

## КОМПРЕССИЯ ДАННЫХ МЕДИЦИНСКОГО МОНИТОРИНГА С ПОМОЩЬЮ ГИБРИДНОЙ СИСТЕМЫ ВЫЧИСЛИТЕЛЬНОГО ИНТЕЛЛЕКТА

<sup>1</sup>Е.В. Бодянский, <sup>1</sup>Е.А. Винокурова, <sup>2</sup>П.П. Мулеса, <sup>3</sup>А.Н. Слипченко

<sup>1</sup>Харьковский национальный университет радиоэлектроники; 61166, г. Харьков, пр. Ленина, 14, e-mail: bodya@kture.kharkov.ua, vinokurova@kture.kharkov.ua

<sup>2</sup>Ужгородский национальный университет; 88000, м. Ужгород, пл. Народна, 3, e-mail: ppmulesa@gmail.com

<sup>3</sup>Харьковский национальный университет им. Каразина; 61022, Харьков, площадь Свободы 4, e-mail: slipchenko@gmail.com

Однією з важливих проблем, що пов'язана з обробкою великих масивів даних, є задача їх стиснення (компресії) без істотної втрати інформації, що присутня у початковому масиві. Для вирішення таких задач на сьогодні розроблена ціла низка методів. Кожен із таких підходів має свої переваги, недоліки, галузі доцільного застосування тощо. Пропонується гібридна система обчислювального інтелекту для компресії великих масивів інформації та її метод навчання, що поєднує у собі можливості методу головних компонентів, штучних нейронних мереж, вейвлет-аналізу, довірливих систем нечіткого виведення.

Ключові слова: Компресія великих масивів даних, гібридний нейро-фаззи компресор, обчислювальний інтелект, медичний моніторинг

Одной из важных проблем, связанных с обработкой крупных массивов данных, является задача их сжатия (компрессии) без существенной потери информации, содержащейся в исходном массиве. Для решения указанных задач на сегодня разработан целый ряд методов. Каждый из таких подходов имеет свои преимущества, недостатки, области целесообразного применения и т.п. Предлагается гибридная система вычислительного интеллекта для компрессии крупных массивов информации и метод ее обучения, объединяющая в себе возможности метода главных компонент, искусственных нейронных сетей, вейвлет-анализа, различных систем нечеткого вывода.

Ключевые слова: Компрессия больших массивов данных, гибридный нейро-фаззи-компрессор, вычислительный интеллект, медицинский мониторинг.

One of the most important problems that is connected with big data processing is the task of data compression without significant loss of information, which is contained in an initial data set. Today to solve such problems a lot of methods are proposed. Each approach has advantages, disadvantages, appropriate areas of usage etc. Thus, the paper suggests hybrid system of computational intelligence for big data compression and its learning algorithm. This system combines the capabilities of principal component analysis, artificial neural networks, wavelet-analysis, and different fuzzy inferences systems.

Key words: big data compression, hybrid neuro-fuzzy compressor, computational intelligence, medical monitoring.

### Введение

Последние годы методы интеллектуально-го анализа данных на основе систем вычислительного интеллекта таких как искусственные нейронные сети, фаззи- и нео-фаззи системы, гибридные архитектуры получили достаточно широкое распространение в медицинских приложениях, благодаря своим высоким аппроксимирующим возможностям, способности к обучению и лингвистической интерпретации результатов [1-6].

Одной из важных проблем, связанных с обработкой больших массивов данных, является задача их сжатия (компрессии) без существенной потери информации, содержащейся в исходном массиве. Для решения подобных задач на сегодня разработан целый ряд методов таких, как метод главных компонент [7], линейный дискриминантный анализ [8], вейвлет-

анализ [9-11], специализированные нейронные сети: «Бутылочное горлышко» [12], Хэбба-Сэнгера [13], Оя-Карунена [14-16] и их модификации [17-23]. Каждый из указанных подходов имеет свои достоинства, недостатки, области целесообразного применения и т.п.

Представляется целесообразным, объединив достоинства отмеченных методов, разработать гибридную систему вычислительного интеллекта, объединяющую в себе возможности метода главных компонент, искусственных нейронных сетей, вейвлет-анализа, различных систем нечеткого вывода.

### Вейвлет-нейро-компрессор

В [24, 25] была введена гибридная двухслойная вейвлет-нейронная архитектура для решения задачи компрессии временных рядов и алгоритм её обучения, сочетающие преимуще-

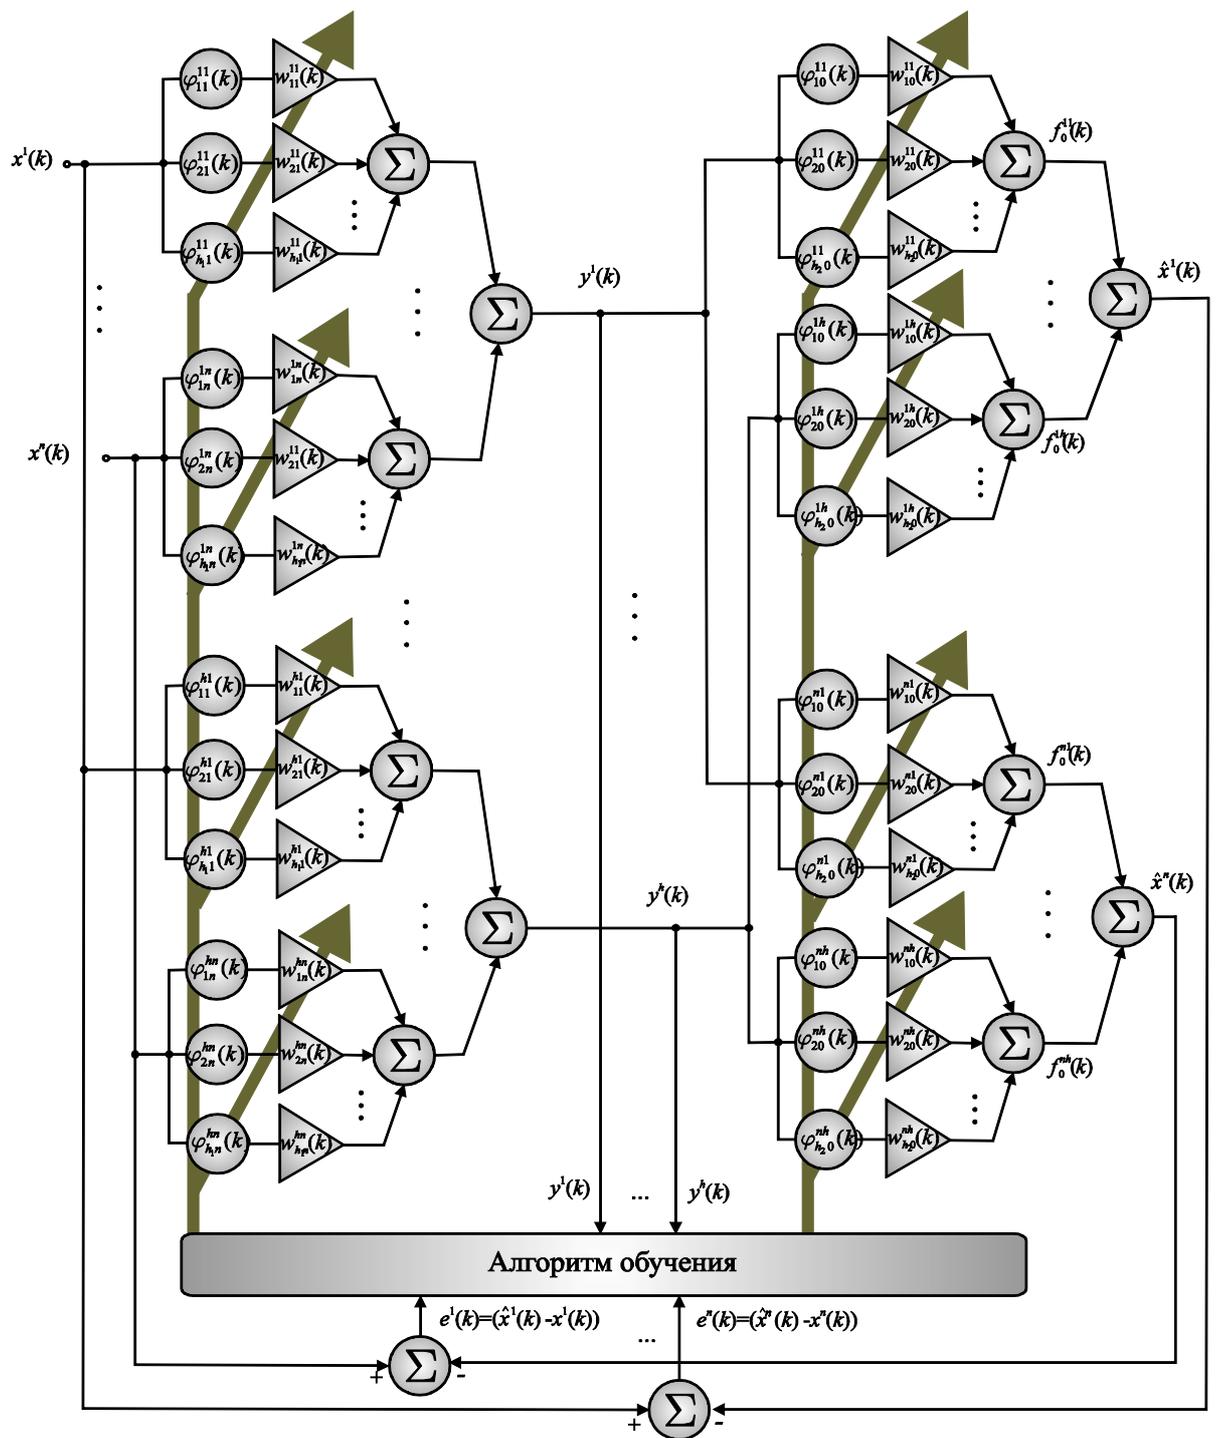


Рисунок 1 – Архитектура вэйвлет-нейро-компрессора

ства теории нейронных сетей и теории вэйвлетов, а именно способность к обобщению и обучению с возможностью выявления локальных особенностей в анализируемой информации.

Строительным элементом такой системы является вэйвлет-нейрон [26] с нелинейными вэйвлет-синапсами, а ее архитектура приведена на рис. 1.

При подаче на вход многомерного сигнала  $X = \{x^1(k), x^2(k), \dots, x^n(k)\}$  на выходе системы получаем сигналы вида (так называемые главные компоненты):

$$y^m(k) = \sum_{i=1}^n \sum_{l=1}^{h_1} \varphi_{li}^{mi}(x^i(k))w_{li}^{mi}(k), \quad (1)$$

при этом сигналы, получаемые на выходе выходного слоя, имеют вид

$$\begin{aligned} \hat{x}^j(k) &= \sum_{m=1}^h f_0^{jm}(y^m(k)) = \sum_{m=1}^h \sum_{j_0=1}^{h_2} \varphi_{j_0}^{jm}(y^m(k))w_{j_0}^{jm}(k) = \\ &= \sum_{m=1}^h \sum_{j_0=1}^{h_2} \varphi_{j_0}^{jm} \left( \sum_{i=1}^n \sum_{l=1}^{h_1} \varphi_{li}^{mi}(x^i(k))w_{li}^{mi}(k) \right) w_{j_0}^{jm}(k), \quad (2) \end{aligned}$$

где  $\varphi_{li}^{mi}(\bullet)$ ,  $\varphi_{j0}^{im}(\bullet)$  - вэйвлет-активационные функции первого и выходного слоев соответственно,

$w_{li}^{mi}(k)$ ,  $w_{j0}^{im}(k)$  - синаптические веса первого и второго слоев соответственно,

$y^m(k)$  -  $m$ -компонента сжатого многомерного сигнала.

В каждом вэйвлет-синапсе реализованы вэйвлеты, отличающиеся между собой параметрами центра и ширины, которые уточняются наряду с синаптическими весами с помощью тех или иных алгоритмов обучения.

С одной стороны, в качестве вэйвлет-активационных функций могут быть взяты различные семейства вэйвлетов, но, с другой стороны, целесообразно использовать адаптивную функцию принадлежности, параметры и форма которой настраивалась бы в процессе обучения системы компрессии.

В данном случае было предложено использовать введенные в [27, 28] настраиваемые активационные функции вида

$$\varphi_{li}^{mi}(x^i(k)) = (1 - \alpha_{li}^{mi} (\tau_{li}^{mi})^2) \exp\left(-\frac{(\tau_{li}^{mi})^2}{2}\right), \quad (3)$$

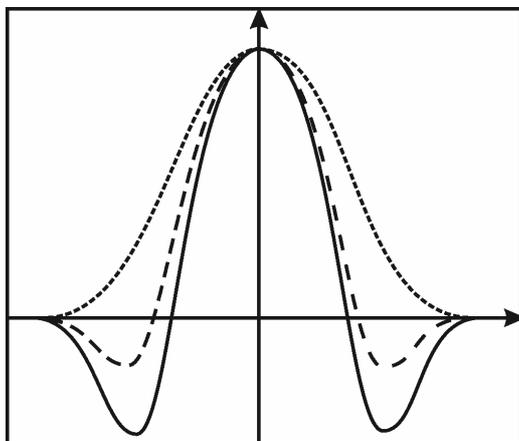
$$\varphi_{j0}^{im}(y^m(k)) = (1 - \alpha_{j0}^{im} (\tau_{j0}^{im})^2) \exp\left(-\frac{(\tau_{j0}^{im})^2}{2}\right), \quad (4)$$

где  $\tau_{li}^{mi}(x^i(k)) = (x^i(k) - c_{li}^{mi}(k))(\sigma_{li}^{mi}(k))^{-1}$ ,

$\tau_{j0}^{im}(y^m(k)) = (y^m(k) - c_{j0}^{im}(k))(\sigma_{j0}^{im}(k))^{-1}$ ,

$\alpha_{li}^{mi}$ ,  $\alpha_{j0}^{im}$  - настраиваемый параметр ( $0 \leq \alpha \leq 1$ ).

Уточняемый параметр  $\alpha$  позволяет настраивать форму активационной функции в процессе обучения, при этом при  $\alpha = 0$  получаем Гауссову функцию активации, при  $\alpha = 1$  получаем вэйвлет-функцию «Mexican Hat», а при  $0 < \alpha < 1$  - гибридную функцию активации. На рис. 2 приведены формы этих функций в зависимости от параметра  $\alpha$ .



точечная линия  $\alpha = 0$ , пунктирная линия  $\alpha = 0.5$ , сплошная линия  $\alpha = 1$

**Рисунок 2 – Адаптивная функция активации с различными параметрами  $\alpha$**

### Обучение вэйвлет-нейро-компрессора

Используя критерий обучения вида

$$E^i(k) = \frac{1}{2} \left( x^i(k) - \sum_{m=1}^h f_0^{im}(y^m(k)) \right)^2, \quad (5)$$

можно записать алгоритм настройки синаптических весов и параметров вэйвлет-активационных функций первого слоя в виде

$$w_{li}^{mi}(k+1) = w_{li}^{mi}(k) + \eta^w e^i(k) \times [f_0^{im}(y^m(k))] \varphi_{li}^{mi}(x^i(k)), \quad (6)$$

$$\left\{ \begin{aligned} c_{li}^{mi}(k+1) &= c_{li}^{mi}(k) + \eta^c e^i(k) \times \\ &\times [f_0^{im}(y^m(k))] w_{li}^{mi}(k) \frac{\partial \varphi_{li}^{mi}(x^i(k))}{\partial c_{li}^{mi}(k)}, \\ (\sigma_{li}^{mi})^{-1}(k+1) &= (\sigma_{li}^{mi})^{-1}(k) + \eta^\sigma e^i(k) \times \\ &\times [f_0^{im}(y^m(k))] w_{li}^{mi}(k) \frac{\partial \varphi_{li}^{mi}(x^i(k))}{\partial (\sigma_{li}^{mi})^{-1}(k)}, \\ \alpha_{li}^{mi}(k+1) &= \alpha_{li}^{mi}(k) + \eta^\alpha e^i(k) \times \\ &\times [f_0^{im}(y^m(k))] w_{li}^{mi}(k) \frac{\partial \varphi_{li}^{mi}(x^i(k))}{\partial \alpha_{li}^{mi}(k)}, \end{aligned} \right. \quad (7)$$

где  $\eta^w, \eta^c, \eta^\sigma, \eta^\alpha$  - шаг алгоритма обучения,

$$[f_0^{im}(y^m(k))] = \sum_{j=1}^{h_2} w_{j0}^{im}(k) \frac{\partial \varphi_{j0}^{im}(y^m(k))}{\partial y^m(k)}.$$

Алгоритм обучения второго слоя основывается на критерии вида

$$E^i(k) = \frac{1}{2} (x^i(k) - \mathcal{F}^i(k))^2 = \frac{1}{2} (e^i)^2(k), \quad (8)$$

где  $e^i$  - ошибка обучения.

Таким образом, алгоритм обучения синаптических весов и параметров активационных вэйвлет-функций второго слоя имеет вид

$$w_{j0}^{im}(k+1) = w_{j0}^{im}(k) + \eta_0^w e^i(k) \varphi_{j0}^{im}(y^m(k)), \quad (9)$$

$$\left\{ \begin{aligned} c_{j0}^{im}(k+1) &= c_{j0}^{im}(k) + \eta_0^c e^i(k) \times \\ &\times w_{j0}^{im}(k) \frac{\partial \varphi_{j0}^{im}(y^m(k))}{\partial c_{j0}^{im}(k)}, \\ (\sigma_{j0}^{im})^{-1}(k+1) &= (\sigma_{j0}^{im})^{-1}(k) + \eta_0^\sigma e^i(k) \times \\ &\times w_{j0}^{im}(k) \frac{\partial \varphi_{j0}^{im}(y^m(k))}{\partial (\sigma_{j0}^{im})^{-1}(k)}, \\ \alpha_{j0}^{im}(k+1) &= \alpha_{j0}^{im}(k) + \eta_0^\alpha e^i(k) \times \\ &\times w_{j0}^{im}(k) \frac{\partial \varphi_{j0}^{im}(y^m(k))}{\partial \alpha_{j0}^{im}(k)}, \end{aligned} \right. \quad (10)$$

где  $\eta_0^w, \eta_0^c, \eta_0^\sigma, \eta_0^\alpha$  - шаг алгоритма обучения.

Таким образом, вэйвлет-нейро-компрессор позволяет реализовать сжатие и выявление локальных особенностей как данных, представ-

ленных таблицей "объект-свойство", так и не-стационарных нелинейных временных рядов в on-line режиме, что обеспечивает преимущество по сравнению с существующими методами.

**Обучение нейро-фаззи компрессора**

Большое число настраиваемых параметров рассмотренной системы заставляет искать более простые методы обучения для решения задачи компрессии. Для этого в рамках архитектуры, приведенной на рис. 1, мы предлагаем заменить адаптивную функцию активации (3), (4) более простой функцией принадлежности нео-фаззи нейрона [29-31] на основе ядер Епанечникова [32] вида

$$\varphi_{li}^{mi}(x^i(k)) = 1 - \frac{(\tau_{li}^{mi})^2}{2} = 1 - \frac{(x^i(k) - c_{li}^{mi}(k))^2}{2(\sigma_{li}^{mi}(k))^2}, \quad (11)$$

$$\varphi_{j0}^{im}(x^i(k)) = 1 - \frac{(\tau_{j0}^{im})^2}{2} = 1 - \frac{(y^m(k) - c_{j0}^{im}(k))^2}{2(\sigma_{j0}^{im}(k))^2}. \quad (12)$$

При этом производные этих функций по настраиваемым параметрам имеют вид:

$$\begin{cases} \frac{\partial \varphi_{li}^{mi}(x^i(k))}{\partial c_{li}^{mi}(k)} = \frac{x^i(k) - c_{li}^{mi}(k)}{(\sigma_{li}^{mi}(k))^2}, \\ \frac{\partial \varphi_{li}^{mi}(x^i(k))}{\partial (\sigma_{li}^{mi})^{-1}(k)} = -\frac{(x^i(k) - c_{li}^{mi}(k))^2}{2}, \\ \frac{\partial \varphi_{j0}^{im}(y^m(k))}{\partial c_{j0}^{im}(k)} = \frac{y^m(k) - c_{j0}^{im}(k)}{(\sigma_{j0}^{im}(k))^2}, \\ \frac{\partial \varphi_{j0}^{im}(y^m(k))}{\partial (\sigma_{j0}^{im})^{-1}(k)} = -\frac{(y^m(k) - c_{j0}^{im}(k))^2}{2}. \end{cases} \quad (13)$$

Таким образом, алгоритм обучения (6), (7), (9), (10) приобретает простую форму:

$$\begin{cases} w_{li}^{mi}(k+1) = w_{li}^{mi}(k) + \eta^w e^i(k) \times \\ \times [f_0^{im}(y^m(k))]' \left[ 1 - \frac{(x^i(k) - c_{li}^{mi}(k))^2}{2(\sigma_{li}^{mi}(k))^2} \right], \\ c_{li}^{mi}(k+1) = c_{li}^{mi}(k) + \eta^c e^i(k) \times \\ \times [f_0^{im}(y^m(k))]' w_{li}^{mi}(k) \frac{(x^i(k) - c_{li}^{mi}(k))}{(\sigma_{li}^{mi}(k))^2}, \\ (\sigma_{li}^{mi})^{-1}(k+1) = (\sigma_{li}^{mi})^{-1}(k) + \eta^\sigma e^i(k) \times \\ \times [f_0^{im}(y^m(k))]' w_{li}^{mi}(k) \frac{(x^i(k) - c_{li}^{mi}(k))^2}{2}, \end{cases} \quad (14)$$

$$\begin{cases} w_{j0}^{im}(k+1) = w_{j0}^{im}(k) + \eta_0^w e^i(k) \times \\ \times \left[ 1 - \frac{(y^m(k) - c_{j0}^{im}(k))^2}{2(\sigma_{j0}^{im}(k))^2} \right], \\ c_{j0}^{im}(k+1) = c_{j0}^{im}(k) + \eta_0^c e^i(k) \times \\ \times w_{j0}^{im}(k) \frac{(y^m(k) - c_{j0}^{im}(k))}{(\sigma_{j0}^{im}(k))^2}, \\ (\sigma_{j0}^{im})^{-1}(k+1) = (\sigma_{j0}^{im})^{-1}(k) + \eta_0^\sigma e^i(k) \times \\ \times w_{j0}^{im}(k) \frac{(y^m(k) - c_{j0}^{im}(k))^2}{2}, \end{cases} \quad (15)$$

где

$$\begin{aligned} [f_0^{im}(y^m(k))] &= \sum_{j=1}^{h_2} w_{j0}^{im}(k) \frac{\partial \varphi_{j0}^{im}(y^m(k))}{\partial y^m(k)} = \\ &= -\sum_{j=1}^{h_2} \frac{w_{j0}^{im}(k)}{2\sigma_{j0}^{im}(k)} \left[ 1 - \frac{(x^i(k) - c_{li}^{mi}(k))^2}{2(\sigma_{li}^{mi}(k))^2} \right]. \end{aligned}$$

Эти процедуры могут быть оптимизированы по быстрдействию по типу процедур обучения нео-фаззи нейрона [33].

Для оптимизации алгоритма обучения введем следующие замены переменных:

$$\begin{aligned} Jw_{li}^{mi}(k) &= -\left[ \sum_{j=1}^{h_2} \frac{w_{j0}^{im}(k)}{2\sigma_{j0}^{im}(k)} \right] \left[ 1 - \frac{(x^i(k) - c_{li}^{mi}(k))^2}{2(\sigma_{li}^{mi}(k))^2} \right], \\ Jc_{li}^{mi}(k) &= -\left[ \sum_{j=1}^{h_2} \frac{w_{j0}^{im}(k)}{2\sigma_{j0}^{im}(k)} \right] w_{li}^{mi}(k) \left[ \frac{(x^i(k) - c_{li}^{mi}(k))}{(\sigma_{li}^{mi}(k))^2} \right], \\ J\sigma_{li}^{mi}(k) &= -\left[ \sum_{j=1}^{h_2} \frac{w_{j0}^{im}(k)}{2\sigma_{j0}^{im}(k)} \right] w_{li}^{mi}(k) \left[ \frac{(x^i(k) - c_{li}^{mi}(k))^2}{2} \right], \end{aligned}$$

$$\begin{aligned} Jw_i^{mi}(k) &= (Jw_{1i}^{mi}(k), Jw_{2i}^{mi}(k), \dots, Jw_{h_i}^{mi}(k))^T, \\ w_i^{mi}(k) &= (w_{1i}^{mi}(k), w_{2i}^{mi}(k), \dots, w_{h_i}^{mi}(k))^T, \\ c_i^{mi}(k) &= (c_{1i}^{mi}(k), c_{2i}^{mi}(k), \dots, c_{h_i}^{mi}(k))^T, \\ \sigma_i^{mi}(k) &= (\sigma_{1i}^{mi}(k), \sigma_{2i}^{mi}(k), \dots, \sigma_{h_i}^{mi}(k))^T, \end{aligned}$$

$$\begin{aligned} Jw_{j0}^{im}(k) &= \left[ 1 - \frac{(y^m(k) - c_{j0}^{im}(k))^2}{2(\sigma_{j0}^{im}(k))^2} \right], \\ Jc_{j0}^{im}(k) &= w_{j0}^{im}(k) \left[ \frac{(y^m(k) - c_{j0}^{im}(k))}{(\sigma_{j0}^{im}(k))^2} \right], \\ J\sigma_{j0}^{im}(k) &= w_{j0}^{im}(k) \left[ \frac{(y^m(k) - c_{j0}^{im}(k))^2}{2} \right], \end{aligned}$$

$$\begin{aligned}
 Jw_{h_20}^{mi}(k) &= (Jw_{10}^{im}(k), Jw_{20}^{im}(k), \dots, Jw_{h_20}^{im}(k))^T, \\
 w_0^{im}(k) &= (w_{10}^{im}(k), w_{20}^{im}(k), \dots, w_{h_20}^{im}(k))^T, \\
 c_0^{im}(k) &= (c_{10}^{im}(k), c_{20}^{im}(k), \dots, c_{h_20}^{im}(k))^T, \\
 \sigma_0^{mi}(k) &= (\sigma_{10}^{im}(k), \sigma_{20}^{im}(k), \dots, \sigma_{h_20}^{mi}(k))^T.
 \end{aligned}$$

Тогда окончательно алгоритм обучения нейро-фаззи компрессора приобретает форму:

$$\left\{ \begin{aligned}
 w_i^{mi}(k+1) &= w_i^{mi}(k) + \frac{e^i(k)Jw_i^{mi}(k)}{rw_i(k)}, \\
 rw_i(k+1) &= \beta rw_i(k) + \|Jw_i^{mi}(k)\|, \\
 c_i^{mi}(k+1) &= c_i^{mi}(k) + \frac{e^i(k)Jc_i^{mi}(k)}{rc_i(k)}, \\
 rc_i(k+1) &= \beta rc_i(k) + \|Jc_i^{mi}(k)\|, \\
 (\sigma_i^{mi}(k+1))^{-2} &= (\sigma_i^{mi}(k))^{-2} + \frac{e^i(k)J\sigma_i^{mi}(k)}{r\sigma_i(k)}, \\
 r\sigma_i(k+1) &= \beta r\sigma_i(k) + \|J\sigma_i^{mi}(k)\|,
 \end{aligned} \right. \quad (16)$$

$$\left\{ \begin{aligned}
 w_0^{im}(k+1) &= w_0^{im}(k) + \frac{e^i(k)Jw_0^{im}(k)}{rw_0(k)}, \\
 rw_0(k+1) &= \beta rw_0(k) + \|Jw_0^{im}(k)\|, \\
 c_0^{im}(k+1) &= c_0^{im}(k) + \frac{e^i(k)Jc_0^{im}(k)}{rc_0(k)}, \\
 rc_0(k+1) &= \beta rc_0(k) + \|Jc_0^{im}(k)\|, \\
 (\sigma_0^{im}(k+1))^{-2} &= (\sigma_0^{im}(k))^{-2} + \frac{e^i(k)J\sigma_0^{im}(k)}{r\sigma_0(k)}, \\
 r\sigma_0(k+1) &= \beta r\sigma_0(k) + \|J\sigma_0^{im}(k)\|,
 \end{aligned} \right. \quad (17)$$

### Выводы

Предложены архитектуры вэйвлет-нейро-компрессора и нейро-фаззи компрессора и алгоритм обучения всех их параметров, обладающие следящими и фильтрующими свойствами. Предложенный подход позволяет решать задачу сжатия данных не только в виде таблице "объект-свойство", но и многомерных нестационарных временных рядов произвольной природы с целью дальнейшей обработки. Имитационные эксперименты подтверждают эффективность развиваемого подхода.

### Литература

1 Dybowski R., Gant V. Clinical Applications of Artificial Neural Networks. – Cambridge University Press, 2001. – 378 p.  
 2 Дюк В. Data Mining / Дюк В., Самойленко А. – СПб.: Питер, 2001. – 368 с.

3 Schmitt M., Teodoreskn H.-M., Jain A. Computational Intelligence Processing in Medical Diagnosis. – N.Y.: Springer, 2012. – 496 p.  
 4 Дюк В. Информационные технологии в медико-биологических исследованиях / В.Дюк, В.Эммануэль. – СПб.: Питер, 2003. – 528 с.  
 5 Бойко В.В. Анализ клинических данных в медицинских исследованиях на основе методов вычислительного интеллекта / В.В.Бойко, Е.В.Бодянский, Е.А.Винокурова, С.В.Сушков, А.А.Павлов. – Харьков: ТО Эксклюзив, 2008. – 120 с.  
 6 Arpad K., Ajith A., Yulan L. Computational Intelligence in Medical Informatics. – Studies in Computational Intelligence. – 2008. – 85. – 380 p.  
 7 Лоули Д. Факторный анализ как статистический метод / Лоули Д., Максвелл А. – М.: Мир, 1967. – 144 с.  
 8 Ким Дж. Факторный, дискриминантный и кластерный анализ/ Дж. Ким, Ч.У. Мюллер и др. – М.: Финансы и статистика, 1989. – 215 с.  
 9 Chui C. K. An Introduction to Wavelets / C. K. Chui. – New York: Academic, 1992. – 264 p.  
 10 Szu H. Wavelet transforms and neural networks for compression and recognition / H. Szu, B. Telfer, J. Garcia // Neural Networks. – 1996. – 9. – P. 695-709.  
 11 Meyer Y. Wavelets: Algorithms and Applications / Y. Meyer. - Philadelphia, PA: SIAM., 1993. – 133 p.  
 12 Cichocki A. Neural Networks for Optimization and Signal Processing / Cichocki A., Unbehauen R. – Stuttgart: Teubner, 1993. – 526 p.  
 13 Sanger T. Optimal unsupervised learning in a single-layer linear feedforward neural network / Sanger T. // Neural Networks. – 1989. – 2. – P. 459-473.  
 14 Oja E. Neural networks, principal components, and subspaces / Oja E. // Int. J. of Neural Systems. – 1989. – 1. – P.61-68.  
 15 Oja E. An analysis of convergence for a learning version of the subspace method / Oja E., Karhunen J. //J. Math. Anal. Appl. – 1983. – 91. – P.102-111.  
 16 Chen T. Global convergence of Oja's subspace algorithm for principal component extraction / Chen T., Hua Y., Yan W.-Y. // IEEE Trans. on Neural Networks. – 1998. – 9. – P.58-67.  
 17 Бодянский Е.В. Модифицированный нейрон Оя для анализа нестационарных данных / Бодянский Е.В., Плисс И.П., Тесленко Н.А. // Автоматизация: проблемы, идеи решения: Междунар. науч.-техн. конф.: тезисы докл. – Севастополь, 2006. – С.18-21.  
 18 Bishop C. M. Neural Networks for Pattern Recognition / Bishop C. M. – Oxford: Clarendon Press, 1995. – 482 p.  
 19 Haykin S. Neural Networks. A Comprehensive Foundation / Haykin S. – N.J.: Upper Saddle River, Prentice Hall, Inc., 1999. – 842 p.  
 20 Abonyi J, Feil B., Németh S.Z., Arva P. Fuzzy Clustering Based Segmentation of Time-Series / Abonyi J, Feil B., Németh S.Z., Arva P. // Proc. 5th International Symposium on Intelligent

Data Analysis. - Berlin, Germany. - 2003. - P. 275-285.

21 Abonyi J. Introduction to Fuzzy Data Mining Methods. / Abonyi J, Feil B. // Handbook of Research on Fuzzy Information Processing in Databases / J. Galindo (Ed.) - 2008. - P. 55-95.

22 Abonyi J. Cluster analysis for data mining and systems identification / Abonyi J, Feil B. - Birkhäuser. Verlag AG. - Basel-Boston-Berlin. - 2007. - 303 p.

23 Bodyanskiy Ye., Teslenko N. Biomedical information in operative lethality analysis task // Int. J. of Biomedical Soft Computing and Human Sciences. - 2011. - 17. - № 2. - P. 3-9.

24 Винокурова Е.А. Компрессор данных медицинского мониторинга на основе гибридной вейвлет-нейро-архитектуры / Е.А.Винокурова, А.А.Павлов, И.П. Плисс // Автоматизация: проблемы, идеи, решения. Зб. науч. трудов по материалам международной научно-технич. конференции. - Севастополь: СевНТУ, 2008. - С. 156-159.

25 Винокурова Е.А. Проблемы компрессии данных большого объема в условиях неопределенности с целью выявления локальных особенностей // Прикладная радиоэлектроника. - 2012. - 11. - №2. - С. 250-254.

26 Bodyanskiy Ye. An adaptive learning algorithm for a wavelet neural network / Bodyanskiy Ye., Lamonova N., Pliss I., Vynokurova O. // Blackwell Synergy: Expert Systems. - 22. - №5 - P. 235-240.

27 Бодянский Е.В. Адаптивный вейвлон и алгоритм его обучения / Бодянский Е.В., Винокурова Е.А.// Управляющие системы и машины. - 2009. - 1 (219). - С.47-53.

28 Bodyanskiy Ye. Radial-basis-fuzzy-wavelet-neural network with adaptive activation-membership function / Bodyanskiy Ye., Vynokurova O., Yegorova E. // International Journal on Artificial Intelligence and Machine Learning. - 2008. - V.8. - II. - P. 9-15.

29 Yamakawa T. A neo-fuzzy neuron and its application to system identification and prediction of the system behavior / T. Yamakawa, E. Uchino, T.Miki, H. Kusanagi // Proc. 2nd Int. Conf. on Fuzzy Logic and Neural Networks -Iizuka, Japan. - 1992. - P.477-483.

30 Uchino E., Yamakawa T. Soft computing based signal prediction, restoration and filtering. Intelligent Hybrid Systems: Fuzzy Logic, Neural Networks and Genetic Algorithms. Ed. Da Ruan. Boston: Kluwer Academic Publisher. - 1997. - P. 331-349.

31 Miki I. Analog implementation of neo-fuzzy neuron and its on-board learning / I. Miki, I. Yamakawa // Computational Intelligence and Applications [Ed. by N.E. Mastorakis]. - Piraeus: WSES Press. - 1999. - P. 144-149.

32 Епанечников В.А. Непараметрическая оценка многомерной плотности вероятности // Теория вероятности и её применение. - 1969.- 14.-№1.-С.156-161

33 Bodyanskiy Ye. An adaptive learning algorithm for a neo fuzzy neuron / Ye. Bodyanskiy, I. Kokshenev, V. Kolodyazhniy // Proc. 3 rd Int. Conf. of European Union Society for Fuzzy Logic and Technology (EUSFLAT'2003). - Zittau. - 2003. - P. 375-379.

*Стаття надійшла до редакційної колегії  
16.04.14*

*Рекомендована до друку  
професором **Семенцовим Г.Н.**  
(ІФНТУНГ, м. Івано-Франківськ)  
професором **Філатовим В.О.**  
(Харківський національний університет,  
радіоелектроніки, м. Харків)*