

УДК 004.032.26

БОДЯНСКИЙ Е.В., д.т.н., профессор,

ДЕЙНЕКО А.А., к.т.н.,

КУЦЕНКО Я.В., аспирантка (Харьковский национальный университет радиоэлектроники)

## Ядерная кластеризация на основе обобщенной регрессионной нейронной сети и самоорганизующейся карты Т. Кохонена

*В работе предлагается архитектура гибридной нейронной сети и метод ее самообучения, предназначенные для ядерной кластеризации потока наблюдений, последовательно в on-line режиме поступающих на обработку. Предлагаемая система построена на основе эволюционирующей обобщенной регрессионной нейронной сети и самоорганизующейся карты Т. Кохонена. Настройка параметров системы основана на «ленивом» обучении и самообучении на основе принципа «Победитель получает больше», при этом в качестве функции соседства используется выходной сигнал гибридной сети. Предлагаемая система не подвержена «проклятию размерности», проста в реализации, не критична к форме восстанавливаемых кластеров.*

**Ключевые слова:** нейронные сети, эволюционирующая обобщенная регрессионная нейронная сеть, самоорганизующаяся карта Т. Кохонена, «проклятие размерности»

### Введение

В настоящее время системы и методы вычислительного интеллекта [1 - 4] получили широкое распространение для решения различного круга задач, возникающих в рамках интеллектуального анализа данных (Data Mining) таких, как прогнозирование, классификация, кластеризация и т.п. При этом кластеризация в этом ряду занимает особое место [7, 8], поскольку решение этой задачи основывается на парадигме самообучения [9], что существенно усложняет процесс поиска решения. Здесь наиболее популярными являются BSB - и ART-искусственные нейронные сети, предназначенные для обработки информации в пакетном режиме, и самоорганизующиеся карты Т. Кохонена (SOM) [10], предназначенные для решения задач кластеризации больших массивов информации, благодаря простоте вычислительной реализации и возможности последовательной on-line обработки данных, что позволяет их использовать в задачах Dynamic Data Mining и Data Stream Mining [11]. При этом предполагается, что восстанавливаемые классы взаимно не пересекаются и имеют выпуклую форму, т.е. в процессе самонастройки восстанавливаются разделяющие гиперплоскости, четко разграничивающие разные кластеры.

### Постановка задачи исследования

Для решения задач кластеризации в ситуациях, когда классы имеют произвольную форму, могут быть использованы, так называемые, ядерные самоорганизующиеся карты (KSOM) [12 - 14], построенные с использованием ядер Дж. Мерсера [15]

и основанные на минимизации критерия эмпирического риска [16], лежащего в основе так называемых машин опорных векторов (SVM) [17], введенных В.Н. Вапником.

SVM-нейронные сети являются эффективным средством решения многих задач Data Mining, включая и кластеризацию, однако, поскольку количество нейронов такой сети определяется объемом обрабатываемой выборки, она явно не подходит для задач, связанных с on-line анализом поступающей в систему информации. Здесь следует отметить, что в [18] введены модификации SVM-сетей для больших массивов данных, однако их обучение возможно только в пакетном режиме.

В связи с этим представляется целесообразным вместо традиционного SVM-подхода в ядерных системах кластеризации использовать идеи, связанные с оценками Э.Парзена [19], обобщенными регрессионными нейронными сетями (GRNN) Д.Шпехта [20] и теоремой Т.Кавера [21] о линейной разделимости классов в пространствах повышенной размерности. При этом основными требованиями, предъявляемыми к синтезируемой гибридной нейронной сети, являются простота и скорость процесса самообучения в задаче on-line кластеризации потока векторных наблюдений, поступающих в систему.

### Архитектура ядерной самоорганизующейся карты на основе обобщенной регрессионной нейронной сети

На рис. 1 приведена архитектура рассматриваемой ядерной самоорганизующейся карты на основе обобщенной регрессионной нейронной сети.

© Е.В. Бодянский, А.А. Дейнеко, Я.В. Куценко, 2016

Исходной информацией для данной сети является выборка (возможно, растущая) векторов наблюдений  $x(1), x(2), \dots, x(k), \dots, x(N), \dots$ ;

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

которая должна быть разбита на  $m$  кластеров произвольной формы, при этом  $k$  здесь может быть как номером наблюдения, так и моментом текущего времени.

Векторы наблюдений  $x(k)$  последовательно поступают на первый слой радиально-базисных функций ( $R$ -нейронов), полностью совпадающий по структуре с первым слоем (слоем образов) стандартной обобщенной регрессионной сети Д. Шпехта и сформированный ядерными колоколообразными функциями активации  $\varphi_1, \dots, \varphi_k, \dots, \varphi_N$ , с помощью которых производится повышение размерности входного пространства. В качестве таких функций обычно используются традиционные гауссианы, а настройка этого слоя обеспечивается с помощью «ленивого» обучения на основе концепции «нейроны в точках данных» [22]. При этом в качестве центров активационных функций принимаются сами обрабатываемые векторы-образы. Таким образом, при

подаче на вход нейронной сети некоторого неклассифицированного образа  $x$  на выходах  $R$ -нейронов первого слоя появляются значения

$$\varphi_k(x) = e^{-\frac{\|x-x(k)\|^2}{2\sigma^2}}, \quad k = 1, 2, \dots, N$$

(здесь  $\sigma^2$  - параметр рецепторного поля колоколообразной функции), а на выходе GRNN в целом - сигнал

$$\hat{y}(x) = \frac{\sum_{k=1}^N y(k)\varphi_k(x)}{\sum_{k=1}^N \varphi_k(x)}, \quad (1)$$

где  $y(k)$  - внешний обучающий сигнал, соответствующий образу  $x(k)$ . Понятно, что в задаче кластеризации обучающий сигнал отсутствует как таковой, а сама GRNN в общем случае ориентирована на решение задач интерполяции, а не кластеризации.




Рис. 1. Архитектура ядерной самоорганизующейся карты Т.Кохонена, основанная на обобщенной регрессионной нейронной сети

Второй скрытый слой рассматриваемой сети - слой нормализации реализует элементарное преобразование

$$\phi(x) = \frac{\varphi(x)}{\|\varphi(x)\|}.$$

Здесь  $\varphi(x) = (\varphi_1(x), \varphi_2(x), \dots, \varphi_N(x))^T$ , необходимое для обработки информации выходным слоем,

являющимся по сути кластеризующей нейронной сетью Т. Кохонена, настройка параметров которой производится на основе конкурентного самообучения. В этом выходном слое решается задача разбиения последовательности образов повышенной размерности  $\phi_1, \dots, \phi_2, \dots, \phi_N$  на  $m$  кластеров с нахождением прототипов центроидов  $\vartheta_1^K, \vartheta_2^K, \dots, \vartheta_m^K \in R^N$ .

Несмотря на кажущуюся простоту, при реализации этого подхода могут возникать существенные вычислительные проблемы при большом объеме  $N$  обрабатываемой выборки, поскольку сеть, содержащая  $N$  нейронов, становится слишком громоздкой. В связи с этим представляется целесообразным вместо традиционной процедуры обучения GRNN ввести метод, позволяющий не только настроить параметры сети, но и существенно сократить число ее R-нейронов.

**Обучение ядерной самоорганизующейся карты на основе обобщенной регрессионной нейронной сети**

Для формирования первого слоя рассматриваемой гибридной нейронной сети можно воспользоваться идеями, лежащими в основе эволюционирующих систем вычислительного интеллекта [23 - 26], адаптированными к on-line обработке информации, последовательно поступающей в систему [27]. Реализация этого подхода производится в форме следующей последовательности шагов:

шаг 0: задать порог неразличимости векторов центров активационных функций  $\Delta$ , максимально допустимое количество нейронов в первом слое  $H \leq N$  и параметр ширины рецепторного поля  $\sigma^2$ ;

шаг 1: при поступлении наблюдения  $x(1)$  формируется первый центр  $c_1 = x(1)$  и сама активационная функция

$$\varphi_1(x) = e^{-\frac{\|x-c_1\|^2}{2\sigma^2}} = e^{-\frac{\|x-x(1)\|^2}{2\sigma^2}};$$

шаг 2: при поступлении наблюдения  $x(2)$  проверяется условие

$$\|x(2) - c_1\|^2 \leq \Delta, \tag{2}$$

если оно выполняется, то наблюдение  $x(2)$  не формирует новый центр и автоматически считается принадлежащим тому же кластеру, что и  $x(1)$ , если выполняется условие

$$\Delta < \|x(2) - c_1\| \leq 2\Delta,$$

то происходит коррекция  $c_1$  согласно WTA-правилу самообучения Т. Кохонена [10] в форме

$$c_1(2) = c_1(1) + \eta(2)(x(2) - c_1(1))$$

(здесь  $0 < \eta(2) < 1$  - параметр шага настройки), если же  $2\Delta \leq \|x(2) - c_1\|$ , то формируется вторая активационная функция

$$\varphi_2(x) = e^{-\frac{\|x-c_2\|^2}{2\sigma^2}} = e^{-\frac{\|x-x(2)\|^2}{2\sigma^2}};$$

шаг N: Если к  $k$  моменту поступления N-го вектора-образа  $x(N)$  сформировано  $h \leq H$  активационных функций и выполняется условие (2), процесс наращивания числа R-нейронов первого слоя заканчивается и в дальнейшем структура этого слоя остается неизменной.

Оценить качество функционирования первого слоя можно было бы, воспользовавшись выражением (1), которое для  $h = H = N$  приобретает вид

$$\hat{x}(k) = \frac{\sum_{k=1}^N x(k)\varphi_k(x(k))}{\sum_{k=1}^N \varphi_k(x(k))}, \tag{3}$$

после чего оценить погрешность восстановления входных образов

$$\varepsilon = \frac{1}{N} \sum_{k=1}^N \frac{\|x(k) - \hat{x}(k)\|}{\|x(k)\|}. \tag{4}$$

Однако, поскольку в процессе формирования первого слоя с помощью описанного выше подхода некоторые из центров активационных функций не совпадают с векторами наблюдений, использование выражения (3), корректного для «классической» GRNN, в нашем случае может оказаться неправомерным.

В этой ситуации можно воспользоваться модифицированной GRNN [28, 29], чья архитектура приведена на рис. 2.

Данная сеть подобно трехслойному перцептрону содержит три слоя обработки информации, однако, в качестве активационных функций использует радиально-базисные конструкции в первом скрытом слое. Второй скрытый слой содержит  $n + 1$  узлов,  $n$  из которых являются адаптивными линейными ассоциаторами, а  $(n + 1)$ -й стандартным блоком суммирования  $\sum^*$ . Выходной сигнал сети образован  $n$  блоками деления  $\div$ .




Рис. 2. Модифицированная обобщенная регрессионная нейронная сеть

Обучение такой сети представляет собой комбинированный процесс установки центров радиально-базисных функций на основе методов эволюционирующих систем и обучения с учителем синаптических весов линейных ассоциаторов. При этом в качестве обучающего здесь используется сам входной сигнал, т.е. сеть настраивается в автоассоциативном режиме.

Второй скрытый слой сети настраивается аналогично процессу обучения радиально-базисных нейронных сетей. При этом на выходах  $n$  адаптивных линейных ассоциаторов формируются сигналы

$$o_i(k) = \sum_{l=0}^h w_{il}(k) \varphi_l(x(k)), \quad i = 1, 2, \dots, n,$$

а на выходе сумматоров  $\sum^*$  появляется сумма  $\sum_{l=0}^h \varphi_l(x(k))$ .

Выходной слой производит нормирование выходного сигнала по типу нормированной радиально-базисной сети (NRBFN) так, что

$$\hat{x}_i(k) = \frac{\sum_{l=0}^h w_{il}(k) \varphi_l(x(k))}{\sum_{l=0}^h \varphi_l(x(k))} = \sum_{l=0}^h w_{il}(k) \frac{\varphi_l(x(k))}{\sum_{l=0}^h \varphi_l(x(k))} = \sum_{l=0}^h w_{il}(k) \varphi_l^*(x(k)),$$

$$\varphi_0(x(k)) = 1, \quad \varphi_l^*(x(k)) = \varphi_l(x(k)) \left( \sum_{l=0}^h \varphi_l(x(k)) \right)^{-1}, \quad (5)$$

или

$$\hat{x}(k) = W(k) \varphi^*(k), \quad (6)$$

где  $\hat{x}(k) = (\hat{x}_1(k), \dots, \hat{x}_i(k), \dots, \hat{x}_n(k))^T$ ,

$$\varphi^*(k) = (\varphi_0^*(x(k)), \varphi_1^*(x(k)), \dots, \varphi_h^*(x(k)))^T,$$

$W(k) - (n \times (h+1))$  - матрица синаптических весов, подлежащая определению.

Для настройки матрицы синаптических весов  $W(k)$  может быть использован рекуррентный метод наименьших квадратов, являющийся по сути оптимальной по быстродействию гауссовско-ньютоновской процедурой оптимизации вида

$$\begin{cases} W(k) = W(k-1) + \frac{(x(k) - W(k-1)\varphi^*(k))\varphi^{*T}(k)P(k-1)}{1 + \varphi^{*T}(k)P(k-1)\varphi^*(k)}, \\ P(k) = P(k-1) - \frac{P(k-1)\varphi^*(k)\varphi^{*T}(k)P(k-1)}{1 + \varphi^{*T}(k)P(k-1)\varphi^*(k)}. \end{cases}$$

Таким образом можно оценить качество работы первого слоя, используя в выражении (4) вместо стандартного соотношения (3) введенные выше оценки (5), (6).

Выходной сигнал синтезированного первого слоя в форме  $(h \times 1)$  - вектора  $\varphi(x) = (\varphi_1(x), \dots, \varphi_l(x), \dots, \varphi_h(x))^T$  во втором скрытом слое нормализуется к виду

$$\phi(x) = \varphi(x) \|\varphi(x)\|^{-1},$$

т.е. проецируется на  $h$  - мерную гиперсферу единичного радиуса, после чего в виде последовательности  $\phi_1, \phi_2, \dots, \phi_r, \dots, \phi_n$  поступает на вход самоорганизующейся карты Кохонена.

Настройка карты Кохонена, образованной  $m$  адаптивными линейными ассоциаторами, производится на основе WTM-правила самообучения («победитель получает больше») и состоит в разбиении последовательности нормированных векторов-образов  $\phi_1, \phi_2, \dots, \phi_n$  на  $m$  кластеров, каждый из которых характеризуется собственным прототипом-центроидом  $\theta_j^K \in R^h, j = 1, 2, \dots, m$  непрерывно уточняемым при поступлении очередного образа повышенной размерности  $\phi_r$ .

Процесс самообучения начинается с инициализации синаптических весов выходного слоя, в качестве которых выступают достаточно произвольно

$$\theta_r^K(k) = \frac{\theta_r^K(k-1) + \eta(k)\psi(\theta_r^K(k-1), \theta_r^K(k-1))(\phi_r - \theta_r^K(k-1))}{\|\theta_r^K(k-1) + \eta(k)\psi(\theta_r^K(k-1), \theta_r^K(k-1))(\phi_r - \theta_r^K(k-1))\|}, \quad (7)$$

$$\forall l = 1, 2, \dots, m,$$

где  $\psi(\theta_r^K(k-1), \theta_r^K(k-1))$  - так называемая функция соседства, определяющая локальную область топологического соседства, в которой настраиваются не только нейрон-победитель  $\theta_r^K$ , но и его ближайшее окружение, при этом более близкие к победителю нейроны подтягиваются по входному вектору  $\phi_r$

больше, чем удаленные от  $\theta_r^K$  центроиды  $\theta_r^K$ .

В качестве функции соседства обычно используется все тот же гауссиан, приобретающий в данном случае вид

$$\psi(\theta_r^K(k), \theta_r^K(k)) = e^{-\frac{\|\theta_r^K(k) - \theta_r^K(k)\|^2}{2\sigma_c^2}},$$

выбранные начальные значения прототипов  $\theta_r^K(0)$  такие, что

$$\|\theta_r^K(0)\| = 1.$$

При подаче на вход третьего слоя сигнала  $\phi$  вычисляется  $m$  расстояний

$$D(\phi_r, \theta_r^K(0)) = \|\phi_r - \theta_r^K(0)\| \quad \forall j = 1, 2, \dots, m,$$

на основании которых оценивается нейрон-победитель, для которого

$$D(\phi_r, \theta_r^K(0)) = \min_j D(\phi_r, \theta_j^K(0)).$$

После этого производится первый шаг настройки весов-центроидов

$$\theta_r^K(1) = \frac{\theta_r^K(0) + \eta(1)\psi(\theta_r^K(0), \theta_r^K(0))(\phi_r - \theta_r^K(0))}{\|\theta_r^K(0) + \eta(1)\psi(\theta_r^K(0), \theta_r^K(0))(\phi_r - \theta_r^K(0))\|},$$

$$\forall l = 1, 2, \dots, m.$$

Аналогичным образом можно записать правило самообучения для  $k$ -го вектора - образа

где  $\sigma_c^2$  определяет размеры области соседства, при этом в процессе обучения этот параметр должен монотонно уменьшаться [30].

В [31] для обучения самоорганизующейся карты предлагается вообще не определять победителя, а в качестве функции соседства использовать выходной сигнал каждого нейрона

$$y_l(k) = \phi_r^T \theta_r^K, \quad (8)$$

при этом правило (7) может быть переписано в виде

$$\vartheta_{p_l}^K(k) = \frac{\vartheta_{p_l}^K(k-1) + \eta(k)y_l(k)(\varphi_{p_l} - \vartheta_{p_l}^K(k-1))}{\left\| \vartheta_{p_l}^K(k-1) + \eta(k)y_l(k)(\varphi_{p_l} - \vartheta_{p_l}^K(k-1)) \right\|}, \quad \forall l = 1, 2, \dots, m. \quad (9)$$

Заметив, что

$$\|\varphi_{p_l}\| = \left\| \vartheta_{p_l}^K(k-1) \right\| = 1,$$

несложно установить, что выражение (8) есть не что иное, как косинус угла между входным образом  $\varphi_{p_l}$  и

вектором-центроидом  $\vartheta_{p_l}^K(k-1)$ , т.е.  $\cos(\varphi_{p_l}, \vartheta_{p_l}^K(k-1))$ . Тогда с учетом неотрицательности функции соседства можно окончательно переписать правило самообучения в виде

$$\vartheta_{p_l}^K(k) = \frac{\vartheta_{p_l}^K(k-1) + \eta(k)[\cos(\varphi_{p_l}, \vartheta_{p_l}^K(k-1))]_+(\varphi_{p_l} - \vartheta_{p_l}^K(k-1))}{\left\| \vartheta_{p_l}^K(k-1) + \eta(k)[\cos(\varphi_{p_l}, \vartheta_{p_l}^K(k-1))]_+(\varphi_{p_l} - \vartheta_{p_l}^K(k-1)) \right\|}, \quad \forall l = 1, 2, \dots, m, \quad (10)$$

где  $[\bullet]_+$  проектор на положительный ортант.

Процесс кластеризации заканчивается либо по исчерпанию выборки, содержащей  $N$  наблюдений, либо происходит непрерывно, если данные поступают в форме потока в on-line режиме.

### Заключение

Предлагается архитектура гибридной нейронной сети и метод ее самообучения, предназначенные для ядерной кластеризации потока наблюдений, последовательно в on-line режиме поступающих на обработку. Предлагаемая система построена на основе эволюционирующей обобщенной регрессонной нейронной сети и самоорганизующейся карты Т.Кохонена. Настройка параметров системы основана на «ленивом» обучении и самообучении на основе принципа «победитель получает больше», при этом в качестве функции соседства используется выходной сигнал гибридной сети. Предлагаемая система не подвержена «проклятию размерности», проста в реализации, не критична к форме восстанавливаемых кластеров.

### Литература

1. Rutkowski, L. Computational Intelligence. Methods and Techniques. / L. Rutkowski // Berlin: Springer-Verlag, Heidelberg. – 2008. – 514 p.
2. Mumford, C. Computational Intelligence. Collaboration, Fuzzy and Emergence. / C. Mumford, L. Jain // Berlin: Springer-Verlag. – 2009. – 726 p.
3. Kruse, R. Computational Intelligence. A Methodological Introduction. / R. Kruse, C. Borgelt, F. Klawonn, C. Moewes, M. Steinbrecher, P. Held // Berlin: Springer. – 2013. – 488 p.
4. Du, K.-L. Neural Networks and Statistical Learning. / K.-L. Du, M.N.S. Swamy // London: Springer-Verlag. – 2014. – 824 p.
5. Han, J. Data Mining: Concepts and Techniques. / J. Han, M. Kamber // Amsterdam: Morgan Kaufmann Publ. – 2006. – 754 p.
6. Aggarwal, C.C. Data Mining. / C.C. Aggarwal // Cham: Springer, Int. Publ. Switzerland. – 2015. – 734 p.
7. Aggarwal, C.C. Data Clustering. Algorithms and Application. / C.C. Aggarwal, C.K. Reddy // Boca Raton: CRC Press. – 2014. – 648 p.
8. Xu, R. Clustering. / R. Xu, D.C. Wunsch // IEEE Press Series on Computational Intelligence. Hoboken, NJ: John Wiley & Sons, Inc. – 2009. – 370 p.
9. Haykin, S. Neural Networks. A Comprehensive Foundation. / S. Haykin // Upper Saddle River, N.J.: Prentice Hall, Inc. – 1999. – 842 p.
10. Kohonen, T. Self-Organizing Maps / T. Kohonen // Berlin: Springer-Verlag. – 1995. – 362 p.
11. Bifet, A. Adaptive Stream Mining: Pattern Learning and Mining from Evolving Data Streams / A. Bifet // IOS Press. – 2010. – 224 p.
12. MacDonald, D. Clustering in data space and feature space. / D. MacDonald, C. Fyfe // ESANN'2002 Proc. European Symp. on Artificial Neural Networks. Bruges (Belgium), 24-26 April. – 2002. – 137-142 pp.
13. Girolami, M. Mercer kernel-based clustering in feature space. IEEE Trans. on Neural Networks. / M. Girolami // 13. №3. 780-784 pp.
14. Camastra, F. A novel kernel method for clustering. / F. Camastra, A. Verri // IEEE Trans. on Pattern Analysis and Machine Intelligence. No. 5. – 2005. – 801-805 pp.
15. Schölkopf, B. Learning with Kernels. / B. Schölkopf, A. Smola // Cambridge, M.A.: MIT Press. – 2002 – 648 p.
16. Вапник, В.Н. Теория распознавания образов (Статистические проблемы обучения). /

- В.Н.Вапник, А.Я. Червоненкис // М.: Наука. – 1974. – 416 с.
17. Cortes, C. Support Vector Networks. / C.Cortes, V. Vapnik. // Machine Learning. – 1995. – 273–297 pp.
  18. Suykens, J.A.K. Least Squares Support Vector Machines. / J.A.K.Suykens, T.V Gestel, J.D Brabanter, B.D.Moor, J. Vandewalle // Singapore: World Scientific. – 2002. – 294 p.
  19. Parzen E. On the estimation of a probability density function and the mode / E. Parzen // Ann. Math. Statist. – 1962. – no.38. – 1065-1076 pp.
  20. Specht D.F. A general regression neural network / D.F. Specht // IEEE Trans. on Neural Networks. – 1991 – Vol 2. – 568-576 pp.
  21. Cover T. M. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. / T. M. Cover // IEEE Trans. on Electronic Computers. – 1965. – No. 14. – 326-334 pp.
  22. Zahirniak, D., Pattern recognition using radial basis function network. / D. Zahirniak, R.Chapman, S. Rogers, B. Suter, M. Kabrisky, V. Piati // Proc 6th Ann. Aerospace Application of Artificial Intelligence Conf. – Dayton. – OH. – 1990. – 249-260 pp.
  23. Angelov, P. Evolving Rule-based Models: A Tool for Design of Flexible Adaptive Systems. / P. Angelov // Heidelberg-New York: Springer-Verlag. – 2002 – 227 p.
  24. Kasabov, N. Evolving Connectionist Systems. / N. Kasabov // London: Springer-Verlag. – 2003 – 451 p.
  25. Angelov, P. Evolving computational intelligence systems / P. Angelov, N. Kasabov // Proc. 1st Int. Workshop on Genetic Fuzzy Systems. – Granada, Spain. – 2005. – 76-82 p.
  26. Lughofer, E. Evolving Fuzzy Systems – Methodologies, Advanced Concepts and Applications. / E. Lughofer // Berlin-Heidelberg: Springer-Verlag. – 2011 – 456 p.
  27. Bodyanskiy, Ye.V. An Evolving Radial Basis Neural Network with Adaptive Learning of Its Parameters and Architecture / Ye.V. Bodyanskiy, O.K. Tyshchenko, A.O. Deineko // Automatic Control and Computer Sciences. – 2015. – Vol. 49, No. 5. – 255–260 pp.
  28. Бодянский, Е.В. Искусственные нейронные сети: архитектуры, обучение, применение [Текст]/ Е.В. Бодянский, О.Г. Руденко. - Харьков: ТЕЛТЕХ, 2004. – 372 с.
  29. Bodyanskiy, Ye. Evolving Neuro-Fuzzy Systems with Kernel Activation Functions. Their Adaptive Learning for Data Mining Tasks / Ye. Bodyanskiy, O. Tyshchenko, A. Deineko // Saarbrucken: LAP LAMBERT Academic Publishing. – 2015 – 64 p.
  30. Cottrel, M. A stochastic model of retinotopy: a self-organizing process / M.Cottrel, J. Fort // Biological Cybernetics. – 1986. – 53. – 405 – 411 pp.
- Бодянский Є.В., Дейнеко А.О., Куценко Я.В. Ядерне кластерування на основі узагальненої регресійної нейронної мережі та самоорганізованої мапи Т. Когонена.** У роботі запропоновано архітектуру гібридної нейронної мережі та метод її самонавчання, призначені для ядерного кластерування потоку спостережень, які послідовно надходять на обробку в on-line режимі. Запропонована система побудована на основі еволюційної узагальненої регресійної нейронної мережі та самоорганізованої мапи Т. Когонена. Налаштування параметрів системи засновано на «лїнивому» навчанні і самонавчанні на основі принципу «Переможець отримує більше», при цьому як функція сусідства використовується вихідний сигнал гібридної мережі. Запропонована система не схильна до «прокляття розмірності», проста в реалізації, не критична до форми відновлюваних кластерів.
- Ключові слова:** нейронні мережі, еволюційна узагальнена регресійна нейронна мережа, самоорганізована мапа Т. Когонена, «прокляття розмірності».

**Yevgeniy V. Bodyanskiy, Anastasiia O. Deineko, Yana V. Kutsenko. Kernel clustering based on the general regression neural network (GRNN) and T. Kohonen's self-organizing map.** Clustering of multidimensional observations (vectors-patterns) in large databases is often occurs in many real practical tasks and for its solution many algorithms were developed . Last years in the frame the concept of Big Data special attention is given to the processing of information, that is stored either in the very large databases (VLDB), either is fed sequentially in on-line mode in the form of data stream. For solving these tasks mathematical apparatus of computational intelligence successfully can be used and first of all artificial neural networks and soft computing. It is clear that known systems of computational intelligence must be essentially modified for processing of large data volumes, that are sequentially fed into the processing. In this regard the clustering system based on the evolving general regression neural network and self-organizing map of T. Kohonen, is proposed in the paper. The tuning of system is based on «lazy» learning and self-learning using the principle "Winner takes more" at the same time as neighborhood function the output signal of the hybrid network is used. The system implementation is characterized by numerical simplicity. The evolving neural network processes data in an online mode and doesn't suffer from the "curse of dimensionality".

**Keywords:** computational intelligence, kernel clustering, evolving system, «lazy» learning, self-learning, general regression neural networks.

Рецензент д.т.н., профессор В.П. Машталир (ХНУРЕ)

*Поступила 26.04.2016 г.*

**Бодянский Евгений Владимирович**, руководитель ПНИЛ АСУ, профессор, доктор технических наук, профессор кафедры искусственного интеллекта, Харьковский национальный университет радиоэлектроники, e-mail: [yevgeniy.bodyanskiy@nure.ua](mailto:yevgeniy.bodyanskiy@nure.ua)

**Дейнеко Анастасия Александровна**, кандидат технических наук, научный сотрудник ПНИЛ АСУ, Харьковский национальный университет радиоэлектроники, e-mail: [anastasiya.deineko@gmail.com](mailto:anastasiya.deineko@gmail.com)

**Куценко Яна Владимировна**, аспирантка кафедры искусственного интеллекта, Харьковский национальный университет радиоэлектроники, e-mail: [yana.kutsenko@nure.ua](mailto:yana.kutsenko@nure.ua)

**Yevgeniy V. Bodyanskiy**, Dr. Sc., Professor, Control Systems Research Laboratory, Kharkiv National University of Radio Electronics, e-mail: [yevgeniy.bodyanskiy@nure.ua](mailto:yevgeniy.bodyanskiy@nure.ua)

**Anastasiia O. Deineko**, Ph. D., Researcher, Control Systems Research Laboratory, Kharkiv National University of Radio Electronics, e-mail: [anastasiya.deineko@gmail.com](mailto:anastasiya.deineko@gmail.com)

**Yana V. Kutsenko**, Ph. D. Student, Control Systems Research Laboratory, Kharkiv National University of Radio Electronics, e-mail: [yana.kutsenko@nure.ua](mailto:yana.kutsenko@nure.ua)