

УДК 004.032.026



## МНОГОСЛОЙНАЯ САМООБУЧАЮЩАЯСЯ СПАЙК-НЕЙРОННАЯ СЕТЬ

Е.В. Бодянский<sup>1</sup>, А.И. Долотов<sup>2</sup><sup>1</sup>ХНУРЭ, г. Харьков, Украина, bodya@kture.kharkov.ua<sup>2</sup>ХНУРЭ, г. Харьков, Украина, artem.dolotov@gmail.com

Предложена многослойная спайк-нейронная сеть с рецепторными и радиально-базисными нейронами для решения задачи кластеризации. Рассмотрен адаптивный алгоритм обучения на основе правила Хэбба. Приведены результаты кластеризации спутникового изображения.

ВЫЧИСЛИТЕЛЬНЫЙ ИНТЕЛЛЕКТ, СПАЙК-НЕЙРОННАЯ СЕТЬ, РЕЦЕПТОРНЫЙ НЕЙРОН, ПОПУЛЯЦИОННОЕ КОДИРОВАНИЕ, ПРАВИЛО ХЭББА, КЛАСТЕРИЗАЦИЯ

### Введение

Задача кластеризации, или классификации без учителя, занимает важное место в общей проблеме интеллектуального и исследовательского анализа данных (Data Mining and Exploratory Data Analysis), а для ее решения в качестве наиболее эффективных показали себя такие средства вычислительного интеллекта [1], как искусственные нейронные сети (самоорганизующиеся карты Кохонена, ART-сети, BSB-нейромодели) [2] и нечеткие методы кластеризации [3, 4].

Последнее десятилетие характеризуется возникновением нового (третьего) поколения искусственных нейронных сетей [5, 6], получивших название «спайк-нейронные сети» и являющихся по характеру своего функционирования близкими аналогами биологических нейросистем. Решая в принципе те же проблемы, что и традиционные нейронные сети (ИНС), спайк-нейронные сети (СНС) обладают существенно большими быстродействием и вычислительной мощностью. При этом для решения одной и той же задачи для СНС требуется значительно меньшее число нейронов, чем для «классической» ИНС с традиционными функциями активации [5].

Принципиальным отличием СНС от обычных ИНС является способ кодирования обрабатываемой информации. При этом, если рассматривать нейронные сети с позиций теории цифрового автоматического управления [7], то ИНС есть не что иное, как нелинейные амплитудно-импульсные системы, а СНС являются время-импульсными системами, в которых информация передается и преобразуется в форме последовательностей импульсов-спайков.

Нашли свое применение спайк-нейронные сети и в задачах кластеризации [8–10], где показали свою эффективность и быстродействие при обработке больших массивов информации, например, достаточно сложных изображений. В то же время следует учитывать, что, поскольку СНС находятся на начальной стадии своего развития, количество известных архитектур и алгоритмов обучения (самообучения) не так уже велико. В связи с этим целью настоящей

работы является синтез архитектуры многослойной гетерогенной спайк-нейронной сети, предназначенной для решения задач кластеризации в ситуациях, когда классы, подлежащие разделению, имеют произвольную, достаточно сложную форму.

### 1. Архитектура самообучающейся спайк-нейронной сети

Архитектура многослойной самообучающейся спайк-нейронной сети, предназначенной для решения задачи кластеризации, приведена на рис. 1. Как видно, это гетерогенная сеть с прямой передачей информации и латеральными связями в выходном слое.

Первый скрытый слой предназначен для кодирования аналоговых входных сигналов  $x_i$ ,  $i = 1, 2, \dots, n$ , предварительно преобразованных так, что  $0 \leq x_i \leq 1$ , в кортежи импульсов-спайков, отличающимися друг от друга моментами возбуждения. Именно в этом слое реализуется преобразование амплитудно-импульсного сигнала во время-импульсную форму. В рассматриваемой СНС с целью повышения точности кластеризации используется популяционное кодирование [11–13], когда один сигнал одновременно обрабатывается пулом, состоящим из  $h$  рецепторных нейронов  $RN_{li}$ ,  $l = 1, 2, \dots, h$ , активационные функции которых есть одномерные колоколообразные перекрывающиеся конструкции (обычно гауссианы), сдвинутые относительно друг друга так, как это показано на рис. 2.

Как видно из рисунка, сигнал  $x_i(k)$  (здесь  $k = 1, 2, 3, \dots$  — номер образа в обучающей выборке) возбуждает второй и третий нейроны популяции  $i$ -го входа (нейроны, уровень активации которых ниже принятого порога возбуждения  $\vartheta_l$ , не возбуждаются), которые генерируют спайки с временами возбуждения  $t_{2i}$  и  $t_{3i}$ , определяемыми значениями активационных функций  $\psi(x_i, c_2)$  и  $\psi(x_i, c_3)$ . При низком пороге возбуждения могут активироваться все нейроны пула, генерируя кортежи импульсов  $\{t_{1i}, t_{2i}, \dots, t_{hi}\}$ .

В общем случае время возбуждения конкретного спайка лежит в интервале  $0 \leq t_{li} \leq T$ , где  $T$  — интер-

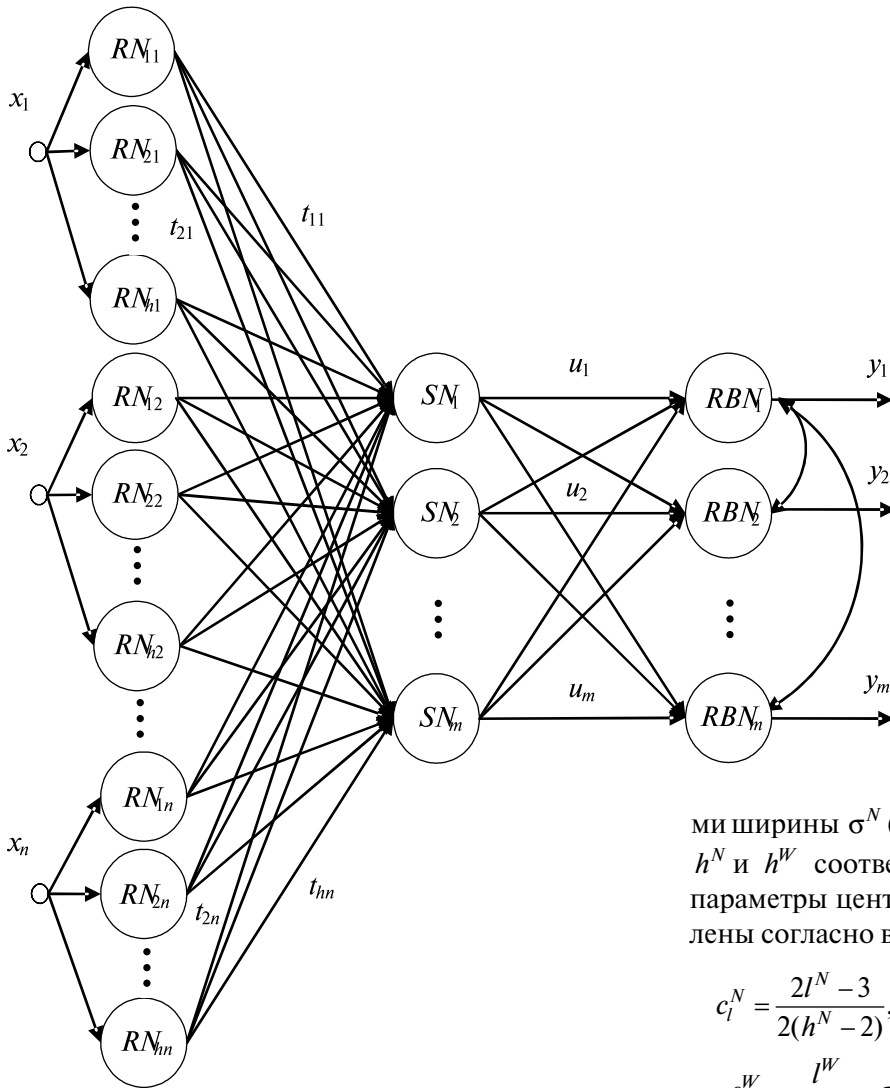


Рис. 1. Многослойная самообучающаяся спайк-нейронная сеть

вал кодирования, и определяется выражением

$$t_{li} = T(1 - \psi(|x_i - c_{li}|, \sigma_i)),$$

которое (полагая без потери общности  $T=1$ ) в случае гауссовской активационной функции принимает простой вид:

$$t_{li} = 1 - \exp\left(-\frac{(x_i - c_{li})^2}{\sigma_i^2}\right),$$

где  $c_i$  и  $\sigma_i$  определяют центр и ширину активационной функции. Несложно видеть, что чем ближе  $i$ -я компонента входного сигнала  $x = (x_1, x_2, \dots, x_n)^T$  расположена к центру  $c_i$  рецепторного нейрона  $RN_{li}$ , тем раньше этот нейрон генерирует спайк.

Достаточно часто [9, 12] при популяционном кодировании одновременно используют функции активации с разными параметрами ширины  $\sigma^N$  («узкие») и  $\sigma^W$  («широкие») числом  $h^N$  и  $h^W$  соответственно ( $h^N + h^W = h$ ). При этом параметры центров и ширины могут быть определены согласно выражениям:

$$c_l^N = \frac{2l^N - 3}{2(h^N - 2)}, \sigma_l^N = (1.5(h^N - 2))^{-1}, l^N = 1, 2, \dots, h^N,$$

$$c_l^W = \frac{l^W}{h^W + 1}, \sigma_l^W = (0.5(h^W + 1))^{-1}, l^W = 1, 2, \dots, h^W.$$

«Узкие» и «широкие» активационные функции приведены на рис. 3.




Рис. 2. Активационные функции первого скрытого слоя




Рис. 3. «Узкие» и «широкие» активационные функции первого скрытого слоя

Таким образом, входным сигналом первого слоя служит  $(n \times 1)$ -вектор образов  $x$ , подлежащих классификации, а выходом —  $n$  кортежей спайков  $\{t_{li}\}$ , которые также могут быть представлены в форме  $(hn \times 1)$ -вектора  $t = (t_{11}, t_{22}, \dots, t_{h1}, t_{12}, \dots, t_{li}, \dots, t_{h-1,n}, t_{hn})^T$ .

Интересно заметить также, что первый скрытый слой СНС по структуре совпадает со слоем фазсификации таких нейро-фаззи-систем, как сети Такаги-Сугено-Канга, Дженга, Ванга-Мендели и им подобных [1], где узлам  $RN_{li}$  соответствуют колоколообразные функции принадлежности  $j_{li}$ . Отличие состоит в том, что выходом нейрона  $RN_{li}$  является спайк со временем возбуждения  $t_{li}$ , а выходом функции принадлежности  $j_{li}$  — уровень соответствующей лингвистической переменной.

Второй скрытый слой СНС образован  $m$  составными спайк-нейронами [8, 14]  $SN_j$  с множественными синапсами  $MS_{li}$ , каждый из которых

образован параллельными субсинапсами с различными временными аксональными задержками  $d^p$ ,  $p=1, 2, \dots, q$ ;  $d^p - d^{p-1} > 0$ . На рис. 4 приведена архитектура составного спайк-нейрона рассматриваемой СНС.

Спайк-нейрон имеет  $hn$  входов, каждому из которых соответствует свой множественный синапс  $MS_{li}$ , образованный  $q$  субсинапсами, состоящими из последовательно соединенных формирователей постсинаптического потенциала  $\epsilon_{jli}^p(t)$  и синаптических весов  $w_{jli}^p$ , подлежащих настройке. При подаче на  $li$ -й вход спайка с моментом активации  $t_{li}$  субсинапс генерирует постсинаптический потенциал

$$\epsilon_{jli}^p(t) = \epsilon(t - t_{li} - d^p),$$

где

$$\epsilon(t) = \begin{cases} \frac{t}{\tau} \exp(1 - \frac{t}{\tau}), & t \geq 0, \\ 0, & t < 0, \end{cases}$$

$\tau$  — постоянная времени, выбираемая из эмпирических соображений. Несложно заметить, что постсинаптический потенциал  $\epsilon(t)$  имеет форму функции распределения Вейбулла.

Выходом множественного синапса является сигнал

$$u_{jli}(t) = \sum_{p=1}^q w_{jli}^p \epsilon(t - t_{li} - d^p),$$

а составного спайк-нейрона в целом —

$$u_j(t) = \sum_{i=1}^n \sum_{l=1}^h \sum_{p=1}^q w_{jli}^p \epsilon(t - t_{li} - d^p).$$

Таким образом, входным сигналом второго скрытого слоя служит  $(hn \times 1)$ -вектор  $t$ , а выходом —  $(n \times 1)$ -вектор обобщенных постсинаптических потенциалов  $u(t) = (u_1(t), \dots, u_j(t), \dots, u_n(t))^T$ .

Интересно заметить также, что составной спайк-нейрон по архитектуре полностью совпадает с нео-фаззи-нейроном [15-18], а множественный синапс — с нелинейным синапсом, однако, при этом они реализуют совершенно разные функции.

Выходной слой СНС образован  $m$  стандартными радиально-базисными нейронами  $RBN_j$ ,  $j=1, 2, \dots, m$ , при этом центр каждой радиально-базисной многомерной функции  $c_j = (c_{j1}, c_{j2}, \dots, c_{jn})^T$  совпадает с вектором-прототипом соответствующего кластера. Выходные радиально-базисные нейроны связаны между собой латеральными связями, обеспечивающими определение принадлежности предъявленного образа  $x(k)$  к конкретному кластеру по принципу «победитель получает все» так, как это реализовано в самоорганизующихся картах Кохонена.

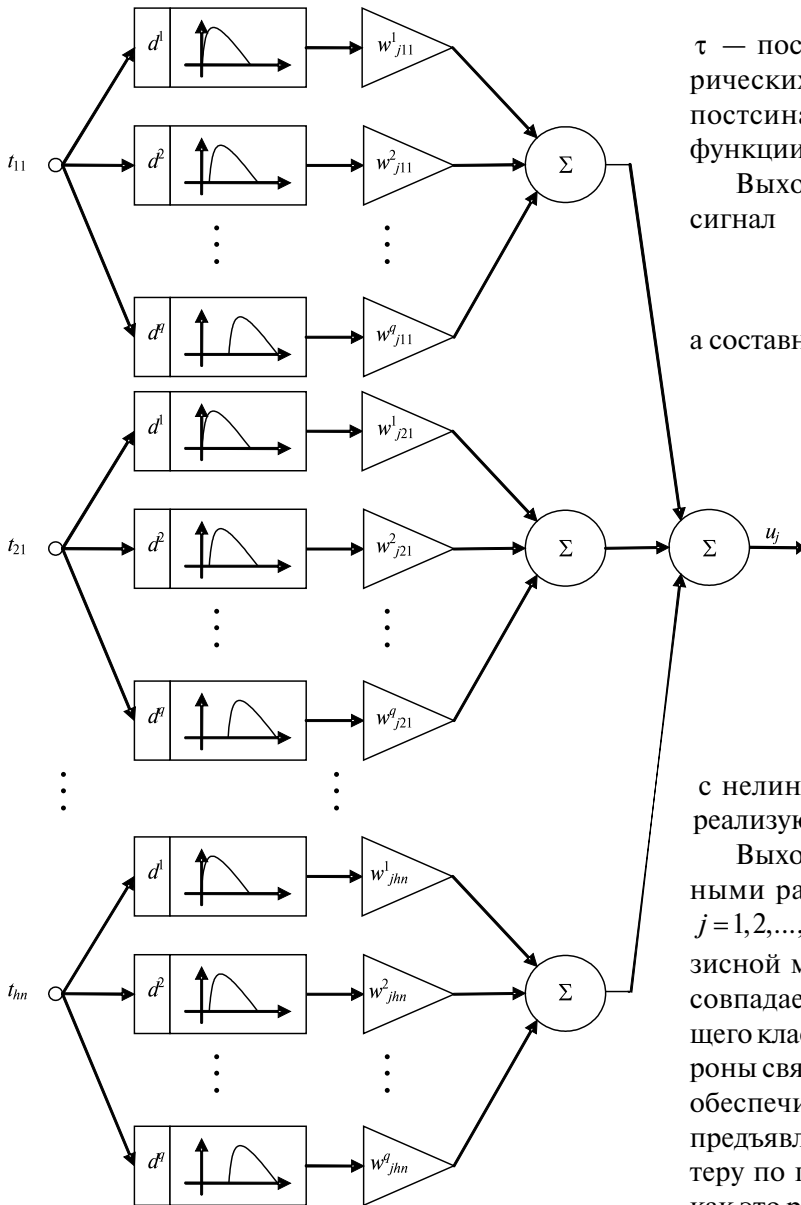


Рис. 4. Составной спайк-нейрон

Для вычисления координат центров радиально-базисных функций выходного слоя в рассмотрение вводится средняя задержка между входом и выходом [8], рассчитываемая согласно выражению

$$d_{ji} = \frac{\sum_{l=1}^h \sum_{p=1}^q w_{jli}^p d^p}{\sum_{l=1}^h \sum_{p=1}^q w_{jli}^p}, \quad j = 1, 2, \dots, m, \quad i = 1, 2, \dots, n.$$

Далее на основании этих задержек определяются собственно центры

$$c_{ji} = d_{ji} - \min\{d_{ji} \mid 1 \leq i \leq n\}, \quad (1)$$

которые устанавливаются в нейронах выходного слоя с активационными функциями  $\varphi_j(\|u - c_j\|^2, \sigma^2)$ , обычно выбираемыми в форме многомерных гауссианов

$$\varphi_j(\|u - c_j\|^2, \sigma^2) = \exp\left(-\frac{\|u - c_j\|^2}{\sigma^2}\right),$$

где параметр  $n$ -мерного рецепторного поля-гипершара  $\sigma$  выбирается из эмпирических соображений.

Латеральные связи между выходными нейронами в процессе самообучения не используются. Их роль проявляется в процессе кластеризации с помощью уже обученной сети, когда на ее вход подается образ, не принадлежащий обучающей выборке. Нейрон с наибольшим уровнем активации объявляется «победителем» и только на его входе появляется сигнал  $y_j$ , сигнализирующий о принадлежности предъявленного образа  $j$ -му кластеру.

## 2. Обучение спайк-нейронной сети

Обучение спайк-нейронной сети в задаче кластеризации обычно производится с помощью хэббовского правила самообучения [2], которое может быть записано в общем виде:

$$\Delta w_{jli}^p = \eta_w(k) L(\Delta t_{jli}),$$

где  $\eta_w > 0$  — скалярный параметр, определяющий скорость обучения;  $k$  — номер эпохи;  $L(\Delta t_{jli})$  — частная производная критерия обучения по настраиваемому параметру;  $\Delta t_{jli}$  — задержка момента активации спайк-нейрона при поступлении на его вход спайка от рецепторного нейрона, определяющаяся разностью

$$\Delta t_{jli} = t_{li} + d^p - t_j,$$

где  $t_{li}$  — момент активации  $l$ -го рецепторного нейрона для  $i$ -го входа;  $d^p$  — временная аксонная задержка  $p$ -го субсинапса;  $t_j$  — момент активации постсинаптического нейрона. Функция  $L(\bullet)$ , как правило, определяется выражением

$$L(\Delta t_{jli}) = \eta_w(k) \left( (1 + \beta) \exp\left(\frac{(\Delta t_{jli} - \alpha)^2}{2(K-1)}\right) - \beta \right),$$

$$K = 1 - \frac{v^2}{2 \ln \frac{\beta}{1 + \beta}},$$

где  $\alpha \geq 0$  — параметр сдвига;  $\beta$  — параметр смещения, устанавливающий значение, на которое будут уменьшаться веса;  $v$  — параметр ширины, определяющий характер функции  $L(\bullet)$ .

В рекуррентной форме алгоритм обучения слоя спайк-нейронов имеет следующий вид:

$$w_{jli}^p(k+1) = w_{jli}^p(k) + \eta_w(k) L(\Delta t_{jli}) \quad (2)$$

или

$$w_{jli}^p(k+1) = w_{jli}^p(k) + \eta_w(k) \left( (1 + \beta) \exp\left(\frac{(\Delta t_{jli} - \alpha)^2}{2(K-1)}\right) - \beta \right).$$

Функция  $L(\bullet)$  задается так, чтобы в процессе обучения веса тех субсинапсов, которые способствуют более ранней активации нейрона-победителя, увеличивались, а веса всех остальных субсинапсов нейрона уменьшались. Таким образом, изменение весов происходит так, чтобы центр соответствующего радиально-базисного нейрона приближался к входному образу.

При достаточно большой по объему обучающей выборке настройка может быть проведена за один проход алгоритма. В противном случае реализуется процесс обучения по эпохам, когда одна и та же выборка обрабатывается многократно.

После окончательной настройки синаптических весов  $w_{jli}^p$  могут быть определены центры радиально-базисных функций выходного слоя согласно выражению (1). Наряду с рассмотренным пакетным алгоритмом обучения может быть реализована и рекуррентная его версия, позволяющая обрабатывать данные в реальном времени по мере их поступления. При этом на основании текущих значений синаптических весов  $w_{jli}^p(k)$ , получаемых с помощью (2), вычисляются значения центров в виде:

$$d_{ji}(k) = \frac{\sum_{l=1}^h \sum_{p=1}^q w_{jli}^p(k) d^p}{\sum_{l=1}^h \sum_{p=1}^q w_{jli}^p(k)},$$

$$c_{ji}(k) = d_{ji}(k) - \min\{d_{ji}(k) \mid 1 \leq i \leq n\},$$

которые затем «сглаживаются» с помощью правила самообучения Кохонена:

$$\bar{c}_j(k+1) = \bar{c}_j(k) + \eta_c(k)(c_j(k) - \bar{c}_j(k)),$$

где  $\bar{c}_{gi}(k)$  — сглаженное значение центра радиально-базисной функции  $j$ -го нейрона на  $k$ -ой итерации обработки;  $\eta_c(k)$  — параметр шага, обычно выбираемый в соответствии с условиями Дворецкого.

### 3. Пример решения задачи кластеризации изображений

Спайк-нейронная сеть тестировалась на цветном спутниковом изображении размером 542 x 845 пикселей (рис. 5).



Рис. 5. Спутниковое изображение пл. Свободы (г. Харьков)

Для обучения использовалась выборка, сформированная половиной всех пикселей, выбранных случайным образом. На вход сети подавалась RGB-компонента каждого пикселя. Сеть имела по 3 рецепторных нейрона на каждом входе и по 5 радиально-базисных нейронов в выходном слое. Для сравнения та же самая задача была решена картой Кохонена. С целью графического представления результатов каждому кластеру в соответствие были поставлены оттенки серого. Результаты приведены на рис. 6. Представленный результат был получен на 4 эпохе для СНС и на 50 — для карты Кохонена.

Таким образом, для обучения предложенной СНС требуется как минимум на порядок меньше эпох, чем для карты Кохонена.

#### Заключение

Рассмотрены архитектура и алгоритм самообучения спайк-нейронной сети в задаче кластеризации, обеспечивающие высокие быстродействие и качество обработки информации. Спайк-нейронная сеть синтезирована на основе принципов, существенно отличающихся от методов построения и обработки данных в традиционных нейронных сетях и лежащих в основе биологических нейросистем живых организмов. Перспектива дальнейших исследований связана с введением нечеткости в процесс кластеризации в условиях перекрывающихся классов.



Рис. 6. Результат кластеризации спутникового изображения предложенной СНС (справа) и картой Кохонена (слева)

- Список литературы:** 1. *Jang J.-Sh. R., Sun Ch.-T., Mizutani E.* Neuro-Fuzzy and Soft Computing: a Computational Approach to Learning and Machine Intelligence. — Upper Saddle River, N.J.: Prentice Hall, Inc., 1997. — 614 p. 2. *Haykin S.* Neural Networks. A Comprehensive Foundation. — Upper Saddle River, N.J.: Prentice Hall, Inc., 1999. — 842 p. 3. *Hoppner F., Klawonn F., Kruse R.* Fuzzy-Clusteranalyse. Verfahren für die Bilderkennung, Klassifikation und Datenanalyse. — Braunschweig: Vieweg, 1996. — 280 S. 4. *Sato-Ilic M., Jain L.C.* Innovations in Fuzzy Clustering. — Berlin Heidelberg New York: Springer, 2006. — 152 p. 5. *Maass W.* Networks of spiking neurons: the third generation of neural network models // Neural Networks. — 1997. — 10. — P. 1659-1671. 6. *Natschlager T.* Networks of spiking neurons: a new generation of neural networks models. — 1998. — [http://www.igi.tugraz.at/tnatschl/online/3rd\\_gen\\_eng/3rd\\_gen\\_eng.html](http://www.igi.tugraz.at/tnatschl/online/3rd_gen_eng/3rd_gen_eng.html). 7. *Пыпкин Я. З.* Теория линейных импульсных систем. — Москва: Физматгиз, 1963. — 968 с. 8. *Natschlager T., Ruf B.* Spatial and temporal pattern analysis via spiking neurons // Network: Computations in Neural Systems. — 1998. — 9. — P. 319-332. 9. *Bohte S.M., Kok J.S., La Poutre H.* Unsupervised clustering with spiking neurons by sparse temporal coding and multi-layer RBF networks // IEEE Trans. on Neural Networks. — 2002. — 13. — P. 426-435. 10. *Долотов А.И.* Обучение без учителя на основе сети спайк-нейронов // Системный анализ и информационные технологии: Материалы IX Междунар. науч.-техн. конф. (15-19 мая 2007 г., Киев). — К.: НТУУ “КПИ”, 2007. — С. 104. 11. *H. P. Snippe.* Parameter extraction from population codes: a critical assesment // Neural Computation. — 1996. — 8(4). — P. 511-529. 12. *Zhang K., Sejnowski T.J.* Neuronal tuning: to sharpen or broaden? // Neural Computation. — 1999. — 11. — P. 75-84. 13. *Долотов А.И., Викторов Е.А.* Применение рецепторных полей в спайк-нейронных сетях при решении задачи кластеризации // 11-й междунар. молодежный форум “Радиоэлектроника и молодежь в XXI веке.”: Сб. материалов форума. — Харьков: ХНУРЭ, 2007. — Ч.1. — С. 351. 14. *Bohte S.M., Kok J.S., La Poutre H.* Error back-propagation in temporally encoded networks of spiking neurons // Neurocomputing. — 2002. — 48. — P. 17-37. 15. *Yamakawa T., Uchino E., Miki T., Kusanagi H.* A neo fuzzy neuron and its applications to system identification and prediction of the system behavior // Proc. 2nd Int. Conf. on Fuzzy Logic and Neural Networks “IIZUKA-92”. — Iizuka, Japan, 1992. — P. 477-483. 16. *Miki T., Yamakawa T.* Analog implementation of neo-fuzzy neuron and its on-board learning / Ed. N. E. Mastorakis “Computational Intelligence and Applications”. — Piraeus: WSES Press, 1999. — P. 144-149. 17. *Bodyanskiy Ye., Kokshenev I., Kolodyazhniy V.* An adaptive learning algorithm for a neo fuzzy neuron // Proc. 3rd Int. Conf. of European Union Society for Fuzzy Logic and Technology “EUSFLAT 2003”. — Zittau, Germany, 2003. — P. 375-379. 18. *Kolodyazhniy V., Bodyanskiy Ye., Otto P.* Universal approximator employing neo-fuzzy neuron / Ed. B. Reusch. — Berlin-Heidelberg: Springer, 2005. P. 631-640.

Поступила в редколлегию 26.09.2007