

УДК 004.93

С.А. Субботин

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

Методы синтеза нейросетевых и нейро-нечетких распознающих моделей с линеаризацией и факторной группировкой признаков

Предложены новые методы синтеза логически прозрачных нейронных и нейро-нечетких классифицирующих моделей в неитеративном режиме. Разработанные методы позволяют решать задачи автоматизации процессов принятия решений в технической и биомедицинской диагностике, распознавании образов.

Введение

Искусственные нейронные и нейро-нечеткие сети находят широкое применение в задачах распознавания образов, технической и биомедицинской диагностики, экономического моделирования, поскольку позволяют автоматизировать процесс принятия решений и способны к обучению по точечным данным.

Несмотря на значительное количество моделей нейронных и нейро-нечетких сетей, известных в настоящее время [1-5], их использование на практике, особенно в задачах диагностики, осложняется недостаточно высоким уровнем логической прозрачности (трудностью для анализа и восприятия человеком) нейросетей, а также длительностью процесса итеративной оптимизационной настройки весов.

Поэтому актуальной является разработка моделей нейронных и нейро-нечетких сетей, обладающих высоким уровнем логической прозрачности, а также неитеративных методов их синтеза.

Ранее были предложены модели и методы синтеза логически прозрачных нейронных и нейро-нечетких сетей с настройкой весов в неитеративном режиме [5-11], которые основывались на использовании разбиения диапазона значений признаков на интервалы с монотонным номером класса для настройки параметров функций принадлежности нечетких термов (для случая нейро-нечетких сетей) и весовых коэффициентов нейронов, а также топологии сети. При этом не учитывались взаимосвязи признаков.

Цель данной работы – создание методов, позволяющих синтезировать нейронные и нейро-нечеткие модели в неитеративном режиме с линеаризацией, факторной группировкой и сверткой признаков.

Постановка задачи синтеза нейронных и нейро-нечетких моделей

Пусть мы имеем обучающую выборку $\langle x, y \rangle$, состоящую из множества экземпляров $\{x^s\} = \{x_j^s\}$, $s = 1, 2, \dots, S$, $j = 1, 2, \dots, N$, где S – количество экземпляров в выборке, N – количество признаков, характеризующих экземпляры, x_j^s – значение

j -го признака, характеризующего s -й экземпляр выборки x^s , и набора значений целевого (выходного) признака $y = \{y^s\}$, сопоставленных каждому экземпляру выборки, где y^s – значение целевого признака для экземпляра x^s .

Тогда задача синтеза модели зависимости $y(x)$ по выборке $\langle x, y \rangle$ на основе нейронной (нейро-нечеткой) сети заключается в определении количества нейроэлементов в сети, задании их дискриминантных (постсинаптических, весовых) и активационных функций, определении топологии сети и расчете весовых коэффициентов межнейронных связей.

Анализ информации о признаках и топологии обучающей выборки

Для синтеза логически прозрачных нейромоделей в неитеративном режиме целесообразно проводить анализ информации о признаках и топологии обучающей выборки, для чего предлагается выполнять следующую последовательность шагов.

Шаг 1. Задать обучающую выборку $\langle x, y \rangle$. Задать пороговое значение $\tau_{\text{порог}}$, $0 < \tau_{\text{порог}} < 1$. Рассчитать логарифмы значений признаков для всех экземпляров и расширить набор признаков x : $x_{j+i}^s = \ln(x_j^s)$, $j = 1, 2, \dots, N$, $i = 1, 2, \dots, N$, $s = 1, 2, \dots, S$.

Шаг 2. Найти минимальные $\min(x_i)$ и максимальные $\max(x_i)$ значения признаков. Пронормировать значения признаков для $i = 1, 2, \dots, 2N$, $s = 1, 2, \dots, S$:

$$x_i^s = \frac{x_i^s - \min(x_i)}{\max(x_i) - \min(x_i)}.$$

Шаг 3. Найти коэффициенты, характеризующие тесноту связи признаков и их логарифмов, r_{ij} , $i, j = 1, 2, \dots, 2N$. Например, коэффициенты парной корреляции:

$$r_{ij} = \frac{\sum_{s=1}^S (x_i^s - \bar{x}_i)(x_j^s - \bar{x}_j)}{\sqrt{\sum_{s=1}^S (x_i^s - \bar{x}_i)^2 \sum_{s=1}^S (x_j^s - \bar{x}_j)^2}}, \quad \bar{x}_i = \frac{1}{S} \sum_{s=1}^S x_i^s.$$

Шаг 4. Сгруппировать признаки.

Шаг 4.1. Установить количество групп признаков: $G = 0$.

Шаг 4.2. Найти в матрице $r = \{r_{ij}\}$ элемент с максимальным по модулю значением: $r_{\max} = \max(|r_{ij}|)$, $i = 1, 2, \dots, 2N$, $j = i + 1, \dots, 2N$. Определить знак r_{ij} .

Шаг 4.3. Если $r_{\max} \leq \tau_{\text{порог}}$, то перейти на шаг 4.5.

Шаг 4.4. Если $r_{\max} > \tau_{\text{порог}}$, то выполнить шаги 4.4.1 – 4.4.4.

Шаг 4.4.1. Установить: $G = G + 1$, $h(G, i) = 1$, $h(G, j) = 1$.

Шаг 4.4.2. Для всех $k = 1, 2, \dots, 2N$, $k \neq i$, $k \neq i+N$, $k \neq i-N$, $k \neq j$, $k \neq j+N$, $k \neq j-N$: если $|r_{ik}| > \tau_{\text{порог}}$ и $|r_{jk}| > \tau_{\text{порог}}$, то установить: $h(G, k) = 1$, $r_{kp} = 0$, $r_{pk} = 0$, $p = 1, 2, \dots, 2N$.

Шаг 4.4.3. Установить: $r_{ip} = 0$, $r_{pi} = 0$, $r_{jp} = 0$, $r_{pj} = 0$, $p = 1, 2, \dots, 2N$.

Шаг 4.4.4. Перейти на шаг 4.2.

Шаг 4.5. Если $\exists p, r_{pj} \neq 0, r_{jp} \neq 0, p = 1, 2, \dots, 2N, j = 1, 2, \dots, N, j \neq p$, тогда принять: $G = G + 1, h(G,j) = 1, r_{jk} = 0, r_{kj} = 0, k = 1, 2, \dots, 2N$, перейти на шаг 4.5, в противном случае – перейти на шаг 4.6.

Шаг 4.6. Установить $h(g, i) = 0$, для всех $g = 1, 2, \dots, G, i = 1, 2, \dots, 2N$, для которых значение $h(g, i)$ не было установлено.

Шаг 4.7. Для $\forall j, j = 1, 2, \dots, N$, установить:

$$g_i = \begin{cases} 0, i = j, \exists g : h(g, j) = 1, j \leq N; \\ 1, i = j - N, \exists g : h(g, j) = 1, j > N. \end{cases}$$

Шаг 4.8. Для $j = N + 1, \dots, 2N, g = 1, 2, \dots, G$, установить: $h(g, j - N) = 1, h(g, j) = 0$.

Шаг 5. Найти коэффициенты I_j , характеризующие тесноту связи признаков и номера класса, такие, что $0 \leq I_j \leq 1$, и с увеличением значения I_j возрастает значимость признака для определения класса. Для этого можно использовать методы, рассмотренные в [5].

Шаг 6. Выполнить кластер-анализ обучающей выборки: разбить ее на кластеры $C^q, q = 1, 2, \dots, Q$, где Q – количество кластеров, определить координаты центров кластеров $C^q_j, j = 1, 2, \dots, N, q = 1, 2, \dots, Q$. Кластер-анализ можно выполнить, используя методы [2, 12]. Определить четкую принадлежность кластеров к каждому из K классов.

Шаг 7. Разбить ось значений каждого признака на Q интервалов (термов) и определить их параметры для синтеза нейронных и нейро-нечетких сетей.

Шаг 7.1. Установить номер текущего признака: $i = 1$.

Шаг 7.2. Если $i > N$, тогда перейти на шаг 7.6, в противном случае – перейти на шаг 7.3.

Шаг 7.3. Установить номер текущего интервала значений текущего признака $q = 1$.

Шаг 7.4. Если $q > Q$, тогда перейти на шаг 7.5, в противном случае – установить для текущего q :

$$v = \arg \min_{s=1,2,\dots,S} \{x_i^s | q^s = q\}, u = \arg \max_{s=1,2,\dots,S} \{x_i^s | q^s = q\},$$

$$K(i,q) = y^v, Q(i,q) = q^v, a(i,q) = x_i^v, b(i,q) = x_i^u, c(i,q) = C_i^q.$$

Принять: $q = q + 1$. Перейти на шаг 7.4.

Шаг 7.5. Принять: $i = i + 1$. Перейти на шаг 7.2.

Шаг 7.6. На основе параметров $K(i,q)$ и $Q(i,q)$ определить $K(j)$ и $Q(j)$ – номера класса и кластера для j -го терма, $j = 1, 2, \dots, NQ$:

$$K(j) = K(1 + ((j - 1) \text{ div } Q), ((j + 1) \text{ mod } Q) - 1), Q(j) = Q(1 + ((j - 1) \text{ div } Q), ((j + 1) \text{ mod } Q) - 1).$$

Шаг 8. Задать функции принадлежности распознаваемого экземпляра к нечетким термам. Для этого предлагается использовать трапециевидные функции:

$$m_{i,q}(x_i) = \begin{cases} 0, x_i \leq 0,5(a(i, q) + b(i, q - 1)), \\ \frac{x_i - 0,5(a(i, q) + b(i, q - 1))}{0,5(a(i, q) - b(i, q - 1))}, 0,5(a(i, q) + b(i, q - 1)) \leq x_i < a(i, q), \\ 1, a(i, q) \leq x_i \leq b(i, q), \\ \frac{0,5(a(i, q + 1) + b(i, q)) - x_i}{0,5(a(i, q + 1) - b(i, q))}, b(i, q) \leq x_i < 0,5(b(i, q) + a(i, q + 1)), \\ 0, 0,5(b(i, q) + a(i, q + 1)) \leq x_i, \end{cases}$$

либо П-образные функции: $m_{i,q}(x_i) = m_{i,q_S}(x_i)m_{i,q_Z}(x_i)$, где $m_{i,q}(x_i)$ – функция принадлежности распознаваемого экземпляра по признаку x_i к q -му терму i -го признака, $m_{i,q_S}(x_i)$ – S-образная функция, а $m_{i,q_Z}(x_i)$ – Z-образная функция:

$$m_{i,q_S}(x_i) = \begin{cases} 0, & x_i < 0,5(a(i,q) + b(i,q-1)), \\ \frac{1}{2} + \frac{1}{2} \cos\left(\frac{x_i - a(i,q)}{0,5(a(i,q) - b(i,q-1))} p\right), & 0,5(a(i,q) + b(i,q-1)) \leq x_i \leq a(i,q), \\ 1, & x_i > a(i,q); \end{cases}$$

$$m_{i,q_Z}(x_i) = \begin{cases} 1, & x_i < b(i,q), \\ \frac{1}{2} + \frac{1}{2} \cos\left(\frac{x_i - b(i,q)}{0,5(a(i,q+1) - b(i,q))} p\right), & b(i,q) \leq x_i \leq 0,5(b(i,q) + a(i,q+1)), \\ 0, & x_i > 0,5(b(i,q) + a(i,q+1)), \end{cases}$$

либо треугольные функции:

$$m_{i,q}(x_i) = \begin{cases} 0, & x_i < a(i,q), \\ 0, & x_i > b(i,q), \\ \frac{x_i - a(i,q)}{c(i,q) - a(i,q)}, & a(i,q) \leq x_i \leq c(i,q), \\ \frac{x_i - b(i,q)}{c(i,q) - b(i,q)}, & c(i,q) < x_i \leq b(i,q), \end{cases}$$

либо функции Гаусса: $m_{i,q}(x_i) = \exp(-(x_i - c(i,q))^2)$.

Синтез нейронной сети

На основе результатов проведенного анализа информации о признаках по обучающей выборке может быть синтезирована нейронная сеть прямого распространения (рис. 1).




Рисунок 1 – Схема нейронной сети

Нейроны первого слоя сети осуществляют нормирование входных сигналов, отображая их в диапазон [0, 1], а также выполняют, где это необходимо, логарифмирование нормированного сигнала.

Нейроны второго слоя группируют преобразованные нейронами первого слоя сигналы и находят взвешенную сумму сигналов группы с учетом оценок их индивидуального влияния на выходной признак (номер класса).

Нейроны третьего слоя сети определяют расстояния от распознаваемого экземпляра до центров кластеров в пространстве сгруппированных сигналов и находят значение функции Гаусса, аргументом которой является определенное расстояние.

Нейроны четвертого слоя соответствуют классам и выдают на выходе значение «1», если распознаваемый экземпляр относится к соответствующему классу, и «0» – в противном случае.

Дискриминантные функции нейронов сети будут задаваться формулами:

$$\begin{aligned} \psi^{(1,i)}(w^{(1,i)}, x^{(1,i)}) &= w_0^{(1,i)} + w_1^{(1,i)} x_1^{(1,i)}, \quad i = 1, 2, \dots, N; \\ \psi^{(2,i)}(w^{(2,i)}, x^{(2,i)}) &= w_0^{(1,i)} + \sum_{j=1}^N w_j^{(1,i)} x_j^{(1,i)}, \quad i = 1, 2, \dots, G; \\ \psi^{(3,i)}(w^{(3,i)}, x^{(3,i)}) &= \sum_{j=1}^G (w_j^{(3,i)} - x_j^{(3,i)})^2, \quad i = 1, 2, \dots, Q; \\ \psi^{(4,i)}(w^{(4,i)}, x^{(4,i)}) &= w_0^{(4,i)} + \sum_{j=1}^Q w_j^{(4,i)} x_j^{(4,i)}, \quad i = 1, 2, \dots, K, \end{aligned}$$

где $\psi^{(3,i)}(w^{(3,i)}, x^{(3,i)})$ – дискриминантная (постсинаптическая, весовая) функция i -го нейрона z -го слоя, $w^{(3,i)}$ – набор весовых коэффициентов i -го нейрона z -го слоя, $w^{(3,i)} = \{w_j^{(3,i)}\}$, $w_j^{(3,i)}$ – весовой коэффициент j -го входа i -го нейрона z -го слоя, $x^{(3,i)}$ – набор входов i -го нейрона z -го слоя, $x^{(3,i)} = \{x_j^{(3,i)}\}$, $x_j^{(3,i)}$ – значение на j -ом входе i -го нейрона z -го слоя нейронной сети.

Функции активации нейронов будут задаваться формулами:

$$\begin{aligned} \psi^{(1,i)}(x) &= \begin{cases} x, & g_i = 0; \\ \ln(x), & g_i = 1, \end{cases} \quad i = 1, 2, \dots, N; \\ \psi^{(2,i)}(x) &= x, \quad i = 1, 2, \dots, G; \quad \psi^{(3,i)}(x^2) = e^{-x^2}, \quad i = 1, 2, \dots, Q; \\ \psi^{(4,i)}(x) &= \begin{cases} 0, & x \leq 0; \\ 1, & x > 0, \end{cases} \quad i = 1, 2, \dots, K, \end{aligned}$$

где $\psi^{(3,i)}(x)$ – функция активации i -го нейрона z -го слоя нейросети.

Весовые коэффициенты нейронов сети предлагается рассчитывать по формуле:

$$w_j^{(3,i)} = \begin{cases} 1 + \min(x_p)(\max(x_p) - \min(x_p))^{-1}, p = i + N, g_i = 1, z = 1, i = 1, 2, \dots, N, j = 0; \\ \min(x_i)(\max(x_i) - \min(x_i))^{-1}, g_i = 0, z = 1, i = 1, 2, \dots, N, j = 0; \\ (\max(x_p) - \min(x_p))^{-1}, p = i + N, g_i = 1, z = 1, i = 1, 2, \dots, N, j = 1; \\ (\max(x_i) - \min(x_i))^{-1}, g_i = 0, z = 1, i = 1, 2, \dots, N, j = 1; \\ 0, z = 1, i = 1, 2, \dots, N, j = 0; \\ I_j h(i, j) z(i) g_j = 0, z = 2, i = 1, 2, \dots, G, j = 1, 2, \dots, N; \\ (\ln 2)^{-1} I_j h(i, j) z(i) g_j = 1, z = 2, i = 1, 2, \dots, G, j = 1, 2, \dots, N; \\ C_j^i, z = 3, i = 1, 2, \dots, Q, j = 1, 2, \dots, G; \\ 0, z = 4, i = 1, 2, \dots, K, j = 0; \\ 1, C_j^i \in K_i, z = 4, i = 1, 2, \dots, K, j = 1, 2, \dots, Q; \\ -1, C_j^i \notin K_i, z = 4, i = 1, 2, \dots, K, j = 1, 2, \dots, Q; \end{cases}$$

$$z(i) = \left(\sum_{k=1}^N I_k h(i, k) \right)^{-1}.$$

Синтез нейро-нечетких сетей

Наряду с синтезом четких нейросетей прямого распространения информация, полученная в результате анализа информации о признаках, может быть использована для синтеза шестислойной (рис. 2) и пятислойной (рис. 3) нейро-нечетких сетей.




Рисунок 2 – Схема шестислойной нейро-нечеткой сети

Первый и второй слои обеих нейро-нечетких сетей будут эквивалентны соответствующим слоям вышеописанной нейронной сети.

Нейроны третьего слоя обеих сетей осуществляют вычисление значений функций принадлежности распознаваемого экземпляра к нечетким термам признаков.

Нейроны четвертого слоя шестислойной сети осуществляют объединение нечетких термов в кластеры, а нейроны пятого слоя объединяют принадлежности экземпляра к кластерам в принадлежности к классам.

Нейроны четвертого слоя пятислойной сети осуществляют непосредственное объединение нечетких термов в классы без кластерной группировки.

Единственный нейрон последнего слоя обеих сетей осуществляет объединение принадлежностей к классам и дефазификацию результата.




Рисунок 3 – Схема пятислойной нейро-нечеткой сети

Дискриминантные функции нейронов шестислойной нейро-нечеткой сети будут задаваться формулами:

$$\mu_j^{(4,i)}(w_j^{(4,i)}, x_j^{(4,i)}) = \min \{w_j^{(4,i)}, x_j^{(4,i)}\}, \quad i = 1, 2, \dots, Q, j = 1, 2, \dots, N_3;$$

$$\mu_j^{(5,i)}(w_j^{(5,i)}, x_j^{(5,i)}) = \min \{w_j^{(5,i)}, x_j^{(5,i)}\}, \quad i = 1, 2, \dots, K, j = 1, 2, \dots, Q;$$

$$\mu_j^{(6,1)}(w_j^{(6,1)}, x_j^{(6,1)}) = \min \{w_j^{(6,1)}, x_j^{(6,1)}\}, \quad j = 1, 2, \dots, K,$$

где N_3 – количество нейронов в 3-ом слое сети.

Функции активации нейронов шестислойной нейро-нечеткой сети будут задаваться формулами:

$$\sigma^{(4,i)}(\mu_j^{(4,i)}) = \max_j \{\mu_j^{(4,i)}\}, \quad i = 1, 2, \dots, Q, j = 1, 2, \dots, N_3;$$

$$\sigma^{(5,i)}(\mu_j^{(5,i)}) = \max_j \{\mu_j^{(5,i)}\}, \quad i = 1, 2, \dots, K, j = 1, 2, \dots, Q;$$

$$\sigma^{(6,1)}(\mu_j^{(6,1)}) = \arg \max_j \{\mu_j^{(6,1)}\}, \quad j = 1, 2, \dots, K.$$

Весовые коэффициенты нейронов шестислойной нейро-нечеткой сети будут определяться по формуле:

$$w_j^{(3,i)} = \begin{cases} 1, Q(j) = i, z = 4, i = 1, 2, \dots, Q, j = 1, 2, \dots, N_3; \\ 0, Q(j) \neq i, z = 4, i = 1, 2, \dots, Q, j = 1, 2, \dots, N_3; \\ 1, C^j \in i, z = 5, i = 1, 2, \dots, K, j = 1, 2, \dots, Q; \\ 0, C^j \notin i, z = 5, i = 1, 2, \dots, K, j = 1, 2, \dots, Q; \\ 0, z = 6, i = 1, j = 1, 2, \dots, K. \end{cases}$$

Дискриминантные функции нейронов пятислойной нейро-нечеткой сети будут задаваться формулами:

$$\psi_j^{(4,i)}(w_j^{(4,i)}, x_j^{(4,i)}) = \min \{w_j^{(4,i)}, x_j^{(4,i)}\}, \quad i = 1, 2, \dots, K, j = 1, 2, \dots, N_3;$$

$$\psi_j^{(5,1)}(w_j^{(5,1)}, x_j^{(5,1)}) = \min \{w_j^{(5,1)}, x_j^{(5,1)}\}, \quad j = 1, 2, \dots, K,$$

где N_3 – количество нейронов в z -ом слое сети.

Функции активации нейронов шестислойной нейро-нечеткой сети будут задаваться формулами:

$$\psi^{(4,i)}(\psi_j^{(4,i)}) = \max_j \{\psi_j^{(4,i)}\}, \quad i = 1, 2, \dots, K, j = 1, 2, \dots, N_3;$$

$$\psi^{(5,1)}(\psi_j^{(5,1)}) = \arg \max_j \{\psi_j^{(5,1)}\}, \quad j = 1, 2, \dots, K.$$

Весовые коэффициенты нейронов шестислойной нейро-нечеткой сети будут определяться по формуле:

$$w_j^{(3,i)} = \begin{cases} 1, K(j) = i, z = 4, i = 1, 2, \dots, K, j = 1, 2, \dots, N_3; \\ 0, K(j) \neq i, z = 4, i = 1, 2, \dots, K, j = 1, 2, \dots, N_3; \\ 0, z = 5, i = 1, j = 1, 2, \dots, K. \end{cases}$$

Заключение

В работе предложены новые методы неитеративного синтеза логически прозрачных нейронных и нейро-нечетких сетей. Предложенные методы позволяют на основе обучающих выборок данных создавать структуру нейронных и нейро-нечетких сетей, а также настраивать их параметры без оптимизационной подгонки весов, и могут быть рекомендованы для применения при решении задач диагностики и распознавания образов по признакам.

Литература

1. Abraham A. Neuro-Fuzzy Systems: State-of-the-Art Modeling Techniques // Connectionist Models of Neurons, Learning Processes, and Artificial Intelligence / Eds.: J. Mira and A. Prieto. – Granada: Springer-Verlag, 2001. – P. 269-276.
2. Леоненков А.В. Нечеткое моделирование в среде MATLAB и fuzzyTECH. – СПб.: БХВ-Петербург, 2003. – 736 с.
3. Ярушкина Н.Г. Основы теории нечетких и гибридных систем. – М.: Финансы и статистика, 2004. – 320 с.
4. Руденко О.Г., Бодянский Е.В. Основы теории искусственных нейронных сетей. – Харьков: Телетех, 2002. – 317 с.
5. Интеллектуальные средства диагностики и прогнозирования надежности авиадвигателей / В.И. Дубровин, С.А. Субботин, А.В. Богуслаев, В.К. Яценко. – Запорожье: ОАО «Мотор-Січ», 2003. – 279 с.

6. Субботин С.А. Синтез распознающих нейро-нечетких моделей с учетом информативности признаков // Нейрокомпьютеры: разработка, применение. – 2006. – № 10. – С. 50-56.
7. Субботин С.А. Неитеративный синтез и редукция нейро-нечетких моделей // Искусственный интеллект. – 2006. – № 3. – С. 323-330.
8. Субботин С.А. Методы синтеза нейро-нечетких классификаторов для случая нескольких классов // Информационные технологии. – 2006. – № 11. – С. 31-36.
9. Субботин С.А. Метод формирования баз знаний для нейро-нечетких моделей // Нейроинформатика и ее приложения: Материалы XIV Всероссийского семинара, 6 – 8 октября 2006 г. / Под ред. А.Н. Горбана, Е.М. Миркеса. Отв. за выпуск Г.М. Садовская. – Красноярск: ИВМ СО РАН, 2006. – С. 116-118.
10. Субботин С.А. Синтез нейро-нечетких сетей с группировкой признаков // Программные продукты и системы. – 2006. – № 4. – С. 3-7.
11. Субботин С.А. Синтез нейро-нечетких моделей для выделения и распознавания объектов на сложном фоне по двумерному изображению // Комп'ютерне моделювання та інтелектуальні системи: Збірник наукових праць / За ред. Д.М. Пізи, С.О. Субботіна. – Запоріжжя: ЗНТУ, 2007. – С. 68-91.
12. Прикладная статистика. Классификация и снижение размерности / С.А. Айвазян, В.М. Бухштабер, И.С. Енюков, Л.Д. Мешалкин. – М.: Финансы и статистика, 1989. – 607 с.

С.О. Субботін

Методи синтезу нейромережних і нейро-нечітких розпізнавальних моделей з лінеаризацією і факторним групуванням ознак

Запропоновано нові методи синтезу логічно прозорих нейронних і нейро-нечітких класифікуючих моделей у неітеративному режимі. Розроблені методи дозволяють вирішувати завдання автоматизації процесів прийняття рішень у технічній та біомедичній діагностиці, розпізнаванні образів.

S.A. Subbotin

Methods of neural and neuro-fuzzy recognizing model synthesis with feature linearization and factor grouping

The new non-iterative methods of logically transparent neural and neuro-fuzzy classifying model synthesis are offered. The developed methods allow to automatize the decision making processes in technical and biomedical diagnostics, in pattern recognition.

Статья поступила в редакцию 04.09.2007.