

УДК 004.032.26

Вирішено задачу прогнозування стислих нелінійних часових рядів з нестационарними характеристиками. Запропоновано нейромережеву архітектуру, що складається з трьохшарового перцептронів та нейро-нео-фаззи мережі зустрічного поширення

Ключові слова: компресія, прогнозування, перцептрон, нео-фаззи-нейрон

Решена задача прогнозирования сжатых нелинейных временных рядов с нестационарными характеристиками. Предложена нейросетевая архитектура, состоящая из трехслойного перцептрона и нейро-нео-фаззи сети встречного распространения

Ключевые слова: компрессия, прогнозирование, перцептрон, нео-фаззи-нейрон

The task of compressed nonlinear time series prediction with nonstationary characteristics is solved. The new architecture of a neural network is proposed that consists of a three-layer "bottle-neck" perceptron and a counterpropagation neo-neuro-fuzzy network

Keywords: compression, prediction, perceptron, neo-fuzzy-neuron

ПРЕДИКТОР СЖАТЫХ ДАННЫХ НА ОСНОВЕ НЕЙРО-НЕО-ФАЗЗИ СЕТИ ВСТРЕЧНОГО РАСПРОСТРАНЕНИЯ

А.К. Тищенко

Аспирант*

Контактный тел.: 050-607-90-89

E-mail: lehatish@mail.ru

И.П. Плисс

Кандидат технических наук, ведущий научный сотрудник, старший научный сотрудник*

Контактный тел.: (057) 702-18-90

E-mail: pliss@kture.kharkov.ua

Н.А. Тесленко

Кандидат технических наук, старший научный сотрудник*

Контактный тел.: (057) 702-18-90

E-mail: ntesl@yandex.ru

*Проблемная научно-исследовательская лаборатория автоматизированных систем управления Харьковский национальный университет радиоэлектроники пр. Ленина, 14, г. Харьков, 61166

Введение

Задача сжатия (компрессии) информации состоит в уменьшении количества хранимых или передаваемых данных с возможностью их полного восстановления (декомпрессии). Применение многослойной нейронной сети позволяет решать задачу компрессии с потерями (с допустимой утратой определенной части информации) при хороших обобщающих способностях и относительно высоком коэффициенте компрессии. При этом в отличие от стандартного анализа главных компонент, многослойная нейронная сеть способна отображать и сохранять нелинейные зависимости внутри данных. Данная сеть эффективно производит нелинейный анализ главных компонент. Её преимущество состоит в том, что такая сеть не ограничена линейным преобразованием, хотя и содержит стандартный анализ главных компонент как частный случай. Основным недостатком этого подхода к решению задачи сокращения размерности является низкая скорость сходимости алгоритма обучения, присущая всем многослойным нейронным сетям с нелинейными активационными функциями типа логистической кривой или гиперболического тангенса.

Также следует заметить, что предложенная сеть позволяет решить задачу прогнозирования в условиях короткой, предварительно сжатой обучающей

выборки и характеризуется высоким быстродействием. Данная архитектура может быть применена, например, в медицине при обработке кардиограммы, получаемой с нескольких датчиков.

1. Архитектура сети

Предложенная система представляет собой гибрид двух сетей – многослойного перцептрона и нейро-нео-фаззи сети встречного распространения.

В общем случае не существует теоретического ограничения на количество слоев в перцептроне, однако на практике их обычно три. Все нейроны одного слоя однонаправленно связаны с нейронами смежных слоев. Заметим, что в перцептроне не существует связей между нейронами внутри слоя и от высшего слоя к низшему. В общем случае перцептрон может иметь различное число нейронов и различные синаптические веса в различных слоях. Каждый нейрон многослойного перцептрона характеризуется одним выходом и множеством входов, которые, в свою очередь, являются выходами нейронов предыдущего слоя [1]. Количество нейронов во всех слоях, кроме второго, равно n , а во втором – m , причем $m < n$.

Пусть $u_j^{[s]}$ - внутренний сигнал j -го нейрона s -го слоя, содержащего n_s нейронов, является взвешенной суммой выходов предыдущего слоя

$$u_j^{[s]} = \sum_{i=0}^{n_{s-1}} w_{ji}^{[s]} o_i^{[s-1]}, \quad (1)$$

где $w_{ji}^{[s]}$ - синаптические веса, связывающие каждый нейрон s -го слоя со всеми нейронами предыдущего слоя так, что $o_i^{[s-1]} = x_i^{[s]}$, $o_1^{[0]} = x$, $o_1^{[3]} = \tilde{x}_1$.

Тогда выход каждого нейрона есть нелинейное преобразование вида

$$o_j^{[s]} = \psi_j^{[s]}(u_j^{[s]}) = \psi_j^{[s]} \left(\sum_{i=0}^{n_{s-1}} w_{ji}^{[s]} o_i^{[s-1]} \right), \quad (2)$$

где для сокращения записи величина смещения $\theta_j^{[s]}$ обозначается как синаптический вес $w_{j0}^{[s]} = \theta_j^{[s]}$, а $o_0^{[s-1]} \equiv 1$.

Предиктор представляет собой нейро-нео-фаззи сеть встречного распространения [11-13], в свою очередь состоящую из слоя нечеткой кластеризации Кохонена и слоя нео-фаззи-нейронов. На вход слоя-предиктора подаются выходные сигналы со второго слоя персептрона (слоя-компрессора), таким образом на вход подается вектор сжатых значений $o^{[2]}(k) = (o_1^{[2]}(k), o_2^{[2]}(k), \dots, o_m^{[2]}(k))^T$. В дальнейшем обозначим данный вектор входных значений через $y(k) = (y_1(k), y_2(k), \dots, y_m(k))^T$. Работа сети заключается в вычислении уровней принадлежности текущего наблюдения к кластерам, определяемым весами нейронов слоя Кохонена, вычислении значений выходных сигналов нео-фаззи-нейронов и ранжировании этих значений по соответствующим степеням принадлежности на выходах слоя Кохонена. Выходом сети является вектор прогнозов $\tilde{y}(k) = (\tilde{y}_1(k), \tilde{y}_2(k), \dots, \tilde{y}_n(k))^T$. Данная нейро-нео-фаззи сеть решает задачу прогнозирования.

Таким образом, между нейронами слоев Кохонена и слоем нео-фаззи нейронов устанавливается взаимнооднозначное соответствие, а именно: каждому нейрону Кохонена ϕ_l соответствует нео-фаззи нейрон NFN_l , $l=1, 2, \dots, p$, p - количество нейронов в скрытых слоях.

Выходы нейронов слоя Кохонена вычисляются в виде

$$\phi_l(k) = \frac{\Phi_l(k)}{\sum_{i=1}^p \Phi_i(k)}, \quad (5)$$

где $\phi_l(k) = \Phi(\|x(k) - c_l\|_{R_1}^2)$ - функции принадлежности нейронов (функции соседства), $\|\cdot\|_{R_1}$ - норма вектора по матрице R_1^{-1} .

Таким образом, выходы нейронов слоя Кохонена удовлетворяют условию

$$\sum_{l=1}^p \phi_l(k) = 1. \quad (6)$$

Архитектура нео-фаззи-нейрона [14, 15] представлена на рис. 1. Здесь

$$q_l(k) = \sum_{i=1}^m f_i^{[l]}(y_i(k)), \quad (7)$$

$$f_i^{[l]}(y_i(k)) = \sum_{j=1}^h \mu_{ij}(y_i(k)) w_{ij}^{[l]}(k), \quad (8)$$

где h - количество функций принадлежности в нелинейном синапсе NS_i ,

m - длина вектора y .

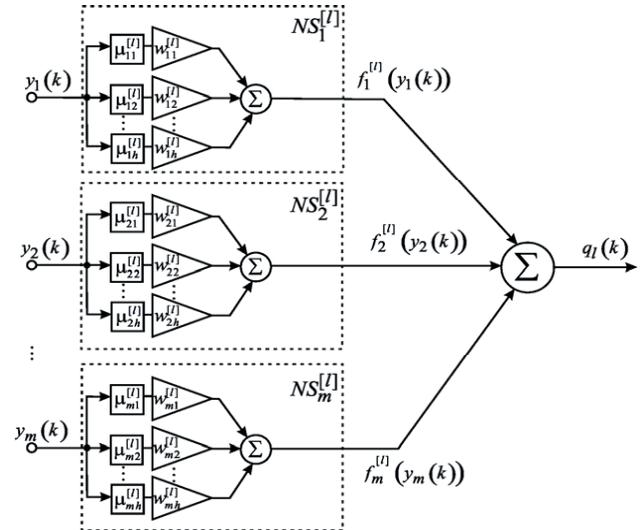


Рис. 1. Нео-фаззи-нейрон

В качестве функций принадлежности в нео-фаззи-нейроне обычно используются треугольные конструкции, вид которых приведен на рис. 2, а их значения определяются расстоянием между величиной входного сигнала y и параметрами центров c_{ij} :

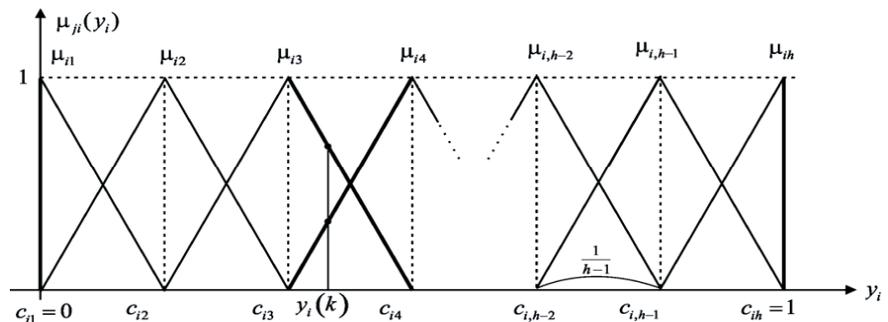


Рис. 2. Функции принадлежности нео-фаззи-нейрона

Функции принадлежности μ_{ij} нелинейных синапсов обеспечивают разложение единицы на некотором интервале $[a, b]$. В дальнейшем в качестве μ_{ij} будем рассматривать треугольные функции, которые определяются как

$$\mu_{ij}(y_i) = \begin{cases} \frac{c_{ij} - y_i}{c_{ij} - c_{i,j-1}}, & y_i \in (c_{i,j-1}; c_{ij}], \\ \frac{y_i - c_{ij}}{c_{i,j+1} - c_{ij}}, & y_i \in (c_{ij}; c_{i,j+1}], \\ 0, & \text{иначе} \end{cases} \quad (9)$$

для $i=1,2,\dots,m, j=1,2,\dots,h$.
Обозначим

$$m_\Sigma = \sum_{i=1}^m h_i, \tag{10}$$

$$M(k) = (\mu_{11}, \mu_{12}, \dots, \mu_{1h}, \mu_{21}, \mu_{22}, \dots, \mu_{2h}, \dots, \mu_{m1}, \mu_{m2}, \dots, \mu_{mh})^T \tag{11}$$

– вектор функций принадлежности нео-фаззи-нейронов размерности

$$(m_\Sigma \times 1)$$

и

$$W_{NFN}^T = \begin{pmatrix} w_{11}^{[1]} & w_{21}^{[1]} & \dots & w_{mh}^{[1]} \\ w_{11}^{[2]} & w_{21}^{[2]} & \dots & w_{mh}^{[2]} \\ \dots & \dots & \ddots & \dots \\ w_{11}^{[p]} & w_{21}^{[p]} & \dots & w_{mh}^{[p]} \end{pmatrix} = (w_{NFN}^{[1]}, w_{NFN}^{[2]}, \dots, w_{NFN}^{[p]})^T \tag{12}$$

– матрицу весов нео-фаззи-нейронов размерностью $(h \times m_\Sigma)$, при этом выходом сети в целом является вектор:

$$\tilde{y}(k) = (\tilde{y}_1(k), \tilde{y}_2(k), \dots, \tilde{y}_m(k))^T, \tag{13}$$

где $\tilde{y}_l(k) = q_l(k)\phi_l(k), l=1..m$.

2. Обучение нейронной сети

Обучение многослойного персептрона может быть осуществлено с помощью любой процедуры обратного распространения ошибок с тем отличием, что в качестве обучающего образа $d(k)$ используется сам входной сигнал $x(k)$, подлежащий сжатию.

Целью ассоциативного обучения является восстановление на выходе сети сигнала $\tilde{x}(k)$, наилучшим образом аппроксимирующего входной сигнал $x(k)$. Собственно же сжатие информации происходит во втором скрытом слое, содержащем меньшее число нейронов, чем первый и выходной слои. Именно с выхода второго скрытого слоя снимается «сжатый» сигнал $y(k) = o^{[2]}(k)$, при этом в результате такого подхода к компрессии информации достигается оптимальное решение задачи нелинейного факторного анализа [1].

В качестве активационных функций искусственных нейронных сетей часто используются сигмоидальные функции, поскольку они являются непрерывными, монотонными, возрастающими, ограниченными и имеют отличные от нуля производные на всей области определения. Для решения задачи сжатия информации предлагается использовать многослойную автоассоциативную искусственную нейронную сеть прямого распространения, построенную на формальных нейронах с полиномиальной функцией активации, где параметр крутизны $\gamma_j(k)$ является постоянным и принят равным единице [3, 4].

$$\Psi(\gamma_j(k)u_j(k)) = \gamma_j(k)u_j(k) - \frac{1}{3}\gamma_j^3(k)u_j^3(k). \tag{14}$$

Процесс обучения нейронной сети сводится к настройке матриц синаптических весов $W^{[s]}$, $s=1,2,3$, путем минимизации принятой целевой функции, в качестве которой используется выражение:

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

где $e_j(k) = x_j(k) - \tilde{x}_j(k)$, $\tilde{x}(k) - (n \times 1)$ – выходной векторный сигнал сети;

$x(k) - (n \times 1)$ – входной вектор.

В данном случае в качестве обучающего используется сам входной сигнал, подлежащий компрессии. Применение процедуры градиентного спуска приводит к алгоритму обучения общего вида:

$$\begin{aligned} w_{ji}^{[s]}(k+1) &= w_{ji}^{[s]}(k) - \eta(k) \frac{\partial E(k)}{\partial w_{ji}^{[s]}(k)} = \\ &= w_{ji}^{[s]}(k) - \eta(k) \frac{\partial E(k)}{\partial u_j^{[s]}(k)} \frac{\partial u_j^{[s]}(k)}{\partial w_{ji}^{[s]}(k)} = \\ &= w_{ji}^{[s]}(k) + \eta(k) \delta_j^{[s]}(k) o_i^{[s-1]}(k), \\ \Delta w_{ji}^{[s]}(k) &= -\eta(k) \frac{\partial E(k)}{\partial w_{ji}^{[s]}(k)}, \end{aligned} \tag{15}$$

где $\delta_j^{[s]}(k) = \frac{\partial E(k)}{\partial u_j^{[s]}(k)}$ – локальная ошибка j -го нейрона s -го слоя;

$\eta(k)$ – скалярный параметр, определяющий скорость обучения сети;

$o_i^{[s-1]}$ – выходной сигнал $(s-1)$ -го (предыдущего) слоя.

Таким образом, предложенный алгоритм обучения данной сети представляет собой процедуру настройки трех матриц синаптических весов, начиная с выходного (третьего) слоя и имеет вид [4]:

$$\begin{cases} \Delta w_{ji}^{[3]}(k) = \eta(k)(1 - u_j^{[3]}(k))e(k)o_i^{[2]}(k), \\ \Delta w_{ji}^{[2]}(k) = \eta(k)(1 - u_j^{[2]}(k))o_i^{[1]} \sum_{l=1}^n \delta_l^{[3]}(k)w_{il}^{[3]}(k), \\ \Delta w_{ji}^{[1]}(k) = \eta(k)(1 - u_j^{[1]}(k))x_i(k) \sum_{l=1}^m \delta_l^{[2]}(k)w_{il}^{[2]}(k). \end{cases} \tag{16}$$

Полиномиальная функция активации (14) удовлетворяет всем требованиям, предъявляемым к сигмоидальным функциям активации, обладая при этом более простыми производными по настраиваемым параметрам, что позволяет упростить численную реализацию процедуры обучения.

Процедура обучения предложенной прогнозирующей нейро-нео-фаззи сети является двухэтапной: на первом этапе происходит настройка параметров слоя Кохонена, на втором этапе выполняется обучение нео-фаззи-нейронов с учетом сигналов на выходах

нейронов слоя Кохонена. Такая процедура обучения согласуется с подходом к обучению сети встречного распространения.

Обучение слоя Кохонена происходит в режиме самообучения без использования обучающих сигналов. Для нахождения центров $c_l(k)$ нейронов этого слоя предлагается использовать рекуррентный алгоритм кластеризации

Бездека нечетких s -средних [6, 7] в модификации для обучения нечеткой кластеризирующей сети Кохонена [8, 9]:

$$\left\{ \begin{array}{l} \phi_l(k+1) = \frac{\left(\|y(k+1) - c_l(k)\|_{R_l^{-1}}^2 \right)^{\frac{1}{1-\beta}}}{\sum_{i=1}^p \left(\|y(k+1) - c_i(k)\|_{R_i^{-1}}^2 \right)^{\frac{1}{1-\beta}}}, \\ c_l(k+1) = c_l(k) + \tilde{\eta}(k) \phi_l^{\beta}(k+1) (y(k+1) - c_l(k)), \quad l=1, 2, \dots, p, \end{array} \right. \quad (17)$$

где β – неотрицательный параметр, называемый «фазсификатором» и определяющий нечеткую границу между кластерами с центроидами в точках $c_l(k)$, соответствующим нейронам слоя Кохонена; $\tilde{\eta}(k)$ – убывающий коэффициент, определяющий скорость обучения.

На втором этапе для обучения параметров неофаззи нейронов используется процедура взвешенных

наименьших квадратов [10]. Обучающим сигналом для каждого неофаззи нейрона является соответствующее значение на входе сети, а настройка параметров выполняется с учетом выхода соответствующего нейрона слоя Кохонена в качестве весового коэффициента. Процедура обучения в рекуррентном виде:

$$\left\{ \begin{array}{l} w_{NFN}^{||}(k) = w_{NFN}^{||}(k-1) + \frac{P_1(k-1)(\tilde{y}(k) - M^T(k)w_{NFN}^{||}(k-1))}{1 + \phi_1(k)M^T(k)P_1(k-1)M(k)} M(k), \\ P_1(k) = \phi_1(k) \left(P_1(k-1) - \frac{\phi_1(k)P_1(k-1)M(k)M^T(k)P_1(k-1)}{1 + \phi_1(k)M^T(k)P_1(k-1)M(k)} \right), \end{array} \right. \quad (18)$$

где $M = (M(1), M(2), \dots, M(N))^T$, $P_1(k)$ – матрица размерности $(m_{\Sigma} \times m_{\Sigma})$.

4. Выводы

Предложенная сеть одновременно может использоваться для решения задачи компрессии информации и задачи прогнозирования.

Представленный алгоритм обучения трехслойной нейронной сети позволяет упростить численную реализацию процедуры обратного распространения ошибки, что, в свою очередь, позволяет сократить время обучения.

Литература

- Haykin, S. Neural Networks. A Comprehensive Foundation [Текст] / S. Haykin. – N.J.: Upper Saddle River, Prentice Hall, Inc., 1999. – 842 p.
- Arbib, M.A. The Handbook of Brain Theory and Neural Networks [Текст] / M.A. Arbib. – Madison: Impressions Books and Journals Services, Inc., 2003. – 1300p.
- Hristev, R.M. The ANN Book [Текст] / R.M. Hristev. – GNU Public Licence, 1998. – 392 p.
- Бодянский, Е.В. Прогнозирующая нейронная метасеть с нетрадиционными функциями активации [Текст] / Е.В. Бодянский, А.Н. Слипченко, Н.А. Тесленко // Автомобильный транспорт. – 2003. – 13. – С.273-275.
- Kohonen, T. Self-Organizing Maps [Текст] / T. Kohonen. – Berlin: Springer-Verlag, 1995. – 362 p.
- Tsao, E. C.-K. Fuzzy Kohonen clustering networks [Текст] / E. C.-K. Tsao, J.C. Bezdek, N. R. Pal. // Pattern Recognition. – 1994. – V.5. – 27. – P. 757–764.
- Looney, C.G. A fuzzy clustering and fuzzy merging algorithm [Текст] / C.G. Looney. – Reno, NV, 1999.
- Bezdek, J.C. Pattern Recognition with Fuzzy Objective Function Algorithms [Текст] / J.C. Bezdek. – N.Y.: Plenum Press, 1981. – 272 p.
- Bodyanskiy, Ye. Recursive fuzzy clustering algorithms for segmentation of biological time series [Текст] / Ye. Bodyanskiy, Ye. Gorshkov, V. Kolodyazhnyi, O. Shylo // Proc. 13-th East West Fuzzy Coll. 2006. – Zittau/Goerlitz: University of Applied Sciences (FH), 2006. – P. 130–139.
- Эйкхофф, П. Основы идентификации систем управления [Текст] / П. Эйкхофф. – М.: Мир, 1975. – 683с.
- Hecht-Nielsen, R. Counterpropagation Networks [Текст] / R. Hecht-Nielsen // Applied Optics. – 1987. – V. 26. – P. 4979–4984.
- Hecht-Nielsen, R. Applications of counterpropagation networks [Текст] / R. Hecht-Nielsen // Neural Networks. – 1988. – V.1. - 2. – P. 131–139.
- Zhang, Z. Fuzzy generalization of the counter-propagation neural network: a family of soft competitive basis function neural networks [Текст] / Z. Zhang, N. Zheng, T. Wang // Soft Computing. – 2001. – V.5. - 6. – P. 440–450.
- Horio, K. Modified counterpropagation employing neo fuzzy neurons and its application to system modelling [Текст] / K. Horio, T. Yamakawa // Proc. Int. Conf. on Info-tech and Info-net (ICII 2001). – IEEE Press, 2001. – V.4. – P. 50–55.
- Yamakawa, T. A neo fuzzy neuron and its applications to system identification and prediction of the system behaviour [Текст] / T. Yamakawa, E. Uchino, T. Miki, H. Kusanagi // Proc. 2nd Int. Conf. on Fuzzy Logic and Neural Networks ``IIZUKA-92''. – Iizuka, Japan, 1992. – P. 477–483.
- Тесленко, Н.А. Алгоритм обучения автоассоциативной искусственной многослойной нейронной сети [Текст] / Н.А. Тесленко // Бионика интеллекта. – 2004. – №1(61). – С.103-106.