

УДК 004.032.26

А.В. Бабенко, Е.В. Бодянский, С.В. Попов, Е.В. Слипченко

Харьковский национальный университет радиоэлектроники, Харьков

ПРОГНОЗИРУЮЩЕ-ДИАГНОСТИРУЮЩАЯ РЕКУРРЕНТНАЯ НЕЙРО-ФАЗЗИ СЕТЬ В ЗАДАЧЕ КОНТРОЛЯ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ

Рассмотрена специализированная прогнозирующе-диагностирующая нейро-фаззи сеть, являющаяся обобщением многослойного персептрона, рекуррентной сети Вильямса-Зипсера и прогнозирующей многослойной нейро-фаззи сети, а также соответствующий алгоритм обучения и диагностики. Такой гибридный подход позволяет одновременно решать задачи краткосрочного прогнозирования и контроля потребления электрической энергии.

Ключевые слова: *нейро-фаззи сеть, прогнозирование временных рядов, техническая диагностика.*

Введение

В условиях энергетического кризиса задача точного прогнозирования потребления электроэнергии приобретает важное значение для решения проблемы эффективного управления энергетической отраслью как на уровне государства в целом, так и на уровне отдельных регионов и энергосистем. Неточное же прогнозирование ведет к существенным экономическим потерям. Среди множества подходов, используемых в настоящее время для решения этой задачи, особенно эффективными показали себя искусственные нейронные сети и нейро-фаззи сети [1], благодаря, прежде всего, своим универсальным аппроксимирующим и экстраполирующим возможностям и способности обучения в условиях существенной структурной и параметрической неопределенности о характеристиках прогнозируемых процессов. В настоящее время имеется достаточно много примеров удачного использования этих сетей в рассматриваемой задаче. При этом интересно отметить, что в большинстве случаев в основе прогнозирующих систем лежат сети с прямой передачей информации и элементами задержки во входных слоях, реализующие нелинейные модели авторегрессии с экзогенными входами (NARX-модели), являющиеся частным случаем более общих структур, содержащих компоненты скользящего среднего и известных как NARMAX-модели, обладающие большей гибкостью и потенциально более высокой точностью. NARMAX-модели достаточно просто могут быть реализованы на основе рекуррентных нейронных сетей [2], которые с вычислительной точки зрения гораздо более эффективны, чем сети с прямой передачей информации [3 – 5].

К настоящему времени в задачах обработки нелинейных временных рядов наибольшее распространение получили три типа рекуррентных нейронных сетей: сети Вильямса-Зипсера [6], Элмана [7] и Джордана [8]. При этом интересно отметить, что исходно авторы этих конструкций использовали их для решения задач распознавания образов и адаптивной фильтрации, обработки речевых сигнала

лов и управления роботами, соответственно, но не для прогнозирования и диагностики. Понятно, что для решения задач анализа и предсказания временных рядов и обнаружения изменений их свойств эти сети требуют существенной модификации, касающейся, прежде всего, алгоритмов обучения, поскольку все отмеченные нейросети обучаются в пакетном режиме и не предусматривают ситуацию, когда данные наблюдений временного ряда поступают на обработку последовательно одно за другим.

В [9] была введена архитектура прогнозирующей рекуррентной искусственной нейронной сети, являющейся своеобразным гибридом многослойного персептрона и рекуррентной сети Вильямса-Зипсера и предназначенной для прогнозирования временных рядов в режиме последовательной обработки данных реального времени. Эта сеть имеет специфическую архитектуру с линейным выходным нейроном и одним дополнительным линейным нейроном (адаптивным линейным ассоциатором) в первом скрытом слое. Главной же особенностью этой сети является отсутствие контекстного слоя обратной связи, вместо которого между скрытым и выходным слоями установлены элементы чистого запаздывания. Данная сеть реализует прогнозирующую NARMAX-модель с числовыми экзогенными входами и обучается с помощью градиентного алгоритма с постоянным шагом, подстраивая свои веса по мере поступления новых данных.

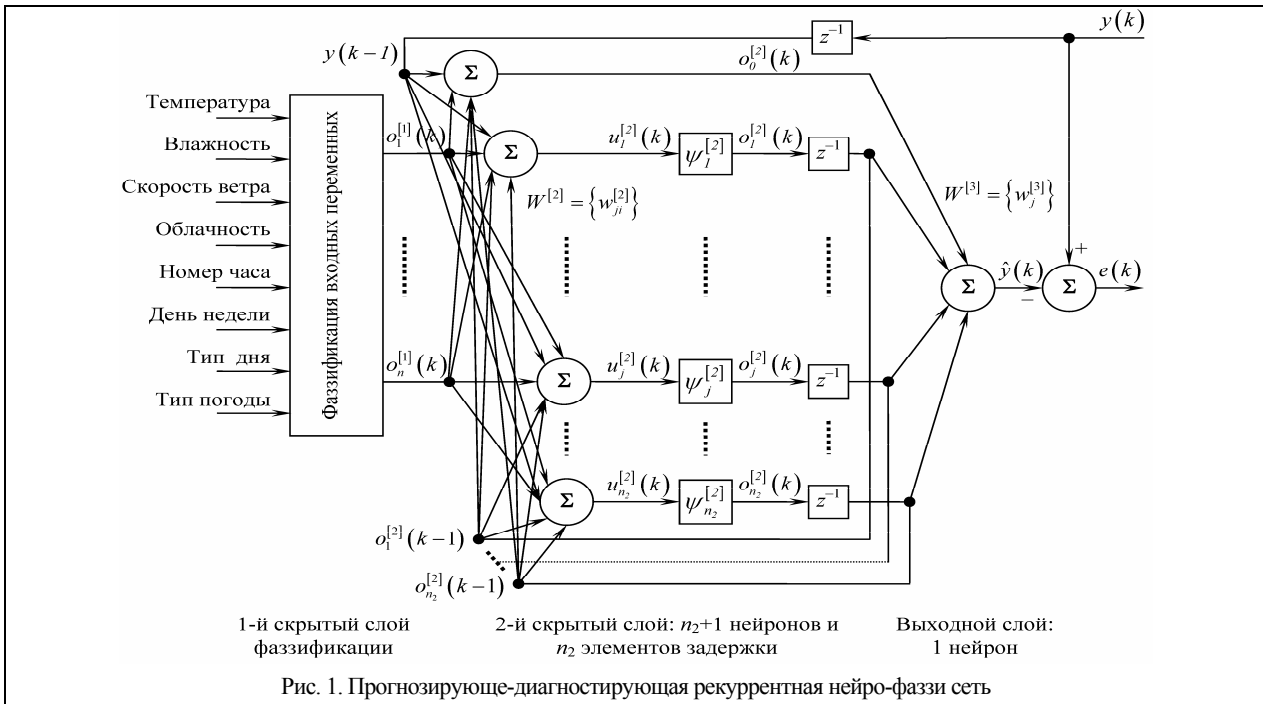
К основным недостаткам этой сети в задаче прогнозирования потребления электроэнергии относится невозможность обработки информации, заданной в нечисловой форме и поступающей на обработку в реальном времени.

В связи с этим в настоящей работе предпринимается попытка синтеза гибридной нейро-фаззи системы, объединяющей рекуррентную прогнозирующую нейронную сеть [9] с ее гибкостью и простотой и многослойную прогнозирующую нейро-фаззи сеть [10] с ее высокой скоростью обучения и возможностью обработки информации, заданной как в числовой, так и порядковой и номинальной шкалах.

1. Архитектура прогнозирующе-диагностирующей рекуррентной нейро-фаззи сети

Архитектура прогнозирующе-диагностирующей рекуррентной нейро-фаззи сети приведена на рис. 1. Сеть имеет три слоя (первый скрытый слой фаззификации, второй скрытый слой, выходной слой), а ее «строительными блоками» являются стандартные нейроны (элементарные перцептроны Розенблатта с сигмоидальными активационными функциями, адап-

тивные линейные ассоциаторы), элементы задержки z^{-1} и блоки фаззификации, предназначенные для преобразования входных переменных, характеризующих влияние окружающей среды, в количественную форму уровней принадлежности, лежащих в интервале $[0, 1]$. Блоки фаззификации, использующие треугольные функции принадлежности и синглтоны, формируют первый скрытый слой сети, полностью совпадающий по своей структуре с первым скрытым слоем прогнозирующей нейро-фаззи сети [10].



Сигналы первого скрытого слоя в виде $(n \times 1)$ -вектора $o^{[1]}(k) = (o_1^{[1]}(k), o_2^{[1]}(k), \dots, o_n^{[1]}(k))^T$ с компонентами, описывающими погодные и временные характеристики в числовой форме уровней принадлежности, поступают на второй скрытый слой, образованный одним адаптивным линейным ассоциатором с дополнительным входом задержанного значения прогнозируемого сигнала $y(k-1)$ (здесь $k=0,1,2,\dots$ – текущее дискретное время) и n_2 идентичными нейронами с сигмоидальными активационными функциями $\psi_j^{[2]}$, $j=1,2,\dots,n$ и синаптическими весами $w_{ji}^{[2]}$. Выходы второго скрытого слоя могут быть объединены в $((n_2+1) \times 1)$ -вектор $o^{[2]}(k) = (o_0^{[2]}(k), o_1^{[2]}(k), \dots, o_{n_2}^{[2]}(k))^T = (o_0^{[2]}(k), o_{\psi}^{[2]}(k))^T$. Между выходами элементарных перцептронов Розенблатта второго скрытого слоя и входами выходного слоя, образованного единственным адаптив-

ным линейным ассоциатором с синаптическими весами $w_i^{[3]}$, установлено n_2 элементов задержки z^{-1} так, что вектор задержанных сигналов $o_{\psi}^{[2]}(k-1)$ подается одновременно и на входы выходного слоя, и по каналу обратной связи на входы второго скрытого слоя. Таким образом, каждый нейрон второго скрытого слоя имеет $n+n_2+1$ входов (и соответственно $n+n_2+1$ синаптических весов $w_{ji}^{[2]}$), а нейрон выходного слоя имеет n_2+1 входов и столько же синаптических весов.

Таким образом, преобразование, реализуемое архитектурой, приведенной на рис. 1, может быть записано в виде:

$$\hat{y}(k) = w_0^{[3]}(k) o_0^{[2]}(k) + \sum_{i=1}^{n_2} w_i^{[3]}(k) o_i^{[2]}(k-1); \quad (1)$$

$$o_0^{[2]}(k) = u_0^{[2]}(k); \quad (2)$$

$$o_j^{[2]}(k) = \psi_j^{[2]}(u_j^{[2]}(k)), 1 \leq j \leq n_2; \quad (3)$$

$$u_j^{[2]}(k) = \sum_{i=0}^{n+n_2} w_{ji}^{[2]}(k) \delta_i^{[1]}(k); \quad (4)$$

$$\delta_i^{[1]}(k) = \begin{cases} y(k-1), & \text{для } i=0; \\ o_i^{[1]}(k), & \text{для } 1 \leq i \leq n; \\ o_{i-n}^{[2]}(k-1), & \text{для } n+1 \leq i \leq n+n_2. \end{cases} \quad (5)$$

Вводя далее векторы

$$\delta^{[2]}(k) = \left(o_0^{[2]}(k), o_1^{[2]}(k-1), \dots, o_{n_2}^{[2]}(k-1) \right)^T,$$

$$w^{[3]}(k) = \left(w_0^{[3]}(k), w_1^{[3]}(k), \dots, w_{n_2}^{[3]}(k) \right)^T$$

размерности $(n_2+1) \times 1$;

$$\delta^{[1]}(k) = \left(y(k-1), o_1^{[1]}(k), \dots, o_n^{[1]}(k), \right. \\ \left. o_1^{[2]}(k-1), \dots, o_{n_2}^{[2]}(k-1) \right)^T$$

размерности $(n+n_2+1) \times 1$; матрицы синаптических весов второго скрытого слоя $W^{[2]}$ размерности $(n_2+1) \times (n+n_2+1)$ и активационных функций

$$\Psi^{[2]} = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & \psi_1^{[2]} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \psi_{n_2}^{[2]} \end{pmatrix} \quad (6)$$

размерности $(n_2+1) \times (n_2+1)$, можно переписать соотношения (1)-(5) в компактной форме

$$\hat{y}(k) = w^{[3]T}(k) o^{[2]}(k) = \\ = w^{[3]T}(k) \Psi^{[2]} \left(W^{[2]}(k) \delta^{[1]}(k) \right). \quad (7)$$

В процессе обучения нейро-фаззи сети необходимо определить оптимальные значения параметров $w^{[3]}, W^{[2]}$, а также моменты резкого изменения свойств прогнозируемого процесса, проявляющиеся в неожиданных «скачках» синаптических весов.

2. Обучение прогнозирующе-диагностирующей рекуррентной нейро-фаззи сети

Обучение конструкции, приведенной на рис. 1, будем проводить путем пошаговой минимизации стандартного квадратичного критерия

$$E(k) = \frac{1}{2} e^2(k) = \frac{1}{2} (y(k) - \hat{y}(k))^2 = \\ = \frac{1}{2} \left(y(k) - w_0^{[3]}(k) o_0^{[2]}(k) - \sum_{i=1}^{n_2} w_i^{[3]}(k) o_i^{[2]}(k-1) \right)^2 \quad (8)$$

с помощью градиентной процедуры оптимизации с учетом очевидных соотношений:

$$\frac{\partial E(k)}{\partial w_{ji}^{[s]}(k)} = \frac{\partial}{\partial w_{ji}^{[s]}(k)} \left(\frac{1}{2} e^2(k) \right) = -e(k) \frac{\partial \hat{y}(k)}{\partial w_{ji}^{[s]}(k)}; \quad (9)$$

$$w_{ji}^{[s]}(k+1) = w_{ji}^{[s]}(k) - \eta(k) \frac{\partial E(k)}{\partial w_{ji}^{[s]}(k)} = \\ = w_{ji}^{[s]}(k) + \eta(k) e(k) \frac{\partial \hat{y}(k)}{\partial w_{ji}^{[s]}(k)}, \quad s = 2, 3, \quad (10)$$

где $\eta(k)$ – параметр шага поиска, выбираемый обычно из эмпирических соображений и достаточно часто полагаемый постоянной величиной.

Рассмотрим вначале процесс настройки весов выходного нейрона сети. Из уравнений (9), (10) следует следующее соотношение

$$w_i^{[3]}(k+1) = w_i^{[3]}(k) + \eta(k) e(k) \frac{\partial \hat{y}(k)}{\partial w_i^{[3]}(k)}, \quad (11)$$

$$i = 0, 1, \dots, n_2,$$

$$\frac{\partial \hat{y}(k)}{\partial w_i^{[3]}(k)} = \frac{\partial}{\partial w_i^{[3]}(k)} \left(w_0^{[3]}(k) o_0^{[2]}(k) + \sum_{i=1}^{n_2} w_i^{[3]}(k) o_i^{[2]}(k-1) \right).$$

где

Для настройки синаптических весов второго скрытого слоя будем использовать стандартную процедуру обратного распространения ошибки в форме [11]:

$$w_{ji}^{[2]}(k+1) = w_{ji}^{[2]}(k) + \eta(k) \delta_j^{[2]}(k) \delta_i^{[1]}(k), \quad (13)$$

где $\delta_j^{[2]}(k)$ – локальная ошибка второго скрытого слоя, описываемая в данном случае выражением

$$\delta_j^{[2]}(k) = \frac{\partial \psi_j^{[2]}(u_j^{[2]}(k))}{\partial u_j^{[2]}(k)} e(k) w_j^{[3]}(k). \quad (14)$$

Таким образом, окончательно процесс обучения синаптических весов второго скрытого слоя описывается рекуррентным соотношением

$$w_{ji}^{[2]}(k+1) = w_{ji}^{[2]}(k) + \\ + \eta(k) \frac{\partial \psi_j^{[2]}(u_j^{[2]}(k))}{\partial u_j^{[2]}(k)} e(k) w_j^{[3]}(k) \delta_i^{[1]}(k), \quad (15)$$

$$j = 0, 1, \dots, n_2; \quad i = 0, 1, \dots, n+n_2.$$

Скорость сходимости процессов (11), (15) полностью определяется значением параметра шага $\eta(k)$ и может быть существенно увеличена путем специального его выбора [10]. Следует, однако, отметить, что в данном случае мы рассматриваем совместную задачу прогнозирования и диагностики, состоящую в обнаружении резких изменений свойств прогнозируемого процесса.

В связи с этим для обучения весов выходного

слюя целесообразно использовать процедуру, обладающую как фильтрующими (сглаживание возмущений и помех), так и следящими (обнаружение скачков) свойствами. Поскольку выходной сигнал сети линейно зависит от синаптических весов выходного нейрона, для их настройки может быть использован экспоненциально взвешенный рекуррентный метод наименьших квадратов в форме

$$\begin{cases} w_i^{[3]}(k+1) = w_i^{[3]}(k) + \frac{P(k)e(k)\delta^{[2]}(k)}{\alpha + \delta^{[2]T}(k)P(k)\delta^{[2]}(k)}; \\ P(k+1) = \frac{1}{\alpha} \left(P(k) - \frac{P(k)\delta^{[2]}(k)\delta^{[2]T}(k)P(k)}{\alpha + \delta^{[2]T}(k)P(k)\delta^{[2]}(k)} \right), \end{cases} \quad (16)$$

где $0 < \alpha < 1$ – параметр «забывания» устаревшей информации, определяющий компромисс между фильтрующими и следящими свойствами. Чем больше значение α , тем инерционнее процесс обучения, чем меньше это значение – тем быстрее возникает реакция на возможные изменения.

Для обнаружения этих изменений может быть использован алгоритм Хегглунда [12] в форме

$$\begin{cases} \theta(k+1) = \eta_\theta \theta(k) + w^{[3]}(k+1) - w^{[3]}(k); \\ \mu(k+1) = \text{sign} \left(\theta^T(k+1) \left(w^{[3]}(k+1) - w^{[3]}(k) \right) \right), \end{cases} \quad (17)$$

где $0 \leq \eta_\theta < 1$.

Если диагностирующий сигнал $\mu(k+1)$ в течение нескольких шагов подряд принимает значение +1, это свидетельствует о том, что в контролируемом сигнале $u(k)$ возникли резкие изменения.

Таким образом, предлагаемая нейро-фаззи сеть обеспечивает не только краткосрочное прогнозирование процессов потребления электроэнергии, но и контроль за резкими его изменениями, что весьма важно для эффективной работы диспетчерских систем.

Заключение

Предложенная архитектура является обобщением многослойного перцептрона, рекуррентной сети Вильямса-Зипсера и прогнозирующей многослойной нейро-

фаззи сети. Такой гибридный подход позволяет одновременно решать задачи краткосрочного прогнозирования и контроля потребления электрической энергии.

Список литературы

1. Tzafestas S. Computational intelligence techniques for short-term electric load forecasting / S. Tzafestas, E. Tzafestas // *Journal of Intelligent and Robotic Systems*. – 2001. – 31. – P. 7-68.
2. Mandic D.P. Recurrent Neural Networks for Prediction / D.P. Mandic, J.A. Chambers. – Chichester: John Wiley&Sons, 2001. – 285 p.
3. Geqay R. Nonlinear modeling and prediction with feedforward and recurrent networks / R. Geqay, T. Liu // *Physica D*. – 1997. – 108. – P. 119-134.
4. Wang J. Global asymptotic stability and global exponential stability of continuous-time recurrent neural networks / J. Wang, S. Hu // *IEEE Trans. Automatic Control*. – 2002. – 47. – P. 802-807.
5. Prediction of chaotic time series based on the recurrent predictor neural network / M. Han, J. Xi, S. Xu, F.-L. Yin // *IEEE Trans. Signal Processing*. – 2004. – 52. – N. 12. – P. 3409-3416.
6. Williams R.J. A Learning Algorithm for Continually Running Fully Recurrent Neural Networks / R.J. Williams, D. Zipser // *Neural Computation*. – 1989. – 1. – P. 270-280.
7. Elman J.L. Finding structure in time / J.L. Elman // *Cognitive Science*. – 1990. – 14. – P. 179-211.
8. Jordan M. Constrained supervised learning / M. Jordan // *Journal of Mathematical Psychology*. – 1992. – 36. – P. 396-452.
9. Madhavan P.G. Recurrent Neural Network for Time Series Prediction / P.G. Madhavan // *Proc. 15th Annual Int. Conf. of the IEEE Engineering in Medicine and Biology Society*. – October 28-31, 1993. – P. 250-251.
10. Bodyanskiy Y. Multilayer neuro-fuzzy network for short term electric load forecasting / Y. Bodyanskiy, S. Popov, T. Rybalchenko // *Lecture Notes in Computer Science – Berlin, Heidelberg: Springer-Verlag, 2008. – 5010. – P. 339-348.*
11. Cichocki A. Neural Networks for Optimization and Signal Processing / A. Cichocki, R. Unbehauen. – Stuttgart: Teubner, 1993. – 526 p.
12. Haeggglund T. Adaptive control of systems subject to large parameter changes / T. Haeggglund // *Proc. IFAC 9th Triennial World Congress*. – Budapest, 1984. – P. 993-998.

Поступила в редколлегию 14.04.2009

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

ПРОГНОЗУЮЧЕ-ДІАГНОСТУЮЧА РЕКУРЕНТНА НЕЙРО-ФАЗЗИ МЕРЕЖА В ЗАДАЧІ КОНТРОЛЮ СПОЖИВАННЯ ЕЛЕКТРОЕНЕРГІЇ

О.В. Бабенко, Є.В. Бодянський, С.В. Попов, О.В. Сліпченко

Розглянуто спеціалізовану прогноуюче-діагностуючу нейро-фаззі мережу, що є узагальненням багатосарового перцептрона, рекуррентної мережі Вільямса-Зипсера та прогноуючої багатосарової нейро-фаззі мережі, а також відповідний алгоритм навчання й діагностики. Такий гібридний підхід дозволяє одночасно вирішувати задачі коротко-строкового прогнозування і контролю споживання електричної енергії.

Ключові слова: нейро-фаззі мережа, прогнозування часових рядів, технічна діагностика.

FORECASTING AND DIAGNOSTIC RECURRENT NEURO-FUZZY NETWORK IN THE PROBLEM OF ELECTRIC LOAD MONITORING

A.V. Babenko, Ye.V. Bodyanskiy, S.V. Popov, E.V. Slipchenko

Specialized forecasting and diagnostic neuro-fuzzy network is considered, which is a generalization of a multilayer perceptron, recurrent Williams-Zipser network and forecasting multilayer neuro-fuzzy network. The corresponding learning and diagnostic algorithm is proposed. Such hybrid approach allows simultaneously to decide the tasks of short-term prognostication and control of consumption of electric energy.

Keywords: neuro-fuzzy network, prognostication of temporal rows, technical diagnostics.