

УДК 004.93



СТРУКТУРНО-ПАРАМЕТРИЧЕСКАЯ ИДЕНТИФИКАЦИЯ НЕЙРО-НЕЧЕТКИХ МОДЕЛЕЙ ДЛЯ ДИАГНОСТИКИ

С.А. Субботин

Запорожский национальный технический университет, г. Запорожье, Украина, subbotin@zntu.edu.ua

Предложены методы построения, дообучения и упрощения нейро-нечетких диагностических моделей по прецедентам. Разработанные методы позволяют в неитеративном режиме устанавливать значения весовых коэффициентов нейро-нечетких сетей, не требуют вычисления производных, выбора начальной точки поиска, что позволяет ускорить процесс получения нейро-нечеткой модели по прецедентам.

ДИАГНОСТИКА, РАСПОЗНАВАНИЕ ОБРАЗОВ, НЕЧЕТКАЯ СИСТЕМА, ТЕРМ, НЕЙРО-НЕЧЕТКАЯ СЕТЬ, КЛАССИФИКАЦИЯ, ПРИЗНАК, МЕТОД ПОТЕНЦИАЛЬНЫХ ФУНКЦИЙ

Введение

Автоматизация процессов принятия решений является средством повышения эффективности процедур технической и биомедицинской диагностики, поскольку снижает негативное влияние человеческого фактора (усталость, невнимательность), повышает производительность труда, а также делает процесс принятия решений хорошо формализованным, понятным и предсказуемым.

Нейро-нечеткие сети [1–3] как инструмент автоматизации принятия решений в задачах технической и биомедицинской диагностики нашли широкое применение благодаря сочетанию таких свойств нейронных сетей, как способность к обучению и обобщению по примерам, со свойством логической прозрачности (интерпретируемости) нечетких моделей.

Вместе с тем при построении нейро-нечетких моделей на основе экспериментальных данных возникает необходимость выделения нечетких термов признаков, что, как правило, на практике возлагается на пользователя либо достигается в результате кластер-анализа [2, 3], а также требует последующей высокитеративной коррекции весов модели и параметров нечетких термов, расчета производных и выбора начальной точки поиска в пространстве управляемых параметров модели, что является весьма нетривиальной задачей.

Целью работы является создание методов автоматического построения нейро-нечетких моделей, не требующего участия пользователя при выделении нечетких термов, а также позволяющего осуществлять структурно-параметрическую идентификацию нейро-нечетких сетей в неитеративном режиме.

1. Постановка задачи синтеза нейро-нечеткой модели

Пусть задана обучающая выборка $\langle x, y \rangle$, где $x = \{x^s\}$; $y = \{y^s\}$; $x^s = \{x_j^s\}$; x_j^s – значение j -го признака s -го экземпляра выборки; y^s – значение выходного признака, сопоставленное s -му экземпляру обучающей выборки; $y^s \in \{k\}$, $k = 1, 2, \dots, K$; K – число классов.

Необходимо сформировать разбиение признакового пространства на кластеры, для каждого кластера выделить нечеткие термы по признакам, определить схему нечеткого вывода номера класса из значений функций принадлежности к нечетким термам, представить нечеткую систему в нейробазисе (выполнить структурно-параметрическую идентификацию нейро-нечеткой модели).

2. Формирование разбиения признакового пространства

Определение нечетких термов требует разбиения пространства признаков на прямоугольные блоки (кластеры), проекции которых на оси признаков позволяют выделить интервалы значений признаков для соответствующих областей, на основе комбинации которых можно будет определить принадлежность распознаваемого экземпляра к блокам, а на их основе – принадлежности к классам. Формирование разбиения предлагается осуществлять путем выполнения последовательности шагов 1–12.

Шаг 1. Инициализация. Задать обучающую выборку $\langle x, y \rangle$.

Шаг 2. Определить минимальные и максимальные значения для каждого признака на множестве экземпляров обучающей выборки $\min(x_j)$ и $\max(x_j)$, на основе которых определить длину интервала наблюдаемых значений каждого признака: $r_j = \max(x_j) - \min(x_j)$, $j = 1, 2, \dots, N$.

Шаг 3. Определить по координатным расстояниям между экземплярами обучающей выборки, на основе которых найти для каждого признака:

$$R_j = \min_{\substack{s=1, 2, \dots, S; \\ g=s+1, s+2, \dots, S}} |x_j^s - x_j^g| \text{ или}$$

$$R_j = \min_{\substack{s=1, 2, \dots, S; \\ g=s+1, s+2, \dots, S}} \left\{ |x_j^s - x_j^g| \mid y^s \neq y^g \right\} \text{ или}$$

$$R_j = \frac{2}{S(S-1)} \sum_{s=1}^S \sum_{g=s+1}^S |x_j^s - x_j^g|,$$

$$j = 1, 2, \dots, N.$$

Шаг 4. Определить количество интервалов разбиения диапазона значений j -го признака n_j , исходя из формулы:

$$n_j = \begin{cases} \text{round}\left(\frac{r_j}{R_j}\right), & \text{если } \text{round}\left(\frac{r_j}{R_j}\right) \leq S; \\ S, & \text{в противном случае.} \end{cases}$$

Шаг 5. Рассчитать координаты левой и правой границ для p -го интервала j -го признака по формулам:

$$l_{j,p} = \min(x_j) + (p-1) \frac{r_j}{n_j},$$

$$r_{j,p} = \min(x_j) + p \frac{r_j}{n_j},$$

$$j = 1, 2, \dots, N; p = 1, 2, \dots, n_j.$$

Шаг 6. Задать для p -го интервала значений j -го признака ($j = 1, 2, \dots, N; p = 1, 2, \dots, n_j$) номер класса:

$$K_{j,p} = \begin{cases} 0, & \text{если } \neg \exists x^s, s = 1, 2, \dots, S: l_{j,p} \leq x_j^s \leq r_{j,p}; \\ y^s, & \text{если } \forall y^s = y^g; s, g = 1, 2, \dots, S: l_{j,p} \leq x_j^s \leq r_{j,p} \\ & \text{и } l_{j,p} \leq x_j^g \leq r_{j,p}; \\ -1, & \text{если } \exists y^s: y^s \neq y^g; s, g = 1, 2, \dots, S: l_{j,p} \leq x_j^s \leq r_{j,p} \\ & \text{и } l_{j,p} \leq x_j^g \leq r_{j,p}. \end{cases}$$

Шаг 7. Сформировать прямоугольные блоки $\{B_q\}$, $q = 1, 2, \dots, Q$, $Q = \prod_{j=1}^N n_j$, в N -мерном пространстве признаков на пересечении соответствующих интервалов значений признаков. Занести в $B_{q,j}$ номер интервала j -го признака, который соответствует q -му блоку.

Шаг 8. Определить номера классов для прямоугольных блоков в N -мерном пространстве признаков:

$$K_q = \begin{cases} K_{j,p}, & \text{если } \forall K_{j,p} = K_{i,t}; p = B_{q,j}, t = B_{q,i}, \\ & i = 1, 2, \dots, N; j = i + 1, \dots, N; \\ -1, & \text{в противном случае.} \end{cases}$$

Установить коэффициент уверенности классификации для блоков:

$$\alpha_q = \begin{cases} 1, & \text{если } K_q > 0; \\ 0, & \text{если } K_q \leq 0. \end{cases}$$

Шаг 9. Пока $\exists q: K_q = -1$, для тех блоков, у которых $K_q = -1$, выполнять процедуру разрешения конфликтов классов на основе одного из следующих способов.

Способ 1. Установить номер класса в соответствии с формулой:

$$K_q = \arg \max_{k=1,2,\dots,K} S_q^k,$$

где S_q^k — количество экземпляров k -го класса, попавших в q -ый блок.

Установить коэффициент уверенности:

$$\alpha_q = \frac{S_q^{K_q}}{\sum_{d=1}^K S_q^d}.$$

Достоинствами данного способа являются простота и высокая скорость вычислений, а недостатком — увеличение ошибки распознавания вследствие подавления одним классом других классов в блоке (огрубление аппроксимации границ классов).

Способ 2. Для исходного блока установить $K_q = 0$. Используя метод [1, 4, 5], разбить для q -го блока соответствующие ему интервалы значений признаков на интервалы с монотонным номером класса. Увеличить для каждого признака n_j : $n_j = n_j + n_j^*$, где n_j^* — количество интервалов с монотонным номером класса по j -му признаку внутри исходного блока. Занести в $l_{j,p}$ и $r_{j,p}$ границы новых интервалов, а в $K_{j,p}$ — номера классов, $j = 1, 2, \dots, N; p = n_j - n_j^*, \dots, n_j$. Образовать внутри исходного блока новые блоки B_q , а также соответствующим образом (как на шаге 8) определить для новых блоков номера классов K_q , и установить $\alpha_q = 1$, $q = Q+1, \dots, Q + \prod_{j=1}^N n_j^*$.

Занести в $B_{q,j}$ номер интервала j -го признака, который соответствует соответствующему q -му блоку. Установить: $Q = Q + \prod_{j=1}^N n_j^*$.

Достоинством данного способа является более высокая точность аппроксимации границ классов внутри исходного блока по сравнению с предыдущим способом, а недостатками — более низкая скорость и итеративный характер вычислений.

Способ 3. Для исходного блока установить $K_q = 0$. Рекурсивно выполнять шаги 2–9 для подмножества обучающей выборки, соответствующего разбиваемому блоку, корректируя соответствующие параметры n_j , $l_{j,p}$, $r_{j,p}$, $K_{j,p}$, B_q , K_q , $B_{q,j}$, α_q и Q .

Достоинством данного способа является очень высокая точность аппроксимации границ классов внутри исходного блока, а недостатками — существенно более низкая скорость, а также высокоитеративный и рекурсивный характер вычислений.

Шаг 10. Для тех блоков, у которых номер класса $K_q = 0$, определить расчетный номер класса, для чего предлагается использовать модифицированный нерекуррентный метод потенциальных функций [6, 7].

Шаг 10.1 Вычислить расстояние между q -ым и p -ым блоками, $q = 1, 2, \dots, Q$, $p = q+1, \dots, Q$, как:

$$R(B_q, B_p) = \sqrt{\sum_{j=1}^N r_j^{-1} (C_{q,j} - C_{p,j})^2} \quad \text{или}$$

$$R(B_q, B_p) = \sqrt{\sum_{j=1}^N r_j^{-1} |C_{q,j} - C_{p,j}|},$$

где $C_{q,j} = \frac{l_{j,B_{q,j}} + r_{j,B_{q,j}}}{2}$. Заметим, что $R(B_q, B_p) = R(B_p, B_q)$.

Шаг 10.2 Определить потенциал, наводимый совокупностью блоков, принадлежащих к k -му классу, на p -ый блок с неизвестной классификацией:

$$\Phi_p^k = \frac{1}{L_k} \sum_{q=1}^Q \left\{ S_q e^{-R^2(B_q, B_p)} \mid K_q = k, K_p = 0, q \neq p \right\},$$

где L_k – количество блоков, принадлежащих к k -му классу, S_q – количество экземпляров обучающей выборки, попавших в q -ый блок.

Шаг 10.3 Установить номер класса для p -го блока с неизвестной классификацией ($K_p = 0$) по формуле:

$$K_p = \arg \max_{k=1, 2, \dots, K} \Phi_p^k.$$

Шаг 10.4. Модифицировать значения коэффициентов уверенности для блоков:

$$\alpha_q = \{\Phi_q^{K_q} \mid \alpha_q = 0\}.$$

Шаг 11. Выполнить объединение смежных блоков, принадлежащих к одному и тому же классу: для $\forall q, p=1, 2, \dots, Q, q \neq p$: если $K_q > 0, K_q = K_p$ и $\exists j: |B_{q,j} - B_{p,j}| = 1, \forall i \neq j: B_{q,i} = B_{p,i}, i=1, 2, \dots, N, j=1, 2, \dots, N$; тогда объединить блоки q и p по j -му признаку:

– установить:

$$\alpha_q = \frac{\alpha_q \prod_{j=1}^N (r_{j, B_{q,j}} - l_{j, B_{q,j}}) + \alpha_p \prod_{j=1}^N (r_{j, B_{p,j}} - l_{j, B_{p,j}})}{\prod_{j=1}^N (r_{j, B_{q,j}} - l_{j, B_{q,j}}) + \prod_{j=1}^N (r_{j, B_{p,j}} - l_{j, B_{p,j}})},$$

$$n_j = n_j + 1,$$

$$l_{j, n_j} = l_{j, \min(B_{q,j}, B_{p,j})}, r_{j, n_j} = r_{j, \max(B_{q,j}, B_{p,j})}, B_{q,j} = n_j;$$

– удалить p -ый блок: $K_p = 0, \alpha_p = 0, B_{p,i} = 0, i=1, 2, \dots, N$.

Шаг 12. Останов.

3. Система нечеткого вывода

Для расчета принадлежностей распознаваемого экземпляра x^s к нечетким термам признаков целесообразно использовать трапецевидные функции принадлежности:

$$\mu_{j,p}(x^s) = \begin{cases} 0, x^s < l_{j,p}; \\ \frac{x^s - l_{j,p}}{l_{j,p}(2-\delta) - l_{j,p}}, l_{j,p} \leq x^s < l_{j,p}(2-\delta); \\ 1, l_{j,p}(2-\delta) \leq x^s \leq \delta r_{j,p}; \\ \frac{r_{j,p} - x^s}{r_{j,p} - \delta r_{j,p}}, \delta r_{j,p} < x^s \leq r_{j,p}; \\ 0, r_{j,p} < x^s, \end{cases}$$

где δ – некоторая константа, $0 < \delta \leq 1$.

Определив принадлежности экземпляра к термам признаков, необходимо определить его принадлежности к прямоугольным блокам:

$$\mu_q(x^s) = \min_{j=1, 2, \dots, N} \left\{ \min_{p=1, 2, \dots, n_j} \{ \mu_{j,p}(x^s) \mid B_{q,j} = p \} \right\},$$

$$q = 1, 2, \dots, Q;$$

после чего определить принадлежности к классам:

$$\mu_k(x^s) = \max_{q=1, 2, \dots, Q} \{ \alpha_q \mu_q(x^s) \mid K_q = k \},$$

$$k = 1, 2, \dots, K.$$

Четкий номер класса определим как

$$y = \arg \max_{k=1, 2, \dots, K} \{ \mu_k(x^s) \},$$

а уверенность в результате классификации

$$\mu_y = \max_{k=1, 2, \dots, K} \{ \mu_k(x^s) \}.$$

4. Синтез нейро-нечеткой сети

Рассмотренная система нечеткого вывода может быть представлена в нейробазисе в виде нейро-нечеткой сети, схема которой изображена на рисунке.




Схема нейро-нечеткой сети

На входы сети подаются значения признаков распознаваемого экземпляра. Нейроны первого слоя вычисляют принадлежности распознаваемого экземпляра к термам признаков $\mu_{j,p}(x^s)$ (фаззификация), нейроны второго слоя определяют принадлежности к блокам-кластерам $\mu_q(x^s)$, нейроны третьего слоя объединяют принадлежности к блокам в принадлежности к классам $\mu_k(x^s)$, после чего первый нейрон четвертого слоя осуществляет дефаззификацию результата, а второй нейрон четвертого слоя определяет достоверность классификации.

Функции постсинаптического потенциала нейронов сети будут задаваться формулами:

$$\phi_j^{(2,i)}(w_j^{(2,i)}, x_j^{(2,i)}) = \max\{w_j^{(2,i)}, x_j^{(2,i)}\},$$

$$i = 1, 2, \dots, Q; j = 1, 2, \dots, z;$$

$$\phi_j^{(3,i)}(w_j^{(3,i)}, x_j^{(3,i)}) = \min\{w_j^{(3,i)}, x_j^{(3,i)}\},$$

$$i = 1, 2, \dots, K; j = 1, 2, \dots, Q;$$

$$\phi_j^{(4,i)}(w_j^{(4,i)}, x_j^{(4,i)}) = \min\{w_j^{(4,i)}, x_j^{(4,i)}\},$$

$$i = 1, 2; j = 1, 2, \dots, K,$$

где $z = \sum_{j=1}^N n_j$; $x_j^{(n,i)}$ – значение сигнала на j -ом входе i -го нейрона n -го слоя сети; $w_j^{(n,i)}$ – вес j -го входа

i -го нейрона η -го слоя сети; $\varphi_j^{(\eta,i)}$ – функция постсинаптического потенциала j -го входа i -го нейрона η -го слоя сети.

Функции активации нейронов будут определяться по формулам:

$$\psi^{(2,i)}\left(\varphi_j^{(2,i)}(w_j^{(2,i)}, x_j^{(2,i)})\right) = \min\{\varphi_j^{(2,i)}(w_j^{(2,i)}, x_j^{(2,i)})\},$$

$$i = 1, 2, \dots, Q; j = 1, 2, \dots, z;$$

$$\psi^{(3,i)}\left(\varphi_j^{(3,i)}(w_j^{(3,i)}, x_j^{(3,i)})\right) = \max\{\varphi_j^{(3,i)}(w_j^{(3,i)}, x_j^{(3,i)})\},$$

$$i = 1, 2, \dots, K; j = 1, 2, \dots, Q;$$

$$\psi^{(4,1)}\left(\varphi_j^{(4,1)}(w_j^{(4,1)}, x_j^{(4,1)})\right) = \arg \max\{\varphi_j^{(3,i)}(w_j^{(3,i)}, x_j^{(3,i)})\};$$

$$\psi^{(4,2)}\left(\varphi_j^{(4,2)}(w_j^{(4,2)}, x_j^{(4,2)})\right) = \max\{\varphi_j^{(4,2)}(w_j^{(4,2)}, x_j^{(4,2)})\},$$

где $\psi^{(\eta,i)}$ – функция активации i -го нейрона η -го слоя сети.

Весовые коэффициенты нейроэлементов сети будут устанавливаться по формуле:

$$w_j^{(\eta,i)} = \begin{cases} 1, \eta = 2, B_{i,p} \neq j, i = 1, 2, \dots, Q, \\ p = 1, 2, \dots, N, j = 1, 2, \dots, z; \\ 0, \eta = 2, B_{i,p} = j, i = 1, 2, \dots, Q, \\ p = 1, 2, \dots, N, j = 1, 2, \dots, z; \\ \alpha_j, \eta = 3, i = K_j, i = 1, 2, \dots, K, j = 1, 2, \dots, Q; \\ 0, \eta = 3, i \neq K_j, i = 1, 2, \dots, K, j = 1, 2, \dots, Q; \\ 1, \eta = 4, i = 1, 2, j = 1, 2, \dots, K. \end{cases}$$

Как видно из приведенных формул, синтез и настройка параметров нейро-нечеткой сети осуществляются в неитеративном режиме, что позволяет избежать необходимости расчета производных целевой функции по весам сети, а также итеративного характера коррекции весов, присущего традиционно применяемым градиентным методам обучения на основе техники обратного распространения ошибки.

5. Дообучение нейро-нечеткой сети

Ранее синтезированная нейро-нечеткая сеть может быть дообучена на основе следующего метода.

Шаг 1. Задать дополнительную выборку $\langle x^*, y^* \rangle$, $x^* = \{x^{g*}\}$, $g = 1, 2, \dots, G$ для дообучения, а также нейро-нечеткую сеть с настроенными параметрами функций принадлежности и весами. Сохранить в Q^* текущее значение Q , а в z^* значение z .

Шаг 2. Произвести распознавание экземпляров дополнительной выборки. Исключить из дополнительной выборки те экземпляры для которых расчетное значение выходного признака будет совпадать с целевым, скорректировать соответствующим образом G .

Шаг 3. Последовательно для каждого экземпляра дополнительной выборки x^{g*} , $g = 1, 2, \dots, G$ выполнять шаги 3.1 – 3.3.

Шаг 3.1 Сформировать термы по признакам и добавить в сеть соответствующие им нейроны на первый слой, а также задать соответствующие функции принадлежности к термам, для чего предлагается использовать модифицированные функции Гаусса:

$$\mu_{j,p}(x^s) = 2e^{-0.5(x_j^s - x_j^{s*})^2},$$

$$l_{Q,j} = x^{g*}, r_{Q,j} = x^{g*},$$

$$j = 1, 2, \dots, N, p = n_j + 1.$$

Шаг 3.2 Установить: $\forall j = 1, 2, \dots, N: n_j = n_j + 1$, $B_{Q,j} = z + j$; $Q = Q + 1$, $K_j = y^{g*}$, $z = z + N$.

Шаг 3.3 Добавить на второй слой сети нейрон, соответствующий блоку-кластеру для текущего экземпляра дополнительной выборки.

Шаг 4. Установить для новых нейронов второго слоя функции постсинаптического потенциала:

$$\varphi_j^{(2,i)}\left(w_j^{(2,i)}, x_j^{(2,i)}\right) = \max\{w_j^{(2,i)}, x_j^{(2,i)}\},$$

$$i = Q^* + 1, \dots, Q; j = 1, 2, \dots, z,$$

а также функции активации:

$$\psi^{(2,i)}\left(\varphi_j^{(2,i)}(w_j^{(2,i)}, x_j^{(2,i)})\right) = \min\{\varphi_j^{(2,i)}(w_j^{(2,i)}, x_j^{(2,i)})\},$$

$$i = Q^* + 1, \dots, Q; j = 1, 2, \dots, z.$$

Установить веса новых нейронов второго слоя по формуле:

$$w_j^{(\eta,i)} = \begin{cases} 1, \eta = 2, i = 1, 2, \dots, Q^*, j = z^* + 1, \dots, z; \\ 1, \eta = 2, i = Q^* + 1, \dots, Q, j = 1, 2, \dots, z^*; \\ 0, \eta = 2, B_{i,p} = j, i = Q^* + 1, \dots, Q, \\ p = 1, 2, \dots, N, j = z^* + 1, \dots, z; \\ 1, \eta = 2, B_{i,p} \neq j, i = Q^* + 1, \dots, Q, \\ p = 1, 2, \dots, N, j = z^* + 1, \dots, z. \end{cases}$$

Шаг 4. Для всех вновь введенных блоков-кластеров добавить на третий слой один нейрон для нормирования их принадлежностей к классам, для которого функцию постсинаптического потенциала определим, как:

$$\varphi_j^{(3,K+1)}\left(w_j^{(3,K+1)}, x_j^{(3,K+1)}\right) = \min\{w_j^{(3,K+1)}, x_j^{(3,K+1)}\},$$

$$j = 1, 2, \dots, Q,$$

а функцию активации – как:

$$\psi^{(3,K+1)}\left(\varphi_j^{(3,K+1)}(w_j^{(3,K+1)}, x_j^{(3,K+1)})\right) =$$

$$= -\frac{1}{2} \max\{\varphi_j^{(3,K+1)}(w_j^{(3,K+1)}, x_j^{(3,K+1)})\},$$

$$j = 1, 2, \dots, Q.$$

Для нейронов третьего и четвертого слоев установить значения весов новых связей:

$$w_j^{(\eta,i)} = \begin{cases} 1, \eta = 3, i = K_j, i = 1, 2, \dots, K, j = Q^* + 1, \dots, Q; \\ 0, \eta = 3, i \neq K_j, i = 1, 2, \dots, K, j = Q^* + 1, \dots, Q; \\ 0, \eta = 3, i = K + 1, j = 1, 2, \dots, Q^*; \\ 1, \eta = 3, i = K + 1, j = Q^* + 1, \dots, Q; \\ 0, \eta = 4, i = 1, j = K + 1; \\ 1, \eta = 4, i = 2, j = K + 1. \end{cases}$$

Шаг 5. Останов.

Предложенный метод дообучения не требует итеративной коррекции весов, не предполагает использования и хранения исходной обучающей выборки, не требует расчета производных целевой функции ошибки.

6. Упрощение нейро-нечеткой сети

Нейро-нечеткая сеть, синтезированная на основе предложенных методов, может быть упрощена за счет исключения проверок принадлежности к некоторым интервалам признаков при принятии решения об отнесении распознаваемого экземпляра к кластерам. Это достигается путем изменения весов:

$$w_j^{(\eta,i)} = \begin{cases} 1, \eta = 2, B_{i,p} \neq A_{i,p}, A_{i,p} \neq 0, i = 1, 2, \dots, Q^*, \\ p = 1, 2, \dots, N, j = 1, 2, \dots, z; \\ 0, \eta = 2, B_{i,p} = A_{i,p}, A_{i,p} \neq 0, i = 1, 2, \dots, Q^*, \\ p = 1, 2, \dots, N, j = 1, 2, \dots, z. \end{cases}$$

где

$$A_{q,j} = \begin{cases} p, B_{q,j} = p, \neg \exists v = 1, 2, \dots, Q^*, v \neq q: B_{v,j} = p; \\ \neg \exists u = 1, 2, \dots, Q^*, u \neq q: \\ (l_{u,j} < l_{q,j} \wedge r_{q,j} < r_{u,j}) \vee (r_{u,j} > l_{q,j} \wedge \\ \wedge (r_{u,j} < r_{q,j} \vee l_{u,j} < r_{q,j})); \\ \neg \exists A = Q^* + 1, \dots, Q, A \neq q: \\ l_{q,j} < l_{c,j}, r_{q,j} > r_{c,j}; \\ 0, \text{ в противном случае.} \end{cases}$$

Выводы

В работе решена актуальная задача разработки математического обеспечения для построения диагностических нейро-нечетких моделей по прецедентам.

Впервые предложен метод структурно-параметрической идентификации нейро-нечетких моделей, позволяющий в неитеративном режиме определить значения весовых коэффициентов, функции постсинаптического потенциала и активационные функции нейро-нечеткой сети на основе предварительно сформированного разбиения признакового пространства, что позволяет исключить необходимость вычисления производных целевой функции по весам сети и избежать проблемы выбора начальной точки поиска, что, в свою очередь, позволяет ускорить процесс получения нейро-нечеткой модели по прецедентам.

Получил дальнейшее развитие не рекуррентный метод потенциальных функций, который модифицирован для расчета потенциала, наводимого блоками с известной классификацией на блок-кластер с неизвестной классификацией, что позволило существенно расширить аппроксимационные и обобщающие свойства разбиения признакового пространства.

Работа выполнена в рамках госбюджетной темы “Научно-методические основы и математическое обеспечение для автоматизации и моделирования процессов управления и поддержки принятия решений на основе процедур распознавания и эволюционной оптимизации в нейросетевом и нечеткологическом базисах” (номер гос. регистрации 0106U008621).

Список литературы: 1. Суботин, С. О. Подання й обробка знань у системах штучного інтелекту та підтримки прийняття рішень [текст] : Навчальний посібник / С.О. Суботин. — Запоріжжя: ЗНТУ, 2008. — 341 с. 2. Леоненков, А.В. Нечеткое моделирование в среде MATLAB и fuzzyTECH [текст] / А. В. Леоненков. — СПб.: БХВ-Петербург, 2003. — 736 с. 3. Борисов, В.В. Нечеткие модели и сети [текст] / В. В. Борисов, В. В. Круглов, А. С. Федулов. — М.: Горячая линия-Телеком, 2007. — 284 с. 4. Субботин, С. А. Метод синтеза классифицирующих нейро-нечетких сетей с учетом значимости термов признаков [текст] / С. А. Субботин // Информационные технологии. — 2008. — № 7. — С. 31–33. 5. Субботин, С. А. Неитеративный синтез и редукция нейро-нечетких моделей [текст] / С. А. Субботин // Искусственный интеллект. — 2006. — № 3. — С. 323–330. 6. Айзерман, М. А. Метод потенциальных функций в теории обучения машин [текст] / М. А. Айзерман, Э. М. Браверман, Л. И. Розоноэр. — М.: Наука, 1970. — 384 с. 7. Фор, А. Восприятие и распознавание образов [текст] / Пер. с фр. А. В. Серединского / под ред. Г. П. Катуса. — М.: Машиностроение, 1989. — 272 с.

Поступила в редколлегию 30.10.2009

УДК 004.93

Структурно-параметрична ідентифікація нейро-нечітких моделей для діагностики / С.О. Суботін // Біоніка інтелекту: наук.-техн. журнал. — 2009. — № 2 (71). — С. 118-122.

Розроблено методи синтезу структури, донавчання та спрощення нейро-нечітких діагностичних моделей за прецедентами, що дозволяють у неітеративному режимі встановлювати значення ваг нейро-нечітких мереж, не потребують обчислення похідних і вибору початкової точки пошуку, що дозволяє прискорити процес одержання нейро-нечіткої моделі за прецедентами.

Лл. 1. Бібліогр.: 7 найм.

UDC 004.93

The neuro-fuzzy model structural-parametrical identification for diagnostics / Subbotin S.A. // Bionics of Intelligence: Sci. Mag. — 2009. — № 2 (71). — P. 118-122.

The methods of synthesis of a structure, retraining and simplification of neuro-fuzzy diagnostic model on precedents are developed. They permitting in a uniterated mode to evaluate a weights values of neuro-fuzzy networks, do not require an evaluation of derivatives and choice of a starting point of searching. This allows to speed up the neuro-fuzzy model building on precedents.

Fig.1. Ref.: 7 items.