
НЕЙРОІНФОРМАТИКА ТА ІНТЕЛЕКТУАЛЬНІ СИСТЕМИ

НЕЙРОИНФОРМАТИКА И ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ

NEUROINFORMATICS AND INTELLIGENT SYSTEMS

УДК 004.032.26

Е. В. Бодянский, Е. А. Викторов

ПРОГНОЗИРОВАНИЕ ВРЕМЕННЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ НА ОСНОВЕ КАСКАДНОЙ ОРТОГОНАЛЬНОЙ НЕЙРОННОЙ СЕТИ

В статье рассматривается новая нетрадиционная нейросетевая архитектура – каскадная ортогональная нейронная сеть, алгоритм ее обучения в пакетном режиме и в режиме реального времени, а также применение этой архитектуры для решения задач прогнозирования и аппроксимации.

ВВЕДЕНИЕ

В настоящее время для решения широкого класса задач, связанных с обработкой информации, заданной в виде временных рядов или массивов числовых данных, порождаемых нестационарными, хаотическими или стохастическими системами, широкое распространение получили искусственные нейронные сети, благодаря своим аппроксимирующим возможностям и способности к обучению. Традиционно под обучением понимается процесс настройки весовых параметров сети в соответствии с той или иной процедурой оптимизации принятого критерия обучения [1, 2].

Улучшить качество получаемого результата можно, настраивая не только синаптические веса, но и архитектуру (количество узлов) самой нейронной сети путем либо увеличения числа нейронов относительно ис-

ходной простой архитектуры – конструктивный подход [3–5], либо путем уменьшения их количества в исходной сложной архитектуре – деструктивный подход [6–8].

С вычислительной точки зрения более привлекательным представляется конструктивный подход, в рамках которого можно выделить каскадные нейронные сети [9–11], наиболее характерным и эффективным представителем которых является Cascade-Correlation Learning Architecture (CasCorLA) [9]. Эти сети, стартуя с простой архитектуры, состоящей из единственного нейрона, в процессе обучения добавляют один за другим новые нейроны, образуя многослойную структуру. При этом в течение каждой эпохи обучения настраивается только один нейрон последнего каскада, все же предыдущие нейроны обрабатывают информацию с «замороженными» весами. Авторы CasCorLA Фальман и Лебьер отмечают высокую скорость обучения и хорошие аппроксимирующие свойства этой сети. Вместе с тем, следует отметить, что в качестве узлов в этой архитектуре используются элементарные перцептроны Розеллатта с функциями активации типа гиперболического тангенса так, что выходной сигнал каждого нейрона

© Бодянский Е. В., Викторов Е. А., 2008

нелинейно зависит от синаптических весов. Отсюда следует, что обучение должно производиться на основе дельта-правила и его модификаций, представляющих собой, по сути, градиентные алгоритмы оптимизации. Очевидно, что говорить об оптимизации скорости обучения в этом случае затруднительно. В связи с этим представляется целесообразным синтезировать каскадную архитектуру, использующую такие искусственные нейроны, в которых выходной сигнал будет линейно зависеть от синаптических весов, что позволит оптимизировать скорость обучения и сократить размер обучающей выборки.

1 ОРТО-НЕЙРОН

Среди множества функциональных структур, используемых для аппроксимации нелинейных зависимостей, особого внимания заслуживают ортогональные полиномы [12, 13]. Они обладают весьма привлекательными свойствами как с вычислительной точки зрения и обеспечиваемой ими точности, так и с точки зрения нейросетевой реализации [14–21].

При этом элементарная одномерная система, описываемая в пространстве «вход – выход» некоторой неизвестной функциональной зависимости $y(x)$ со сколь угодно высокой точностью, может быть представлена следующей суммой:

$$\hat{y} = \hat{f}(x) = w_0\phi_0(x) + w_1\phi_1(x) + \dots + w_h\phi_h(x) = \sum_{j=0}^h w_j\phi_j(x), \quad (1)$$

где x и $y(x)$ – входные и выходная переменные оцениваемого процесса, $\phi_j(x)$ – ортогональный полином j -го порядка ($j = 0, 1, 2, \dots, h$), j, q – неотрицательные целые числа, $k = 1, 2, \dots, N$ – дискретное время или порядковый номер элемента в выборке.

Выражение (1) может быть представлено с помощью элементарной схемы, приведенной на рис. 1 и названной нами орто-синапс.

На рис. 1 x_i – i -я компонента ($i = 1, 2, \dots, n$) сигнала $x = (x_1, x_2, \dots, x_n)^T$, w_{ji} ($j = 1, 2, \dots, h$) – синапти-

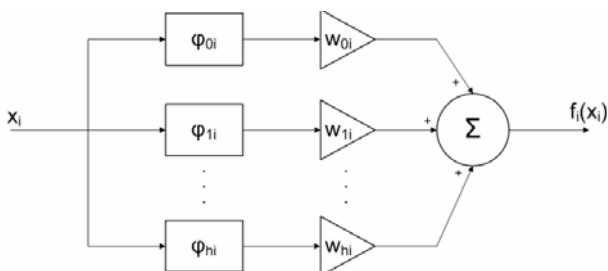


Рисунок 1 – Орто-синапс – OS

ческие веса, подлежащие определению, $f_i(x_i)$ – выходной сигнал орто-синапса, который может быть записан следующим образом:

$$f_i(x_i) = \sum_{j=0}^h w_{ji}\phi_{ji}(x_i). \quad (2)$$

Различные системы ортогональных полиномов могут быть использованы в качестве активационных функций в орто-синапсах. Выбор системы ортогональных полиномов зависит от специфики решаемой задачи. Если входные данные нормализованы на гиперкуб $[-1, 1]^n$, целесообразным представляется использовать систему ортогональных полиномов Лежандра, ортогональных на интервале $[-1, 1]$ с весом $\gamma(x) = 1$:

$$\phi_{ji}^L(x_i) = 2^{-j} \sum_{p=0}^{[j/2]} (-1)^p \frac{(2j-2p)!}{p!(j-p)!(j-2p)!} x_i^{j-2p}. \quad (3)$$

Также для упрощения вычислений может быть использована рекуррентная формула:

$$\phi_{j+1,i}^L(x_i) = \frac{2j+1}{j+1} x_i P_j(x_i) - \frac{j}{j+1} P_{j-1}(x_i). \quad (4)$$

Система ортогональных полиномов Лежандра лучше всего подходит в том случае, когда до построения нейромодели нам известен интервал, в котором изменяются данные. В ином случае может быть использована система ортогональных полиномов Эрмита:

$$H_l(u) = l! \sum_{p=1}^{[l/2]} (-1)^p \frac{(2u)^{l-2p}}{p!(l-2p)!}. \quad (5)$$

Эта система ортогональна на интервале $(-\infty, +\infty)$ с весовой функцией $h(u) = e^{-u^2}$ и дает возможность уменьшить влияние на результат точек, лежащих далеко от начала координат.

Также несложно заметить, что орто-синапс имеет идентичную архитектуру с нелинейным синапсом неофаззи-нейрона [22–24], однако реализует более гладкое полиномиальное приближение с помощью ортогональных полиномов, вместо кусочно-линейной аппроксимации.

Мы использовали орто-синапс в качестве строительного блока для архитектуры, названной нами орто-нейроном и приведенной на рис. 2.

Орто-нейрон имеет такую же архитектуру, как и неофаззи-нейрон, реализующая отображение

$$\hat{y} = \sum_{i=1}^n f_i(x_i) = \sum_{i=1}^n \sum_{j=0}^h w_{ji}\phi_{ji}(x_i), \quad (6)$$




Рисунок 2 – Орто-нейрон – ON

и позволяет добиться высокой точности аппроксимации и экстраполяции существенно нелинейных сигналов и процессов [16, 17, 19–21, 25]. Однако, как будет показано далее, орто-нейрон будет использован нами в качестве элементарного узла в архитектуре, названной каскадная ортогональная нейронная сеть (CONN – Cascade Orthogonal Neural Network).

2 КАСКАДНАЯ ОРТОГОНАЛЬНАЯ НЕЙРОННАЯ СЕТЬ

Архитектура каскадной ортогональной нейронной сети приведена на рис. 3.

Представленная конструкция реализует отображение следующего вида:

– нейрон первого каскада

$$\hat{y}_1 == \sum_{i=1}^n \sum_{j=0}^h w_{ji}^{[1]} \varphi_{ji}(x_i); \quad (7)$$

– нейрон второго каскада

$$\hat{y}_2 == \sum_{i=1}^n \sum_{j=0}^h w_{ji}^{[2]} \varphi_{ji}(x_i) + \sum_{j=0}^h w_{j,n+1}^{[2]} \varphi_{j,n+1}(\hat{y}_1); \quad (8)$$

– нейрон третьего каскада

$$\hat{y}_3 == \sum_{i=1}^n \sum_{j=0}^h w_{ji}^{[3]} \varphi_{ji}(x_i) + \sum_{j=0}^h w_{j,n+1}^{[3]} \varphi_{j,n+1}(\hat{y}_1) + \sum_{j=0}^h w_{j,n+2}^{[3]} \varphi_{j,n+2}(\hat{y}_2); \quad (9)$$

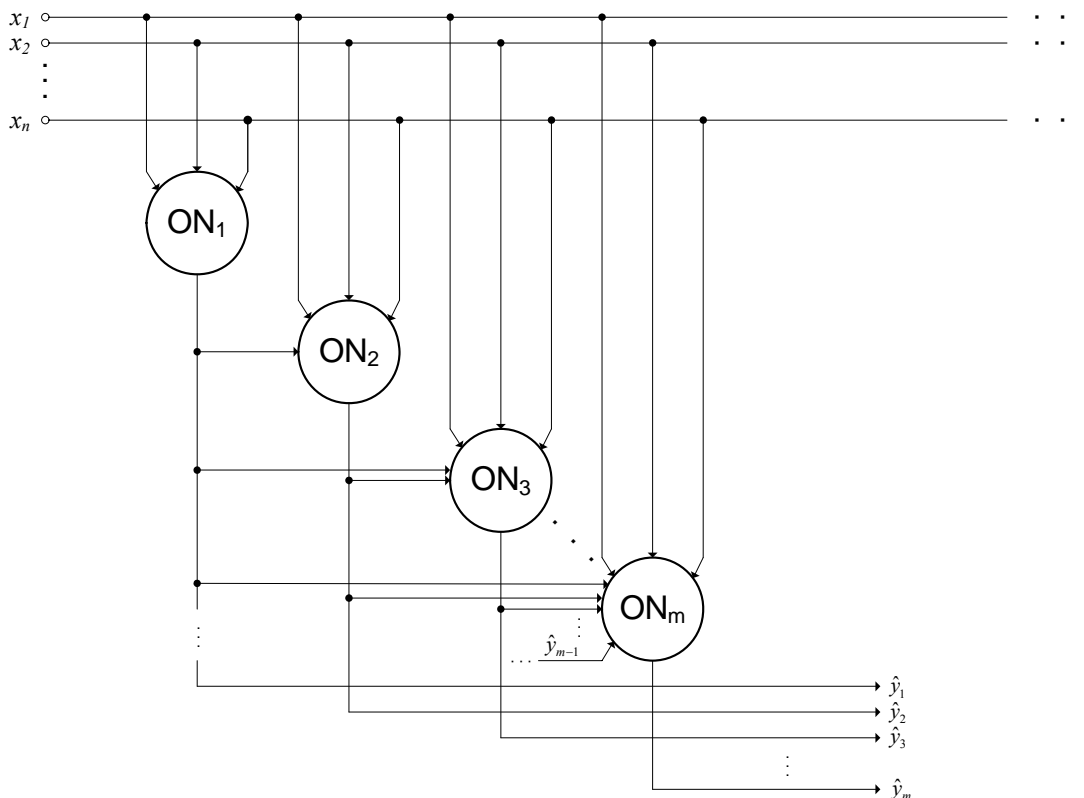


Рисунок 3 – Каскадная ортогональная нейронная сеть

– нейрон m -го каскада

$$\hat{y}_m = \sum_{i=1}^n \sum_{j=0}^h w_{ji}^{[m]} \varphi_{ji}(x_i) + \sum_{i=n+1}^{n+m-1} \sum_{j=0}^h w_{ji}^{[m]} \varphi_{ji}(\hat{y}_{l-n}), \quad (10)$$

где \hat{y}_m – выход m -го каскада нейронной сети; $w_{ji}^{[m]}$ – j -й синаптический весовой коэффициент в i -м орто-синапсе орто-нейрона m -го каскада; φ_{ji} – ортогональный полином i -го порядка в j -м орто-синапсе; h – количество ортогональных полиномов в орто-синапсах, по которым происходит разложение входных сигналов; n – количество орто-синапсов в ортонейроне первого каскада; $(n+m-1)$ – количество орто-синапсов в ортонейроне m -го каскада.

Каскадная ортогональная нейронная сеть содержит

$$(h+1) \left(n + \sum_{l=n+1}^{n+m-1} l \right) \text{ настраиваемых параметров и, что}$$

очень важно, все они линейно входят в описание (10).

Вводя далее вектор ортогональных полиномов $(h+1)(n+m-1) \times 1$ m -го орто-нейрона $\varphi^{[m]} = (\varphi_{01}(x_1), \varphi_{11}(x_1), \dots, \varphi_{h1}(x_1), \varphi_{02}(x_2), \dots, \varphi_{h2}(x_2), \dots, \varphi_{ji}(x_i), \dots, \varphi_{hn}(x_n), \varphi_{0,n+1}(\hat{y}_1), \dots, \varphi_{h,n+1}(\hat{y}_1), \dots, \varphi_{h,n+m-1}(\hat{y}_{m-1}))^T$ и соответствующий ему вектор синаптических весов $w^{[m]} = (w_{01}^{[m]}, w_{11}^{[m]}, \dots, w_{h1}^{[m]}, w_{02}^{[m]}, \dots, w_{h2}^{[m]}, \dots, w_{ji}^{[m]}, \dots, w_{hn}^{[m]}, w_{0,n+1}^{[m]}, \dots, w_{h,n+1}^{[m]}, \dots, w_{h,n+m-1}^{[m]})^T$ той же размерности, можно представить (10) в более компактной форме:

$$\hat{y}_m = w^{[m]T} \varphi^{[m]}. \quad (11)$$

3 ОБУЧЕНИЕ КАСКАДНОЙ ОРТОГОНАЛЬНОЙ НЕЙРОННОЙ СЕТИ

Обучение каскадной нейронной сети производится в пакетном режиме с использованием всех элементов обучающей выборки $x(1), y(1); x(2), y(2); \dots; x(k), y(k); \dots; x(N), y(N)$. Сначала вычисляется набор значений ортогональных функций $\varphi^{[1]}(1), \varphi^{[1]}(2), \dots, \varphi^{[1]}(N)$ для каждого образа из обучающей выборки, после чего путем прямой минимизации критерия обучения

$$E_N^{[1]} = \frac{1}{2} \sum_{k=1}^N e_1(k)^2 = \frac{1}{2} \sum_{k=1}^N (y(k) - \hat{y}_1(k))^2, \quad (12)$$

вычисляется вектор синаптических весов

$$w^{[1]}(N) = \left(\sum_{k=1}^N \varphi^{[1]}(k) \varphi^{[1]T}(k) \right)^+ \sum_{k=1}^N \varphi^{[1]}(k) y(k) = P^{[1]}(N) \sum_{k=1}^N \varphi^{[1]}(k) y(k). \quad (13)$$

Если размер обучающей выборки достаточно велик, удобнее использовать процедуру (13) в форме рекуррентного метода наименьших квадратов с последовательной обработкой элементов обучающей выборки:

$$\begin{cases} w^{[1]}(k+1) = w^{[1]}(k) + \frac{P^{[1]}(k)(y(k+1) - w^{[1]T}(k)\varphi^{[1]}(k+1))}{1 + \varphi^{[1]T}(k+1)P^{[1]}(k)\varphi^{[1]}(k+1)} \varphi^{[1]}(k+1), \\ P^{[1]}(k+1) = P^{[1]}(k) - \frac{P^{[1]}(k)\varphi^{[1]}(k+1)\varphi^{[1]T}(k+1)P^{[1]}(k)}{1 + \varphi^{[1]T}(k+1)P^{[1]}(k)\varphi^{[1]}(k+1)}. \end{cases} \quad (14)$$

Необходимо отметить, что использование процедур (13), (14) позволяет существенно сократить время необходимое для настройки весовых коэффициентов, по сравнению с градиентными алгоритмами, в основе которых лежит дельта-правило. Также ортогональность активационных функций обеспечивает численную устойчивость в процессе обращения матриц.

После завершения обучения первого каскада сети, синаптические веса орто-нейрона ON_1 «замораживаются», и генерируется второй каскад, состоящий из орто-нейрона ON_2 , содержащего один дополнительный вход для выходного сигнала предыдущего каскада. Затем процедуры (13), (14) снова применяются для настройки вектора весовых коэффициентов $w^{[2]}$, который имеет размерность $(h+1)(n+1) \times 1$.

Процесс роста нейронной сети (увеличения количества каскадов) продолжается до тех пор, пока не будет получена требуемая точность рассматриваемой задачи. При этом, для оценки весовых коэффициентов последнего m -го каскада используются следующие выражения:

$$w^{[m]}(N) = \left(\sum_{k=1}^N \varphi^{[m]}(k) \varphi^{[m]T}(k) \right)^+ \sum_{k=1}^N \varphi^{[m]}(k) y(k) = P^{[m]}(N) \sum_{k=1}^N \varphi^{[m]}(k) y(k) \quad (15)$$

или

$$\left\{ \begin{aligned} w^{[m]}(k+1) &= w^{[m]}(k) + \\ &+ \frac{P^{[m]}(k)(y(k+1) - w^{[m]T}(k)\phi^{[m]}(k+1))}{1 + \phi^{[m]T}(k+1)P^{[m]}(k)\phi^{[m]}(k+1)}\phi^{[m]}(k+1), \\ P^{[m]}(k+1) &= P^{[m]}(k) - \\ &- \frac{P^{[m]}(k)\phi^{[m]}(k+1)\phi^{[m]T}(k+1)P^{[m]}(k)}{1 + \phi^{[m]T}(k+1)P^{[m]}(k)\phi^{[m]}(k+1)}. \end{aligned} \right. \quad (16)$$

Основным недостатком CasCorLA является возможность обучения только в пакетном режиме, когда вся обучающая выборка задана априорно. Благодаря максимально возможной (квадратичной) скорости сходимости алгоритма (16), каскадная ортогональная нейронная сеть может обучаться и в реальном режиме времени. При этом сразу формируется архитектура, состоящая из m каскадов, каждый из которых обучается с помощью собственного алгоритма. Поскольку для m -го каскада дополнительными входами являются выходы предыдущих орто-нейронов, алгоритм (7) фактически реализует рекуррентный метод ошибки прогноза [26], получивший широкое распространение в теории адаптивной идентификации. Изменение числа каскадов в процессе обучения также не представляет никаких трудностей.

4 РЕЗУЛЬТАТЫ ИМИТАЦИОННОГО МОДЕЛИРОВАНИЯ

При апробации предложенной архитектуры в качестве тестовой решалась задача прогнозирования временного ряда Мэки – Гласса. Этот ряд представляет собой хаотическую, детерминированную последовательность, определяемую следующим дифференциальным уравнением:

$$y'(t) = \frac{0,2t(t-\tau)}{1+y^{10}(t-\tau)} - 0,1y(t). \quad (17)$$

Квантование сигнала было проведено с шагом 0,1. Под обучающую выборку был отведен участок сигнала, содержащий 500 элементов. Целью являлось про-

гнозирование сигнала на шесть шагов вперед по его предыстории: значениям элементов в моменты времени k , $(k-6)$, $(k-12)$ и $(k-18)$. Тестовая выборка содержала 9500 элементов последовательности – значения сигнала с 501 до 10000.

Для оценки полученного прогноза использовалась среднеквадратическая ошибка (18)

$$MSE(k, N) = \frac{\sum_{q=1}^N e_q^2}{N}. \quad (18)$$

Перед тем, как начинать обучение каскадной ортогональной нейронной сети необходимо определить три опциональных параметра: 1) тип системы ортогональных полиномов в каждом орто-синапсе; 2) количество ортогональных полиномов в каждом орто-синапсе; 3) максимальное количество каскадов. Поскольку входные данные были нормализованы на интервал $[-1, 1]$, нами использовалась система ортогональных полиномов Чебышева 1-го рода, что позволило избежать неограниченного роста весовых коэффициентов с увеличением количества каскадов. Основываясь на результатах предыдущих экспериментов, в орто-синапсах использовалось по 3–5 полиномов. А также, для того чтобы предотвратить потерю возможности обобщения сетью, количество каскадов было ограничено до 10.

Результаты прогнозирования временного ряда Мэки – Гласса приведены в табл. 1. Для сравнения эта же задача решалась при помощи Cascade-Correlation Learning Architecture и традиционного многослойного персептрона (MLP), который имел архитектуру 4–7–1 и обучался по алгоритму Левенберга – Марквардта в течение 100 эпох.

Как показывают результаты, каскадная ортогональная сеть предоставляет хорошее качество аппроксимации и прогнозирования существенно нелинейных процессов. Полученная ошибка прогнозирования сравнима с ошибкой, даваемой многослойным персептроном, и намного меньше, чем ошибка CasCorLA. При этом необходимо отметить, что процедура обучения каскадной

Таблица 1 – Ошибки при прогнозировании ряда Мэки – Гласса

Архитектура ИНС	Ошибка на обуч. выборке / Номер каскада										Ошибка на тест. выборке	
	1	2	3	4	5	6	7	8	9	10		
CONN	0,0005	0,0003	0,0003	0,0002	0,0002	0,0002	0,0002	0,0002	0,0002	0,0002	0,0002	0,0003
CasCorLA	0,11	0,1	0,098	0,095	0,092	0,089	0,088	0,084	0,083	0,083	0,083	0,055
MLP	Ошибка на обучающей выборке / Номер эпохи										Ошибка на тест. выборке	
	4	8	12	16	20	24	28	32	36	40		
	0,8	0,3	0,09	0,06	0,04	0,03	0,01	0,003	0,001	0,0009		0,0006

ортогональной нейронной сети требует значительно меньше времени и вычислительных ресурсов, чем обратное распространение ошибки или процедура Левенберга – Марквардта. Также, используя каскадную ортогональную нейронную сеть, удается избежать двух существенных недостатков, свойственных CasCorLA и многослойному перцептрону: неповторимости полученных результатов и использование нелинейных процедур обучения.

ЗАКЛЮЧЕНИЕ

В статье предложена каскадная ортогональная нейронная сеть, отличающаяся от своего прототипа – Cascade-Correlation Learning Architecture – повышенным быстродействием и точностью, численной устойчивостью и возможностью обработки данных в реальном времени по мере поступления новой информации. Теоретическое обоснование и результаты экспериментов подтверждают эффективность развиваемого подхода к синтезу каскадных нейронных сетей.

ПЕРЕЧЕНЬ ССЫЛОК

1. Cichocki A. Neural Networks for Optimization and Signal Processing / A. Cichocki, R. Unbehauen. – Stuttgart: Teubner, 1993. – 544 p.
2. Haykin S. Neural Networks: A Comprehensive Foundation / S. Haykin. – Upper Saddle River, N. J.: Prentice Hall. – 1999. – 864 p.
3. Platt J. A resource allocating network for function interpolation / J. Platt // Neural Computation. – 1991. – 3. – P. 213–225.
4. Nag A. Flexible resource allocating network for noisy data / A. Nag, J. Ghosh // Proc. SPIE Conf. on Applications and Science of Computational Intelligence. – 1998. – P. 551–559.
5. Yingwei L. Performance evaluation of a sequential minimal radial basis function (RBF) neural network learning algorithm / L. Yingwei, N. Sundararajan, P. Saratchandran // IEEE Trans. on Neural Networks. – 1998. – 9. – P. 308–318.
6. Cun Y. L. Optimal brain damage / Y.L. Cun, J.S. Denker, S.A. Solla // Advances in Neural Information Processing Systems. – San Mateo, CA: Morgan Kaufman, 1990. – 2. – P. 598–605.
7. Hassibi B. Second-order derivatives for network pruning: Optimal brain surgeon / B. Hassibi, D.G. Stork // Advances in Neural Information Processing Systems. Ed. Hanson et al. – San Mateo, CA: Morgan Kaufman, 1993. – P. 551–559.
8. Prechelt L. Connection pruning with static and adaptive pruning schedules / L. Prechelt // Neurocomputing. – 1997. – 16. – P. 49–61.
9. Fahlman S. E. The cascade-correlation learning architecture / S. E. Fahlman, C. Lebiere // Advances in Neural Information Processing Systems. Ed. D. S. Touretzky. – San Mateo, CA: Morgan Kaufman, 1990. – P. 524–532.
10. Schalkoff R. J. Artificial Neural Networks / R. J. Schalkoff. – N.Y.: The McGraw-Hill Comp., 1997. – 528 p.
11. Аведьян Э. Д. Каскадные нейронные сети / Э. Д. Аведьян, Г. В. Баркан, И. К. Левин // Автоматика и телемеханика. – 1999. – № 3. – С. 38–55.
12. Bateman H., Erdelyi A. Higher Transcendental Functions. Vol. 2. / H. Bateman, A. Erdelyi. – N. Y.: The McGraw-Hill Comp. – 1953. – 396 p.
13. Graupe D. Identification of Systems / D. Graupe. – Huntington, N.Y.: Robert E. Kreiger Publishing Comp. – 1976. – 276 p.
14. Scott I., Mulgrew B. Orthonormal function neural network for nonlinear system modeling / I. Scott, B. Mulgrew // Proceedings of the International Conference on Neural Networks. – 1996. – Vol. 4. – P. 1847–1852.
15. Patra J. C. Nonlinear dynamic system identification using Chebyshev functional link artificial neural network / J. C. Patra, A. C. Kot // IEEE Trans. on System, Man and Cybernetics. – 2002. – 32. Part B. – P. 505–511.
16. Bodyanskiy Ye. Artificial neural network with orthogonal activation functions for dynamic system identification / Ye. Bodyanskiy, V. Kolodyazhnyi, O. Slipchenko // Synergies between Information Processing and Automation. Ed. O. Sawodny and P. Scharff – Aachen: Shaker Verlag. – 2004. – P. 24–30.
17. Bodyanskiy Ye. Structural and synaptic adaptation in the artificial neural networks with orthogonal activation functions / Ye. Bodyanskiy, V. Kolodyazhnyi, O. Slipchenko // Sci. Proc. of Riga Technical University. Comp. Sci., Inf. Technology and Management Sci. – 2004. – 20. – P. 69–76.
18. Liying M. Constructive feedforward neural network using Hermite polynomial activation functions / M. Liying, K. Khorasani // IEEE Trans. on Neural Networks. – 2005. – 4. – P. 821–833.
19. Bodyanskiy Ye. Growing neural networks based on orthogonal activation functions / Ye. Bodyanskiy, I. Pliss, O. Slipchenko // Proc. XII-th Int. Conf. “Knowledge – Dialog – Solution”. – Varna, 2006. – P. 84–89.
20. Bodyanskiy Ye. Ontogenic neural networks using orthogonal activation functions / Ye. Bodyanskiy, O. Slipchenko // Prace naukowe Akademii Ekonomicznej we Wroclawiu. – 2006. – 21. – P. 13–20.
21. Bodyanskiy Ye. Growing neural network using nonconventional activation functions / Ye. Bodyanskiy, I. Pliss, O. Slipchenko // Int. J. Information Theories & Applications. – 2007. – 14. – P. 275–281.
22. Бодянский Е. В. Ортоинапс, ортонейроны и нейропредиктор на их основе / Е. В. Бодянский, Е. А. Викторов, А. Н. Слипченко // Системи обробки інформації. – Х.: ХУПС, 2007. – Вип. 4(62). – С. 139–143.
23. Yamakawa T. A neo fuzzy neuron and its applications to system identification and prediction of the system behavior / T. Yamakawa, E. Uchino, T. Miki, H. Kusanagi // Proc. 2-nd Int. Conf. on Fuzzy Logic and Neural Networks (LIZUKA-92). – Lizuka, 1992. – P. 477–483.
24. Uchino E. Soft computing based signal prediction, restoration and filtering / E. Uchino, T. Yamakawa // Intelligent Hybrid Systems: Fuzzy Logic, Neural Networks and Genetic Algorithms. Ed. Da Ruan. – Boston: Kluwer Academic Publisher. – 1997. – P. 331–349.
25. Miki T. Analog implementation of neo-fuzzy neuron and its on-board learning / T. Miki, T. Yamakawa // Computational Intelligence and Applications. Ed. N.E. Mastorakis. – Piraeus: WSES Press. – 1999. – P. 144–149.
26. Льюнг Л. Идентификация систем. Теория для пользователя / Л. Льюнг; пер. с англ. Под ред. Я. З. Цыпкина. – М.: Наука, 1991. – 432 с.

Надійшла 14.04.2008

У статті розглянуто нову нетрадиційну нейромережеву архітектуру – каскадну ортогональну нейронну мережу, алгоритм її навчання у пакетному режимі і в режимі реального часу, а також застосування цієї архітектури для вирішення задач прогнозування й апроксимації.

In the article new non-conventional architecture called Cascade Orthogonal Neural Network is considered. Learning algorithms which can operate in batch or real-time mode are given. Also application of this architecture for solving forecasting and approximation problems is proposed.