

Рассмотрена задача прогнозирования нестационарных временных рядов энергопотребления в условиях структурной неопределенности. Предложена специализированная прогнозирующая искусственная нейронная сеть, характеризующаяся высокой скоростью обучения, хорошими аппроксимирующими и экстраполирующими свойствами, а также возможностью работы в реальном времени

УДК 004.032.26

И.П. Плисс, канд. техн. наук, ст. науч. сотр.,

С.В. Попов, канд. техн. наук, ст. науч. сотр.,

Харьковский национальный университет радиоэлектроники

Т.В. Рыбальченко,

ООО «Хартэп»

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ НЕСТАЦИОНАРНЫХ ВРЕМЕННЫХ РЯДОВ ЭНЕРГОПОТРЕБЛЕНИЯ В УСЛОВИЯХ СТРУКТУРНОЙ НЕОПРЕДЕЛЕННОСТИ

Введение. Последние два десятилетия характеризуются «взрывом» исследований в области прогнозирования временных рядов с использованием интеллектуальных технологий и, прежде всего, искусственных нейронных сетей [1-7]. Эффективность применения нейронных сетей определяется их универсальными аппроксимирующими возможностями и способностью к обучению по данным наблюдений за исследуемым объектом, представленным, обычно, в форме временных рядов. Прогнозирующие нейронные сети обеспечивают высокое качество предсказания в условиях априорной параметрической и структурной неопределенности, при этом неявно предполагается, что внутренняя структура объекта хотя и неизвестна, но не меняется с течением времени, а нестационарность генерируемых им сигналов определяется параметрами этой структуры.

В общей проблеме нейросетевого прогнозирования особое место занимает задача предсказания потребления электрической энергии [8-18], благодаря как своей практической значимости, так и сложности (хаотичность, квазипериодичность, скачки) соответствующих временных рядов, структура которых может меняться непредсказуемым образом. В связи с этим представляется целесообразным разработать архитектуру и алгоритм обучения специализированной искусственной нейронной сети, предназначенной для нестационарных временных рядов с неизвестной внутренней структурой и ориентированной на решение задач краткосрочного и оперативного прогнозирования потребления электрической энергии.

Архитектура специализированной прогнозирующей нейронной сети. Архитектура специализированной прогнозирующей нейронной сети приведена на рис. 1. Это пятислойная гетерогенная сеть, образованная нейронами, отличающимися между собой активационными функциями и алгоритмами обучения, основанными на процедурах безусловной и условной оптимизации.

Прогнозируемый временной ряд $y^R(k)$, описывающий, например, реальное энергопотребление в конкретно взятом регионе ($\{y^R(k)\}, k = 1, 2, 3, \dots$), предварительно кодируется на интервал $[-1, 1]$ с помощью следующих рекуррентных процедур [19]:

$$y_{\max}^R(k) = y_{\max}^R(k-1) + 0.5 \left(1 - \frac{y_{\max}^R(k-1) - y^R(k)}{\sqrt{(y_{\max}^R(k-1) - y^R(k))^2}} \right) (y^R(k) - y_{\max}^R(k-1)),$$

$$y_{\min}^R(k) = y_{\min}^R(k-1) + 0.5 \left(1 + \frac{y_{\min}^R(k-1) - y^R(k)}{\sqrt{(y_{\min}^R(k-1) - y^R(k))^2}} \right) (y^R(k) - y_{\min}^R(k-1)),$$

$$y(k) = \frac{2y^R(k) - y_{\max}^R(k) - y_{\min}^R(k)}{y_{\max}^R(k) - y_{\min}^R(k)},$$

в результате чего в каждый момент времени обеспечивается выполнение условия $-1 \leq y(k) \leq 1$.




Рис.1 – Рекуррентная специализированная прогнозирующая нейронная сеть

Далее преобразованная временная последовательность $\{y(k)\}$ подается на входной слой нейронной сети, образованный элементами чистого запаздывания $z^{-1} : z^{-1}y(k) = y(k-1)$. В результате во входном слое формируется множество задержанных значений входной последовательности $y(k-1), y(k-2), \dots, y(k-d)$ при этом

понятно, что чем больше значение d , тем более широкими возможностями обладает сеть, хотя время обучения при этом также увеличивается.

Первый скрытый слой сформирован из элементарных персептронов Розенблатта, охваченных обратной связью. На их входы подаются задержанные значения входного сигнала $y(k)$ и задержанные же значения выходного предсказанного значения $\hat{y}_j(k), j = 1, 2, \dots, d$. В результате на выходах нейронов первого скрытого слоя формируются одношаговые прогнозы

$$\begin{cases} \hat{y}_1(k) = \psi(y(k-1), \hat{y}_1(k-1)), \\ \hat{y}_2(k) = \psi(y(k-1), y(k-2), \hat{y}_2(k-1), \hat{y}_2(k-2)), \\ \vdots \\ \hat{y}_d(k) = \psi(y(k-1), y(k-2), \dots, y(k-d), \\ \hat{y}_d(k-1), \hat{y}_d(k-2), \dots, \hat{y}_d(k-d)), \end{cases}$$

являющиеся по сути выходами нелинейных моделей авторегрессии-скользящего среднего (NARMA) порядков от 1 до d .

Второй скрытый слой образован элементарными нейроподобными элементами [20], вычисляющими в реальном времени дисперсии обновляющих последовательностей $\sigma_{\varepsilon_j}^2(k)$, ($\varepsilon_j(k) = y(k) - \hat{y}_j(k)$) и служащими для непрерывной оценки качества прогнозирования, реализуемого в первом скрытом слое.

Нейроны третьего скрытого слоя производят попарное объединение сигналов из второго слоя, формируя оценки $\hat{u}_j(k), j = 1, 2, \dots, d-1$ такие, что

$$\begin{cases} \hat{u}_j(k) = c_j(k)\hat{u}_{j-1}(k) + (1-c_j(k))\hat{y}_{j+1}(k), \\ \hat{u}_0(k) \equiv \hat{y}_1(k), \end{cases} \quad (1)$$

где настраиваемые веса $c_j(k)$ формируют объединенный прогноз, который по точности не должен уступать ни $\hat{u}_{j-1}(k)$, ни $\hat{y}_{j+1}(k)$. Вектор же весов $c(k) = (c_1(k), c_2(k), \dots, c_{d-1}(k))^T$ описывает качество прогнозов, полученных в этом слое сети, которые по точности должны превосходить прогнозы, полученные в первом скрытом слое. Изменение элементов $c_j(k)$, происходящее в процессе прогнозирования, свидетельствует об изменении внутренней структуры прогнозируемой последовательности.

Четвертый скрытый слой идентичен второму и служит для оценки качества прогнозов третьего слоя $\hat{u}_j(k)$ на основе вычисления текущих значений дисперсий $\sigma_{v_j}^2(k)$, ($v_j(k) = y(k) - \hat{u}_j(k)$).

Пятый выходной слой образован единственным нейроном – адаптивным линейным ассоциатором $N^{[5]}$, который вычисляет объединенный прогноз $\hat{y}(k)$. После вычис-

ления прогноза $\hat{y}(k)$, он должен быть «раскодирован» в исходную шкалу измерений с помощью соотношения

$$\hat{y}^R(k) = 0.5(y_{\max}^R(k)(\hat{y}(k)+1) - y_{\min}^R(k)(\hat{y}(k)-1)). \quad (2)$$

Алгоритмы обучения нейронной сети. Выходной сигнал j -го нейрона первого скрытого слоя может быть представлен в виде

$$\begin{aligned} \hat{y}_j(k) &= \psi\left(\sum_{i=1}^j w_{ji}(k)y(k-i) + \sum_{i=1}^j \hat{w}_{ji}\hat{y}(k-i) + w_{j0}(k)\right) = \\ &= \psi(w_j^T(k)Y_j(k)) = \psi(u_j(k)), \end{aligned}$$

где $\psi(\square)$ – нелинейная функция активации, чаще всего гиперболический тангенс

$$\psi(u_j(k)) = \tanh(u_j(k)) = \frac{1 - e^{-2u_j(k)}}{1 + e^{-2u_j(k)}}, \quad (3)$$

$w_j(k) = (w_{j0}(k), w_{j1}(k), \dots, w_{jj}(k), \hat{w}_{j1}(k), \hat{w}_{jj}(k))^T$ – $(2j+1) \times 1$ -вектор настраиваемых синоптических весов, $Y_j(k) = (1, y(k-1), \dots, y(k-j), \hat{y}_j(k-1), \dots, \hat{y}_j(k-j))^T$ – вектор входов j -го нейрона $N_j^{[1]}$, $u_j(k) = w_j^T(k)Y_j(k)$, $j = 1, 2, \dots, d$; $k = 1, 2, 3, \dots$ – текущее дискретное время.

Вводя в рассмотрение ошибку предсказания j -го нейрона первого скрытого слоя

$$\varepsilon_j(k) = y(k) - \hat{y}_j(k) = y(k) - \psi(u_j(k)),$$

можно записать дельта-правило обучения нейронов $N_j^{[1]}$ в виде

$$w_j(k+1) = w_j(k) + \eta_j(k)\varepsilon_j(k)\nabla_{w_j}\psi(u_j(k)) = w_j(k) + \eta_j(k)\varepsilon_j(k)G_j(k), \quad (4)$$

где $\eta_j(k)$ – параметр шага поиска, обычно выбираемый из эмпирических соображений, $\nabla_{w_j}\psi(u_j(k)) = G_j(k) = \gamma(1 - \hat{y}_j^2(k))Y_j(k)$ – градиент активационной функции (3) по настраиваемым параметрам. Сходимость алгоритма (4) обеспечивается в достаточно широком диапазоне изменения параметра шага $\eta_j(k)$, однако, желательно найти такое значение, которое обеспечивало бы максимально возможное быстрое действие процедуры настройки. В [19] показано, что в «беспомеховом» случае (а измерение потребления

электроэнергии характеризуются достаточно высокой точностью) высокое быстродействие обеспечивается процедурой

$$w_j(k+1) = w_j(k) + \frac{y(k) - \hat{y}_j(k)}{\|G_j(k)\|^2} G_j(k) = w_j(k) + \frac{y(k) - \hat{y}_j(k)}{\gamma(1 - \hat{y}_j^2(k)) \|Y_j(k)\|^2} Y_j(k), \quad (5)$$

где $\hat{y}_j(k) \neq 1$. Можно видеть, что в линейном случае процедура (5) совпадает с популярным алгоритмом обучения Качмажа-Уидроу-Хоффа.

В процессе обучения нейронов первого скрытого слоя одновременно вычисляются одношаговый и многошаговые прогнозы в виде

$$\hat{y}_j(k+1) = \psi(w_j^T(k+1)Y_j(k+1)), \quad (6)$$

где

$$\left\{ \begin{array}{l} Y_j(k+1) = (1, y(k), \dots, y(k-j+1), \hat{y}_j(k), \dots, \hat{y}_j(k-j+1))^T, \\ Y_j(k+2) = (1, \hat{y}_j(k+1), y(k), \dots, y(k-j+2), \hat{y}_j(k+1), \dots, \hat{y}_j(k-j+2))^T, \\ \vdots \\ Y_j(k+j) = (1, \hat{y}_j(k+j-1), \dots, y(k), \hat{y}_j(k+j-1), \dots, \hat{y}_j(k))^T, \\ \vdots \\ Y_j(k+1) = (1, \hat{y}_j(k+1-1), \dots, \hat{y}_j(k+1-j), \hat{y}_j(k+1-1), \dots, \hat{y}_j(k+1-j))^T. \end{array} \right.$$

Во втором скрытом слое производится оценивание точности прогнозов первого слоя с помощью рекуррентных соотношений

$$\sigma_{\varepsilon_j}^2(k) = \frac{k-1}{k} \sigma_{\varepsilon_j}^2(k-1) + \frac{1}{k} \varepsilon_j^2(k) \quad (7)$$

для стационарного и

$$\sigma_{\varepsilon_j}^2(k) = \alpha \sigma_{\varepsilon_j}^2(k-1) + (1-\alpha) \varepsilon_j^2(k) \quad (8)$$

для нестационарного случаев, где $0 \leq \alpha \leq 1$ – параметр экспоненциального сглаживания.

Попарное объединение прогнозов в третьем скрытом слое в форме (1) призвано повысить точность предсказания. Обучение нейронов этого слоя, являющихся по сути двухвходовыми линейными адаптивными ассоциаторами, производится с помощью алгоритма [19]

$$\begin{cases} c_j(k+1) = \frac{s_j(k)}{s_j(k+1)} c_j(k) + \frac{\varepsilon_j(k+1)(\hat{u}_{j-1}(k+1) - \hat{y}_{j+1}(k+1))}{s_j(k+1)}, \\ s_j(k+1) = s_j(k) + (\hat{u}_{j-1}(k+1) - \hat{y}_{j+1}(k+1))^2, \\ c_j(0) = 0.5. \end{cases}$$

В четвертом скрытом слое нейроноподобными элементами $N_j^{[4]}$ вычисляются текущие дисперсии обновлений $v_j(k) = y(k) - \hat{u}_j(k)$ с помощью соотношений (7) или (8). Можно доказать [21], что

$$\sigma_{v_j}^2(k) \leq \min\{\sigma_{v_{j-1}}^2(k), \sigma_{\varepsilon_{j+1}}^2(k)\}, \tag{9}$$

т.е. прогнозы, получаемые в третьем скрытом слое, по точности никогда не могут уступать прогнозам первого слоя.

Многошаговый прогноз в этом слое по аналогии с (6) может быть построен в виде

$$\hat{u}_j(k+1) = c_j(k+1)\hat{u}_{j-1}(k+1) + (1 - c_j(k+1))\hat{y}_j(k+1).$$

В пятом входном слое, образованном $(d-1)$ -входным адаптивным линейным ассоциатором, прогнозы предыдущих слоев объединяются в виде

$$\hat{y}(k) = \sum_{j=1}^{d-1} c_j^o(k)\hat{u}_j(k) = \hat{u}^T(k)c^o(k),$$

где вектор синаптических весов $c^o(k) = (c_1^o(k), c_2^o(k), \dots, c_{d-1}^o(k))^T$ обеспечивает несмещенность выходного прогноза

$$\sum_{j=1}^{d-1} c_j^o(k) = E^T c^o(k) = 1, \tag{10}$$

$$\hat{u}(k) = (\hat{u}_1(k), \hat{u}_2(k), \dots, \hat{u}_{d-1}(k))^T, E = (1, 1, \dots, 1)^T.$$

Оптимальный алгоритм обучения $N^{[5]}$ с учетом (10) может быть записано в виде [21]

$$\begin{cases} P(k+1) = P(k) - (P(k)\hat{u}(k+1))(P(k)\hat{u}(k+1))^T (1 + \hat{u}^T(k+1)P(k)\hat{u}(k+1))^{-1}, \\ c^*(k+1) = c^*(k) + P(k+1)(y(k+1) - \hat{u}^T(k+1)c^*(k))\hat{u}(k+1), \\ c^o(k+1) = c^o(k) - P(k+1)(E^T P(k+1)E)^{-1}(E^T c^*(k+1) - 1)E, \\ c_j^*(0) = (d-1)^{-1}E, \end{cases}$$

где $c^*(k+1)$ – обычная оценка рекуррентного метода наименьших квадратов.

Многошаговый прогноз этого слоя может быть записан в виде

$$\hat{y}(k+1) = \hat{u}^T(k+1)c^o(k+1)$$

и после декодирования с помощью (2) представлен в виде оценки реального процесса $\hat{y}^R(k+1)$.

По аналогии с (9) можно доказать, что

$$\sigma_{y(k)-\hat{y}(k)}^2(k) \leq \min\{\min \sigma_{\varepsilon_j}^2(k), \min \sigma_{v_j}^2(k)\} \forall j,$$

то есть прогноз, синтезируемый введенной нейронной сетью, является оптимальным на классе прогнозирующих NARMA-моделей порядков от 1 до d .

Выводы. Введенная прогнозирующая искусственная нейронная сеть представляет собой специализированную вычислительную структуру, предназначенную для обработки нелинейных временных рядов, характеризующихся структурной нестационарностью. Высокая скорость обучения, хорошие аппроксимирующие и экстраполирующие свойства и возможность работы в реальном времени позволяют ей решать широкий класс практических проблем и, в том числе, задачи оперативного и краткосрочного прогнозирования потребления электрической энергии.

Литература

1. Armstrong J.S. Long-Range Forecasting: From Crystal Ball to Computer. – New York: John Wiley and Sons, 1985. – 688 p.
2. Brockwell P.J., Davis R.A. Introduction to Time Series and Forecasting. – New York: Springer, 2003. – 456 p.
3. Zhang G.P. Time series forecasting using a hybrid ARIMA and neural network model // Neurocomputing. – 2003. – 50. – P. 159-175.
4. Bowerman B.L. Forecasting, Time Series, and Regression. – South-Western College Pub, 2004. – 696 p.
5. Neural Networks in Business Forecasting / Ed. by Zhang G.P. – Hershey: Idea Group Publishing, 2004. – 350 p.
6. Palit A.K., Popovic D. Computational Intelligence in Time Series Forecasting: Theory and Engineering Applications. – Berlin: Springer, 2005. – 372 p.
7. Gomes G.S.S., Maia A.L.S., Ludermir T.B., Carvalho F.d.A.T.d., Araujo A.F.R. Hybrid model with dynamic architecture for forecasting time series // Proc. 2006 International Joint Conference on Neural Networks. – Vancouver, BC, Canada, July 16-21, 2006. – P. 3742-3747.
8. Piras A., Germond A., Buchenel B., Imhof K., Jaccard Y. Heterogeneous artificial neural network for short term electrical load forecasting // IEEE Trans. Power Systems. – 1996. – 11. – N. 2. – P. 397-402.

9. Kiartzis S.J., Zoumas C.E., Theocharis J.B., Bakirtzis A.G., Petridis V. Short-term load forecasting in an autonomous power system using artificial neural networks // IEEE Trans. Power Systems. – 1997. – 12. – N. 4. – P. 1591-1596.
10. Mueller H., Petrisch G. Energy and load forecasting by fuzzy-neural networks // Proc. EUFTT'98. – September 7-10, 1998. – P. 1925-1929.
11. Hippert H.S., Pedreira C.E., Souza R.C. Neural networks for short-term load forecasting: a review and evaluation // IEEE Trans. Power Systems. – 2001. – 16. – N. 1. – P. 44-55.
12. Tzafestas S., Tzafestas E. Computational intelligence techniques for short-term electric load forecasting // Journal of Intelligent and Robotic Systems. – 2001. – 31. – P. 7-68.
13. Ling S.H., Leung F.H.F., Lam H.K., Tam P.K.S. Short-term electric load forecasting based on a neural fuzzy network // IEEE Trans. Industrial Electronics. – 2003. – 50. – N. 6. – P. 1305-1316.
14. Chen B.-J., Chang M.-W., Lin C.-J. Load forecasting using support vector machines: A study on EUNITE competition 2001 // IEEE Trans. Power Systems. – 2004. – 19. – N. 4. – P. 1821-1830.
15. Fan S., Chen L.N. Short-term load forecasting based on an adaptive hybrid method // IEEE Trans. Power Systems. – 2006. – 21. – N. 1. – P. 392-401.
16. Бодянский Е.В., Попов С.В., Рыбальченко Т.В. Адаптивное краткосрочное прогнозирование энергопотребления с помощью искусственной нейронной сети // «Автоматизация: проблемы, идеи, решения»: Материалы международной научно-технической конференции. – Севастополь, 10-15 сентября, 2007. – С. 17-18.
17. Bodyanskiy Y., Popov S., Rybalchenko T. Multilayer neuro-fuzzy network for short term electric load forecasting // Lecture Notes in Computer Science – Berlin, Heidelberg: Springer-Verlag, 2008. – 5010. – P. 339-348.
18. Плисс И.П., Попов С.В., Рыбальченко Т.В. Прогнозирование узловых нагрузок электроэнергетической системы на основе нейронной сети встречного распространения // Системні технології. Регіональний міжвузівський збірник наукових праць. – 2008. – 2. – N. 3(58). – С. 186-190.
19. Бодянский С.В., Михальов О.И., Плисс И.П. Адаптивные выявление разладов в объектах управления за допомогою штучних нейронних мереж. – Дніпропетровськ: Системні технології, 2000. – 140 с.
20. Бодянский Е.В., Руденко О.Г. Искусственные нейронные сети: архитектуры, обучение и применение. – Харьков: ТЕЛТЕХ, 2004. – 372 с.
21. Бодянский Е.В. Автоматическое обнаружение разладов с помощью искусственной нейронной метасети // Проблемы бионики. – 1998. – 49. – С. 34-38.

НЕЙРОМЕРЕЖЕВЕ ПРОГНОЗУВАННЯ НЕСТАЦІОНАРНИХ ЧАСОВИХ РЯДІВ ЕНЕРГОСПОЖИВАННЯ В УМОВАХ СТРУКТУРНОЇ НЕВИЗНАЧЕНОСТІ

І.П. Плисс, С.В. Попов, Т.В. Рыбальченко

Розглянуто задачу прогнозування нестационарних часових рядів енергоспоживання в умовах структурної невизначеності. Запропоновано спеціалізовану прогнозуючу штучну нейронну мережу, яка характеризується високою швидкістю навчання, дорими апроксимуючими та екстраполюючими властивостями, а також можливістю роботи в реальному часі.

NEURAL NETWORK FORECASTING OF NONSTATIONARY ELECTRIC LOAD TIME SERIES UNDER STRUCTURAL UNCERTAINTY

I.P. Pliss, S.V. Popov, T.V. Rybalchenko

The effective mathematical models of calculation and forecasting of distribution of energy flows in multilevel electroheating and accumulating heating system are received which provide the given thermal standards of a technologically active zone of a cattle-breeding premise.