

Бодянский С. В.,
 д-р техн. наук, профессор кафедры штучного інтелекту,
 науковий керівник Проблемної науково-дослідної лабораторії АСУ,
 Харківський національний університет радіоелектроніки, м. Харків, Україна;
 bodya@kture.kharkov.ua

Перова І. Г.,
 канд. техн. наук, доцент кафедри біомедичної інженерії,
 Харківський національний університет радіоелектроніки, м. Харків, Україна
 churyumova@mail.ru

НЕЧЕТКАЯ КЛАСТЕРИЗАЦИЯ БИОМЕДИЦИНСКИХ ДАННЫХ НА ОСНОВЕ BSB-НЕЙРО-ФАЗЗИ-МОДЕЛИ

В статье рассматривается специальный класс нейросетевой автоассоциативной памяти BSB- и GBSB-модели. Данные модели, реализованные на гиперкубе, решают задачу кластеризации заданного массива данных за счет того, что вершины гиперкуба действуют как точечные аттракторы. Также в статье рассмотрено создание на основе BSB-модели BSB-нейро-фаззи-модели за счет введения нечеткой функции принадлежности, которая позволит решать задачи нечеткой кластеризации. Предлагается обоснование выбора вида такой функции. Рассмотрен алгоритм обучения, который наделяет BSB-нейро-фаззи-модели адаптивными свойствами. Работа BSB-нейро-фаззи-модели апробирована на данных медико-биологических исследований.

Ключевые слова: нечеткая кластеризация; гиперкуб; устойчивое состояние; аттрактор; адаптивный алгоритм обучения.

Введение

Одним из важных свойств биологического мозга является способность к запоминанию информации и ее последующему восстановлению с помощью системы ассоциаций, при этом увиденный когда-то образ может быть опознан даже спустя длительное время, несмотря на произошедшие с ним изменения. Эту функцию мозга моделирует достаточно широкий класс искусственных нейронных сетей, называемых нейронными сетями ассоциативной памяти [1-5].

Такая искусственная память представляет собой, как правило, нейронную сеть либо с прямой передачей информации (статическая ассоциативная память), либо рекуррентную (динамическая ассоциативная память), которая в режиме обучения накапливает предъявляемые ей образы (фаза запоминания), а в режиме (фазе) восстановления вызывает их из памяти, ассоциируя вновь предъявляемые данные с ранее увиденными. При этом весь набор предъявляемых и запоминаемых образов формирует множество фундаментальной памяти.

Основное отличие нейросетевой ассоциативной памяти от аппроксимирующих нейронных сетей состоит в том, что если последние реализуют однозначное нелинейное отображение:

$$R^m \ni y(k) = F(x(k) \in R^n),$$

то ассоциативная память отображает в $y(k)$ все возможные векторы входов x , принадлежащие некоторой окрестности $x(k)$ такой, что

$$\|x - x(k)\| < \varepsilon.$$

Здесь $y(k)$, $x(k)$ – $(m \times 1)$ и $(n \times 1)$ – векторы фундаментальной памяти, $k=1,2,\dots,l$ – номер конкретного образа в множестве фундаментальной памяти, ε – некоторый положительный параметр.

Настоящая работа посвящена рассмотрению и модификации одного специального класса нейросетевой автоассоциативной памяти, реализующей отображение

$$R^n \ni x(k) = F(x(k) \in R^n)$$

для всех x , принадлежащих окрестности, определяемой параметром ε , при этом заметим, что основная функция автоассоциативных сетей – восстановление неполной или искаженной информации, например, узнавание образа по обрывку старой фотографии или диагностика, включая медицинскую, по зачастую неточным и искаженным данным с пропусками и ошибками.

BSB-нейромодель

Среди множества структур нейросетевой автоассоциативной памяти можно выделить достаточно простую, однако эффективную конструкцию, введенную Дж. Андерсоном и его коллегами [6; 7] и получившую название «Brain-State-In-a-Box Model» (BSB-модель). Эта структура изучалась рядом исследователей [8–17] и имеет на сегодня весьма серьезное теоретическое обоснование.

BSB-модель представляет собой нейродинамическую нелинейную замкнутую систему с амплитуд-

ными ограничениями, охваченную положительной обратной связью.

Динамика этой системы определяется парой уравнений в пространстве состояний

$$\begin{cases} y(k, \tau) = x(k, \tau) + \alpha Wx(k, \tau), \\ x(k, \tau + 1) = \psi(y(k, \tau)), \end{cases} \quad (1)$$

где $x(k, 0) \equiv x(k)$ – вектор-образ, подаваемый в систему; $\tau = 0, 1, 2, \dots, T$ – итерации машинного времени; $x(k, T)$ – вектор состояний в установившемся режиме;

$$x_i(k, \tau + 1) = \psi(y_i(k, \tau)) = \begin{cases} +1, & \text{если } y_i(k, \tau) > +1, \\ y_i(k, \tau), & \text{если } -1 \leq y_i(k, \tau) \leq +1, \\ -1, & \text{если } y_i(k, \tau) < -1, \end{cases} \quad (2)$$

$$i = 1, 2, \dots, n.$$

Таким образом, фазовое пространство BSB-модели ограничено n -мерным гиперкубом с центром в начале координат и ребром, имеющим длину два. Всего гиперкуб имеет 2^n вершин, которые целесообразно некоторым образом пронумеровать. Сделать это удобно, заменяя отрицательные координаты вершин нулями, переводя полученное двоичное число в десятичную форму и добавляя единицу. При этом вершине с отрицательными координатами $(-1, -1, \dots, -1)^T$ соответствует первый номер, а вершине со всеми положительными координатами – номер 2^n .

Наличие положительной обратной связи приводит к тому, что подаваемые в BSB-модель сигналы (предварительно закодированные для работы в гиперкубе так, что $-1 \leq x_i(k) \leq +1$, $i = 1, 2, \dots, n$) усиливаются до тех пор, пока все состояния $x_i(k, \tau)$ не войдут в насыщение, при этом поданный в систему аналоговый входной сигнал преобразуется в дискретную форму, соответствующую одной из вершин гиперкуба. Несложно видеть, что при подаче в систему n -мерного аналогового вектора $x(k) \equiv x(k, 0)$, BSB-модель вычисляет:

$$y(k, 0) = (I + \alpha W)x(k, 0)$$

(здесь $I - (n \times n)$ – единичная матрица) и $x(k, 1) = \psi(y(k, 0))$,

причем сигнал $x(k, 1)$ сверху и снизу ограничен по амплитуде. Итерации τ продолжают до тех пор, пока не будет достигнуто устойчивое состояние (аттрактор) в одной из вершин гиперкуба. Наличие положительной обратной связи заставляет поданный в нейросеть сигнал увеличиваться по норме до достижения грани гиперкуба, после чего усиленный сигнал «скользит» по грани или ребру пока не достигнет одного из углов «ящика», выйти откуда он уже не может.

Анализ устойчивости BSB-модели показывает [5], что в процессе функционирования она реализует алгоритм градиентного спуска, минимизируя энергетическую функцию (функцию Ляпунова) вида:

$$E = -\frac{\alpha}{2} x^T W x \quad (3)$$

при ограничениях (2). В случае симметричности и неотрицательной определенности матрицы W мини-

α – малый положительный параметр обратной связи; $W - (n \times n)$ – матрица синаптических весов линейной корреляционной автоассоциативной памяти, представляющей собой по сути однослойную нейронную сеть, образованную адаптивными линейными ассоциаторами; $\psi(\bullet)$ – активационная кусочно-линейная функция с насыщением, действующая покомпонентно на элементы вектора $y(k, \tau)$ так, что:

мум достигается в одной из вершин-аттракторов n -мерного гиперкуба.

BSB-нейро-фаззи-модель

BSB-модель, являясь автоассоциативной памятью решает по сути задачу кластеризации заданного массива данных $x(k)$, $k = 1, 2, \dots, l$. Это следует из того факта, что вершины гиперкуба в процессе обработки информации действуют как точечные аттракторы с выраженными областями притяжения, которые делят n -мерное пространство признаков. Здесь, однако, возникает определенная проблема, связанная с тем, что емкость линейной автоассоциативной памяти W не может превышать n (абсолютная емкость $l/n \leq 1$), а количество аттракторов гиперкуба равно $2^n \gg n$ так, что большинство вершин будет оставаться «пустым». В том же время возможна ситуация, когда данные, принадлежащие одному и тому же кластеру, могут располагаться в нескольких соседних вершинах гиперкуба. В связи с этим целесообразно ввести некоторую функцию соседства между вершинами гиперкуба так, что образы, попавшие в соседние вершины, могли бы считаться принадлежащими одному или, по крайней мере, близким кластерам.

В этом случае удобно воспользоваться идеями нечеткой кластеризации [18; 19] применяя наиболее простую треугольную функцию принадлежности. При этом уровень принадлежности образа $x(k, T)$ к q -й вершине гиперкуба определяется элементарным соотношением [20]:

$$\mu_q(x(k, T)) = 1 - \frac{d(x(k, T), x_q)}{2n}, \quad (4)$$

где $d(x(k, T), x_q) = \sum_{i=1}^n |x_i(k, T) - x_{q,i}|$ – хэммингово расстояние между $x(k, T)$ и вершиной гиперкуба x_q , $q = 1, 2, \dots, 2^n$. Несложно видеть, что $\mu_p(x(k, T)) = 1$, а уровень принадлежности к наиболее удаленной от x_p^* вершине равен нулю.

Представляется целесообразным установить связь между нечеткой кластеризацией на основе BSB-модели и наиболее популярным алгоритмом нечетких С-средних (FCM) [18]. В рамках FCM уровень

принадлежности образа $x(k, T)$ к q -й вершине-центроиду кластера определяется выражением:

$$\mu_q(x(k, T)) = \frac{d^{-1}(x(k, T), x_q)}{\sum_{l=1}^{2^n} d^{-1}(x(k, T), x_l)},$$

где $d(x(k, T), x_q) = \sum_{i=1}^n |x_i(k, T) - x_{q,i}|$ – хэммингово

расстояние между образом $x(k, T)$ и вершиной гипер-

$$\begin{aligned} \mu_q(x(k, T)) &= \frac{d^{-1}(x(k, T), x_q)}{d^{-1}(x(k, T), x_q) + \sum_{\substack{l=1 \\ l \neq q}}^{2^n} d^{-1}(x(k, T), x_l)} = \frac{1}{1 + d(x(k, T), x_q) \sum_{\substack{l=1 \\ l \neq q}}^{2^n} d^{-1}(x(k, T), x_l)} = \\ &= \frac{1}{1 + \frac{d(x(k, T), x_q)}{\sum_{\substack{l=1 \\ l \neq q}}^{2^n} (d^{-1}(x(k, T), x_l))^{-1}}} = \frac{1}{1 + \frac{d(x(k, T), x_q)}{\sigma_q}}, \end{aligned}$$

где σ_q – параметр ширины колоколообразной функции принадлежности образа $x(k, T)$ к вершине x_q . При этом очевидно, что, если $x(k, T) \equiv x_q$, то уро-

куба $x_q, q=1, 2, \dots, 2^n$. Здесь интересно заметить, что поскольку образ $x(k, T)$ находится в одной из вершин гиперкуба, например, x_p , то хэммингово расстояние между x_p и x_q определяется удвоенным числом несовпадающих знаков координат, задающих эти вершины.

(5)

Соотношение, задающее $\mu_p(x(k, T))$, может быть преобразовано к виду:

вень принадлежности тождественно равен единице. На рис. 1 приведен вид функции принадлежности для различных размерностей n вектора признаков $x(k)$.




Рис. 1. Функция принадлежности BSB-нейро-фаззи-модели

Алгоритм обучения BSB-модели

Качество работы BSB-нейромодели определяется в значительной мере емкостью автоассоциативной памяти, включенной в контур обратной связи, а эта емкость, в свою очередь, существенно зависит от принятой процедуры настройки n^2 синаптических весов адаптивных линейных ассоциаторов. В качестве такой простейшей процедуры можно использовать оценку, введенную Дж. Андерсоном [6; 7] и имеющую вид:

$$W = \sum_{k=1}^l x(k)x^T(k) = XX^T, \quad (6)$$

где $X = X(l) = (x(1), x(2), \dots, x(l))^T - (n \times l)$ – матрица фундаментальной памяти, при этом в дальнейшем будем использовать кроме $X = X(l)$ также матрицы $X(k) = (x(1), x(2), \dots, x(k))^T (k < l)$ и $X(1) = x(1)$.

Выражение (6) может быть записано в рекуррентной форме:

$$W(k) = W(k-1) + x(k)x^T(k), \quad W(0) = 0 \cdot I, \quad (7)$$

при этом несложно видеть, что для нормированных и центрированных векторов $x(k)$ (6) описывает автокорреляционную матрицу последовательности предъявляемых образов, а рекуррентное соотношение (7)

представляет собой вариант стандартного хэббовского правила обучения, широко используемого в теории и практике искусственных нейронных сетей [3–5].

$$\hat{x}(r) = \sum_{k=1}^l x(k)x^T(k)x(r) = x(r)x^T(r)x(r) + \sum_{\substack{k=1 \\ k \neq r}}^l x(k)x^T(k)x(r), \quad (8)$$

при этом, если кроме предварительной кодировки на гиперкуб образы также пронормированы на гипер-

$$\hat{x}(r) = x(r) + \sum_{\substack{k=1 \\ k \neq r}}^l x^T(k)x(k)x(r) = x(r) + v(r),$$

где $x(r)$ – представляет собой полезную часть выходного сигнала, а $v(r)$ – помеху (crosstalk), определяемую уровнем корреляции между предъявляемым образом и всеми векторами фундаментальной памяти.

Помеховую компоненту $v(r)$ можно переписать в виде:

$$v(r) = \sum_{\substack{k=1 \\ k \neq r}}^l \cos(x(k), x(r))x(k),$$

При подаче на вход линейной автоассоциативной памяти одного из ранее предъявленных образов $x(r)$ или достаточно близкого к нему ($\|x - x(r)\| < \varepsilon$), на её выходе появляется сигнал:

шар так, что $\|x(k)\| = 1, k = 1, 2, \dots, l$, выходной сигнал (8) может быть переписан в форме

откуда видно, что безошибочное восстановление образа возможно только при ортогональных векторах фундаментальной памяти, чего на практике практически не встречается.

Можно показать, что матрица синаптических весов W , рассчитанная согласно (6), (7), представляет собой неортогональный проекционный оператор на линейную оболочку векторов фундаментальной памяти, действующий так, как приведено на рис. 2.




Рис. 2. Проецирование с помощью матрицы синаптических весов W

Уменьшить влияние помеховой компоненты, а, следовательно, улучшить качество восстановления можно, минимизируя норму $\|v(r)\|$ или, что то же самое, осуществляя ортогональное проецирование предъявляемого образа на линейную оболочку векторов фундаментальной памяти. Из рис. 2 видно, что искомое решение может быть получено в результате минимизации критерия

$$E^k = \sum_{k=1}^l E(k) = \sum_{k=1}^l \|x(k) - Wx(k)\|^2$$

$$W(k) = W(k-1) + \eta(k)(x(k) - W(k-1)x(k))x^T(k) = W(k-1) + \eta(k)(x(k) - \hat{x}(k))x^T(k). \quad (10)$$

и минимизирующее локальный критерий $E(k) = \|x(k) - Wx(k)\|^2$, где $\eta(k)$ – скалярный параметр шага поиска, выбираемый из эмпирических соображений.

или, что то же самое, квадрата сферической матричной нормы

$$E^k = \|X - WX\|^2 = Tr(X - WX)(X - WX)^T. \quad (9)$$

Для этого могут быть использованы, в частности, линейные проекционные многошаговые адаптивные алгоритмы идентификации [21–24]. Наиболее же распространенным является автоассоциативное правило Уидроу-Хоффа, имеющее вид:

Оптимизация этого правила по быстродействию приводит к процедуре [25]

$$W(k) = W(k-1) + \eta(k) \frac{x(k) - W(k-1)x(k)}{\|x(k)\|^2} x^T(k), \quad 0 < \eta(k) < 2, \quad (11)$$

являючоїся обобщением известного алгоритма Качмажа [26; 27] на многомерный случай.

Здесь, однако, следует помнить, что алгоритмы типа (10), (11) реализуют операцию проецирования не на все множество фундаментальной памяти $X(l)$, а только на последний предъявляемый ей образ $x(k)$ [28], что ведет к снижению помехоустойчивости, а следовательно и качества восстановления.

В то же время из линейной алгебры известно [29; 30], что минимизация сферической нормы (9) обеспечивается с помощью матрицы ортогонального проецирования

$$W = XX^+ = X(X^T X)^{-1} X^T, \quad l < n \quad (12)$$

где X^+ – псевдообратная матрица Мура-Пенроуза.

$$X^+(k) = \left(\frac{X^+(k-1) - d(k)b(k)}{b(k)} \right), \quad (13)$$

где

$$d(k) = X^+(k-1)x(k), \quad (14)$$

$$b(k) = \begin{cases} f^+(k) = \frac{f^T(k)}{\|f(k)\|^2}, & \text{если } f(k) = x(k) - X(k-1)d(k) \neq 0, \\ \frac{d^T(k)X^+(k-1)}{1 + \|d(k)\|^2}, & \text{если } f(k) = 0, \end{cases} \quad (15)$$

$$X^+(1) = x^T(1)\|x(1)\|^{-2}.$$

Далее несложно записать с учетом (14):

$$\begin{aligned} W(k) &= X(k)X^+(k) = (X(k-1)Mx(k)) \left(\frac{X^+(k-1) - d(k)b(k)}{b(k)} \right) = \\ &= X(k-1)X^+(k-1) - X(k-1)d(k)b(k) + x(k)b(k) = W(k-1) + (I - W(k-1))x(k)b(k). \end{aligned} \quad (16)$$

Из выражений (10), (16) видно, что настройка автоассоциативной линейной памяти может проводиться как в режиме контролируемого обучения (по типу алгоритма Уидроу-Хоффа), так и в режиме самообучения (с использованием метода Гревилля). На рис. 3 приведена схема, иллюстрирующая этот процесс, который продолжается до тех пор, пока не будут запомнены все векторы фундаментальной памяти, т. е. не будет построена оценка

$$W = W(l) = X(l)X^+(l) = XX^+.$$

В ряде случаев возникает ситуация, когда из памяти необходимо удалить некоторый образ $x(r)$. В

$$X^+(l,r) = \begin{cases} S(r) + S(r) \frac{x(r)z(r)}{1 - z(r)x(r)}, & \text{если } z(r)x(r) \neq 1, \\ S(r) - S(r)z^+(r)z(r), & \text{если } z(r)x(r) = 1. \end{cases} \quad (17)$$

С учетом того, что $W = W(l) = X(l,r)S(r) + x(r)z(r)$, можно использовать алгоритм настройки автоассоциативной памяти вида [20]

Именно эта оценка и обеспечивает оптимальный набор синаптических весов линейной автоассоциативной памяти.

С тем, чтобы записать выражение (12) в рекуррентной форме удобной для обработки в реальном времени предъявляемых образов, целесообразно воспользоваться методом Гревилля последовательного нахождения псевдообратной матрицы [30; 31].

В случае, если в нашем распоряжении имеется $(n \times (k-1))$ -матрица $X(k-1)$, известна её псевдообратная $((k-1) \times n)$ -матрица $X^+(k-1)$ и на обработку поступил следующий образ $x(k)$ так, что $X(k) = (X(k-1)Mx(k))$, то

этом случае матрица фундаментальной памяти может быть представлена в форме

$$X = X(l) = (X(l,r)Mx(r)),$$

где $X(l,r) - (n \times (l-1))$ – матрица с исключенным столбцом $x(r)$.

В [15] доказана теорема, гласящая, что если известна псевдообратная матрица

$$X^+ = X(l) = \left(\frac{S(r)}{z(r)} \right),$$

то

$$W(l,r) = X(l,r)X^+(l,r) = \begin{cases} (W(l) - x(r)z(r)) \left(I + \frac{x(r)z(r)}{1 - z(r)x(r)} \right), & \text{если } z(r)x(r) \neq 1, \\ (W(l) - x(r)z(r)) \left(I - \frac{z^T(r)z(r)}{\|z(r)\|^2} \right), & \text{если } z(r)x(r) = 1. \end{cases} \quad (18)$$

Процедуры (16) и (18) позволяют как накапливать, так и «забывать» предъявляемые образы, обеспечивая тем самым BSB-нейромодель адаптивными свойствами.

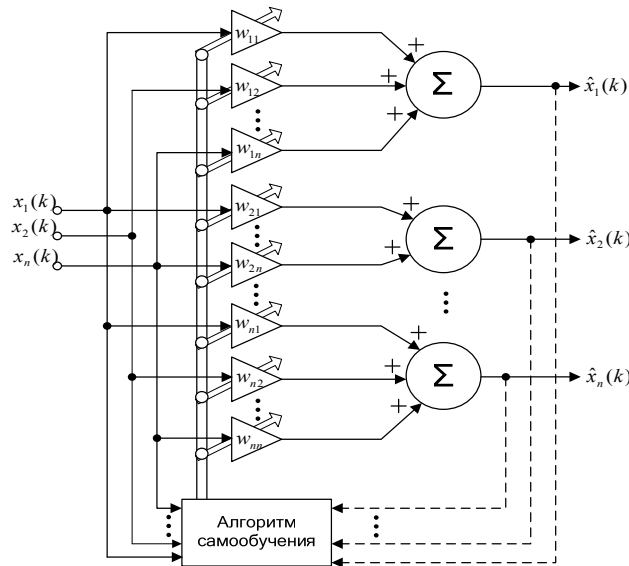


Рис. 3. Схема самообучения автоассоциативной линейной памяти.

GBSB-нейромодель

К настоящему времени кроме стандартной BSB-модели (1) определенное распространение получили её различные модификации, среди которых можно отметить конструкцию, описанную в [5] и имеющую вид:

$$x(k, \tau + 1) = \psi(\beta x(k, \tau) + \alpha Wx(k, \tau) + \gamma x(k, 0)),$$

в которой используется фактор забывания $0 < \beta < 1$ и малый положительный параметр γ , обеспечивающий постоянное «присутствие» в модели запоминаемого образа $x(k) = x(k, 0)$. Данная модель характеризуется более высокой скоростью сходимости и устойчивостью к ошибкам.

В работах [12; 15; 17; 20] была исследована обобщенная BSB-модель (Generalized Brain-State-in-a-Box Model), отличающаяся тем, что матрица синаптических весов W не является симметрической. Такая несимметричность может возникать, например, при использовании алгоритмов обучения типа Качмажа-Уидроу-Хоффа и вызывать нарушение условий сходимости к минимумам энергетической функции (3). С другой стороны, симметричность матрицы W также не является благом, поскольку BSB-модели, обучаемые процедурами (6) или (12), кроме образов фундаментальной памяти накапливают и их «негативы» [12], формируя при этом ложные аттракторы.

Именно для преодоления этого недостатка была введена GBSB-модель, описываемая рекуррентным соотношением:

$$x(k, \tau + 1) = \psi(x(k, \tau) + \alpha Wx(k, \tau) + \alpha g) \quad (19)$$

и минимизирующая энергетическую функцию:

$$E = -\left(\frac{\alpha}{2} x^T W x + \alpha x^T g \right),$$

где $g - (n \times 1)$ – вектор, вводимый в (19) с целью исключения ложных аттракторов.

Использование оценки (19) приводит к тому, что в результате обучения будет сформировано ровно l устойчивых аттракторов-вершин гиперкуба с каждой из которых можно связать собственную функцию принадлежности (5). В фазе восстановления образы, не попавшие ни в один из сформированных аттракторов, приписывают к вершине гиперкуба, соответствующей максимальному уровню принадлежности. Вершины, взаимный уровень принадлежности которых превышает некоторый априори заданный порог, могут формировать один кластер, при этом, естественно возможна ситуация принадлежности одного образа нескольким кластерам согласно принципам нечеткой кластеризации [19; 20].

Результаты экспериментального исследования

Для экспериментального исследования рассматривалась задача определения процессов возбуждения и торможения в организме человека. Поддержание оптимального состава внутренней среды организма, нормальная работа органов и систем организма, эффективное и рациональное взаимодействие его с окружающей средой, формирование и проявление эмоций и поступков человека зависят от состояния

двух основных процессов в центральной нервной системе: процессов возбуждения и торможения. Сила, уравновешенность и подвижность этих процессов являются фундаментом, на котором строятся все остальные процессы в организме: восприятие раздражителей, двигательные реакции, регуляция деятельности органов и систем организма. Высокая динамичность и новизна социальноэкономических, экологических и нравственных условий жизни современного человека предъявляют чрезвычайно высокие требования к его адаптационным возможностям, к его способности быстро, точно и надежно перестраивать свои функции в соответствии с меняющимися условиями жизни. При этом особую важность приобретает оптимальность расходования жизненных ресурсов и своевременность их восстановления, а также исходное увеличение резервов здоровья.

В свою очередь, основные процессы зависят от состояния тонкоструктурной организации человека и его мыслей, а также от внешних энергоинформационных воздействий. В последнем случае результат взаимодействия собственной тонкоструктурной организации и внешнего влияния, в значительной степени, зависит от исходного состояния внутренней структуры, ее полноты, мощности и устойчивости, от способности к саморегуляции и самовосстановлению.

Следует отметить, что перспективным путем профилактики нарушений в вегетативной и психоэмоциональной сферах является разработка средств и способов нормализации основных процессов центральной нервной системы через гармонизацию тонкоструктурной организации человека. Но предварительно предлагается исследовать внутреннюю структуру данных путем проведения процедуры нечеткой клас-

теризации данных с помощью введения BSB-нейрофаззи-модели.

Для анализа была взята выборка, состоящая из 182 объектов. Показатели включали в себя 24 различных зрительных и психофизических реакции, измеренных с помощью специализированной компьютерной программы. Поступающие на обработку данные предварительно были центрированы и стандартизированы по всем признакам так, чтобы все наблюдения принадлежали гиперкубу $[-1; 1]^n$.

Результаты эксперимента показали, что данные были разделены на 2 кластера, которые соответствовали преобладанию процессов возбуждения или торможения. При этом 82 % данных попали в две вершины гиперкуба, а 18 % – в близлежащие к ним вершины и были отнесены к ним в соответствии с функцией принадлежности (5). Результаты кластеризации соответствуют клиническим данным с большой степенью достоверности.

Выводы

В работе рассмотрена задача синтеза адаптивных алгоритмов обучения специального типа автоассоциативной памяти на основе BSB- и GBSB-нейро-фаззи-моделей. Введенные рекуррентные процедуры обладают высоким быстродействием, а использование нечетких функций принадлежности позволило связать процесс восстановления в нейросетевой модели с процедурами фаззи-кластеризации, что расширяет функциональные возможности развиваемого подхода. Решена практическая задача кластеризации (разбиение на группы) факторов, определяющих преобладание процессов возбуждения или торможения в организме. В результате получены две группы объектов, разделяемых по факторам отнесения пациентов к одному из психотипов.

ЛИТЕРАТУРА

1. Michel A. N., Farrel J. A. Associative memories via artificial neural networks // IEEE Control Systems Magazine. – 1990. – 10. – № 3. – P. 6–17.
2. Hassoun M.H. Fundamentals of Artificial Neural Networks. – Cambridge, MA: MIT, 1995.
3. Rojas R. Neural Networks. A Systematic Introduction. – Berlin : Springer-Verlag, 1996. – 502 p.
4. Hagan M. T., Demuth H. B., Beale M. Neural Network Design. – Boston : PWS Publishing Company, 1996. – 729 p.
5. Haykin S. Neural Networks. A Comprehensive Foundation. – Upper Saddle River, N. J. : Prentice Hall, Inc., 1999. – 842 p.
6. Anderson J. A. Cognitive and psychological computation with neural models // IEEE Trans. on Systems, Man, and Cybernetics. – 1983. – 13. – P. 799–815.
7. Anderson J. A., Silverstein J. W., Ritz S. A., Jones R. S. Distinctive features. Categorical perception and probability learning: Some applications of a neural model // Eds. J.A. Anderson, E. Rosenfeld «Neurocomputing: Foundations of Research». – Cambridge, MA : MIT Press, 1988. – P. 413–451.
8. Golden R. M. The Brain-State-in-a-Box neural model is a gradient descent algorithm// J. Mathematical Psychology. – 1986. – 30. – P. 73–80.
9. Yen G., Michel A. N. A learning and forgetting algorithm in associative memories: Results involving pseudoinverses // IEEE Trans. on Circuits Syst. – 1991. – 38. – P. 1193–1205.
10. Hui S., Zak S. H. Dynamical analysis of the Brain-State-in-a-Box (BSB) neural models // IEEE Trans. on Neural Networks. – 1992. – 3. – P. 86–94.
11. Anderson J. A. The BSB model: A simple nonlinear autoassociative neural network // Ed. M. H. Hassoun «Associative neural memories: theory and implementation». – N.Y. : Oxford University Press, 1993. – P. 77–103.
12. Lillo W. E., Miller D. C., Hui S., Zak S. H. Synthesis of Brain-State-in-a-Box (BSB) based associative memories // IEEE Trans. on Neural Networks. – 1994. – 5. – P. 730–732.
13. Bohner M., Hui S. Brain State in a Convex Body // IEEE Trans. on Neural Networks. – 1995. – 6. – P. 1053–1060.
14. Perfetti R. A synthesis procedure for Brain-State-in-a-Box (BSB) neural networks // IEEE Trans. on Neural Networks. – 1995. – 6. – P. 1071–1080.
15. Zak S. H., Lillo W. E., Hui S. Learning and forgetting in generalized Brain-State-in-a-Box (BSB) neural associative memories // Neural Networks. – 1996. – 9. – № 5. – P. 845–854.
16. Бодянский Е. В. Алгоритм обучения модифицированной BSB-модели в задачах кластеризации / Е. В. Бодянский, В. В. Колодяжный, Н. А. Тесленко // Автоматика-2005: Матеріали Міжнар. конф. з автоматичного управління. – Харків : Вид-во НТУ «ХП», 2005. – Т. 1. – С. 49–50.
17. Oh C., Zak S. H. Image recall using a large scale generalized Brain-State-in-a-Box neural network // Int. J. Appl. Math. Comput. Sci. – 2005. – 15. – P. 99–114.
18. Bezdek J. C. Pattern Recognition with Fuzzy Objective Function Algorithms. – N. Y. : Plenum Press, 1981. – 272 p.
19. Hoepfner F., Klawonn F., Kruse R. Fuzzyklusteranalyse. Verfahren fuer die Bilderkennung, Klassifikation und Datenanalyse. – Braunschweig : Vieweg, 1996.

20. Bodyanskiy Ye.V., Teslenko N. A. Adaptive learning of fuzzy bsb and gbsb neural models // Cybernetics and Systems Analysis, Vol. 42, No. 6, 2006. – P. 786–794.
21. Аведьян Э. Д. Модифицированные алгоритмы Качмажа для оценки параметров линейных объектов / Э. Д. Аведьян // Автоматика и телемеханика. – 1978 – № 5 – С. 64–72.
22. Бодянский Е. В. Адаптивные алгоритмы идентификации с конечной памятью / Е. В. Бодянский. – Харьков, 1984. – 47 с. Рук. деп. в УкрНИИИИТИ 05.02.1985, № 218Ук. – 85 Деп.
23. Бодянский Е. В. Адаптивный конечношаговый алгоритм идентификации / Е. В. Бодянский, Ю. О. Буряк, М. Л. Содин // АСУ и приборы автоматики. – Харьков : Выша шк. – 1987. – Вып. 84. – С. 53–57.
24. Бодянский Е. В. Адаптивные модели в системах управления техническими объектами / Е. В. Бодянский, О. Г. Руденко. – Киев : УМК ВО, 1988. – 212 с.
25. Руденко О. Г. Адаптивный алгоритм прогнозирования случайных последовательностей / Е. В. Бодянский, И. П. Плисс // Автоматика. – 1979. – № 1. С. 51–54.
26. Kaczmarz S. Angenaehernte Ausloesung von Systemen linearer Gleichungen // Bull. Int. Acad. Polon. Sci. – 1937. – Let.A. – S. 355–357.
27. Kaczmarz S. Approximate solution of linear equations // Int. J. Control. – 1993. – 53. – P. 1269–1271.
28. Райбман Н. С. Построение моделей процессов производства / В. М. Чадеев. – Москва : Энергия, 1975. – 367 с.
29. Фадеев Д. Е. Вычислительные методы линейной алгебры / Д. Е. Фадеев, В. Н. Фадеева. – Москва, Ленинград : ГИФМЛ, 1963. – 623 с.
30. Алберт А. Регрессия, псевдоинверсия и рекуррентное оценивание / А. Алберт. – М. : Наука, 1977. – 224 с.
31. Гантмахер Ф. Р. Теория матриц / Ф. Р. Гантмахер – Москва : Наука, 1988– 552 с.

Бодянский Є. В., Харківський національний університет радіоелектроніки, м. Харків, Україна
Перова І. Г., Харківський національний університет радіоелектроніки, м. Харків, Україна

НЕЧІТКА КЛАСТЕРИЗАЦІЯ БІОМЕДИЧНИХ ДАНИХ НА ОСНОВІ BSB-НЕЙРО-ФАЗЗИ-МОДЕЛІ

У статті розглядається спеціальний клас нейромережевої автоасоціативної пам'яті BSB- і GBSB-моделі. Ці моделі, реалізовані на гіперкубі, вирішують задачу кластеризації заданого масиву даних за рахунок того, що вершини гіперкуба діють як аттрактори. Також у статті розглянуто створення на основі BSB-моделі BSB-нейро-фаззи-моделі за рахунок введення нечіткої функції належності, що дозволить вирішити задачі нечіткої кластеризації. Пропонується обґрунтування вибору виду такої функції. Розглянуто алгоритм навчання, який наділяє BSB-нейро-фаззи-моделі адаптивними властивостями. Робота BSB-нейро-фаззи-моделі апробована на даних медико-біологічних досліджень.

Ключові слова: *нечітка кластеризація; гіперкуб; стабільний стан; аттрактор; адаптивний алгоритм навчання.*

Perova I., Kharkiv National University of Radio Electronics, Kharkiv, Ukraine
Bodyanskiy Y., Kharkiv National University of Radio Electronics, Kharkiv, Ukraine

FUZZY CLUSTERING OF BIOMEDICAL DATA USING BSB-NEURO-FUZZY-MODEL

In this article the problem of clusterization in conditions of uncertainty about clusters amount and its separability is considered. Subject of research is development of fuzzy-clusterization in online mode of biomedical data, described by multidimensional feature vectors. The goal of this article is synthesis of neuro-fuzzy self-learning system that can solve clusterization task in online mode as new data are fed to the input of system. Synthesis of neuro-fuzzy-model and algorithm of its learning has developed using methods of Computational Intelligence. The novelty of approach under consideration consists in synthesis of neuro-fuzzy-clustering system with membership function of special type that permits to solve fuzzy clustering task in online mode in the presence of uncertainty about amount of possible clusters. We suppose that clusters can have arbitrary form and can be overlapped. As basic for our self-learning neural network under consideration the «Brain-State-in-a-Box Model» (BSB) was used. We have proposed fuzzy modification of this system and the adaptive algorithm for its self-learning. This procedure is modification of Kaczmarz-Widrow-Hoff algorithm and characterized by high speed convergency. As procedure of fuzzy inference we have proposed to use the approach connected with fuzzy-c-means algorithm of clusterization. It has shown, that this approach allows to obtain membership function of Cauchian type. The process of leaning of «Generalized Brain-State-in-a-Box Model» (GBSB) was considered too. Proposed self-learning neuro-fuzzy system was used for solving of biomedical datasets processing, that are data of psychophysiological research. Online clustering system is proposed for solving of fuzzy medical diagnostics problems in condition of uncertainty about amount of possible medical diagnoses.

© Бодянский Є. В., Перова І. Г., 2014

Дата надходження статті до редколегії: 17.12.2014 р.