  $\mu_{r_3}^{(1)} = 0$  И  $\mu_{r_4}^{(1)} = 1$

В классической логике истинность формулы определяется синтаксическими и семантическими операциями вывода и при этом считается, что при разных посылках выводится одинаковое заключение.

Для того, чтобы производить действия с семантикой и синтаксисом в нечеткой логике необходимо произвести их оценку в конкретной модели формальной теории.

Для простоты восприятия информации степень принадлежности каждого элемента запишем в виде табл. 1 с учетом оцененных синтаксиса и семантики.

Построенная база нечетких правил была проверена с точки зрения полноты и непротиворечивости. Оценивалось каждое правило в отдельности. В результате анализа было получено, что все синтаксические выводы правил являются подмножеством семантических, а, следовательно, эти правила – непротиворечивы. Степени принадлежности посылок и заключений неполных правил (6, 16, 21, 54 и 57) приведены в табл. 2.

Исходя из таблицы 1, супремум всех выводов возможных посылок равен 0,4, а инфимум всех возможных заключений по каждому правилу – 0,25. Следовательно, будем говорить, что данная база нечетких правил полна “в пределе” 0,85. Так как процент неполных правил в общей базе правил менее 15, а “предел” – менее 30, что не превышает коэффициента валидности (0,3), определён-

ного экспертами, будем считать, что база правил для данной предметной области является полной и непротиворечивой.

## 2 АЛГОРИТМ ГЕНЕРАЦИИ БАЗЫ НЕЧЁТКИХ ПРАВИЛ И ПРОВЕРКИ ЕЁ НА НЕПРОТИВОРЕЧИВОСТЬ И ПОЛНОТУ

Авторами предложен алгоритм автоматической генерации базы нечетких правил с учётом проверки на полноту и непротиворечивость, который является модификацией известного алгоритма Абе-Лэна [5,7,12].

1 этап: реализуются нечеткие правила “ЕСЛИ–ТО”, вычисляющие степени принадлежности посылок и заключений по каждому правилу. Производится проверка на полноту и непротиворечивость согласно следующему выражению  $C^{syn}(\tilde{A}_i)(F^{(s)}) \leq C^{sem}(\tilde{A}_i)(F^{(s)})$ . Если правило не отвечает условию непротиворечивости, то считаем, что базу правил составлена некорректно.

Если доля подмножества неполных правил больше, чем 0,15 всей базы, или  $\max(\mu_{a_i}^{(s)}(\hat{A}_i^{(s)})) - \min(\mu_{\tilde{r}_s}(\tilde{R})) > 0,3$ , то считаем, что нечеткая продукционная модель построена некорректно.

2 этап: вычисляются степени принадлежности переменных входного вектора  $a$ .

Таблица 1. Степени принадлежности элементов правил

№ правила	$\mu$ посылки		$\mu$ заключения
	посылка	значение	
1	A1	0	0
2	A2	0	0
...	...	...	...
11	A11	1	1
...	...	...	...
21	A18	0,3	0,6
	A16	1	
	A20	1	
	A21	1	
...	...	...	...

Таблица 2. Степени принадлежности элементов неполных правил

№ правила	$\mu$ посылки		$\mu$ заключения
	посылка	значение	
6	A6	0,1	0,25
16	A14	0,6	0,6
	A16	0,4	
21	A18	0,3	0,6
	A16	1	
	A20	1	
	A21	1	
54	A50	0,4	0,6
57	A51	0,4	0,6

3 этап: рассчитываются максимальные значения выходов элементов второго этапа, которые представляют собой степени принадлежности, полученные в результате ликвидации перекрытий между парой выходных интервалов. Число элементов для выходного интервала  $i_k$  определяется по числу выходных интервалов, чьи входные пространства перекрываются со входным пространством данного выходного интервала  $i_k$ . Поэтому, если нет перекрытия между входными пространствами выходного интервала  $i_k$  и какого-либо другого выходного интервала, то алгоритм для выходного интервала  $i_k$  уменьшается до двух этапов.

4 этап: для выходного интервала  $i_k$  определяется минимальное среди максимальных значений, определенных ранее и соответствующих перекрытию между двумя выходными интервалами.

Если выходной интервал  $i_k$  перекрывается только с одним выходным интервалом, то алгоритм для выходного интервала  $i_k$  сокращается до трёх этапов. Таким образом, в процессе образования входных областей необходимо избавиться от перекрытия между интервалами.

Данный подход позволяет сформировать корректную нечёткую продукционную модель и оптимизировать ее в ходе работы с данными. В автоматически сформулированной базе продукционных правил контролируется ее полнота и непротиворечивость, что приводит к улучшению механизмов нечёткого логического вывода. Структуризация базы знаний позволит повысить каче-

ство и эффективность систем принятия решения.

### 3. МОДИФИЦИРОВАННЫЙ ГИБРИДНЫЙ НЕЙРОНЕЧЁТКИЙ КЛАССИФИКАТОР

Традиционная структура гибридного нейро-нечёткого классификатора построена на основе сети ANFIS с алгоритмом нечёткого вывода Цукamoto и была предложена Саном (Sun) и Чангом (Jang) [13]. Одна из возможных структур гибридного нейро-нечёткого классификатора представлена на рис. 1.

Элементы третьего слоя выполняют агрегирование степеней истинности предпосылок всех правил базы в соответствии с операцией нормализации.

Для решения поставленной задачи классификации соискателей на замещение вакантных должностей на основе психодиагностики объем входной выборки довольно мал и составляет в среднем 50 значений. С целью ускорения работы алгоритма обучения сети и его упрощения, заменим нейроны третьего слоя с операцией S-нормы на нейроны, которые выполняет нормализацию и вычисляют следующие значения:

$$\beta_s = \frac{\alpha_s}{\alpha_1 + \alpha_2 + \dots + \alpha_m}$$

Элементы четвертого слоя вычисляют значения заключений по каждому правилу:

$$y'_s = B_s^{-1}(\alpha_s) = a_s + \frac{1}{b_s} \ln \frac{1 - \alpha_s}{\alpha_s},$$

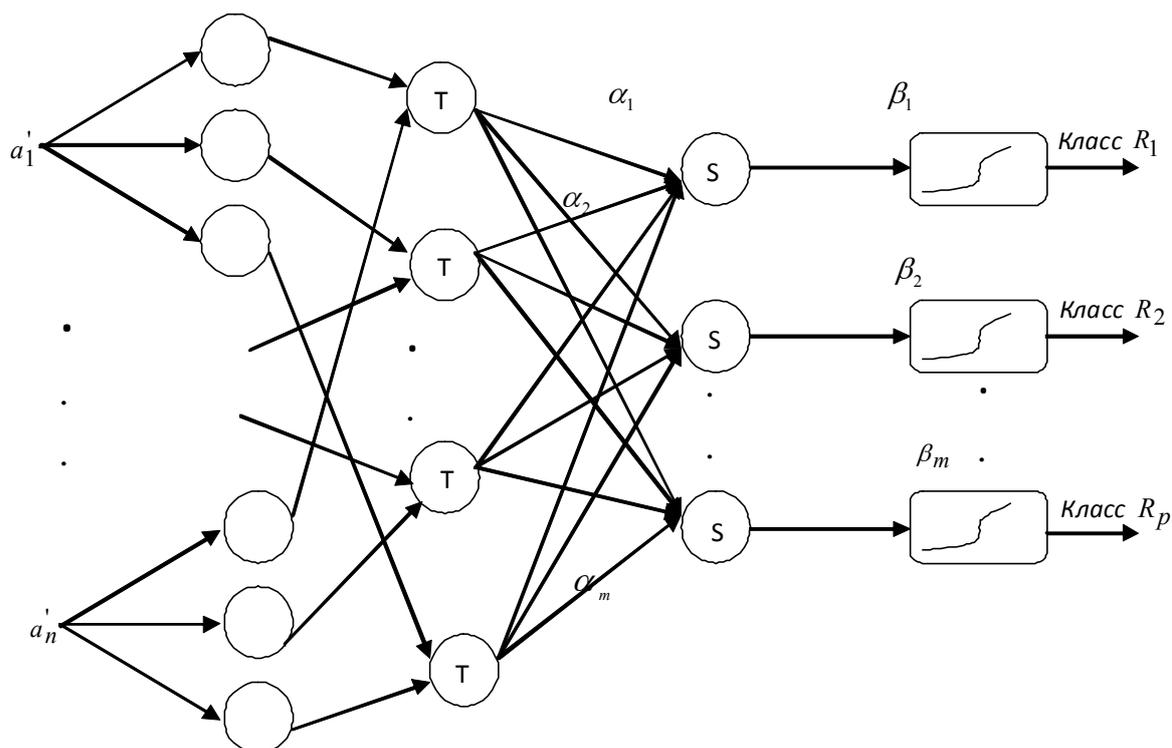


Рис. 1. Структура гибридного нейро-нечёткого классификатора

где  $a_s, b_s$  – нелинейные параметры функций принадлежности  $\mu_{B_s}(y)$  нечётких множеств заключений правил, которые в модифицированном гибридном нейронечётком классификаторе рассчитываются для четырёх классов в каждом правиле [12].

Выходы нечёткой сети вычисляются следующим образом:  $y'_s = \beta_s B_s^{-1}(\alpha_s)$ .

Эти выходы трактуются как степени принадлежности предъявленного объекта соответствующему классу  $R_p$ .

Так как гибридный нейронечёткий классификатор представляется в виде многослойной структуры с прямым распространением сигнала, а значение выходной переменной можно изменять, корректируя параметры элементов слоев, то для обучения этой сети можно использовать градиентные алгоритмы. Авторами использовался алгоритм наискорейшего спуска вместе с методом обратного распространения ошибки для коррекции параметров нейронной сети [5].

#### 4. ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ

Целью проведённых исследований является определение эффективности построенной сети как универсального классификатора и выявление влияния параметров сети, алгоритмов обучения и характеристик входных данных на качество классификации. Исследования проведены при помощи разработанной авторами автоматизированной системы [14].

Исследование проводилось путем постановки ряда экспериментов для различных значений соответствующего параметра. Результаты экспериментов фиксировались в виде графиков. Точность получаемых числовых значений ограничивается пятью знаками после запятой с применением правил округления.

Для проведения исследования влияния объема обучающей выборки на качество обучения был зафиксирован минимум функционала качества обучения на уровне 0,001. Длительность обучения сети равна 1000 итерациям. В качестве функции фазификации использовалась функция Гаусса.

При объеме обучающей выборки меньше 15 примеров среднеквадратичное отклонение (СКО) результатов обучения достаточно велико. Это объясняется тем, что сеть не успевает обучиться. При увеличении объема выборки до 33 примеров наблюдается резкое уменьшение СКО. Дальнейшее возрастание объема выборки до 66 примеров приводит к ухудшению показателей качества классификации.

На рис. 2 представлен график зависимости СКО результатов обучения от объема обучающей выборки.

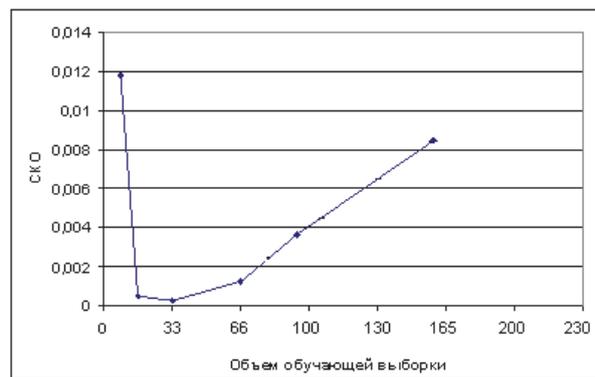


Рис. 2. График зависимости среднего квадратичного отклонения от объема обучающей выборки

По результатам экспериментов, можно сделать вывод о том, что зависимость качества классификации от объема обучающей выборки имеет нелинейный характер, при этом минимальное значение СКО достигается при объеме обучающей выборки, равном 33. При маленьком значении обучающей выборки сеть не может хорошо обучиться, так как она не может выявить все зависимости в исходных данных. При большом объеме обучающей выборки, наоборот, происходит адаптация сети исключительно к последней обучающей выборке. Таким образом, обучающая выборка большой размерности не ведет к улучшению качества обучения нейронной сети, а лишь вызывает ее нечувствительность к избыточным данным или даже принуждает сеть к поиску несуществующей функциональной зависимости, что отрицательно скажется на этапе классификации. Поэтому для данной задачи обучающую выборку объемом в 100 примеров можно считать оптимальной.

Были проведены исследования влияния шага обучения сетей на длительность обучения. Минимум функционала качества обучения зафиксирован на уровне 0,001. Объем обучающей выборки равен 100 примерам. Максимальное количество шагов обучения равно 1000.

Была проведена серия экспериментов для гибридного нейронечёткого классификатора при значениях шага  $h=0,1$ ;  $h=0,3$ ;  $h=0,5$ ;  $h=0,7$ ;  $h=0,9$ . Из проведённых исследований получено, что зависимость размера шага обучения от скорости обучения сети обратно пропорциональна.

При малых значениях шага обучения ( $h<0,01$ ) длительность обучения сильно возрастает. Сеть может не достигнуть необходимого уровня обученности сети за ограниченное количество шагов. При шаге обучения  $h=0,9$  система не достигает правильного решения, “проскакивая” его.

Исходя из проведённых исследований, шаг обучения для гибридного нейронечёткого клас-

сификатора следует выбирать в диапазоне значений от 0,3 до 0,5.

На рис. 3 представлен график изменения результатов обучения гибридного нейронечёткого классификатора от шага при значениях шага  $h=0,35$ ,  $h=0,45$ ,  $h=0,5$ , при этом минимальное значение СКО достигается при значении шага обучения  $h=0,45$ .

Были проведены исследования зависимости вида функции фаззификации на качество обучения сети. Для этого функция Гаусса была заменена на треугольную функцию. Минимум функционала качества обучения зафиксирован на уровне 0,001. Объем обучающей выборки равен 100

примерам. Максимальное количество шагов обучения равно 1000.

Графики изменения результатов обучения гибридного нейронечёткого классификатора с треугольной функцией фаззификации от шага при значениях шага  $h=0,1$ ,  $h=0,45$ ,  $h=0,9$  представлены на рис. 4 – 6.

Из графиков видно, что взаимосвязь шага сети со скоростью обучения остается прежней. Следовательно, значение шага обучения для системы с треугольной функцией фаззификации также следует выбирать в пределах от 0,3 до 0,5.

Обучение гибридного нейронечёткого классификатора с гауссовской функцией фаззифика-

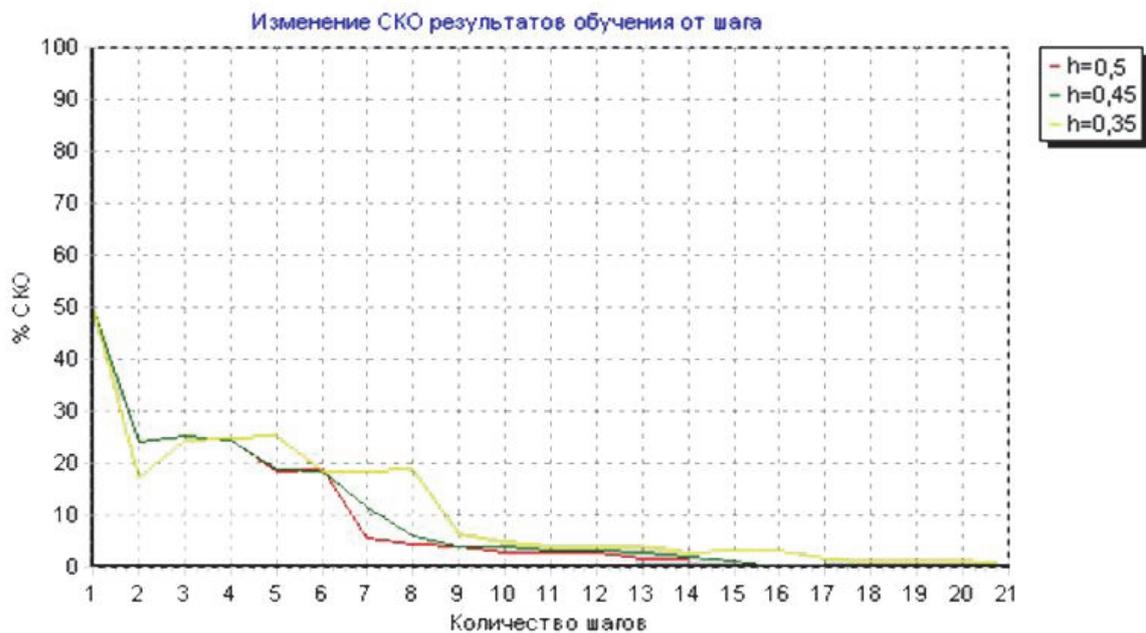


Рис. 3. Графики изменения длительности обучения гибридного нейронечёткого классификатора от шага при значениях шага  $h=0,35$ ,  $h=0,45$ ,  $h=0,5$



Рис. 4. График изменения длительности обучения гибридного нейронечёткого классификатора с треугольной функцией фаззификации от шага при значении шага  $h=0,1$

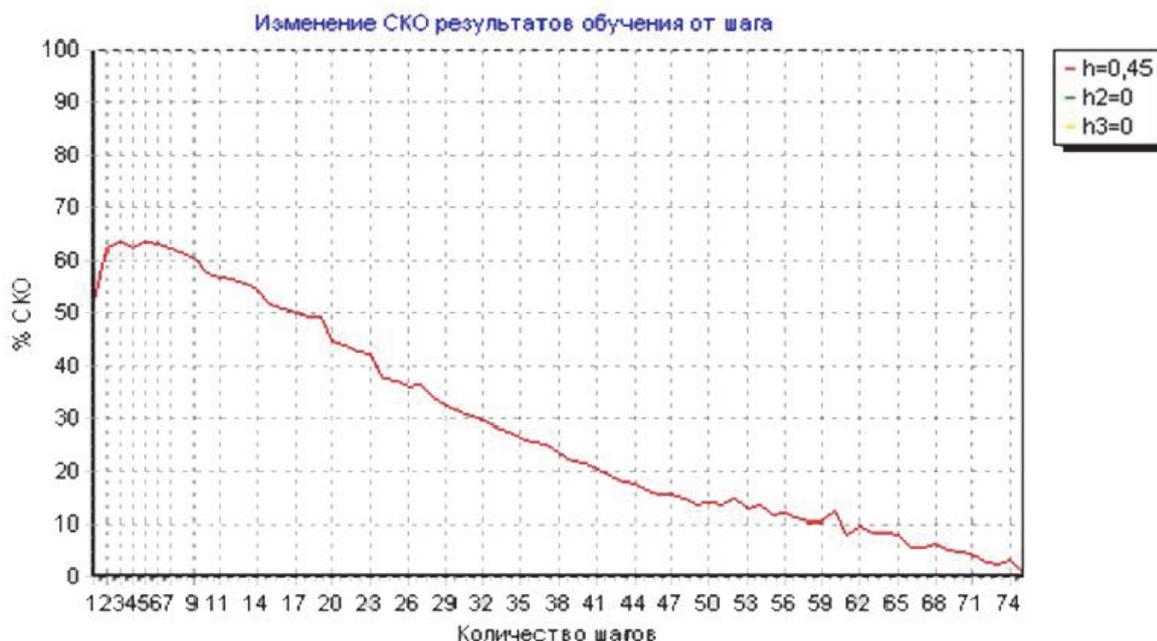


Рис. 5. График изменения длительности обучения гибридного нейронечёткого классификатора с треугольной функцией фаззификации от шага при значении шага  $h=0,45$



Рис. 6. График изменения длительности обучения гибридного нейронечёткого классификатора с треугольной функцией фаззификации от шага при значении шага  $h=0,9$

ции происходит быстрее, чем его модификации с треугольной функцией, однако в последнем случае алгоритм обучения сети значительно упрощается за счет более простого вида самой функции фаззификации, благодаря чему система ведет себя более предсказуемо.

Графики изменения длительности обучения с гауссовской (пунктир) и треугольными функциями фаззификации при оптимальном значении шага  $h=0,45$  представлены на рис. 7.

Для решения данной задачи классификации кандидатов на конкретную должность на основе анализа их профессиональной пригодности целесообразно использовать модифицированный гибридный нейронечёткий классификатор, так как при работе в условиях неточных или недостаточно определенных данных данный классификатор имеет быстрый алгоритм обучения сети, что удобно при решении прикладных задач.

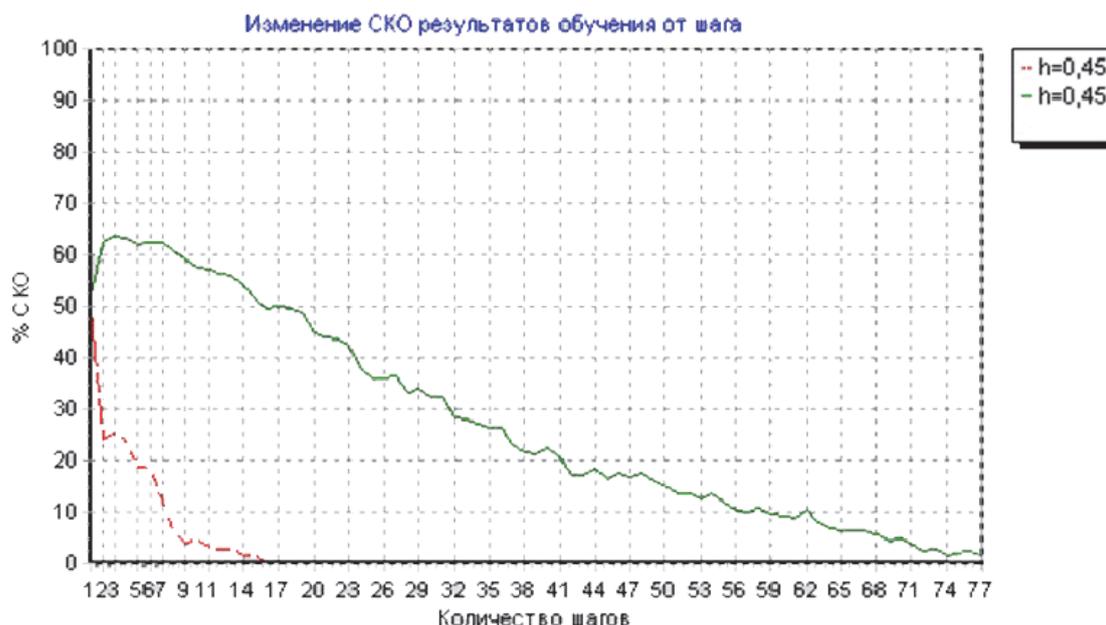


Рис. 7. Графики изменения длительности обучения гибридного нейронно-четкого классификатора с гауссовской и треугольной функциями деффузификации при значении шага  $h=0,45$

## ЗАКЛЮЧЕНИЕ

После окончания обучения сети был проведен сравнительный анализ результатов работы гибридного нейронно-четкого классификатора и экспертов для различных специальностей. По каждой профессии было протестировано 100 человек. Процент соответствия результатов работы системы и экспертной оценки по профессии: летчика – 93%, военнослужащего спецподразделения – 95%, спасателя МЧС – 94% [15].

Данный подход даёт возможность с определённой степенью достоверности рассчитывать предрасположенность к ошибочным действиям в каждом конкретном случае. Такой принцип, используемый в организационно-управленческой деятельности, может помочь в прогнозировании опасности, вызванной человеческим фактором.

## СПИСОК ЛИТЕРАТУРЫ

1. Mamdani E.H. Application of fuzzy logic to approximate reasoning using linguistics systems // Fuzzy Sets and Systems, 1977.V.26.P.1182-1191.
2. Takagi T., Sugeno M. Fuzzy identification of systems and its application to modeling and control // IEEE Transactions on Systems, Man and Cybernetics, 1985.V.15,N1. P.116-132.
3. Wang L., Mendel J.M. Generating fuzzy rules by learning from examples // IEEE Transactions on Systems, Man and Cybernetics, 1992. V.22, N6. P.1414-1427.
4. Осовский С. Нейронные сети для обработки информации [пер. с польского И.Д. Рудинского]. М.: Финансы и статистика, 2002. 344 с.
5. Нечеткие модели и сети / В.В. Борисов, В.В. Круглов, А.С. Федюлов. М.: Горячая линия – Телеком, 2007.284 с.
6. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский [пер. с польск. И.Д. Рудинского]. М.: Горячая линия – Телеком, 2007. 452 с.: ил.
7. Abe S., Lan M.-S. Fuzzy rules extraction directly from numerical data and its application to pattern classification // IEEE Trans. On Fuzzy Systems. 1995. V.3 P.18-28.
8. Математические принципы нечеткой логики / В. Новак, И. Перфильева, И. Мочкорж. М.: Физматлит. 2006.
9. Даниленко А.Н. Интеллектуальная поддержка принятия решений при оценивании человеческого фактора в сфере профессиональной деятельности: дисс. ... канд. техн. наук: 05.13.10. Самара, 2012. 156 с.
10. Автоматизированная информационная система многофакторной диагностики профессионально значимых качеств личности на основе интерактивного перечня требований к профессии / А.Н. Даниленко, С.Г. Ихсанова, В.В. Комаков // Свидетельство о государственной регистрации программ для ЭВМ. Рег. № 2012610996 от 24.01.12.
11. Прогностическое планирование карьеры студента вуза / А.Н. Даниленко, С.Г. Ихсанова, Комаков В.В. // Современные исследования социальных систем. 2012. №1. С.1-8.
12. Даниленко А.Н. Генерация нечетких правил для решения задачи интеллектуальной поддержки принятия решений в системах управления // Молодежь, техника, космос: материалы общероссийской молодежной научно-технической конференции. Изд-во БГТУ «Военмех», Санкт-Петербург, 2011. №3. С. 165-167.
13. Нечеткая логика и искусственные нейронные сети / В.В. Круглов, М.И. Дли, Р.Ю. Голунов. М.: ФИЗМАТЛИТ, 2001. 284 с.
14. Автоматизированная информационная система психологического тестирования и анализа профессиональной пригодности «АИСТ» / А.Н. Даниленко, В.В. Комаков, О.П. Солдатова // Свидетельство о государственной регистрации программ для ЭВМ. Рег. № 2009612163 от 27.04.09.

15. *Даниленко А.Н.* Нейросетевая модель прогноза ошибочных действий лётчиков // Вестник Самарского госу-

дарственного аэрокосмического университета имени академика С.П. Королева. 2011. №6(30). С.207-211.

**SOLUTION OF CLASSIFICATION IN MANAGEMENT DECISIONS  
IN CONDITIONS OF FUZZY INITIAL DATA USING HYBRID NEURO CLASSIFIER**

© 2014 O.P. Soldatova, A.N. Danilenko

Samara State Aerospace University named after Academician S.P. Korolyov  
(National Research University)

The results of methodology application of verification (testing, checking) fuzzy production rules base on consistency and completeness of the example fuzzy production rules database were obtained in this paper. Rules were composed on the psychological testing results of group applicants for professional suitability. The verification on consistency and completeness algorithms of rules base were described. The efficiency of algorithm using for the base of fuzzy production rules in the model of the hybrid neural classifier in solving classification problem for professional suitability specialists was researched.

Keywords: fuzzy logic, completeness limit, fuzzy production rules base, hybrid neural fuzzy classifier, Abe Lan algorithm, gradient learning algorithms.

---

*Olga Soldatova, Candidate of Technical Science, Associate Professor, Associate Professor of Information Systems and Technologies Department. E-mail: op-soldatova@yandex.ru*  
*Aleksandra Danilenko, Candidate of Technical Science, Lecture of Programming Systems Department.*  
*E-mail: danilenko.al@gmail.com*