

УДК 681.3.16

Н.В. НЕЧИПОРУК, Н.В. КУЗНЕЦОВА

*Национальный аэрокосмический университет им. Н.Е. Жуковского «ХАИ», Украина***СИНТЕЗ И НАСТРОЙКА БАЗ НЕЧЕТКИХ ЗНАНИЙ ДЛЯ МОДЕЛИРОВАНИЯ ПРОФЕССИОНАЛЬНОЙ ПСИХОФИЗИОЛОГИЧЕСКОЙ ПРИГОДНОСТИ**

Предложено применение синтезированной нечеткой базы знаний для моделирования профессионального психофизиологического отбора лиц, занятых во вредных и опасных условиях труда. Построение синтезированной нечеткой базы знаний осуществляется с помощью генетического алгоритма и многослойной нейронной сети. Генетический алгоритм позволяет найти решение глобального оптимума, а нейронная сеть, уменьшая погрешность формы функции принадлежности с каждой последующей итерацией, улучшает достоверность модели профессиональной пригодности.

**синтезированная нечеткая база знаний, слабо формализованные процессы, профессиональный психофизиологический отбор, функции принадлежности, генетический алгоритм, многослойные нейронные сети**

Согласно статистическим данным, экологическая и техногенная безопасность на 87% зависит от влияния «человеческого фактора». В современных условиях одним из средств снижения этого показателя, а, следовательно, предупреждения аварий и катастроф, является проведение автоматизированного профессионального психофизиологического отбора с использованием прогрессивных информационных технологий. Проведение автоматизированного психофизиологического отбора заключается в идентификации исследуемого объекта эталонной профессиональной пригодности. Как вид математического моделирования идентификация играет важнейшую роль в автоматическом и ситуационном управлении, в технической и медицинской диагностике, в распознавании образов, а также в других задачах принятия решений.

В основе современной теории идентификации лежит моделирование слабо формализованных процессов (СФП) с помощью уравнений. При этом сложность исследуемого объекта самым непосредственным образом влияет на качество построения его модели. Если для описания исследуемого объекта применяется информация, которая не может быть выражена количественно, то классическая теория

оказывается плохо приспособленной для таких случаев. Основные причины малоэффективности или же вообще неприспособленности традиционных методов моделирования состоят в следующем [1]:

- не все входные и выходные параметры исследуемого объекта могут описываться количественно;
- между рядом входных и выходных параметров невозможно установить количественные зависимости;
- входные параметры исследуемого объекта, в силу своей активной природы, могут быть не только неполными, но и противоречивыми.

Таким образом, при моделировании профессиональной пригодности, которая также характеризуется вышеуказанными особенностями, возникает проблема построения так называемых лингвистических моделей, т.е. моделей, в которых средства обработки информации основаны на логике, а экспериментальные данные представляются в лингвистической форме. Такие модели должны основываться на системах знаний, представленных экспертами-специалистами данной области. Для обработки экспертной естественно-языковой информации хорошо зарекомендовали себя лингвистические переменные, базирующиеся на нечетких

множествах. В соответствии с этой теорией, модель профессиональной пригодности представляет собой так называемую нечеткую базу знаний в виде совокупности логических высказываний «ЕСЛИ-ТО», которые связывают лингвистические оценки входных и выходного параметров профессиональной пригодности претендента.

Например, ЕСЛИ лабильность нервной системы низкая, ТО переключение с одного вида деятельности на другой у претендента происходит с трудом, с потерей времени на перестройку; ЕСЛИ толерантность к физической нагрузке ниже средней и сила нервной системы ниже средней, а возраст больше среднего, ТО претендент на должность водителя автотранспорта мало пригоден.

Поэтому для моделирования СФП целесообразно применять логико-лингвистические модели, в основу которых легли бы экспериментальные данные, характеризующие исследуемый объект [2]. Но такие модели обычно являются «грубыми», и для них не менее важен вопрос об эффективном методе их «тонкой» настройки.

В данной статье для моделирования профессиональной психофизиологической пригодности предлагается рассмотреть использование синтезированной нечеткой базы знаний с применением генетического алгоритма и нейронной сети. Генетический алгоритм представляет собой поисковый метод решений, в котором комбинируются элементы двух стратегий одновременно – эксплуатация наилучшего решения и исследование пространства решений. При таком подходе генетический алгоритм позволяет найти решение глобального оптимума и избежать попадания в локальный минимум [2]. Последующая настройка базы знаний с помощью многослойной нейронной сети успешно обучает модель, приближая выходное значение параметра к эталонному, уменьшая погрешность формы функции принадлежности на каждом последующем шаге, что улучшает достоверность модели профессиональной пригодности.

Построение модели производится в два этапа: первый – структурная идентификация СФП; второй – параметрическая идентификация. На первом этапе строится структура зависимости профессиональной пригодности от параметров функционального состояния организма с применением правил «ЕСЛИ-ТО». На втором этапе проводится настройка модели путем подбора таких параметров функций принадлежности нечетких термов и весов правил «ЕСЛИ-ТО», которые обеспечивают минимальное расхождение эталонных и экспериментальных результатов.

Учитывая перечисленные особенности, при установлении профессиональной пригодности, вид функций принадлежности задается аксиоматически, а необходимые для построения функций принадлежности параметры определяются экспертом-специалистом. Наиболее целесообразным представляется генерация функций принадлежности колоколообразной (гауссовской) формы. При выборе формы функций принадлежности исходим из следующих соображений:

- колоколообразная функция является удобной аппроксимацией сложных (нелинейных) функциональных зависимостей, используемых в теории нечетких множеств;

- данная функция хорошо описывает реальные функции принадлежности, полученные методом статистической обработки экспериментальной и экспертной информации для параметров функционального состояния претендента;

- колоколообразная функция адекватна, поскольку она имеет возможность изменять свою форму путем изменения собственных параметров;

- данную функцию несложно настроить с целью минимизации различия между эталонными и экспериментальными данными для повышения достоверности диагностирования;

- аналогичные методы уже использовались для решения кибернетических задач и зарекомендовали себя с хорошей стороны.

Для установления структуры зависимостей в статье приводится частичный список следующих входных параметров функционального состояния претендента на должность водителя:

- $x_1$  – возраст претендента (20 лет);
- $x_2$  – рост (180 см);
- $x_3$  – вес тела (80 кг);
- $x_4$  – окружность грудной клетки (78 см);
- $x_5$  – индекс «стени» (0,74);
- $x_6$  – частота пульса (65 уд./мин.);
- $x_7$  – систолическое АД (118 мм рт.ст);
- $x_8$  – диастолическое АД (75 мм рт.ст);
- $x_9$  – толерантность к физической нагрузке (450 кг/мин.);
- $x_{10}$  – образование (высшее(3));
- $x_{11}$  – средний балл оценок в дипломе (4,4);
- $x_{12}$  – стаж работы по специальности (0 лет);
- $x_{13}$  – экстраверсия (49);
- $x_{14}$  – нейротизм (56);
- $x_{15}$  – ситуационная тревожность (55);
- $x_{16}$  – личностная тревожность (80);
- $x_{17}$  – сила нервной системы (0,85);
- $x_{18}$  – лабильность нервной системы (0,45);
- $x_{19}$  – уравновешенность нервных процессов (1);
- $x_{20}$  – устойчивость и концентрация внимания (0,74).

Если проанализировать природу данных входных переменных, то можно сделать вывод о том, что часть параметров имеет дискретный характер (вес тела, частота пульса, артериальное давление и т.д.), а часть параметров – непрерывный (рост тела, экстраверсия, нейротизм, лабильность нервной системы и т.д.), их значения можно указать лишь приближенно – нечетко. При таких условиях осуществляемый профессиональный отбор также носит лишь приближенный или нечеткий характер. Учитывая данные обстоятельства, для формализации профессиональной пригодности исследуемого претендента в статье предлагается воспользоваться нечеткими базами знаний, как наиболее удобным и полезным

методом обработки данных, особенно для лиц, принимающих решения [5].

Однако, имея большое количество экспериментальных данных разной природы и разных по физическому смыслу, построение нечеткой базы знаний о неизвестной зависимости становится затруднительным. В связи с этим целесообразно провести классификацию входных параметров и по ней построить структурное дерево вывода, определяющее систему вложенных друг в друга нечетких баз знаний меньшей размерности.

Поэтому представим иерархическую взаимосвязь между входными параметрами, классами входных параметров и выходным параметром (интегральным показателем) в виде дерева логического вывода, которому соответствует система следующих соотношений:

$g$  – профессиональная пригодность, которая измеряется уровнями  $g_1 \div g_5$ ;

$y$  – инструментальная профессиональная пригодность, которая зависит от факторов  $x_2 \div x_9$ ;

$z$  – учебно-трудовая профессиональная пригодность, которая зависит от факторов  $x_{10} \div x_{12}$ ;

$c$  – тестовая профессиональная пригодность, которая зависит от факторов  $x_{13} \div x_{20}$ .

Взаимосвязь введенных лингвистических переменных определяется соотношениями вида:

$$\begin{aligned} g &= f_g \{x_1, y, z, c\}, \\ y &= f_y \{x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9\}, \\ z &= f_z \{x_{10}, x_{11}, x_{12}\}, \\ c &= f_c \{x_{13}, x_{14}, x_{15}, x_{16}, x_{17}, x_{18}, x_{19}, x_{20}\}, \end{aligned} \quad (1)$$

где  $g$  – выходная переменная (интегральный показатель);  $y, z, c$  – классы входных переменных.

Структура модели для определения профессиональной пригодности в виде дерева логического вывода представлена на рис. 1, где типы профессиональной пригодности определены как:  $g_1$  – не пригоден (Н),  $g_2$  – мало пригоден (мП),  $g_3$  – пригоден (П),  $g_4$  – относительно пригоден (оП),  $g_5$  – абсолютно не пригоден (аН).




Рис. 1. Дерево логического вывода

Для проведения оценки значений лингвистических переменных  $x_1 \div x_{20}$ , а также  $y, z,$  и  $c$  будем использовать единую шкалу качественных термов: Н – не пригоден, мН – мало пригоден, П – пригоден, оП – относительно пригоден, аН – абсолютно не пригоден, соответственно равных  $g_1, g_2, g_3, g_4, g_5$ . Каждый из этих термов представляет нечеткое множество, заданное с помощью соответствующих функций принадлежности.

Пользуясь введенными качественными термами и знаниями эксперта, представим соотношения (1) в виде нечетких баз знаний, содержащих логические высказывания о взаимосвязи входных переменных функционального психофизиологического состояния претендента и выходной переменной – о профессиональной пригодности. Фрагмент нечеткой базы знаний для (1) имеет следующий вид:

$$\begin{aligned}
 & \text{ЕСЛИ} \\
 & (x = x^{j1}) \text{И} (y = y^{j1}) \text{И} \dots \text{И} (z = z^{j1}) \text{И} (c = c^{j1}) \\
 & \text{ИЛИ} \\
 & (x = x^{j2}) \text{И} (y = y^{j2}) \text{И} \dots \text{И} (z = z^{j2}) \text{И} (c = c^{j2}) \\
 & \text{ИЛИ} \dots \quad (2) \\
 & (x = x^{jh}) \text{И} (y = y^{jh}) \text{И} \dots \text{И} (z = z^{jh}) \text{И} (c = c^{jh}) \\
 & \text{ИЛИ} \\
 & (x = x^{jk1}) \text{И} (y = y^{jk1}) \text{И} \dots \text{И} (z = z^{jk1}) \text{И} (c = c^{jk1}),
 \end{aligned}$$

ТО

$$g = g_j, j = \overline{1, r}.$$

Эти правила можно представить в виде матрицы знаний  $M_g$ :

$x_1$	$y$	$z$	$c$	$g$
Н	Н	Н	Н	$g_1$
Н	Н	мП	мП	
аН	мП	Н	Н	
мП	мП	мП	мП	$g_2$
П	мП	мП	П	
мП	мП	П	мП	
П	мП	мП	П	$g_3$
оП	мП	П	П	
оП	П	П	мП	
аН	П	оП	оП	$g_4$
П	аП	оП	П	
мП	аП	оП	оП	
аН	Н	Н	мП	$g_5$
П	мП	Н	П	
аН	Н	оП	оП	

Аналогично представим матрицы знаний  $M_y, M_z, M_c$  для остальных соотношений фрагмента нечеткой базы знаний (2)

Матрица знаний  $M_y$ :

$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$g$
аН	аН	аП	Н	Н	Н	аН	Н
аН	мП	оП	мП	Н	Н	Н	
оП	аП	оП	Н	Н	Н	аН	
оП	мП	аН	мП	Н	мП	мП	мП
аН	аН	оП	П	Н	аН	оП	
мП	мП	оП	мП	оП	мП	мП	
П	П	П	П	П	П	мП	П
аН	оП	П	мП	оП	П	оП	
П	оП	мП	П	оП	оП	оП	
мП	П	мП	аН	мП	мП	оП	оП
мП	мП	П	П	Н	мП	мП	
П	мП	мП	аН	мП	П	оП	
Н	Н	Н	оП	аН	Н	аН	аН
мП	Н	мП	аН	аН	аН	аН	
Н	мП	мП	оП	аН	Н	аН	

Используя (4) и применяя  $\wedge$  (И - min) и  $\vee$  (ИЛИ - max) [4], запишем систему нечетких логических уравнений, связывающую функции принадлежности профессиональной пригодности и входные пере-

менные. Фрагмент системы нечетких логических уравнений для матриц (4) имеет следующий вид:

$$\begin{aligned} \mu^{g_1}(g) &= [\mu^H(x_1) \wedge \mu^H(y) \wedge \mu^H(z) \wedge \mu^H(c)] \vee [\mu^H(x_1) \wedge \\ &\wedge \mu^{m\Pi}(y) \mu^{m\Pi}(z) \wedge \mu^{m\Pi}(c)] \vee [\mu^{aH}(x_1) \wedge \\ &\wedge \mu^{m\Pi}(y) \mu^{m\Pi}(z) \wedge \mu^{m\Pi}(c)], \\ \mu^{g_2}(g) &= [\mu^{m\Pi}(x_1) \wedge \mu^{m\Pi}(y) \wedge \mu^{m\Pi}(z) \wedge \mu^{m\Pi}(c)] \vee \\ \vee [\mu^{\Pi}(x_1) \wedge \mu^{m\Pi}(y) \wedge \mu^{m\Pi}(z) \wedge \mu^{\Pi}(c)] \vee [\mu^{m\Pi}(x_1) \wedge \\ &\vee \mu^{m\Pi}(y) \wedge \mu^{\Pi}(z) \wedge \mu^{m\Pi}(c)], \\ \mu^{g_3}(g) &= [\mu^{\Pi}(x_1) \wedge \mu^{m\Pi}(y) \wedge \mu^{m\Pi}(z) \wedge \mu^{\Pi}(c)] \vee \\ &\vee [\mu^{\Pi}(x_1) \wedge \mu^{o\Pi}(y) \wedge \mu^{m\Pi}(z) \wedge \mu^{m\Pi}(c)] \vee \\ &\vee [\mu^{o\Pi}(x_1) \wedge \mu^{\Pi}(y) \wedge \mu^{m\Pi}(z) \wedge \mu^{m\Pi}(c)], \quad (5) \\ \mu^{g_4}(g) &= [\mu^{a\Pi}(x_1) \wedge \mu^{\Pi}(y) \wedge \mu^{o\Pi}(z) \wedge \mu^{o\Pi}(c)] \vee \\ \vee [\mu^{\Pi}(x_1) \wedge \mu^{aH}(y) \mu^{o\Pi}(z) \wedge \mu^{\Pi}(c)] \vee [\mu^{m\Pi}(x_1) \wedge \\ &\wedge \mu^{aH}(y) \wedge \mu^{o\Pi}(z) \wedge \mu^{o\Pi}(c)], \\ \mu^{g_5}(g) &= [\mu^{a\Pi}(x_1) \wedge \mu^H(y) \wedge \mu^H(z) \wedge \mu^{m\Pi}(c)] \vee \\ &\vee [\mu^{\Pi}(x_1) \wedge \mu^{m\Pi}(y) \mu^H(z) \wedge \mu^{\Pi}(c)] \vee \\ &[\mu^{a\Pi}(x_1) \wedge \mu^H(y) \wedge \mu^{o\Pi}(z) \wedge \mu^{o\Pi}(c)]. \end{aligned}$$

$$\begin{aligned} \mu^H(y) &= [\mu^{aH}(x_2) \wedge \mu^{aH}(x_3) \wedge \mu^{aH}(x_4) \wedge \mu^H(x_5) \mu^H(x_6) \wedge \\ &\wedge \mu^H(x_7) \wedge \mu^{aH}(x_8)] \vee [\mu^{aH}(x_2) \wedge \mu^{m\Pi}(x_3) \wedge \\ &\wedge \mu^{o\Pi}(x_4) \wedge \mu^{m\Pi}(x_5) \mu^H(x_6) \wedge \mu^H(x_7) \wedge \mu^H(x_8)] \\ &\vee [\mu^{oH}(x_2) \wedge \mu^{a\Pi}(x_3) \wedge \mu^{o\Pi}(x_4) \wedge \mu^H(x_5) \mu^H(x_6) \wedge \\ &\wedge \mu^H(x_7) \wedge \mu^{aH}(x_8)], \\ \mu^{m\Pi}(y) &= [\mu^{oH}(x_2) \wedge \mu^{mH}(x_3) \wedge \mu^{aH}(x_4) \wedge \mu^{m\Pi}(x_5) \mu^H(x_6) \wedge \\ &\wedge \mu^{m\Pi}(x_7) \wedge \mu^{m\Pi}(x_8)] \vee [\mu^{aH}(x_2) \wedge \mu^{a\Pi}(x_3) \wedge \\ &\wedge \mu^{o\Pi}(x_4) \wedge \mu^{\Pi}(x_5) \mu^H(x_6) \wedge \mu^{aH}(x_7) \wedge \mu^{o\Pi}(x_8)] \vee \\ &\vee [\mu^{mH}(x_2) \wedge \mu^{m\Pi}(x_3) \wedge \mu^{o\Pi}(x_4) \wedge \mu^{m\Pi}(x_5) \mu^{o\Pi}(x_6) \wedge \\ &\wedge \mu^{m\Pi}(x_7) \wedge \mu^{m\Pi}(x_8)], \\ \mu^{\Pi}(y) &= [\mu^{\Pi}(x_2) \wedge \mu^{\Pi}(x_3) \wedge \mu^{\Pi}(x_4) \wedge \mu^{\Pi}(x_5) \mu^{\Pi}(x_6) \wedge \\ &\wedge \mu^{\Pi}(x_7) \wedge \mu^{m\Pi}(x_8)] \vee [\mu^{aH}(x_2) \wedge \mu^{o\Pi}(x_3) \wedge \\ &\wedge \mu^{\Pi}(x_4) \wedge \mu^{\Pi}(x_5) \mu^{o\Pi}(x_6) \wedge \mu^{\Pi}(x_7) \wedge \mu^{o\Pi}(x_8)] \vee \\ &\vee [\mu^{\Pi}(x_2) \wedge \mu^{o\Pi}(x_3) \wedge \mu^{m\Pi}(x_4) \wedge \mu^{\Pi}(x_5) \mu^{o\Pi}(x_6) \wedge \\ &\wedge \mu^{o\Pi}(x_7) \wedge \mu^{o\Pi}(x_8)], \quad (6) \\ \mu^{o\Pi}(y) &= [\mu^{m\Pi}(x_2) \wedge \mu^{\Pi}(x_3) \wedge \mu^{m\Pi}(x_4) \wedge \mu^{aH}(x_5) \mu^{m\Pi}(x_6) \wedge \\ &\wedge \mu^{m\Pi}(x_7) \wedge \mu^{o\Pi}(x_8)] \vee [\mu^{mH}(x_2) \wedge \mu^{m\Pi}(x_3) \wedge \\ &\wedge \mu^{\Pi}(x_4) \wedge \mu^{\Pi}(x_5) \mu^H(x_6) \wedge \mu^{m\Pi}(x_7) \wedge \mu^{m\Pi}(x_8)] \vee \\ &\vee [\mu^{\Pi}(x_2) \wedge \mu^{m\Pi}(x_3) \wedge \mu^{m\Pi}(x_4) \wedge \mu^{aH}(x_5) \mu^{m\Pi}(x_6) \wedge \\ &\mu^{\Pi}(x_7) \wedge \mu^{o\Pi}(x_8)], \\ \mu^{aH}(y) &= [\mu^H(x_2) \wedge \mu^H(x_3) \wedge \mu^H(x_4) \wedge \mu^{oH}(x_5) \mu^{aH}(x_6) \wedge \\ &\wedge \mu^H(x_7) \wedge \mu^{aH}(x_8)] \vee [\mu^{m\Pi}(x_2) \wedge \mu^H(x_3) \wedge \\ &\wedge \mu^{m\Pi}(x_4) \wedge \mu^{aH}(x_5) \mu^{aH}(x_6) \wedge \mu^{aH}(x_7) \wedge \end{aligned}$$

$$\begin{aligned} &\wedge \mu^{aH}(x_8)] \vee [\mu^H(x_2) \wedge \mu^{m\Pi}(x_3) \wedge \mu^{m\Pi}(x_4) \wedge \\ &\wedge \mu^{o\Pi}(x_5) \mu^{aH}(x_6) \wedge \mu^H(x_7) \wedge \mu^{aH}(x_8)]. \end{aligned}$$

...

Несмотря на то, что каждая входная переменная  $x_1 \div x_{20}$  имеет свою собственную функцию принадлежности нечетким термам (H, mH, П, oП, aH), для упрощения моделирования используем для всех переменных только одну форму функции принадлежности, показанную на рис. 2.

Одновременно установим интервалы изменения каждой переменной к одному универсальному интервалу  $[0, 4]$  в соответствии с единой шкалой качественных термов.

Учитывая, что аналитическая модель заданной формы функции принадлежности имеет следующий вид:

$$\mu^T(x_i) = \frac{1}{1 + \left(\frac{x-b}{c}\right)^2}, \quad (7)$$

где  $b$  – координата максимума функции;

$c$  – коэффициент концентрации-растяжения функции.

Являясь параметрами настройки функции принадлежности,  $b$  и  $c$  при  $\mu^T(x_i)=1$  приведены в табл. 1.

Таблица 1

Параметры грубых функций принадлежности

Терм	H	mП	П	oП	aH
$b$	0	1	2	3	4
$c$	0,923	0,923	0,923	0,923	0,923

Графическое изображение данных функций принадлежности нечетких термов входных переменных до настройки представлены на рис. 2.

С помощью определенной выше системы нечетких логических высказываний, определим функции принадлежности  $\mu^{gT}(x, y, z, c)$  термов – оценок выходной переменной (профессиональной пригодности  $g$ ).




Рис. 2. Грубые функции принадлежности

При этом логические операции И ( $\wedge$ ) и ИЛИ ( $\vee$ ) над функциями принадлежности заменим операциями  $\min$  и  $\max$ :

$$\begin{aligned} \mu^{g1}(g) &= \max_{j=1,20} \left\{ \min \left[ \mu^g(x_1), \mu^{g_j}(y), \mu^g(z), \mu^g(c) \right] \right\}, \\ \mu^{g2}(g) &= \max_{j=1,20} \left\{ \min \left[ \mu^{g2}(y_i) \right] \right\}, \\ \mu^{g3}(g) &= \max_{j=1,20} \left\{ \min \left[ \mu^{g3}(z_i) \right] \right\}, \\ \mu^{g4}(g) &= \mu^{g4}(g) = \max_{j=1,20} \left\{ \min \left[ \mu^{g4}(c_i) \right] \right\}, \\ \mu^{g5}(g) &= \max_{j=1,20} \left\{ \min \left[ \mu^{g5}(x_i) \right] \right\}. \end{aligned} \tag{8}$$

Решением  $g_j$  будет являться максимальная функция принадлежности:

$$\begin{aligned} \mu^{g_j}(x_1, x_2, \dots, x_{20}) &= \\ &= \max_{j=1,20} \left[ \mu^g(x_1, x_2, \dots, x_{20}) \right]. \end{aligned} \tag{9}$$

Вычислительную часть алгоритма легко реализовать, если построить на основе матрицы знаний матрицу значений функций принадлежности, с указанием экспериментальных входных данных исследуемого претендента. Для этого необходимо, используя формулу (7) и параметры  $b$  и  $c$  из табл. 1, определить значения функций принадлежности для всех типов пригодности. Наконец, в соответствии с уравнением (8), находим наибольшее значение функции принадлежности, которое и будет отвечать профессиональной пригодности претендента, рас-

смотренного выше в качестве примера, при фиксированных значениях его параметров  $x_i$ :

$$\begin{aligned} \mu^{g1}(g) &= [1,663 \wedge 0,098 \wedge 0,096 \wedge 0,111] \vee \\ &\vee [1,663 \wedge 0,086 \wedge 0,227 \wedge 0,086] \vee \\ &\vee [0,058 \wedge 0,086 \wedge 0,062 \wedge 0,086] = \\ &= 0,0017 + 0,0027 + 0,00002 = 0,00442. \end{aligned}$$

Аналогично:  $\mu^{g2}(g) = 0,00137$ ;  $\mu^{g3}(g) = 0,00628$ ;

$\mu^{g4}(g) = 0,00176$ ;  $\mu^{g5}(g) = 0,00210$ . Поскольку максимальное значение функции принадлежности соответствует решению типа  $g_3$ , то в качестве заключительного решения будет – «профессионально пригоден».

Для получения синтезированной нечеткой базы знаний в целях определения профессиональной пригодности воспользуемся генетическим алгоритмом [6]. Данная процедура требует определения следующих важных величин:

- количества термов выходной переменной  $M$ ;
- максимально допустимое количество правил  $\bar{r}_j$ , которое соответствует  $j$ -классу выходной переменной;
- границы диапазонов изменения параметров  $b$  и  $c$  (коэффициентов концентрации-растяжения);
- размер начальной популяции хромосом-решений;
- коэффициент скрещивания  $\rho_c$ ;
- коэффициент мутации  $\rho_m$ ;
- количество итераций генетического алгоритма.

После реализации основных операций генетического алгоритма мутации, скрещивания и отбора, сформируем случайным образом набор переменных параметров функций принадлежности и весов правил, с учетом ограничений на их диапазоны. Синтезированная таким образом матрица знаний представлена в табл. 2.

Полученная база знаний является, как правило, субоптимальной, что соответствует этапу «грубой» настройки синтезированной нечеткой базы знаний.

В связи с этим, возникает необходимость проведения следующего этапа – «тонкой» настройки переменных параметров с помощью нейронной сети.

Таблица 2

Параметры синтезированной матрицы знаний

ЕСЛИ						Вес	ТО
$x_1$		...		$x_{20}$			
$c$	$c$	$c$	$c$	$c$	$c$	1	$g$
0,61	0,29	...	...	0,005	0,27		g <sub>1</sub>
0,89	0,25	...	...	0,37	0,15		
0,80	0,12	...	...	0,11	0,08		
0,42	0,17	...	...	0,40	0,07		g <sub>2</sub>
0,88	0,22	...	...	0,66	0,28		
0,16	0,11	...	...	0,88	0,17		
0,10	0,21	...	...	0,34	0,19		g <sub>3</sub>
0,45	0,16	...	...	0,31	0,08		
0,13	0,07	...	...	0,81	0,23		
0,43	0,24	...	...	0,09	0,17		g <sub>4</sub>
0,14	0,11	...	...	0,23	0,25		
0,85	0,24	...	...	0,03	0,24		
0,86	0,11	...	...	0,84	0,16		g <sub>5</sub>
0,18	0,05	...	...	0,77	0,12		
0,06	0,12	...	...	0,05	0,17		

Нейронные сети и нечеткая логика – это принципиально разные математические конструкции, но вместе с тем они обе могут применяться в качестве универсальных аппроксиматоров СФП, таких как функциональное психофизиологическое состояние человека и его профессиональная пригодность. При этом главным преимуществом нейронных сетей является их способность к так называемому обучению. Данная способность реализуется с помощью специально разработанных алгоритмов. Кроме этого следует отметить ту особенность, что обучение нейронной сети не требует никакой априорной информации, нужна лишь обучающая выборка в виде экспериментальных пар «входы-выход».

Исследованиями доказано, что хорошие результаты обучения приносит объединение алгоритмов глобальной оптимизации с одним из детерминированных методов, использующих какой-либо специальный, локальный алгоритм. Поэтому, на основании результатов имитационных экспериментов,

наиболее эффективным из алгоритмов глобальной оптимизации является генетический алгоритм, а из детерминированных методов – метод «обратного распространения ошибки» back propagation [6].

Представим обучающую выборку в виде массива экспериментальных данных – реальных верифицированных психофизиологических пригодностей. После генерации обучающей выборки – эталона профессиональной психофизиологической пригодности, определим структуру и параметры нейронной сети. Начальные веса правил после проведения оптимизации генетическим алгоритмом равняются 1. Структура нейро-нечеткой сети, соответствующая модели профессиональной психофизиологической пригодности, приведена на рис. 3.

Обучение нейронной сети с использованием алгоритма обратного распространения ошибки состоит из двух фаз – алгоритма прямого и обратного хода.

Обучение продолжается до тех пор, пока не будет достигнута заданная погрешность достоверности. Действие алгоритма завершается в тот момент, когда норма градиента упадет ниже заданного значения, характеризующего точность процесса обучения, тем самым, повышая достоверность модели профессиональной пригодности [6]. Параметры функций принадлежности синтезированной базы знаний после настройки (обучения) представлены в табл. 3. А веса правил до и после обучения, которые установились при использовании соответствующего алгоритма, приведены в табл. 4.

В результате обучения сети была получена модель профессиональной психофизиологической пригодности, графики функций принадлежности которой после настройки показаны на рис. 4.

При сравнении верифицированной и компьютерной профессиональных пригодностей для 24-х претендентов, значения которых сведены в табл. 5, видно, что только одно компьютерное решение (\*\*\*) слишком далеко от верифицированной профессиональной пригодности.




Рис. 3. Структура нейро-нечеткой сети

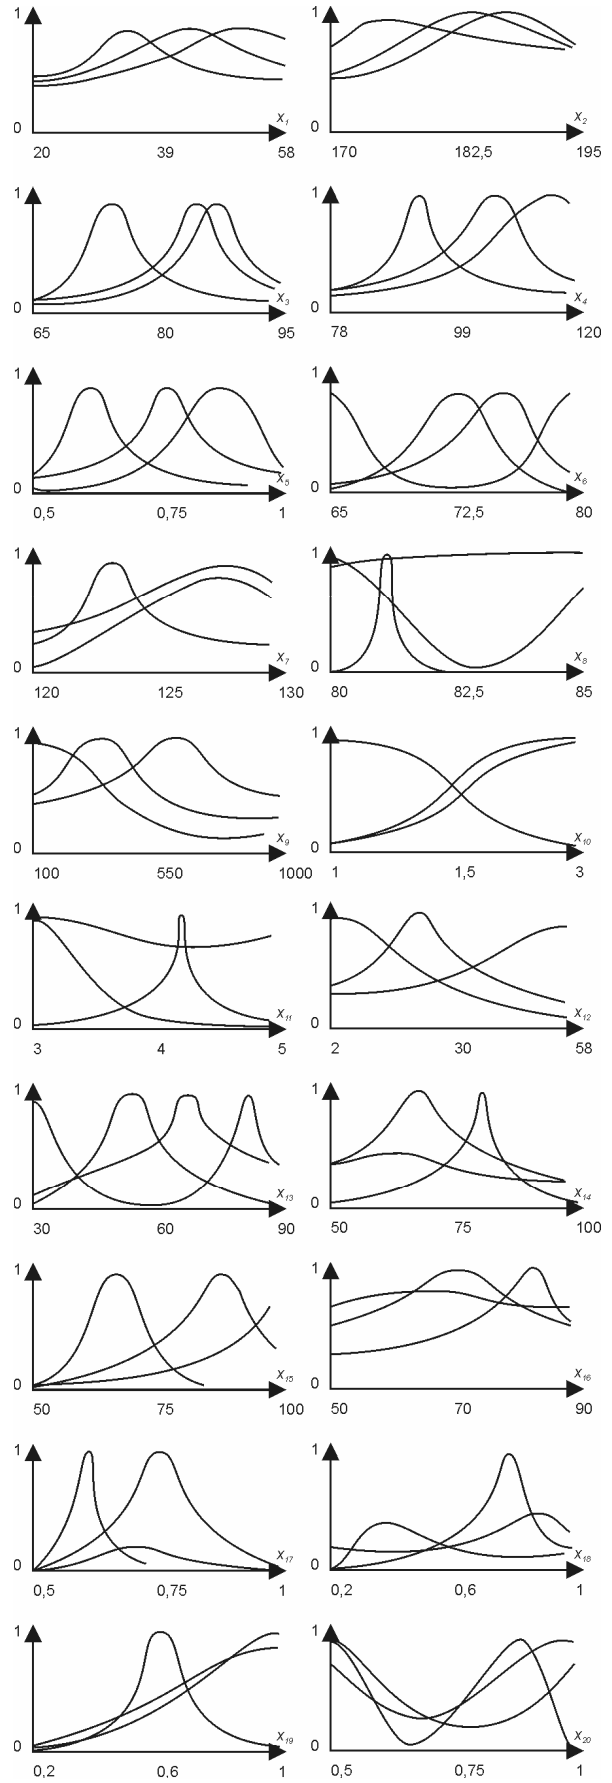


Рис. 4. Графики функций принадлежности после настройки

Таблица 3

Параметры  $b$  и  $c$  функций принадлежности синтезированной базы знаний после настройки (обучения)

	Н		мП		П		оП		аН	
	$b$	$c$	$b$	$c$	$b$	$c$	$b$	$c$	$b$	$c$
$x_1$	32,58	23,33	38,21	9,80	43,39	11,92	51,07	16,01	56,74	22,62
$x_2$	128,00	57,31	186,39	87,84	135,24	80,39	132,76	109,61	189,33	162,75
...	...	...	...	...	...	...	...	...	...	...
$x_{20}$	0,861	1,288	0,985	1,847	0,386	2,852	1,421	1,900	3,700	0,086

Таблица 4

Веса правил функций принадлежности синтезированной базы знаний до ( $w_b$ ) и после ( $w_{q'}$ ) обучения

	$y$		$z$		$c$		$g$	
	$w_b$	$w_{q'}$	$w_b$	$w_{q'}$	$w_b$	$w_{q'}$	$w_b$	$w_{q'}$
<b>Н</b>	1,00	0,500	1,00	0,500	1,00	0,744	1,00	0,934
<b>мН</b>	1,00	0,500	1,00	0,500	1,00	0,500	1,00	0,500
<b>П</b>	1,00	0,757	1,00	0,500	1,00	0,480	1,00	0,428
<b>оН</b>	1,00	0,524	1,00	0,771	1,00	0,664	1,00	0,663
<b>аН</b>	1,00	0,499	1,00	0,500	1,00	0,500	1,00	0,499



В 2-х случаях компьютерные решения и верифицированные находятся в соседних классах решений. В остальных случаях наблюдается полное совпадение верифицированной и компьютерной пригодности. Это свидетельствует о высоком, с точки зрения практического использования, качестве построения математической модели.

Таблица 5

Сравнение компьютерной и верифицированной пригодности

№	Параметры функционального состояния претендента				Пригодность	
	$x_1$	$x_2$	...	$x_{20}$	1	2
1	31	169	...	0,74	$g_1$	$g_1$
2	36	165	...	0,70	$g_1$	$g_1$
3	39	179	...	0,55	$g_2$	$g_2$
4	42	169	...	0,62	$g_2$	$g_2$
5	48	175	...	0,59	$g_3$	$g_3$
6	34	180	...	0,70	$g_3$	$g_3$
7	37	181	...	0,80	$g_4$	$g_4$
8	35	178	...	0,59	$g_4$	$g_4$
9	49	175	...	0,50	$g_5$	$g_4^*$
10	55	180	...	0,44	$g_5$	$g_5$
11	33	183	...	0,34	$g_1$	$g_1$
12	51	186	...	0,39	$g_1$	$g_1$
13	54	192	...	0,36	$g_1$	$g_1$
14	40	166	...	0,30	$g_1$	$g_1$
15	29	170	...	0,49	$g_2$	$g_4^{**}$
16	20	169	...	0,50	$g_2$	$g_2$
17	31	186	...	0,50	$g_2$	$g_2$
18	43	184	...	0,51	$g_2$	$g_3^*$
20	39	177	...	0,81	$g_3$	$g_3$
21	50	187	...	0,78	$g_3$	$g_3$
22	44	186	...	0,63	$g_3$	$g_3$
23	42	174	...	0,81	$g_3$	$g_3$
24	45	180	...	0,84	$g_3$	$g_3$

1 – верифицированная пригодность,  
2 – компьютерная пригодность

Проведенные компьютерные эксперименты подтверждают дееспособность синтезированной нечеткой базы знаний. После сравнения верифицированной профессиональной пригодности и компьютерной, наблюдается почти полное их совпадение. Это свидетельствует о высоком, с точки зрения практического использования, качестве построения модели СФП, в частности, модели профессиональной психофизиологической пригодности.

Синтезированная таким образом нечеткая база знаний дает возможность достоверно определять и перестраивать модель профессиональной пригодности, а также обновлять массивы экспериментальных данных. Результаты проведенных исследований дают основания принять разработанную методику за основу для синтеза аналогичных моделей.

## Литература

1. Соколов А.Ю. Применение методов искусственного интеллекта в управлении проектами. – Х.: Нац. аэрокосмический ун-т «ХАИ». – 2002. – 474 с.
2. Ротштейн А.П. Интеллектуальные технологии идентификации: нечёткие множества, генетические алгоритмы, нейронные сети. – Винница: «УНИВЕРСУМ – Винница», 1999. – 320 с.
3. Осовский С. Нейронные сети для обработки информации. – М.: Финансы и статистика, 2002. – 344 с.
4. Mamdani E.N. Rull-based Fuzzy Approach to the Control of Dinamic Processes // IEEE Trans, on Compu. – 1981. – № 12. – P. 432-440.
5. Кузнецова Н.В. Прогнозирование профессиональной психофизиологической пригодности на основе экспертно-лингвистических закономерностей, как одного из инструментов решения современных экологических проблем // Сучасні технології управління екологічною і інформаційною безпекою територій: Матеріали 4 міжнародної конференції. – Х., 2005. – № 4. – С. 34 -36.
6. Кузнецова Н.В. Использование генетического алгоритма и нейронной сети для настройки экспертной системы при проведении профессионального психофизиологического отбора // Екологія і ресурси. – К., 2007. – № 16. – С. 108-115.

Поступила в редакцию 17.09.2007

**Рецензент:** д-р техн. наук, проф. А.Ю. Соколов, Национальный аэрокосмический университет им. Н.Е. Жуковского «ХАИ», Харьков.