

УДК 004.032.23

Д.А. Плиско, В.В. Волкова, Е.В. Бодянский

Харьковский национальный университет радиоэлектроники, Харьков

## ПРОГНОЗИРОВАНИЕ НЕСТАЦИОНАРНЫХ ВРЕМЕННЫХ РЯДОВ НА ОСНОВЕ МОДИФИЦИРОВАННОГО АДАПТИВНОГО НЕО-ФАЗЗИ-ПРЕДИКТОРА

В статье рассмотрена задача адаптивного прогнозирования многомерных нелинейных временных рядов, характеристики которых могут резко меняться во времени непредсказуемым образом, на основе многомерных нео-фаззи-нейронов и алгоритм обучения, сочетающий в себе высокое быстродействие и фильтрующие свойства. Предлагаемый нео-фаззи-предиктор предназначен для решения задачи краткосрочного прогнозирования в условиях короткой обучающей выборки.

**Ключевые слова:** адаптивное прогнозирование, нео-фаззи-нейрон, многомерные временные ряды, алгоритм обучения.

### Введение

Задача прогнозирования в настоящее время актуальна во многих технических, медико-биологических, социально-экономических и иных областях, где качество принимаемых решений существенно зависит от точности синтезируемых прогнозов. Следует отметить, что в большинстве практических задач прогнозируемые временные ряды характеризуются высоким уровнем нелинейности и нестационарности, зашумленностью, наличием нерегулярных трендов, скачков, аномальных выбросов. Следует помнить, что традиционные статистические методы анализа временных рядов часто оказываются неэффективными ввиду того, что эти методы подразумевают априорное наличие достаточно большой и репрезентативной выборки.

Альтернативой статистическим методам может служить математический аппарат вычислительного интеллекта, и, прежде всего, искусственные нейронные сети [1 – 2] и нейро-фаззи системы [3], так как они обладают универсальными аппроксимирующими свойствами и высокой вычислительной эффективностью.

Следует отметить, что при обработке существенно нестационарных рядов учет ранней предыстории может ухудшить качество прогноза.

Таким образом, следует отказаться от процедур обучения, основанных на обратном распространении ошибки (многослойные перцептроны, рекуррентные сети) или методе наименьших квадратов (радиально-базисные и функционально-связанные нейронные сети) в пользу процедур, основанных на локальных критериях и «короткой памяти», таких как, например, алгоритм Качмажа-Уидроу-Хоффа.

### Формальная постановка задачи прогнозирования

В общем случае прогнозируемый  $n$ -мерный временной ряд можно представить в виде:

$$x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T, \quad (1)$$

где  $k = 1, 2, \dots$  – текущее дискретное время. При этом, при наличии в системе  $d$ -элементов чистого запаздывания  $(z^{-1})$ , формирующих предысторию из  $d$  наблюдений

$$\begin{aligned} &x_1(k-1), x_1(k-2), \dots, x_1(k-d), \dots, \\ &x_2(k-1), \dots, x_i(k-p), \dots, x_n(k-d), \end{aligned} \quad (2)$$

можно сформулировать задачу прогнозирования как

$$\hat{x}(k) = F(X(k)), \quad (3)$$

где  $\hat{x}(k) = (\hat{x}_1(k), \hat{x}_2(k), \dots, \hat{x}_n(k))^T$  – вектор прогнозов,  $X(k)$  – вектор предыстории,  $F(\bullet)$  – нелинейный прогнозирующий оператор, обеспечивающий оптимальное в рамках принятого критерия предсказание многомерной последовательности  $x(k)$ .

### Нео-фаззи-нейрон

Нео-фаззи-нейрон (NFN), введенный Т. Ямакой с коллегами [5 – 7], является нелинейной обучаемой системой, по архитектуре достаточно близкой к  $pd$ -входному формальному нейрону.

Структура нео-фаззи-нейрона (применительно к рассматриваемой задаче прогнозирования) приведена на рис. 1.

В отличие от формального нейрона, NFN содержит нелинейные синапсы  $NS_{ij}$ , в которых реализуются элементарные правила нечеткого вывода вида

$$\text{IF } \hat{x}_i \text{ IS } X_{ij} \text{ THEN } f(\hat{x}_i) = \sum_{i=1}^h \mu_{ijl}(\hat{x}_i) w_{ijl} \quad (4)$$

где  $X_{ij}$  – нечеткое множество на  $i$ -м входе в antecedенте  $l$ -го правила,  $\mu_{ijl}(\hat{x}_i)$  – функция принадлежности,  $w_{ijl}$  – синглетон в consequente  $l$ -го правила.




Рис. 1. Нео-фаззи-нейрон

Таким образом, при подаче на вход векторного сигнала, на выходе появляется скалярное значение

$$\begin{aligned} \hat{x}_i(k) &= w_{j00} + \sum_{i=1}^{nd} f_{ji}(\hat{x}_i(k)) = \\ &= w_{j00} + \sum_{i=1}^{nd} \sum_{l=1}^h \mu_{jil}(\hat{x}_i(k)) w_{jil}(k-1), \end{aligned} \quad (5)$$

определяемое одновременно функциями принадлежности  $\mu_{jil}(\hat{x}_i)$  и значениями синаптических весов  $w_{jil}$ . Можно заметить, что данный нейрон достаточно близок к системе нечеткого вывода (FIS) [8] и к радиально-базисным нейронным сетям (RBFN) [1]. Учитывая их функциональную эквивалентность и универсальные аппроксимирующие свойства, возможно их эффективное применение в системах прогнозирования [10, 11].

В качестве функций принадлежности в нео-фаззи нейронах применяются, как правило, треугольные функции, определяемые расстоянием между величиной входного сигнала  $\hat{x}_i(k)$  и параметрами центров  $c_{jil}$ . Применение треугольных функций обусловлено простотой вычисления производных, что позволяет применять оптимальные методы обучения.




Рис. 2. Функции принадлежности

Определяются эти функции следующим образом:

$$\mu_{jil}(\tilde{x}_i) = \frac{c_{jil} - \tilde{x}_i}{c_{ji2}}, \quad (6)$$

$$\mu_{jil}(\tilde{x}_i) = \begin{cases} \frac{\tilde{x}_i - c_{ji,l-1}}{c_{jil} - c_{ji,l-1}}, & \tilde{x}_i \in [c_{ji,l-1}, c_{jil}], \\ \frac{c_{jil} - \tilde{x}_i}{c_{ji,l+1} - c_{jil}}, & \tilde{x}_i \in [c_{jil}, c_{ji,l+1}], \\ 0, & \text{иначе} \end{cases} \quad (7)$$

$$\mu_{jih}(\tilde{x}_i) = \frac{\tilde{x}_i - c_{ji,h-1}}{1 - c_{ji,h-1}}, \quad (8)$$

$$c_{jil} = 0, c_{ji2} = \frac{1}{h-1}, \dots, c_{jil} = \frac{1-l}{h-1}, \dots, c_{jih} = 1. \quad (9)$$

При этом естественно полагается, что все входные данные предварительно закодированы на интервале  $\tilde{x}_i \in [0, 1]$ .

Можно заметить, что такое определение функций принадлежности автоматически обеспечивает единичное разбиение (разбиение Руспини):

$$\sum_{l=1}^h \mu_{jil}(\hat{x}_i) = 1. \quad (10)$$

Таким образом, при активизации нечеткого интервала  $p$ , выход нелинейного синапса можно выразить следующим образом:

$$\begin{aligned} f_{ji}(\hat{x}_i) &= \sum_{l=1}^h w_{jil} \mu_{jil}(\hat{x}_i) = \\ &= w_{jip} \mu_{jip}(\hat{x}_i) + w_{jip+1} \mu_{jip+1}(\hat{x}_i) = \\ &= \frac{c_{ji,p+1} - \hat{x}_i}{c_{ji,p+1} - c_{jip}} w_{jip} + \frac{\hat{x}_i - c_{jip}}{c_{ji,p+1} - c_{jip}} w_{jip+1} = \\ &= a_{ji} \hat{x}_i + b_{ji}, \end{aligned} \quad (11)$$

где

$$a_{ji} = \frac{w_{jip+1} - w_{jip}}{c_{ji,p+1} - c_{jip}}; \quad b_{ji} = \frac{c_{ji,p+1} w_{jip} - c_{jip} w_{jip+1}}{c_{ji,p+1} - c_{jip}}. \quad (12)$$

Таким образом, каждый нелинейный синапс реализует кусочно-линейную аппроксимацию нелинейного сигнала  $\hat{x}_i$ .

### Адаптивный нео-фаззи-предиктор

Рассмотренный нео-фаззи-нейрон не подходит для прогнозирования многомерного временного ряда, так как является одновыходовым. Наиболее простым решением было бы параллельное использование одновыходовых нео-фаззи-нейронов (или сетей на их основе) для вычисления каждого из элементов вектора прогноза, однако в этом случае каждая из сетей будет работать автономно, то есть без учета связей между элементами выходного вектора, что снизит качество прогноза.

Для прогнозирования с учетом связей можно использовать адаптивный нео-фаззи-предиктор [4], структура которого изображена на рис. 3




Рис. 3. Адаптивный нео-фаззи-предиктор

Очевидно, что представленная архитектура является избыточной. Это объясняется тем, что  $\mu_{1i1}(x_1) = \mu_{2i1}(x_1) = \dots = \mu_{jil}(x_1) = \dots = \mu_{nil}(x_1)$ . Избежать этой избыточности можно, введя в рассмотрение многомерный нео-фаззи нейрон, узлами кото-

$$W = \begin{pmatrix} W_{100} & W_{211} & W_{112} & \dots & W_{11h} & W_{121} & \dots & W_{1i1} & \dots & W_{1,nd,h} \\ W_{200} & W_{211} & W_{212} & \dots & W_{21h} & W_{221} & \dots & W_{2i1} & \dots & W_{2,nd,h} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ W_{n00} & W_{n11} & W_{n12} & \dots & W_{n1h} & W_{n21} & \dots & W_{n i1} & \dots & W_{n,nd,h} \end{pmatrix}. \quad (14)$$

Тогда сигнал на выходе в момент времени k можно представить в виде:

$$x(k) = F(X(k)) = W(k-1)\mu(k), \quad (15)$$

где  $W(k-1)$  – матрица синаптических весов, на-

рого будут нелинейные синапсы  $MNS_j$ , каждый из которых будет содержать h функций принадлежности и ph настраиваемых синаптических весов.




Рис. 4. Многомерный нео-фаззи-нейрон

### Обучение нео-фаззи нейрона

Рассмотрим вектор текущих значений функции принадлежности:

$$\mu(k) = (1, \mu_{j11}(\tilde{x}_1(k)), \mu_{j12}(\tilde{x}_1(k)) \dots \mu_{jih}(\tilde{x}_1(k)), \mu_{j21}(\tilde{x}_2(k)), \dots, \mu_{jil}(\tilde{x}_i(k)), \dots, \mu_{jnd,h}(\tilde{x}_{nd}(k)))^T \quad (13)$$

и матрицу синаптических весов  $W(k)$ :

строенных на основании информации полученной до k-го такта.

Тогда процедуру обучения можно записать как многомерную модификацию адаптивного алгоритма обучения [4]:

$$\begin{cases} W(k) = W(k-1) + r^{-1}(k)(x(k) - W(k-1)\mu(k))\mu^T(k) \\ r(k) = \alpha r(k-1) + \|\mu(k)\|^2 \end{cases} \quad (16)$$

где  $\alpha \in [0, 1]$  – параметр сглаживания, обеспечивающий компромисс между следящими и фильтрующими свойствами алгоритма.

При  $\alpha = 0$  алгоритм вырождается в многомерную версию алгоритма Качмажа-Уидроу-Хоффа [14], обеспечивая максимальное быстродействие при слежении за сигналом. При  $\alpha = 1$  алгоритм превращается в процедуру многомерной стохастической аппроксимации [15], обладающей фильтрующими свойствами.

### Заключение

Предложена адаптивная система для прогнозирования многомерных временных рядов в режиме реального времени. Введены нейросетевая архитектура, узлами которой являются нео-фаззи-нейроны, и, как ее обобщение, – многомерный нео-фаззи-нейрон, характеризующийся простотой численной реализации и возможностью быстрого и эффективного обучения.

### Список литературы

1. Haykin S. *Neural Networks. A Comprehensive Foundation*. – Upper Saddle River, N.J.: Prentice Hall, Inc., 1999. – 842 p.
2. Mandic D.P., Chambers J.A. *Recurrent Neural Networks for Prediction*. – Chichester: John Wiley & Sons, 2001. – 285 p.
3. Jang J.-S. R., Sun C.-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.
4. Бодянский Е.В. Адаптивный фильтр-предиктор многомерных существенно нестационарных временных рядов / Е.В. Бодянский, О.А. Романюк, О.С. Удовенко // Системи обробки інформації. – 2009. – Вип. 4(78). – С. 23-28.
5. 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. 2-nd Int. Conf. on Fuzzy Logic and Neural Networks "IIZUKA-92". – Izuka, Japan, 1992. – P. 477-483.*

6. Uchino E., Yamakawa T. *Soft computing based signal prediction, restoration, and Filtering / Ed. Da Ruan. Intelligent Hybrid Systems: Fuzzy Logic, Neural Networks, and Genetic Algorithms*. – Boston: Kluwer Academic Publishers, 1997. – P. 331-349.

7. 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.

8. Sugeno M. *An introductory survey of fuzzy control // Information Sciences*. – 1985. – 36. – P. 59-83.

9. Jang J.-S. R., Sun C.-T. *Functional equivalence between radial basis function networks and fuzzy inference systems // IEEE Trans, on Neural Networks*. – 1993. – 4. – P. 156-159.

10. Park J., Sandberg I.W. *Universal approximation using radial-basis-function network // Neural Computation*. – 1991. – 3. – P. 246-257.

11. Wang L.X. *Fuzzy systems are universal approximators // Proc. 1<sup>st</sup> IEEE Conf. on Fuzzy Systems*. – San Diego. – 1992. – P. 1163-1169.

12. Bodyanskiy Ye., Kolodyazhniy V., Stephan A. *An adaptive learning algorithm for a neuro-fuzzy network / Ed. B. Reusch. Computational Intelligence. Theory and Applications*. – Berlin-Heidelberg – New-York: Springer, 2001. – P. 68-75.

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

14. Руденко О.Г. Адаптивный алгоритм прогнозирования случайных последовательностей / О.Г. Руденко, Е.В. Бодянский, И.П. Плусс // Автоматика. – 1979. – №1. – С. 51-54.

15. Caines P.E., Lafortune S. *Adaptive control with recursive identification for stochastic linear systems // IEEE Trans, on Autom. Control*. – 1984. – 29. – №4. – P. 312-321.

Поступила в редколлегию 16.03.2011

**Рецензент:** д-р техн. наук, проф. В.А. Филатов, Харьковский национальный университет радиоэлектроники, Харьков.

### ПРОГНОЗУВАННЯ НЕСТАЦІОНАРНИХ ЧАСОВИХ РЯДІВ НА ОСНОВІ МОДИФІКОВАНОГО АДАПТИВНОГО НЕО-ФАЗЗИ-ПРЕДІКТОРА

Д.А. Плісько, В.В. Волкова, Є.В. Бодяньський

У статті розглянуто завдання адаптивного прогнозування багатовимірних нелінійних тимчасових рядів, характеристики яких можуть різко мінятися в часі непередбачуваним чином, на основі багатовимірних нео-фаззи-нейронів і алгоритм навчання, що поєднує в собі високу швидкодію і фільтруючі властивості. Пропонований нео-фаззи-предиктор призначений для вирішення завдання короткострокового прогнозування в умовах короткої повчальної вибірки.

**Ключові слова:** адаптивне прогнозування, нео-фаззи-нейрон, багатовимірні тимчасові ряди, алгоритм навчання.

### NON-STATIONARY TIME SERIES PREDICTION BY THE MODIFIED ADAPTIVE NEO-FUZZY-PREDICTOR

D.A. Plisko, V.V. Volkova, Ye.V. Bodyanskiy

The task of adaptive prognostication of multidimensional nonlinear temporal rows descriptions of which can sharply change in time by unforeseeable appearance is considered in the article, on the basis of multidimensional neo-fuzzy-neuron and teaching algorithm, combining in itself a high fast-acting and filtering properties. Offered neo-fuzzy-predictoris intended for the decision of task of short-term prognostication in the conditions of short teaching selection.

**Keywords:** adaptive prognostication, neo-fuzzy-neuron, multidimensional temporal rows, teaching algorithm.