

УДК 519.7:004.8

НЕО-ФАЗЗИ ПОДХОД В ЗАДАЧАХ ONLINE МЕДИКО-БИОЛОГИЧЕСКОЙ ДИАГНОСТИКИ

Е. Н. БРАЖНИКОВА, И. Г. ПЕРОВА, И. П. ПЛИСС

В работе рассматривается применение для интеллектуального анализа медицинских данных методов вычислительного интеллекта, а именно адаптивного линейного элемента (адалины и мадалины) и нелинейную обучаемую систему — нео-фаззи-нейрон. Разработаны алгоритмы их обучения для ситуаций, когда информация поступает на обработку в online-режиме. Разработана многомерная нео-фаззи система, предназначенная для решения задач медицинской диагностики, классификации, распознавания образов.

Ключевые слова: нео-фаззи нейрон, диагностика, адаптивный линейный элемент, синаптический вес.

ВВЕДЕНИЕ

В настоящее время в задачах интеллектуального анализа медицинских данных (Medical Data Mining) все чаще используются методы вычислительного интеллекта [1, 2] и, прежде всего, искусственные нейронные сети и нечеткие системы, благодаря возможности обучения по экспериментальным классифицированным и неклассифицированным данным и прозрачности и интерпретируемости получаемых результатов [3]. Среди множества возможных задач возникающих в рамках Medical Data Mining особое место занимает проблема диагностирования состояния организма по множеству показателей, измеряемых в тех или иных шкалах.

С формальной точки зрения задача медико-биологической диагностики усложняется целым рядом обстоятельств, таких как:

- невыпуклость и перекрытие классов, соответствующих разным диагнозам;
- «зашумленность» (включая аномальные выбросы) и нестационарность массивов исходных данных;
- возможность наличия как сверхмалых обучающих выборок, соразмерных с размерностью векторов признаков, так и очень больших объемов информации, вписывающихся в концепцию Big Data;
- возможность и необходимость представления исходной информации в форме потоков данных (Data Stream), последовательно поступающих на обработку в online режиме.

Отмеченные обстоятельства существенно ограничивают класс известных систем вычислительного интеллекта, пригодных для работы в описанных условиях, хотя наиболее перспективными в этом случае представляются нейро-фаззи-системы [4], которые наряду с высокими аппроксимирующими и экстраполирующими возможностями и способностью к обучению позволяют обеспечить и лингвистическую интерпретацию результатов. Понятно, что и эти

системы не являются панацеей в данном случае, поскольку подвержены «проклятию размерности» в случае решетчатого разбиения пространства входов или возникновению «дыр» в этом же пространстве в случае рассеянного разбиения [5].

Понятно, что синтез диагностирующей нейро-фаззи-системы, лишенной отмеченных недостатков, эффективной в условиях «зашумленных» и нестационарных сверхмалых и сверхбольших выборок, поступающих на вход системы в режиме реального времени, является актуальной задачей.

1. АДАПТИВНОЕ ДИАГНОСТИРОВАНИЕ В СЛУЧАЕ ЛИНЕЙНО РАЗДЕЛИМЫХ КЛАССОВ

Исторически первой системой бинарной online-диагностики является адаптивный линейный элемент (ADALINE), предложенный Б. Уидроу [6, 7]. На рис. 1 приведена его структурная схема.

Структурно адалина весьма напоминает популярный нейрон Маккалоха-Питтса [7] с активационной сигнум-функцией и состоит из двух основных частей: адаптивного линейного ассоциатора и нелинейной активационной функции. Адалина имеет $n+1$ входов

$$x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T \in R^n$$

(здесь $k=1, 2, \dots$ — текущее дискретное время) и два выхода: аналоговый $u(k)$ и бинарный $y(k)$. Кроме того имеется дополнительный вход, на который подается обучающий сигнал $d(k) \in \{-1, 1\}$, показывающий какова должна быть желаемая реакция системы на каждый конкретный набор входных векторов признаков $x(k)$.

Аналоговый выход $u(k)$ представляет собой взвешенную сумму входов $x_i(k)$; $i=0, 1, \dots, n$; $x_0(k)=1$

$$u(k) = \sum_{i=0}^n w_i(k) x_i(k) = w^T(k) x(k)$$

(здесь $w(k) = (w_0(k), w_1(k), \dots, w_n(k))^T$ – $(n+1) \times 1$ – вектор синаптических весов, непрерывно уточняемых в процессе обучения), а бинарный (диагностический) выход может принимать значения $+1$ или -1 в зависимости от полярности аналогового сигнала $u(k)$.

Сигнал $u(k)$ сравнивается с внешним обучающим сигналом $d(k)$, а возникающий при этом сигнал ошибки обучения

$$e(k) = d(k) - u(k) \quad (1)$$

Поступает в алгоритм настройки, который уточняет вектор синаптических весов так, чтобы минимизировать критерий обучения

$$\begin{aligned} E(k) &= \frac{1}{2} e^2(k) = \frac{1}{2} (d(k) - u(k))^2 = \\ &= \frac{1}{2} (d(k) - w^T(k)x(k))^2. \end{aligned} \quad (2)$$

Алгоритм обучения адалины, известный также как алгоритм обучения Уидроу-Хоффа имеет вид:

$$\begin{aligned} w(k+1) &= w(k) + \frac{e(k)x(k)}{\|x(k)\|^2} = \\ &= w(k) + \frac{(d(k) - w^T(k)x(k))x(k)}{\|x(k)\|^2} = \\ &= w(k) + e(k)x^{+T}(k) \end{aligned} \quad (3)$$

и является по сути оптимальной по быстродействию градиентной процедурой оптимизации критерия обучения (2).

Рассматривая процесс обучения адалины с помощью теории распознавания образов содержательно достаточно близкой к задачам диагностики, можно проводить настройку синаптических весов используя не аналоговый сигнал $u(k)$, а бинарную последовательность $y(k)$. Вводя в рассмотрение вместо (1) ошибку

$$e(k) = d(k) - y(k) = d(k) - \text{sign } u(k)$$

и критерий обучения [8]

$$E(k) = e(k)u(k) = d(k)u(k) - |u(k)| =$$

несложно записать градиентную процедуру его минимизации

$$w(k+1) = w(k) + \eta(k)e(k)x(k) =$$

$$= w(k) + \eta(k)(d(k) - \text{sign } w^T(k)x(k))x(k)$$

(здесь $\eta(k) > 0$ – параметр шага обучения) и ее оптимизированную версию [9]

$$\begin{aligned} w(k+1) &= w(k) + \frac{d(k) - \text{sign } w^T(k)x(k)}{\|x(k)\|^2} x(k) = \\ &= w(k) + (d(k) - \text{sign } w^T(k)x(k))x^{+T}(k). \end{aligned} \quad (4)$$

Понятно, что адалина является простейшей системой, позволяющей осуществлять лишь бинарную классификацию типа «да» и «нет». В реальных задачах диагностическая система должна отображать множество факторов-признаков $x(k) \in R^n$ во множество диагнозов $u(k) \in R^m$, $y(k) \in R^m$, где $u(k) = (u_1(k), \dots, u_j(k), \dots, u_m(k))^T$, $y(k) = (y_1(k), \dots, y_j(k), \dots, y_m(k))^T$. Такой системой является MADALINE (Мадалина) [10], представляющая по сути m параллельно подключенных к общим входам обычных адалин.

Тогда для j -го входа мадалины можно записать:

$$u_j(k) = w_j^T(k)x(k),$$

$$y_j(k) = \text{sign } u_j(k) \quad \forall j = 1, 2, \dots, m$$

(здесь $w_j(k) = (w_{j0}(k), w_{j1}(k), \dots, w_{jn}(k))^T$, $e_j(k) = d_j(k) - u_j(k)$ или $e_j(k) = d_j(k) - \text{sign } u_j(k)$, $E_j(k) = \frac{1}{2} e_j^2(k)$ или $E_j(k) = e_j(k)u_j(k)$ и для настройки синаптических весов использовать алгоритмы (3), (4) в форме




Рис. 1. ADALINE (Адалина)

$$w_j(k+1) = w_j(k) + (d_j(k) - w_j^T(k)x(k))x^{+T}(k), \quad (5)$$

$$w_j(k+1) = w_j(k) + (d_j(k) - \text{sign } w_j^T(k)x(k))x^{+T}(k). \quad (6)$$

Несложно ввести в рассмотрение и алгоритмы обучения всех синаптических весов мадалины в целом. Для этого вводя общие критерии обучения

$$E_j(k) = \sum_{j=1}^m E_j(k) = \frac{1}{2} \sum_{j=1}^m e_j^2(k),$$

$$E_j(k) = \sum_{j=1}^m E_j(k) = \sum_{j=1}^m e_j(k)u_j(k),$$

$(m \times (n+1))$ – матрицу настраиваемых весов

$$W(k) = \begin{pmatrix} w_1^T(k) \\ w_2^T(k) \\ \dots \\ w_m^T(k) \end{pmatrix}$$

и $(m \times 1)$ – векторы $d(k) = (d_1(k), d_2(k), \dots, d_m(k))^T$, $\text{sign } u(k) = (\text{sign } u_1(k), \text{sign } u_2(k), \dots, \text{sign } u_m(k))^T$, вместо (5) можно записать многомерную модификацию алгоритма Уидроу-Хоффа [11]

$$W(k+1) = W(k) + \frac{d(k) - W(k)x(k)}{\|x(k)\|^2} x^T(k) = \quad (7)$$

$$= W(k) + (d(k) - W(k)x(k))x^{+T}(k),$$

а вместо (6) – многомерный алгоритм [12]

$$W(k+1) = W(k) + \frac{d(k) - \text{sign } W(k)x(k)}{\|x(k)\|^2} x^T(k) = \quad (8)$$

$$= W(k) + (d(k) - \text{sign } W(k)x(k))x^{+T}(k).$$

2. АДАПТИВНОЕ ДИАГНОСТИРОВАНИЕ НА ОСНОВЕ НЕЙРО-ФАЗЗИ ПОДХОДА

Диагностирование с помощью адалины и мадалины возможно лишь в случае линейной разделимости классов диагнозов. Поскольку в реальных ситуациях это далеко не так, а классы могут иметь произвольную форму и, более того, пересекаться, на первый план выходят нейро-фаззи-технологии [4], адаптированные для задач диагностики.

Одной из таких нелинейных обучаемых систем является нео-фаззи-нейрон [13,14], архитектура которого для рассматриваемых задач приведена на рис. 2.




Рис. 2. Нео-фаззи нейрон

Как несложно заметить, нео-фаззи-нейрон по архитектуре достаточно близок к адалине, однако в отличие от нее содержит нелинейные синапсы NS_i , в которых реализуются элементарные правила нечеткого вывода типа

$$IF\ x_i(k)\ IS\ X_{li}\ THEN\ f_i(x_i(k)) = \sum_{l=1}^h w_{li}(k) \mu_{li}(x_i(k)),$$

где X_{li} – лингвистическое значение (нечеткое множество) на i -м входе в антецеденте l -го правила ($l=1,2,\dots,h$), $\mu_{li}(x_i(k))$ – функция принадлежности нелинейного синапса NS_i , w_{li} – синаптический вес-синглтон в консеквенте l -го правила, h – количество функций принадлежности в каждом нелинейном синапсе.

При поступлении на вход нео-фаззи-нейрона векторного сигнала

$$x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T \in R^n$$

на его аналоговом выходе появляется скалярное значение

$$u(k) = \sum_{i=1}^n f_i(x_i(k)) = \sum_{i=1}^n \sum_{l=1}^h w_{li}(k) \mu_{li}(x_i(k)) \quad (9)$$

а на бинарном $y(k) = \text{sign } u(k)$.

Следует отметить, что несмотря на свою простоту нео-фаззи-нейрон является по сути системой нечеткого вывода Такати-Сугено нулевого порядка [4] и достаточно близок по архитектуре к радиально-базисным нейронным сетям [7], то есть обладает достаточно высокими аппроксимирующими свойствами в смысле нелинейных функций достаточно произвольного вида.

В качестве функций принадлежности в нео-фаззи-нейроне обычно используются треугольные конструкции (хотя возможно использование других ядерных функций, например, В-сплайнов), значение которых определяется расстоянием между величиной входного сигнала x_i и центрами этих функций c_{li} :

$$\mu_{li}(x_i) = \begin{cases} \frac{x_i - c_{l-1,i}}{c_{li} - c_{l-1,i}}, & x_i \in [c_{l-1,i}, c_{li}], \\ \frac{c_{l+1,i} - x_i}{c_{l+1,i} - c_{li}}, & x_i \in [c_{li}, c_{l+1,i}], \\ 0, & \text{в противном случае,} \end{cases}$$

$$\begin{cases} \mu_{li}(x_i) = \frac{c_{li} - x_i}{c_{2i}}, \\ \mu_{hi}(x_i) = \frac{x_i - c_{h-1,i}}{1 - c_{h-1,i}}, \end{cases}$$

$c_{li} = 0$, $c_{2i} = \frac{1}{h-1}$, ..., $c_{li} = \frac{l-1}{h-1}$, ..., $c_{hi} = 1$, при этом естественно предполагается, что все исходные данные закодированы в интервал $x_i \in [0, 1]$.

Важно отметить также, что подобная конструкция функций принадлежности автоматически обеспечивает условие единичного разбиения

$$\sum_{l=1}^h \mu_{li}(x_i) = 1,$$

то есть нео-фаззи-нейрон не требует дефаззификации результатов производимых им вычислений.

Вводя в рассмотрение $(nh \times 1)$ – векторы текущих значений уровней принадлежности

$$\mu(k) = (\mu_{11}(x_1(k)), \mu_{21}(x_1(k)), \dots, \mu_{h1}(x_1(k)), \dots, \mu_{li}(x_i(k)), \dots, \mu_{hn}(x_n(k)))^T$$

и синаптических весов

$$w(k) = (w_{11}(k), \dots, w_{h1}(k), \dots, w_{li}(k), \dots, w_{hn}(k))^T$$

можно записать значение аналогового сигнала на выходе нео-фаззи-нейрона (9) в виде

$$u(k) = w^T(k) \mu(k),$$

что позволяет использовать для его обучения модификация алгоритма Уидроу-Хоффа (3) в виде [15]

$$w(k+1) = w(k) + \frac{(d(k) - w^T(k) \mu(k)) \mu(k)}{\|\mu(k)\|^2} = w(k) + (d(k) - w^T(k) \mu(k)) \mu^{+T}(k) \quad (10)$$

Поскольку одношаговые градиентные процедуры обучения типа (3), (10) достаточно плохо работают в условиях «зашумленных» наблюдений в [16] была введена модификация (10), обладающая как фильтрующими, так и следящими свойствами, которая в данном случае приобретает вид

$$\begin{cases} w(k+1) = w(k) + \\ + r^{-1}(k) (d(k) - w^T(k) \mu(k)) \mu(k), \\ r(k) = \alpha r(k-1) + \|\mu(k)\|^2, \quad 0 \leq \alpha \leq 1 \end{cases} \quad (11)$$

где α – параметр сглаживания.

Несложно также ввести в рассмотрение аналог процедуры обучения (4) для нео-фаззи-нейрона:

$$w(k+1) = w(k) + (d(k) - \text{sign } w^T(k) \mu(k)) \mu^{+T}(k) \quad (12)$$

и

$$\begin{cases} w(k+1) = w(k) + \\ + r^{-1}(k) (d(k) - \text{sign } w^T(k) \mu(k)) \mu(k), \\ r(k) = \alpha r(k-1) + \|\mu(k)\|^2, \quad 0 \leq \alpha \leq 1, \end{cases} \quad (13)$$

В задачах многомерной диагностики можно было бы подобно мадалине соединить параллельно m нео-фаззи-нейронов, однако такая система была бы избыточной и слишком громоздкой. В связи с этим целесообразно воспользоваться модификацией многомерного нео-фаззи-нейрона [17], чья архитектура приведена на рис. 3.

Как видно, в этой архитектуре функции принадлежности $\mu_{ji}(x_i)$ являются общими для всех выходов системы $u_j(k)$, $y_j(k)$, $j = 1, 2, \dots, m$. Для обучения такой системы, воспользовавшись

тем очевидным фактом, что $u_j(k) = w^T(k)\mu(k)$, $y_j(k) = \text{sign } u_j(k)$ логично было бы применить процедуры настройки синаптических весов отдельно для каждого выхода типа (10)-(12). Для обучения же одновременно всех весов введем в рассмотрение $(m \times nh)$ -матрицу

$$W(k) = \begin{pmatrix} w_{111}(k), \dots, w_{1h1}(k), \dots, w_{1li}(k), \dots, w_{1hn}(k) \\ w_{211}(k), \dots, w_{2h1}(k), \dots, w_{2li}(k), \dots, w_{2hn}(k) \\ \vdots \\ w_{m11}(k), \dots, w_{mh1}(k), \dots, w_{mli}(k), \dots, w_{mhn}(k) \end{pmatrix}$$

и запишем преобразование, реализуемое рассматриваемой системой в виде

$$u(k) = W(k)\mu(k), \quad y(k) = \text{sign } u(k). \quad (14)$$

Тогда многомерный аналог алгоритма (11) может быть представлен в форме [18, 19]

$$\begin{cases} W(k+1) = W(k) + \\ + r^{-1}(k)(d(k) - W(k)\mu(k))\mu^T(k), \\ r(k) = \alpha r^{-1}(k-1) + \|\mu(k)\|^2, \quad 0 \leq \alpha \leq 1, \end{cases} \quad (15)$$

при $\alpha = 0$ получаем аналог (10) в виде

$$W(k+1) = W(k) + (d(k) - W(k)\mu(k))\mu^+(k), \quad (16)$$

а процедуре (13) соответствует выражение

$$\begin{cases} W(k+1) = W(k) + \\ + r^{-1}(k)(d(k) - \text{sign } W(k)\mu(k))\mu^T(k), \\ r(k) = \alpha r^{-1}(k-1) + \|\mu(k)\|^2, \quad 0 \leq \alpha \leq 1, \end{cases} \quad (17)$$

Таким образом, с помощью модифицированного многомерного нео-фаззи-нейрона, представленного на рис. 3 и адаптивных алгорит-




Рис. 3. Многомерный нео-фаззи нейрон в задачах диагностики

мов обучения (14-17) можно решать достаточно широкий класс задач online диагностики в режиме последовательной обработки информации.

ВЫВОДЫ

Предложена диагностирующая многомерная нео-фаззи-система и группа адаптивных алгоритмов ее обучения, предназначенная для решения задач медицинской диагностики, классификации, распознавания образов в условиях, когда информация поступает на обработку в online режиме в форме потока данных. Система характеризуется простотой численной реализации и высокой скоростью настройки параметров, благодаря использованию оптимизированных по быстродействию алгоритмов обучения.

Литература

- [1] *Rizzo R.* Computational Intelligence Methods for Bioinformatics and Biostatistics / Rizzo R. - In Lecture Notes in Bioinformatics (7th International Meeting, CIBIB 2010, Palermo, Italy, September 16-18, 2010). - Springer. - 2011. - 301 p.
- [2] *Kountchev R.* Advances in Intelligent Analysis of Medical Data and Decision Support Systems (Studies in Computational Intelligence) / Kountchev R. and etc - Springer. - 2013. - 246 p.
- [3] *L. Rutowski,* Computational Intelligence. Methods and Techniques, *Berlin-Heidelberg: Springer-Verlag,* 2008. - 514 p.
- [4] *Jang J.-S.R.* Neuro-Fuzzy and Soft Computing / J.-S.R. Jang, C.-T. Sun, E. Mizutani. - Prentice Hall, Upper Saddle River, NJ. - 1997. - 640 p.
- [5] *Бодянский Е.В., Винокурова Е.А., Мулеса П.П., Перова И.Г.* Диагностирующая нейро-фаззи-система и ее адаптивное обучение в задачах интеллектуальной обработки данных медико-биологических исследований / Системные технологии. - 2014. - Вып. 2 (91). - с. 125-135.
- [6] *Widrow B., Hoff Jr. M.E.* Adaptive switching circuits // IRE Western Electric Show and Convention (WESCON). - 1960. - Part 4. - P. 96-104.
- [7] *Cichocki A., Unbehauen R.* Neural Networks for Optimization and Signal Processing. - Stuttgart: B.G. Teubner, 1993. - 526 p.
- [8] *Shynk J.J.* Performance surfaces of a single-layer perceptron / Shynk J.J. // IEEE Trans. on Neural Networks. - 1990. - 1. - P. 268-274.
- [9] *Бодянский Е.В., Кучеренко Е.И., Чапланов А.П.* Диагностика и прогнозирование временных рядов с помощью многослойной радиально-базисной нейронной сети // Труды 8-й Всероссийской конф. с междунар. участием «Нейрокомпьютеры и их применение», Москва, 2002, 209-213.
- [10] *Widrow B., Lehr M.A.* 30 years of adaptive neural networks: perceptron, madaline and backpropagation // Proc. of the IEEE. - 1990. - 78. - №9. - P. 1415-1442.
- [11] *Руденко О.Г., Бодянский Е.В., Плисс И.П.* Адаптивный алгоритм прогнозирования случайных последовательностей // Автоматика. - 1979. - № 1. - С. 51-54.
- [12] *Бодянский Е.В., Кучеренко Е.И., Михалев А.И.* Нейро-фаззи сети Петри в задачах моделирования сложных систем // Днепрпетровск: Системные технологии, 2005, 311 с.
- [13] *T. Yamakawa, E. Uchino, T. Miki, and H. Kusanagi.* A neo fuzzy neuron and its applications to system identification and prediction of the system behaviour. Proc. 2nd Int. Conf. on Fuzzy Logic and Neural Networks, pp. 477-483, 1992.
- [14] *Miki T., Yamakawa T.* Analog implementation of neo-fuzzy neuron and its on-board learning / Ed. by N.E. Mastorakis "Computational Intelligence and Applications". - Piraeus: WSES PRESS, 1999. - p. 144-149.
- [15] *Bodyanskiy Ye., Kokshenev I., Kolodyazhnyi V.* An adaptive learning algorithm for a neo-fuzzy neuron // Proc. 3-rd Int. Conf. of European Union Society for Fuzzy Logic and Technology "EUSFLAT 2003". - Zittau, Germany, 2003. - P. 375-379.
- [16] *Otto P., Bodyanskiy Ye., Kolodyazhnyi V.* A new learning algorithm for forecasting neural-fuzzy network // Integrated Computer-Aided Engineering. - 10. - №4. - 2003. - P. 399-409.
- [17] *Landim R.P., Rodrigues B., Silva S.R., Matos W.* A neo-fuzzy-neuron with real-time training applied to flux observer for an induction motor // Proc. Vth Brazilian Symp. on Neural Networks. - Los Alamitos, CA: IEEE Computes Society, 1998. - p.67-72.
- [18] *Бодянский Е., Тищенко О., Копалині Д.* Прогнозування багатовимірних часових рядів на основі адаптивної нейро-фаззі моделі // Вісник НУ "Львівська політехніка". Комп'ютерні науки та інформаційні технології. - 2012. - №744. - с.312-318.
- [19] *Bodyanskiy Ye., Tishchenko O., Wojcik W.* Multivariate non-stationary time series predictor based on an adaptive neuro-fuzzy approach // Elektronika. - 2013. - №8. - P. 10-13.

Поступила в редколлегию

Перова Ирина Геннадьевна, к.т.н., с.н.с., доцент, доцент кафедры биомедицинской инженерии Харьковского национального университета радиоэлектроники. Научные интересы: интеллектуальная обработка данных медико-биологических исследований (Medical Data Mining).



Бражникова Елизавета Николаевна, студент группы ИТБМм-15-1 Харьковского национального университета радиоэлектроники. Научные интересы: методы интеллектуального анализа данных для задач медицины.



Плисс Ирина Павловна, к.т.н., с.н.с., ведущий научный сотрудник Проблемной научно-исследовательской лаборатории АСУ Харьковского национального университета радиоэлектроники. Научные интересы: гибридные системы вычислительного интеллекта, нейро-фаззи системы.



УДК 519.7:004.8

Нео-фаззі підхід в задачах online медико-біологічної діагностики / Є. М. Бражнікова, І. Г. Перова, І. П. Плїсс // Прикладна радіоелектроніка: наук.-техн. журнал. — 2016. — Том 15. — № 1. — С. 00–00.

В роботі розглядається застосування для інтелектуального аналізу медичних даних методів обчислювального інтелекту, а саме адаптивного лінійного елемента (АДАЛІН і Мадаліни) і нелінійну систему, що навчається — нео-фаззі-нейрон. Розроблено алгоритми їх навчання для ситуацій, коли інформація надходить на обробку в онлайн-режимі. Розроблено багатовимірну нео-фаззі систему, призначена для вирішення завдань медичної діагностики, класифікації, розпізнавання образів.

Ключові слова: нео-фаззі нейрон, діагностика, адаптивний лінійний елемент, синаптична вага.

Рис. 03. Бібліогр.: 19 найм.

UDC 519.7:004.8

Neo-fuzzy approach for medical diagnostics tasks in online-mode / E. M. Braghnikova, I. G. Perova, I. P. Pliss // Applied Radio Electronics: Sci. Journ. — 2016. — Vol. 15. — № 1. — P. 00–00.

Diagnostic multidimensional neo-fuzzy system and group of adaptive algorithms for it training, assigned for tasks of medical diagnostics, classification, pattern recognition when information is fed in online-mode was proposed.

Keywords: neo-fuzzy neuron, diagnosys, adaptive linear element, synaptic weight

Fig. 03. Ref.: 19 items.