

## ИДЕНТИФИКАЦИЯ ДИНАМИЧЕСКИХ ОБЪЕКТОВ С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ НА ОСНОВЕ САМООРГАНИЗУЮЩИХСЯ КАРТ КОХОНЕНА

Аверкин Алексей Николаевич<sup>1</sup>, Повидало Илья Сергеевич<sup>2</sup>

<sup>1</sup>Кандидат физико-математических наук, доцент;

ГОУ ВПО «Международный Университет природы, общества и человека «Дубна»,

Институт системного анализа и управления;

141980, Московская обл., г. Дубна, ул. Университетская, 19;

e-mail: averkin2003@inbox.ru.

<sup>2</sup> Аспирант;

ГОУ ВПО «Международный Университет природы, общества и человека «Дубна»,

Институт системного анализа и управления;

141980, Московская обл., г. Дубна, ул. Университетская, 19;

e-mail: ipovidalo@gmail.com.

Идентификация динамических объектов является одной из основных задач, для решения которых, наряду с множеством различных методов, могут быть применены нейронные сети. Идентификация объекта сильно затруднена, если присутствуют шумы в исходных данных, и некоторые из параметров объекта изменяются по неизвестным законам, или точное число параметров объекта неизвестно. В таких случаях для идентификации динамических объектов могут быть применены самообучающиеся нейронные сети, например самоорганизующиеся карты Кохонена и их модификации. Нейронным сетям именно такого типа будет уделено особое внимание в данной статье в виду их все более широкого распространения и успешного применения для решения различного рода задач, в том числе задач прогнозирования и идентификации.

Ключевые слова: нейронные сети, самоорганизующиеся карты, идентификация, SOM, VQTAM, RSOM.

## DYNAMIC OBJECT IDENTIFICATION WITH SOM-BASED NEURAL NETWORKS

Averkin Aleksey<sup>1</sup>, Povidalo Ilya<sup>2</sup>

<sup>1</sup>Candidate of Science in Physics and Mathematics, docent;

Dubna International University of Nature, Society and Man,

Institute of system analysis and management;

141980, Dubna, Moscow reg., Universitetskaya str., 19;

e-mail: averkin2003@inbox.ru.

<sup>2</sup>Postgraduate student;

Dubna International University of Nature, Society and Man,

Institute of system analysis and management;

141980, Dubna, Moscow reg., Universitetskaya str., 19;

e-mail: ipovidalo@gmail.com.

Dynamic object identification is one of the main tasks for which neural networks can be used, along with a number of different other. Object identification is very difficult if there are noises in the input data, or some of the parameters of the object change according to unknown, or the exact number of these parameters is unknown. In such cases, to identify the dynamic object self-organizing maps and their modifications can be applied. Neural networks is of this type will be highlighted in this article due to their more widespread and successful application for solving various problems, including problems of forecasting and identification of.

Keywords: neural networks, self-organizing maps, identification, SOM, VQTAM, RSOM.

## Введение

Теория идентификации занимается решением задач построения математических моделей динамических систем по данным наблюдений за их поведением. Этап идентификации объекта является одним из основных при разработке математических моделей объектов или процессов. От этого этапа зависит качество модели и, следовательно, качество управления или результатов исследования с помощью построенной модели.

Идентификация динамических объектов является одной из основных задач, для решения которых, наряду с множеством различных методов, могут быть применены нейронные сети. Идентификация объекта сильно затруднена, если присутствуют шумы в исходных данных, и некоторые из параметров объекта изменяются по неизвестным законам, или точное число параметров объекта неизвестно. В таких случаях для идентификации динамических объектов могут быть применены нейронные сети. Существует множество типов нейронных сетей, применяющихся при идентификации динамических объектов.

Среди всевозможных архитектур нейронных сетей [1], которые могут быть применены для идентификации динамических объектов, выделяется класс нейронных сетей, основанных на самоорганизующихся картах Кохонена. Нейронным сетям именно такого типа будет уделено особое внимание в данной статье в виду их все более широкого распространения и успешного применения для решения различного рода задач, в том числе задач прогнозирования и идентификации [2, 3].

## 1. Нейросетевые структуры на основе самоорганизующихся карт Кохонена, применимые для идентификации динамических объектов

### Постановка задачи

Идентификацию динамического объекта, получающего на вход в момент времени  $t$  вектор входных параметров  $u(t)$  и имеющего на выходе вектор  $y(t)$ , можно рассматривать как нахождение типа модели этого объекта, с выходом  $\hat{y}(t)$ , и параметров данной модели, удовлетворяющих условию минимизации ошибки  $e = y(t) - \hat{y}(t)$  этой модели (рис. 1).



Рис. 1. Схема идентификации динамического объекта

Пусть задана последовательность векторов входных признаков  $u(t)$ ,  $t \in [0, T]$  и последовательность векторов выходов  $y(t)$ ,  $t \in [0, T]$ , где  $T$  – число дискретных отсчетов. Будем рассматривать решения задачи идентификации, как определение вида функции  $f$ :

$$y(t) = f[y(t-1), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u)],$$

где  $y(t)$  – вектор выходов модели,  $n_y < T$ ,  $n_u < T$ . Рассматриваемая схема идентификации, называется последовательно-параллельной (рис. 2), в каждый момент времени на вход модели подаются известные измеренные значения входного и выходного сигналов объекта.

А также будем рассматривать решение задачи в виде:

$$y(t) = f[y(t-1), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u)],$$

где  $y(t) = y(0)$ ,  $y(t)$  – вектор выходов модели,  $n_y < T$ ,  $n_u < T$ . Такую схему идентификации, называют параллельной (рис. 3), в каждый момент времени на вход модели подаются измеренные значения входного сигнала объекта, и выходы модели в предыдущие моменты времени.

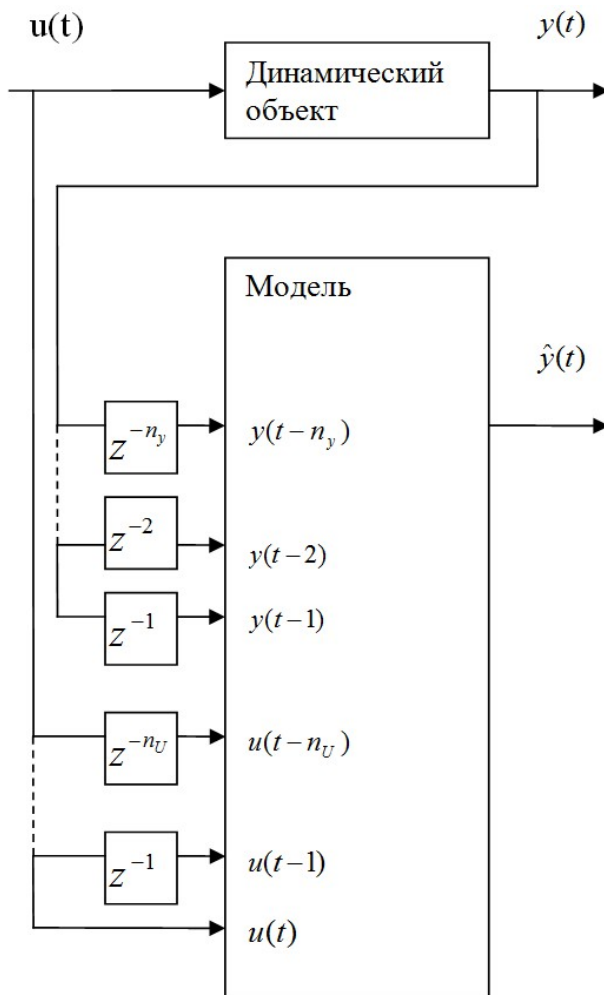


Рис. 2. Последовательно-параллельная схема идентификации

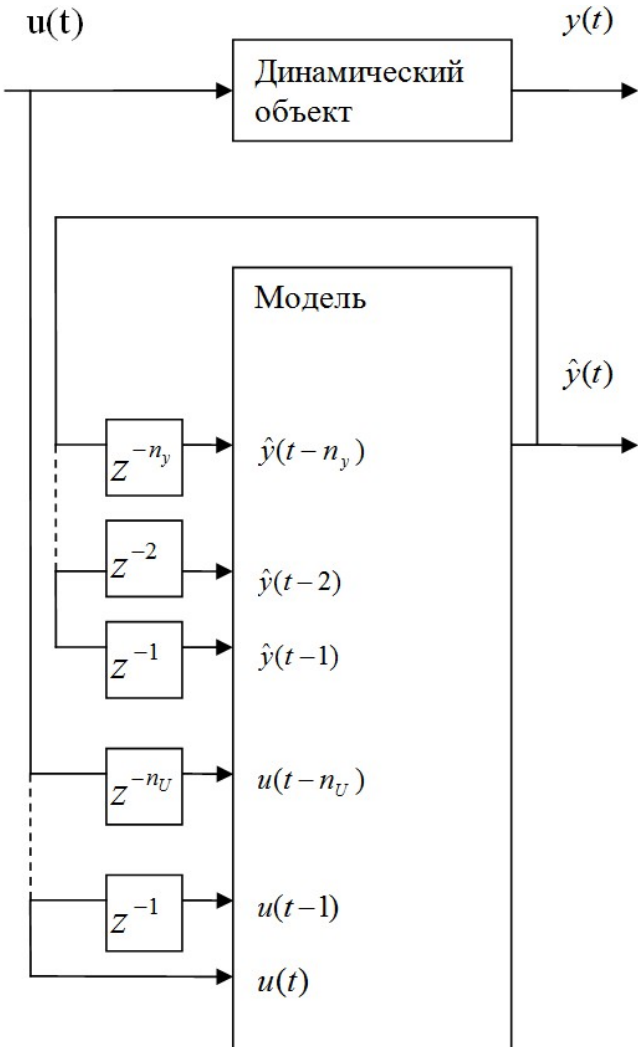


Рис. 3. Параллельная схема идентификации динамического объекта

### Векторная квантированная память (VQTAM)

VQTAM – это модификация самоорганизующихся карт Кохонена, которая может быть применена для идентификации динамических систем [4, 5]. Вектор входных признаков  $u(t)$  данной сети разделен на две части:  $x^{in}(t)$ ,  $x^{out}(t)$ . Первая часть входных признаков  $x^{in}(t)$  содержит информацию о входах динамического объекта и его предыдущих выходах. Вторая часть вектора входных признаков  $x^{out}(t)$  содержит информацию о предполагаемом выходе данного динамического объекта, соответствующем входам  $x^{in}(t)$ . Вектор весов разделен аналогичным способом [5]. Таким образом

$x(t) = \begin{pmatrix} x^{in}(t) \\ x^{out}(t) \end{pmatrix}$  и  $w_i(t) = \begin{pmatrix} w_i^{in}(t) \\ w_i^{out}(t) \end{pmatrix}$ , где  $w_i(t)$  – вектор весов  $i$ -го нейрона,  $w_i^{in}(t)$  часть вектора весов, содержащая информацию о входах процесса, а  $w_i^{out}(t)$  – часть вектора весов, содержащая

информацию о выходах процесса. Первая часть вектора входных признаков содержит информацию о входах процесса и его предыдущих выходах:

$$x^{in}(t) = (y(t-1), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u)),$$

где  $n_y < T$ ,  $n_u < T$ . Вторая часть вектора входных признаков  $x^{out}(t) = y(t)$  содержит информацию о предполагаемом выходе данного процесса, соответствующем входам  $x^{in}(t)$ .

Каждый пример выборки состоит из пары векторов  $(y(t), u(t))$  и выборка должна содержать не менее  $\max(n_u, n_y)$  примеров. Вектора  $y(t)$  представляют собой вектора входов процесса в момент времени  $t$  а  $u(t)$  – вектора выходов этого процесса в тот же момент времени.

После подачи на вход сети очередного входного вектора  $x(t)$ , составленного из нескольких примеров обучающей выборки, нейрон–победитель определяется только по вектору  $x^{in}(t)$ :

$$i^*(t) = \arg \min_i \{ \|x^{in}(t) - w_i^{in}(t)\| \},$$

где  $i^*(t)$  – номер нейрона-победителя на шаге  $t$ .

Для изменения весов может быть применено модифицированное правило изменения весов для обычной SOM:

$$\Delta w_i^{in}(t) = \alpha(t) h(i^*, i, t) [x^{in}(t) - w_i^{in}(t)],$$

$$\Delta w_i^{out}(t) = \alpha(t) h(i^*, i, t) [x^{out}(t) - w_i^{out}(t)],$$

где  $0 < \alpha(t) < 1$  – скорость обучения сети, а  $h$  – функция соседства нейрона  $i$  и  $i^*$ . В качестве функции соседства  $h(i^*, i, t)$  может быть выбрана, например, Гауссова функция:

$$h(i^*, i, t) = \exp \left( - \frac{\|r_i(t) - r_{i^*}(t)\|^2}{2\sigma^2(t)} \right),$$

где  $r_i(t)$  и  $r_{i^*}(t)$  – положения на карте нейронов  $i$  и  $i^*$  соответственно,  $\sigma(t) > 0$  – определяет радиус функции соседства на шаге  $t$ . После выбора нейрона–победителя  $i^*$  выход этого нейрона окрашивается вектором  $w_{i^*}^{out}(t)$ .

В режиме работы на вход VQTAM подается только вектор  $x^{in}(t)$ , для которого определяется нейрон–победитель и его выход окрашивается  $w_{i^*}^{out}(t)$ . Вектор  $w_{i^*}^{out}(t)$  может быть интерпретирован, как предсказанный выход  $y(t)$  процесса объекта в момент времени  $t$ .

#### Рекуррентная самоорганизующаяся карта (RSOM)

В RSOM, в отличие от обыкновенной карты Кохонена с обратными связями, для каждого нейрона определен вектор выходов, затухающий во времени, по которому определяется нейрон–победитель и по которому происходит изменение весов[6], [7].

Представим вектор входов сети следующим образом:

$$x(t) = (y(t-1), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u)),$$

где  $n_y < T$ ,  $n_u < T$ .

Выход каждого нейрона определяется следующим выражением:

$$V_i(t) = \|v_i(t)\|,$$

где  $v_i(t) = (1 - \alpha)v_i(t-1) + \alpha(x(t) - w_i(t))$ ,  $\alpha$  – константа, коэффициент затухания выхода ( $0 < \alpha \leq 1$ ),  $V_i(t)$  – выход  $i$ -го нейрона на такте  $t$ ,  $w_i(t)$  – вектор весов  $i$ -го нейрона.

После подачи на вход сети очередного примера нейрон-победитель определяется, как нейрон с минимальным выходом [7]:

$$i^*(t) = \arg \min_i \{V_i(t)\}.$$

Для изменения весов используется измененное правило для обучения карты Кохонена:

$$\Delta w_i(t) = \alpha(t)h(i^*, i, t)v_i(t),$$

где  $0 < \alpha(t) < 1$  – скорость обучения сети, а  $h$  – функция соседства нейрона  $i$  и  $i^*$ .

После завершения обучения сети – сеть запускается на обучающей выборке и кластеризует её, образуя кластеры, которые могут быть аппроксимированы линейными функциями. Для каждого кластера строится линейная функция  $f_i(t)$ . Таким образом, после запуска сети на тестовой выборке для каждой точки выборки определяется наиболее подходящая линейная функция, по которой может быть предсказан следующий выход процесса.

Этот процесс возможно ускорить, используя алгоритмы построения локальных линейных моделей во время обучения нейронной сети. Каждому нейрону сети RSOM ставится в соответствие матрица  $A_i(t)$ , содержащая коэффициенты соответствующей линейной модели:

$$A_i(t) = [b_{i,1}(t), \dots, b_{i,n_y}(t), a_{i,1}(t), \dots, a_{i,n_U}(t)]^T.$$

Выходное значение сети определяется в соответствии со следующим выражением:

$$y(t) = \sum_{k=1}^{n_y} b_{i^*,k}(t)u(t-k) + \sum_{l=1}^{n_U} a_{i^*,l}(t)y(t-l) = A_{i^*}^T(t)x(t),$$

где  $A_{i^*}(t)$  – матрица коэффициентов, ассоциированная с нейроном победителем  $i^*(t)$ . Матрица  $A_{i^*}(t)$  используется для линейной аппроксимации выхода модели.

При построении локальных линейных моделей одновременно с обучением нейронной сети необходимо дополнительное правило для изменения коэффициентов линейных моделей:

$$A_i(t+1) = A_i(t) + \alpha'h(i^*, i, t)\Delta A_i(t),$$

где  $0 < \alpha' < 1$  – скорость обучения модели, а  $\Delta A_i(t)$  – правило коррекции ошибки Видроу – Хоффа:

$$\Delta A_i(t) = [y(t) - A_i^T(t)x(t)] \frac{x(t)}{\|x(t)\|^2},$$

где  $y(t)$  – желаемый выход модели при подаче на вход вектора  $x(t)$ .

Таким образом, на каждом шаге обучения сети происходит изменение коэффициентов модели вместе с весовыми коэффициентами нейронов. В режиме работы сети после подачи на вход входного вектора – сеть определяет нейрона победителя  $i^*(t)$ . Затем выбирается соответствующая матрица

$A_i^*(t)$  коэффициентов линейной модели. С помощью выбранной матрицы выход модели определяется по формуле:  $y(t) = A_i^{*T}(t)x(t)$ .

### Модульные самоорганизующиеся карты

Модульные самоорганизующиеся карты представлены в ряде работ Тетсуо Фурукавы [8, 9]. Модульная SOM имеет структуру массива, состоящего из функциональных модулей, которые представляют собой обучаемые нейронные сети, например, многослойные персептроны (MLP), а не вектора, как в обычных самоорганизующихся картах. В случае MLP – модулей, модульная самоорганизующаяся карта выделяет группы особенностей или функций в зависимости входных и выходных значений, одновременно строя карту их похожести. Таким образом, модульная самоорганизующаяся карта с MLP модулями представляет собой самоорганизующуюся карту в функциональном, а не в векторном пространстве [9].

По сути, модульная самоорганизующаяся карта представляет собой обыкновенную карту Кохонена, где нейроны заменены более сложными и самостоятельными структурами, такими как другие нейронные сети. Такая замена требует небольшой модификации алгоритма обучения.

В предложенном алгоритме на начальном этапе сеть запускается на  $i$ -й выборке входных данных, соответствующей  $I$  функциям, карту сходства которых может построить сеть, и рассчитывается ошибка каждого модуля сети:

$$E_i^k = \frac{1}{J} \sum_{j=1}^J \|y_{i,j}^k - y_{i,j}\|^2,$$

где  $k$  – номер модуля, для которого рассчитана ошибка,  $J$  – число точек в выборке,  $y_{i,j}^k$  – выход  $k$ -го модуля,  $y_{i,j}$  – ожидаемый выход сети на предложенном наборе входных данных. Модуль-победитель определяется как модуль, минимизирующий ошибку  $E_i^k$ :

$$k_i^* = \arg \min_k E_i^k.$$

Как только модуль – победитель определен, происходит адаптация весов сети – сначала адаптируются веса модуля – победителя по одному из возможных алгоритмов обучения сетей такого типа, после этого начинается адаптация весов карты. В этом процессе параметры каждого из модулей рассматриваются как веса карты и адаптируются по стандартным алгоритмам самоорганизующихся карт Кохонена.

В ходе данного исследования были разработаны сети SOMxVQTAM, представляющие собой самоорганизующуюся карту с модулями типа VQTAM и SOMxRSOM с модулями типа RSOM. Далее будут рассмотрены результаты работы таких сетей.

## 2. Применение нейронных сетей на основе карт Кохонена для идентификации динамических объектов

Для экспериментов все сети имели размерность 4x4 и обучались на одной и той же выборке, состоящей из 1000 точек, выбранных с равным интервалом на промежутке  $[0, 4\pi]$  на функции вида

$$y(t) = \frac{1}{2} \left( \frac{\exp(\cos(t))}{\exp(1)} \sin(t) \sin(15t) + 1 \right) \quad (\text{рис. 4}).$$

Выборка была разделена на обучающую и тестовую в соотношении 6:4. Здесь будут рассмотрены только результаты работы сетей в последовательно-параллельном режиме работы, т.к. в параллельном происходит быстрое накопление ошибки всеми представленными типами сетей. Во время каждого эксперимента были рассчитаны максимальная относительная ошибка MAXPE (Maximum Percentage Error) и среднеквадратическая относительная

ошибка RMSPE (Root Mean Squared Percentage Error). Ошибки были рассчитаны по следующим

формулам:  $MAXPE = \max_{t=1,T} \left| \frac{y(t) - \hat{y}(t)}{y(t)} \right| \cdot 100\%$ ,  $RMSPE = \sqrt{\frac{1}{T} \sum_{t=1}^T \left( \frac{y(t) - \hat{y}(t)}{y(t)} \right)^2} \cdot 100\%$ .




Рис. 4. Обучающая (обозначена жирной красной линией) и тестовая выборки (обозначена тонкой красной линией). Обучающая и тестовая разделены вертикальной пунктирной линией

### Результаты работы VQTAM

На рис. 5 изображен пример работы сети типа VQTAM. Ошибка сети на обучающей выборке:  $MAXPE = 37.84\%$ ,  $RMSPE = 4.97\%$ , на тестовой:  $MAXPE = 37.72\%$ ,  $RMSPE = 4.7\%$ .




Рис. 5. Пример работы сети типа VQTAM. Красным цветом на графика обозначена выборка (обучающая и тестовая разделены вертикальной пунктирной линией), зеленым обозначен результат работы сети

### Результаты работы SOMxVQTAM

Пример работы сети типа SOMxVQTAM показан на рис. 6. В качестве модулей были использованы VQTAM размерности 5x5. Ошибка сети на обучающей выборке:  $MAXPE = 23.34\%$ ,  $RMSPE = 6.89\%$ , на тестовой:  $MAXPE = 23.38\%$ ,  $RMSPE = 6.67\%$ .




Рис. 6. Пример работы сети типа SOMxVQTAM. Красным цветом на графика обозначена выборка (обучающая и тестовая разделены вертикальной пунктирной линией), зеленым обозначен результат работы сети

### Результаты работы RSOM

Пример работы сети RSOM можно видеть на рис. 7. Ошибка сети на обучающей выборке: MAXPE = 2.18%, RMSPE = 0.51%, на тестовой: MAXPE = 2.18%, RMSPE = 0.55%.




Рис. 7. Пример работы сети типа RSOM. Красным цветом на графика обозначена выборка (обучающая и тестовая разделены вертикальной пунктирной линией), зеленым обозначен результат работы сети

### Результаты работы SOMxRSOM

Пример работы сети типа SOMxRSOM виден на рис. 8. В качестве модулей были использованы RSOM размерности 3x3. Ошибка сети на обучающей выборке: MAXPE = 19.37%, RMSPE = 2.15%, на тестовой: MAXPE = 17.37%, RMSPE = 1.76%.






Рис. 8. Пример работы сети типа SOMxRSOM. Красным цветом на графика обозначена выборка (обучающая и тестовая разделены вертикальной пунктирной линией), зеленым обозначен результат работы сети

## Заключение

В данной работе был рассмотрен ряд нейронных сетей на основе самоорганизующихся карт Кохонена, которые могут быть успешно применены для идентификации динамических объектов различной сложности. Также данное исследование обосновывает необходимость исследования возможностей модульных нейронных сетей более высокой сложности для идентификации динамических объектов и исследование способности таких сетей для выявления паттернов во временных рядах.

## Список литературы

1. Хайкин С. Нейронные сети: полный курс, 2-е изд., испр., исправленное – М.: ООО «И.Д. Вильямс», 2006. – С. 1104.
2. Efremovaa N., Asakuraa N., Inuia T., Abdikeevb N. The Neural Network for View-Invariant Object Recognition and Classification (Additional Details). – 2012. – Pp. 1-4.
3. Трофимов А. Г., Повидало И. С., Чернецов С. А. Использование самообучающихся нейронных сетей для идентификации уровня глюкозы в крови больных сахарным диабетом 1 го типа // Наука и образование: электрон. журнал. – 2010. – №5. – [Электронный ресурс]. URL: <http://technomag.edu.ru/doc/142908.html>.
4. Luis Gustavo M. Souza, Guilherme A. Barreto Multiple Local ARX Modeling for System Identification Using the Self-Organizing Map.
5. Koskela T. Neural network methods in analyzing and modelling time varying processes – Espoo, 2003. – Pp. 1-72.
6. Varsta M., Heikkonen J., A recurrent Self-Organizing Map for temporal sequence processing. – Springer, 1997. – Pp. 421-426.
7. Lotfi A., Garibaldi J. In Applications and Science in Soft Computing, Advances in Soft Computing Series – Springer, 2003. – Pp. 3-8.
8. Tokunaga K., Furukawa T. SOM of SOMs – Neural Networks. – 2009. – №22. – Pp. 463-478.
9. Tokunaga K., Furukawa T. Modular network SOM – Neural Networks. – 2009. – №22. – Pp. 82-90.