

## ПРОГНОЗИРОВАНИЕ ЭЛЕКТРИЧЕСКИХ НАГРУЗОК ПРОМЫШЛЕННЫХ ПРЕДПРИЯТИЙ С ПОМОЩЬЮ ВЕЙВЛЕТ-НЕЙРОННЫХ СЕТЕЙ

**И.В. Мошенский**, инженер;

**И.Л. Лебединский**, доцент, канд. техн. наук;

**В.С. Ноздренков**, канд. техн. наук,

Сумский государственный университет, г. Сумы

*В данной работе используется модель прогнозирования получасовых электрических нагрузок предприятия с непрерывным циклом производства, основанная на использовании искусственных вейвлет-нейронных сетей. Программным путем на ЭВМ был выполнен прогноз получасовых электрических нагрузок, при этом полученные результаты представлены в графическом и в табличном виде. Точность прогнозируемых значений в большинстве случаев находилась в пределах 0,3-2,2 %, максимальная погрешность - 3,26 %.*

**Ключевые слова:** вейвлет-нейронная сеть, электрическая нагрузка, прогнозирование.

*В даній роботі використовується модель прогнозування півгодинних електричних навантажень підприємства з безперервним циклом виробництва, яка ґрунтується на використанні вейвлет-нейронних мереж. Програмним шляхом на ЕОМ був виконаний прогноз півгодинних навантажень, при цьому отримані результати представлені в графічному і табличному вигляді. Точність прогнозних значень досягала в більшості випадків 0,3-2,2 %, максимальна похибка - 3,26 %.*

**Ключові слова:** вейвлет-нейронна мережа, електричне навантаження, прогнозування.

### ПОСТАНОВКА ПРОБЛЕМЫ

Знание наперед того факта, как электрическая нагрузка будет вести себя в будущей недалекий момент времени – довольно ценная информация, дающая возможность регулировать потребление электроэнергии путем отключения/включения электроприемников еще до окончания этого промежутка времени. В настоящее время некоторые автоматизированные системы управления режимом потребления промышленных предприятий оснащены соответствующим программным обеспечением по краткосрочному прогнозированию получасовых электрических нагрузок. Это дает возможность, помимо автоматизированного учета электроэнергии, иметь более гибкие средства управления и контроля электропотреблением промышленных предприятий (ПР), выработкой электроэнергии на электростанциях, также внедрять меры по экономии электроэнергии. Наиболее эффективными средствами прогнозирования являются искусственные нейронные сети (ИНС) как уникальные аппроксиматоры любых линейных и нелинейных функций [1].

### ОСНОВНАЯ ЧАСТЬ ИССЛЕДОВАНИЯ

В этой работе предложено прогнозирование с помощью вейвлет-нейронных сетей (ВНС). ВНС представляют собой [4] архитектуру радиально-базисных нейронных сетей с вейвлет-функциями, заключенными в вейвлет-нейронах (рис.1). При подаче на вход вейвлет-нейрона векторного сигнала

$$x(k) = (x_1(k), \dots, x_n(k)) \quad x(k) = (x_1(k), \dots, x_n(k))$$

где  $k$  – момент времени, на его выходе появляется скалярное значение  $y(k)$  :

$$y(k) = \sum_{i=1}^n f_i(x(k)) = \sum_{i=1}^n \sum_{j=1}^{h_i} w_{ji} \varphi_{ji}(x_i(k)), \quad (1)$$

где  $w_{ji}$  – настраиваемые веса ;

$\varphi_{ji}(x_i(k))$  - вейвлет-функция ;

$n$  - количество входов ;

$h_i$  - количество вейвлет-нейронов, обрабатывающий  $i$ -й вход.




Рисунок 1 - Архитектура ВНС из  $n$  вейвлет-нейронов. Каждый нейрон имеет  $h_i$  входов со своей вейвлет- функцией  $\varphi$  и весом  $w$

В качестве критерия обучения ВНС используется квадратичная функция ошибки:

$$E(k) = \frac{1}{2} (y^*(k) - y(k))^2 = \frac{1}{2} e^2(k) = \frac{1}{2} \left( y^*(k) - \sum_{i=1}^n \sum_{j=1}^{h_i} w_{ji} \varphi_{ji}(x_i(k)) \right)^2, \quad (2)$$

где  $y^*(k)$  - идеальный сигнал ;

$y(k)$  - выход ВНС.

Выражение для обучения ВНС в общем виде выглядит так [4]:

$$\begin{cases} w_{ji}(t+1) = w_{ji}(t) + \eta^w(t) \cdot e(t) \cdot \frac{\partial \varphi}{\partial w_{ji}}, \\ c_{ji}(t+1) = c_{ji}(t) + \eta^c(t) \cdot e(t) \cdot w_{ji}(t) \cdot \frac{\partial \varphi}{\partial c_{ji}}, \\ \sigma_{ji}^{-1}(t+1) = \sigma_{ji}^{-1}(t) + \eta^\sigma(t) \cdot e(t) \cdot w_{ji}(t) \cdot \frac{\partial \varphi}{\partial \sigma_{ji}^{-1}}, \end{cases} \quad (3)$$

где  $\varphi$  - вейвлет-функция;

$c_{ji}, \sigma_{ji}$  - параметры, определяющие положение центра (сдвига) и ширину растяжения вейвлета;

$\eta^w(t), \eta^c(t), \eta^\sigma(t)$  - скалярные коэффициенты, определяющие шаг смещения в пространстве настраиваемых параметров.

Представим алгоритм обучения ВНС с вейвлетом Гаусса:

$$\varphi_{ji}(x_i(k)) = \tau_G \cdot \exp\left(-\tau_{ji}^2(k)\right), \quad (4)$$

где  $\tau_{ji}(k) = \frac{x_i(k) - c_{ji}(k)}{\sigma_{ji}(k)}$ ,  $\tau_G$  - константа.

Соотношения для алгоритма обучения ВНС [4] с вейвлетом (4) с использованием градиентного метода для настройки параметров запишется в виде:

$$\begin{cases} w_{ji}(t+1) = w_{ji}(t) + \eta^w(t) \cdot e(t) \cdot \tau_G \cdot \exp\left(-\tau_{ji}^2(k)\right), \\ c_{ji}(t+1) = c_{ji}(t) + \eta^c(t) \cdot e(t) \cdot w_{ji}(t) \cdot 2\tau_G \cdot \tau_{ji} \cdot \sigma_{ji}^{-1} \cdot \exp\left(-\tau_{ji}^2(k)\right), \\ \sigma_{ji}^{-1}(t+1) = \sigma_{ji}^{-1}(t) + \eta^\sigma(t) \cdot e(t) \cdot w_{ji}(t) \cdot 2\tau_G \cdot \tau_{ji} \cdot (x_i(t) - c_{ji}(t)) \cdot \exp\left(-\tau_{ji}^2(k)\right), \end{cases} \quad (5)$$

где  $\eta^w(t), \eta^c(t), \eta^\sigma(t)$  - скалярные коэффициенты, определяющие шаг смещения в пространстве настраиваемых параметров. В процессе программирования и вычисления значения этих величин изменялись от 0,1 в начале цикла обучения до 0,01 в конце цикла [6].

Имеются также алгоритмы обучения ВНС по методу сопряженных градиентов и методу тяжелого шарика.

Программа по обучению ВНС для дальнейшего ее использования в качестве прогнозирования написана в среде программирования Matlab6.5. Создав сеть ВНС и обучая ее данными обучающей выборки (ОВ) получасовых электрических нагрузок ПР с непрерывным циклом производства, получаем прогнозы получасовых нагрузок. При этом происходило варьирование данными:

- размерность входного вектора  $x(k) = (x_1(k), \dots, x_n(k))$ . При этом значение  $N$  изменялось от 5 до 8 с шагом 1; за пределами этого интервала и в ту, и в другую сторону начинают увеличиваться среднеарифметическая и максимальная ошибки прогнозирования;

- изменялось количество входов вейвлет-нейронов. Этот параметр варьировался в пределах от 5 до 7. При этом разным нейронам назначалось разное количество входов. Наиболее оптимальный вариант будет показан ниже;

- изменялся тип вейвлет-функции  $\varphi$ , что давало возможность уменьшить количество эпох обучения ВНС.

Процедура варьирования данными производилась с целью определения оптимального подбора вышеуказанных параметров и получения наилучшего прогноза. Качество прогноза оценивалось в основном по такому параметру, как среднеарифметическое значение ошибки между действительным и прогнозным значениями электрической нагрузки, а также по максимальному значению среднеарифметической ошибки за весь цикл прогноза.




Рисунок 2 - Графики реального (1) и спрогнозированного (2) значения получасовых нагрузок предприятия с непрерывным циклом производства. Ось по вертикали – нагрузка в кВт, по горизонтали – время в течение суток, или 48 получасовых прогнозов. Вычисления для значения  $n = 6$  входов

На рис.2 представлен график реального и прогнозного значений получасовой электрической нагрузки предприятия с непрерывным циклом производства. Этот случай соответствует следующим параметрам архитектуры ВНС :

- количество нейронов  $n = 6$ ; значение берется согласно рекомендациям, описанным в источнике [6];
- количество входов нейронов  $h_1 = 5, h_2 = 5, \dots, h_5 = 7, h_6 = 6$ ;
- вейвлет-функция Гаусса (4);
- количество эпох обучения – 100 эпох;
- алгоритм обучения ВНС – градиентный метод (5).

При этом точность прогнозных значений составила величины :

$$\delta_{\text{средняя}} = 1,28 \% ; \quad \delta_{\text{max}} = 3,25 \% .$$

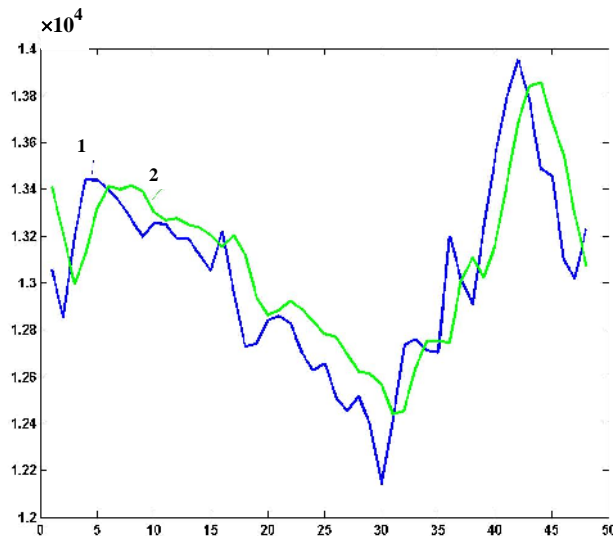


Рисунок 3 - Графики реального (1) и спрогнозированного (2) значения получасовых нагрузок предприятия с непрерывным циклом производства. Вычисления для значения  $n = 7$  входов

Менее точным результатом было вычисление прогноза для  $n=7$  – входовой нейронной сети. Точности прогноза  $\delta_{\text{cp}} = 1,44\%$ ;  $\delta_{\text{max}} = 3,58\%$  (рис.3).

Следует отметить, что вейвлет Гаусса (4) является подходящим для данной архитектуры сети, так как гистограмма обучающей выборки (рис. 3) представляет собой распределения, подобные нормальному

распределению с той лишь разницей, что в ней присутствует много вершин.




Рисунок 4 - Гистограмма обучающей выборки

Еще один результат прогнозирования получен с применением вейвлет-функции типа (6), носящего название «мексиканская шляпа» – «Mexican hat» [8], график которого представлен на рис. 5:

$$\varphi_{ji}(x_i(k)) = \tau_G \cdot (1 - \tau_{ji}^2) \cdot \exp(-\tau_{ji}^2(k)) \quad (6)$$

где  $\tau_{ji}(k) = \frac{x_i(k) - c_{ji}(k)}{\sigma_{ji}(k)}$ ,  $\tau_G$  – константа.




Рисунок 5 - График МНАТ - вейвлета «Мексиканская шляпа» – «Mexican hat»

Точность вычислений составила  $\delta_{cp} = 1,29 \%$ ;  $\delta_{max} = 3,56 \%$ . Но при этом количество эпох обучения ВНС сократилось до 60, т.е. почти в 2 раза, уменьшив тем самым время обучения.

#### ВЫВОДЫ

Итак, в проделанной работе получены результаты прогнозирования с помощью вейвлет-нейронной сети. Эксперимент обладал более высокой точностью полученного результата, чем многослойный перцептрон (МСП) и самоорганизующиеся нейронные сети (СОНС) [1,2]. По сравнению с радиально-базисными сетями ВНС [3] имеются как преимущества, так и недостатки. Это, во-первых, большая усредненная погрешность вычисления  $\delta_{средняя}$ , во-вторых, лучшая максимальная погрешность  $\delta_{max}$  за весь период прогнозирования. Также следует отметить, что в практических расчетах ВНС имеют меньшую размерность, чем РБС, и, что весьма положительно для ВНС по сравнению с РБС, – это наличие в ВНС вейвлет-функции, что дает возможность изменять ее тип для подбора оптимальной точности вычисления. Так, в проделанной работе одним из вариантов расчета был вариант с вейвлет-функцией типа

«мексиканская шляпа». Сравнение результатов прогнозирования для разных вейвлет-функций приведено в табл. 1.

Таблица 1

Тип сети	Тип вейвлет-функции	$\delta_{\text{средняя}}, \%$	$\delta_{\text{max}}, \%$	Кол-во эпох обуч.
ВНС	Гаусса	1,28	3,25	100
ВНС	<i>Mexican hat</i>	1,29	3,56	60

## SUMMARY

### THE ELECTRIC DEMAND PREDICTION OF JSC «SUMYKHIMPROM»

*I.V. Moshenskiy, I.L. Lebedinskiy, V.S. Nozdrenkov*

*The electric demand prediction of JSC “SumyKhimprom” with the continuous cycle of production is done. Most perspective is a method based on the use of artificial neuron networks. Adequacy of application of this method is well-proven by a number of theorems, and the developed programmatic tool allows to predict the electric demand without implementation of additional operations. In the paper the structure of neural network was proposed.*

## СПИСОК ЛИТЕРАТУРЫ

1. Мошенский И. В. Прогнозирование электрических нагрузок ОАО «Сумыхимпром» с помощью искусственных нейронных сетей / И. В. Мошенский, В. С. Ноздренков, А. Ю. Хатунцев // Вісник Сумського державного університету. - 2009. - № 3. - С. 39-43.
2. Мошенский И. В. Применение кластеризации данных обучающей выборки при прогнозировании электронагрузок промышленных предприятий / И. В. Мошенский, В. С. Ноздренков, А. Ю. Хатунцев // Вісник Сумського державного університету. - 2010. - №1. - С.23-29.
3. Мошенский И. В. Прогнозирование электрических нагрузок промышленных предприятий с помощью радиально-базисных нейронных сетей / И. В. Мошенский, И. Л. Лебединский, В. С. Ноздренков // Вісник Сумського державного університету. - 2011. - №1. - С.147-153.
4. Амосов О. С. Модели и алгоритмы обучения вейвлет-нейронных сетей / О. С. Амосов, Д. С. Магола // Сборник трудов конференции ТиПВСИТ ' 2009. - Восточно-Сибирский государственный технический университет (г. Улан-Удэ), июль 2009 г. - г. Улан-Удэ, 2009.
5. Бодянский Е. В. Рекуррентный алгоритм обучения радиально-базисных нейронных сетей, основанный на приближительных множествах / Е. В. Бодянский, Е. В. Горшков, В. В. Колодяжный, И. П. Плисс // Радиоелектроніка. Інформатика. Управління. - 2005.- № 1.
6. Васильев Д. А. Выбор модели электрической нагрузки предприятий с непрерывным характером производства / Д. А. Васильев, В. А. Иващенко, А. Ф. Резчиков, Е. С. Курышова // Электротехнические комплексы и силовая электроника. Анализ, синтез и управление: Межвуз. науч. сб. - Саратов, 2001. - С. 36-39.
7. Козлов П. В. Вейвлет-преобразование и анализ временных рядов / П. В. Козлов, Б. Б. Чен. // Вестник КРСУ. - 2002. - №2.

*Поступила в редакцию 4 октября 2011 г.*