

УДК 681.518:519.718

**ПРОГНОЗИРОВАНИЕ ЭЛЕКТРИЧЕСКИХ НАГРУЗОК
ПРОМЫШЛЕННЫХ ПРЕДПРИЯТИЙ
С ПОМОЩЬЮ РАДИАЛЬНО-БАЗИСНЫХ НЕЙРОННЫХ СЕТЕЙ**

И.В. Мошенский, инженер;

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

В.С. Ноздренков, канд. техн. наук;

Сумский государственный университет, г. Сумы

У даній роботі використовується модель прогнозування півгодинних електричних навантажень підприємства з безперервним циклом виробництва, яка ґрунтується на використанні радіально-базисних 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 0,3-1,5 %, в найгіршому випадку – 3,8 %.

Ключові слова: *радіально-базисна мережа, електричне навантаження, прогнозування.*

В данной работе используется модель прогнозирования получасовых электрических нагрузок предприятия с непрерывным циклом производства, основанная на использовании радиально-базисных искусственных 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 составила в большинстве случаев 0,3-1,5 %, в наихудшем случае- 3,8 %.

Ключевые слова : *радиально-базисная сеть, электрическая нагрузка, прогнозирование.*

ВВЕДЕНИЕ

Знание наперед того факта, как электрическая нагрузка будет вести себя в будущей недалекий момент времени – довольно ценная информация, так как это дает возможность проделать некоторые действия по регулированию потреблением ее путем отключения/включения электроприемников еще до наступления конца этого момента 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, кроме автоматизированного учета электроэнергии, иметь более гибкие средства по управлению и контролю 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

При прогнозировании электрических нагрузок промышленных предприятий (ПР) применяются самые разнообразные нейронные сети: многослойный персептрон, саморганизующиеся нейронные сети, результаты прогнозирования с помощью которых представлены в [1,2]. В этой работе предложено прогнозирование с помощью радиально-базисных нейронных сетей (РБС).

Радиально-базисная сеть [4] имеет фиксированную структуру с одним скрытым слоем и линейными выходными нейронами (рис. 1). Аппроксимирующее решение РБС с учетом того, что в скрытом слое находится K нейронов, можно представить в виде

$$F(x) = \sum_{i=1}^K w_i \varphi(\|x - c_i\|), \quad (1)$$

где c_i ($i = 1, 2, \dots, K$) - множество центров, которые необходимо определить;

$\varphi(\|x - c_i\|)$ - радиальные функции;

w_i - весовые коэффициенты.

Чаще всего в качестве радиальной функции применяется функция Гаусса. При размещении ее центра в точке c_i она может быть определена в сокращенной форме как

$$\varphi(x) = \varphi(\|x - c_i\|) = \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_i^2}\right). \quad (2)$$

В этом выражении σ_i - параметр, от значения которого зависит ширина функции.

Полученное решение, представляющее аппроксимирующую функцию в многомерном пространстве в виде взвешенной суммы локальных базисных радиальных функций (выражение (1)), может быть интерпретировано РБС, представленной на рис. 1.

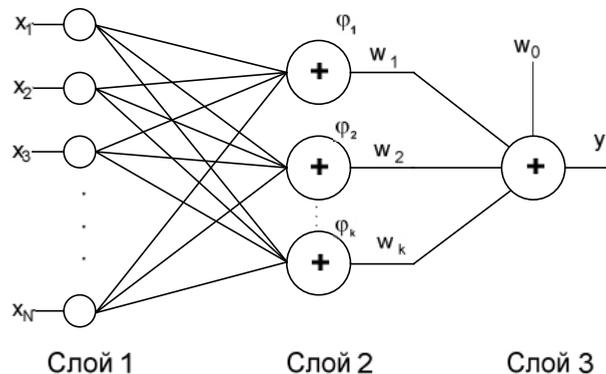


Рисунок 1 - Интерпретация радиально-базисной нейронной сети: слой 1 – входной слой, на который подаются входные векторы сигналов $X(X_1, X_2, \dots, X_N)$;

слой 2 – скрытый слой нейронов с базисными радиальными функциями φ_i ;

слой 3 – выходной слой в виде линейного нейрона

Для упрощения эта сеть имеет только один выход, в которой φ_i определяются зависимостью (2). Это сеть с двухслойной структурой, в которой только скрытый слой выполняет нелинейное отображение, реализуемое нейронами с базисными радиальными функциями. Выходной нейрон, как правило, линеен и его роль сводится к взвешенному суммированию сигналов, поступающих от нейронов скрытого слоя. Вес w_0 представляет собой пороговое значение выходного нейрона.

Обучение РБС происходит в несколько этапов [5]. Сначала определяются центры и отклонения для радиальных элементов; после этого оптимизируются параметры w_i линейного выходного слоя. Расположение центров должно соответствовать кластерам, реально присутствующим в исходных данных. Для процедуры кластеризации можно применить алгоритм K -средних, который стремится выбрать оптимальное множество точек, являющихся центроидами кластеров в обучающих данных. После определения центров кластеров находятся отклонения. Как правило, отклонения выбираются таким образом, чтобы «колпак» каждой гауссовой функции захватывал несколько соседних центров. После того как выбраны центры и отклонения, параметры выходного слоя оптимизируются с помощью стандартного метода линейной оптимизации – алгоритма обратных матриц (сингулярного разложения). РБС имеют ряд преимуществ перед многослойными сетями прямого распространения. Во-первых, они моделируют произвольную нелинейную функцию с помощью всего одного промежуточного слоя, тем самым избавляя нас от необходимости решать вопрос о числе слоев. Во-вторых, параметры линейной комбинации в выходном слое можно полностью оптимизировать с помощью хорошо известных методов линейной оптимизации, которые быстро работают и не испытывают трудностей с локальными минимумами, мешающими при обучении с использованием алгоритма обратного распространения. Поэтому РБС обучаются на порядок быстрее, чем многослойные перцептроны, использующие алгоритм обратного распространения ошибки.

Итак, РБС имеет немалые преимущества по отношению к многослойному перцептрону и самоорганизующимся нейронным сетям в плане времени обучения. Программа по обучению РБС для дальнейшего ее использования в качестве прогнозирования написана в среде программирования Matlab, имеющей в своем распоряжении встроенные модели многих типов нейронных сетей, в том числе и РБС, и предусмотрено их обучение. Создавая командами системы Matlab сети РБС и обучая их данными обучающей выборки (ОВ) получасовых электрических нагрузок ПР с непрерывным циклом производства, получаем прогнозы получасовых нагрузок. При этом происходило варьирование данными:

- размерность входного вектора $X = X(x_1, x_2, \dots, x_N)$. При этом значение N изменялось от 5 до 9 с шагом 1; за пределами этого интервала и в ту и в другую сторону начинает увеличиваться среднеарифметическая и максимальная ошибки прогнозирования;
- количество кластеров K в скрытом радиальном слое нейронов. Этот параметр претерпевал изменения от 54 до 100. Уменьшение и увеличение количества кластеров не приводит к улучшению результата прогнозирования.

Процедура варьирования данными делалась с целью определения оптимального подбора вышеуказанных параметров, чтобы получить наилучший прогноз. Качество прогноза оценивалось в основном по такому параметру, как среднеарифметическое значение ошибки между

действительным и прогнозным значением электрической нагрузки. Следует отметить, что в принципе подавляющее количество вычислений с архитектурами сети, отличающихся друг от друга только количественными значениями $X = X(x_1, x_2, \dots, x_N)$ и K , имели удовлетворительные результаты. Некоторые из них приведены ниже в табл.1.

Таблица 1

Размерность входного вектора $X = X(x_1, x_2, \dots, x_N)$	Количество кластеров K	Среднеарифметическая ошибка прогнозирования δ , %	Макс. ошибка прогноз., %
5	58	0,8311	3,7995
5	66	0,8078	3,7600
6	58	0,8475	3,7667
6	66	0,8122	3,7210
7	58	0,8120	3,7149
7	66	0,8277	3,5331
8	58	0,7777	3,7532
8	66	0,7708	3,7877
9	58	0,8324	3,7539
9	66	0,8437	3,6067

На рис.2 изображены кривые реального ряда (1) и прогнозирования (2) получасовых электрических нагрузок ПР с непрерывным циклом производства. По горизонтальной оси отложено время, в течение которого производился прогноз – 48 часов, или одни сутки, по вертикальной оси – получасовые нагрузки, кВт. Эти результаты получены при выборе параметров:

- точек предыстории $N = 8$;
- количество радиальных нейронов скрытого слоя $K = 66$;

При этом среднеарифметическая ошибка прогнозирования по всем прогнозам составила 0,77 %, максимальная 3,78 %.

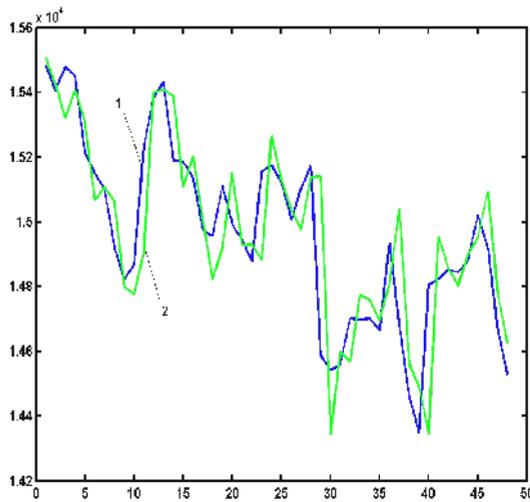


Рисунок 2 - Реальный (1) и спрогнозированный (2) ряды получасовых электрических нагрузок ПР с непрерывным циклом производства для случая:

- точек предыстории $N = 8$;
- количество радиальных нейронов скрытого слоя $K = 66$.

Среднеарифметическая ошибка прогнозирования: $\delta_{cp} = 0,7708$ %

На рис. 3, 4 представлены аналогичные кривые с тем отличием, что параметры прогнозирования выбирались следующими:

- точек предыстории $N = 6, 7$ соответственно;
- количество радиальных нейронов скрытого слоя $K = 66, 58$ соответственно;

При этом среднеарифметическая ошибка прогнозирования по всем прогнозам составила 0,8122 и 0,8120 % соответственно, а максимальная 3,68 и 3,71 %.

Наиболее точным оказался прогноз для случая выбора параметров прогнозирования $N = 8$ и $K = 66$.

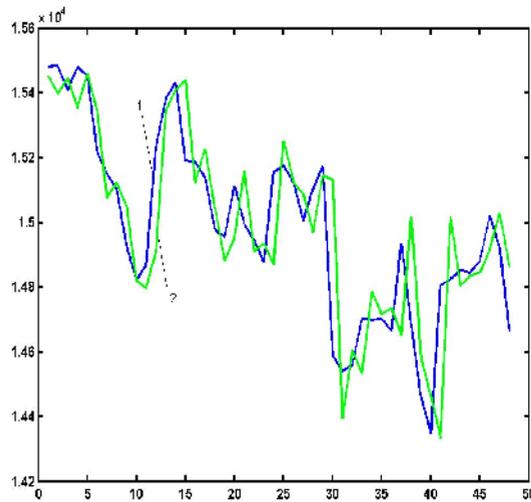


Рисунок 3 - Реальный (1) и спрогнозированный (2) ряды получасовых электрических нагрузок ПР с непрерывным циклом производства для случая :
 - точек предыстории $N = 7$;
 - количество радиальных нейронов скрытого слоя $K = 54$.
 Среднеарифметическая ошибка прогнозирования : $\delta_{cp} = 0,8120$ %

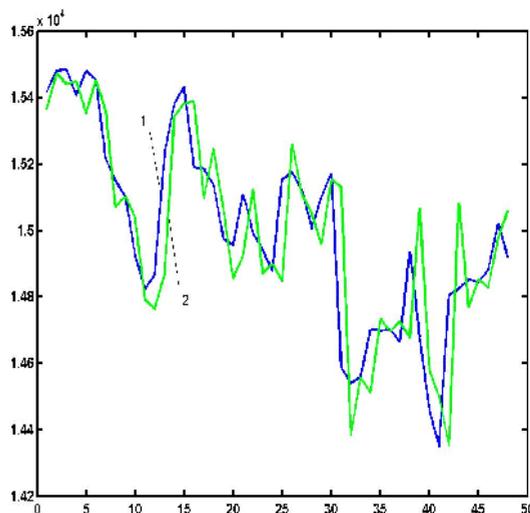


Рисунок 4 - Реальный (1) и спрогнозированный (2) ряды получасовых электрических нагрузок ПР с непрерывным циклом производства для случая:
 - точек предыстории $N = 6$;
 - количество радиальных нейронов скрытого слоя $K = 66$.
 Среднеарифметическая ошибка прогнозирования : $\delta_{cp} = 0,8122$ %

Для анализа результатов был построен график зависимости среднеарифметической ошибки прогнозирования от количества точек предыстории при прочих равных условиях. График представлен на рис. 5. Из графика виден оптимальный вариант прогнозирования, где ошибка имеет минимум, при количестве точек предыстории $N = 8$.

Оптимальное значение достигается при количестве точек предыстории, равном $N = 8$.

Для случая с количеством точек предыстории $N = 8$, где имел место минимум среднеарифметической ошибки прогнозирования (см. рис. 5), была построена еще одна зависимость, в которой исследовалась среднеарифметическая ошибка от количества нейронов внутреннего радиального слоя РВС. Фрагмент этого расчета представлен в табл. 2.

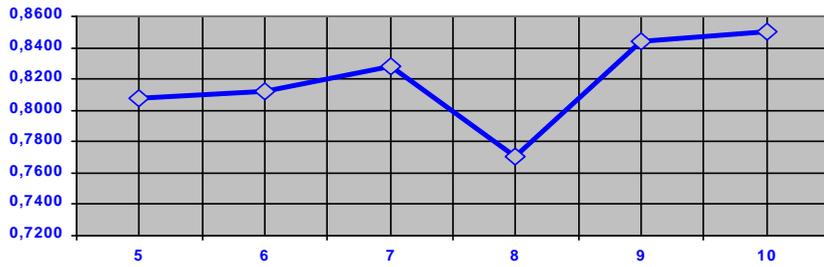


Рисунок 5 - Зависимость среднеарифметической ошибки от количества точек предистории

Таблица 2

Размерность входного вектора $X = X(x_1, x_2, \dots, x_N)$, N	Количество кластеров K	Среднеарифметическая ошибка прогнозирования δ_{cp} , %	Макс. ошибка прогноз., %
8	54,0000	0,7823	3,8672
8	56,0000	0,7993	3,8257
8	58,0000	0,7777	3,7532
8	60,0000	0,7745	3,7268
8	62,0000	0,7756	3,7504
8	64,0000	0,7847	3,7925
8	66,0000	0,7708	3,7877
8	68,0000	0,7899	3,7810
8	70,0000	0,7959	3,7203
8	72,0000	0,8082	3,6730

График этой зависимости приведен на рис. 6, из которого видно, что минимальная ошибка достигается при количестве нейронов, равном 66, дальнейшее увеличение нейронов внутреннего слоя не приводит к улучшению результата.

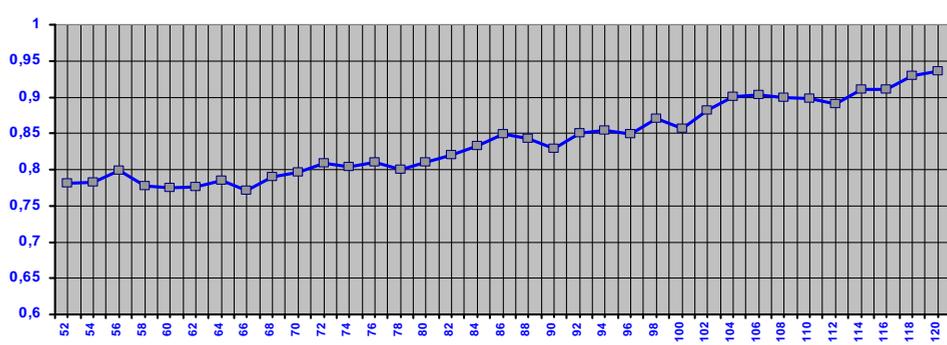


Рисунок 6 - Зависимость среднеарифметической ошибки прогнозирования от количества нейронов внутреннего радиального слоя РВС

ВЫВОДЫ

Итак, в проделанной работе получены результаты прогнозирования с помощью радиально-базисной нейронной сети. Эксперимент обладал следующими преимуществами по сравнению с многослойным персептроном (МСП) и самоорганизующимися нейронными сетями (СОНС) [1,2]:

– так как РБС является немногослойной и содержит всего один скрытый слой радиальных нейронов, то время обучения РБС по сравнению с вышеуказанными сетями, с которыми проводились расчеты, описанные в источниках [1,2], превышает на один, два порядка. Это дает возможность существенно экономить машинное время ЭВМ. Для сравнения ниже приведена таблица (см. табл. 3), в которую внесены данные времени обучения нейронных сетей МСП, СОНС и РБС. Программирование проводилось на ЭВМ с характеристиками: микропроцессор- 2,6 ГГц, ОП – 512 МБ.

Таблица 3

	Тип сети	Размерн. входа	Обучающая выборка, шт.	Количество кластеров	Время обучения, мин.
1	МСП	6	7*48	-	9
2	СОНС	6	7*48	66	34
3	РБС	6	14*48	66	Менее 1 мин.

– в свою очередь, уменьшение времени обучения дает возможность увеличить объем ОБ, подаваемой на вход-выход сети в процессе обучения. В этом эксперименте объем ОБ был увеличен в два раза по сравнению с МСП и СОНС; еще уменьшение времени обучения дает возможность просчитать большее количество вариантов сети, варьируя ее параметрами, и из полученных результатов выбрать наилучший;

– точность экспериментов с РБС не уступает точности с применением МСП и СОНС, а в некоторых случаях превосходит.

SUMMARY

THE ELECTRIC DEMAND PREDICTION OF JSC «SUMYKHIMPROM»

*I.V. Moshenkii, I.L. Lebedinskiy, V.S. Nozdrenkov,
Sumy State University, Sumy*

The electric demand prediction of JSC “SumyKhimprom” with the continuous cycle of production is done. The most advanced 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.

Key words: artificial neuron networks, electric demand, programmatic tools.

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. 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 // Радіоелектроніка. Інформатика. Управління. - 2005.- №1 (13). - С. 116-122 .
4. Осовский С. Нейронные сети для обработки информации / С. Осовский. - М.: Финансы и статистика, 2002. - 344 с.: ил.
5. Круглов В.В. Нечеткая логика и искусственные нейронные сети: учеб. пособ. для высшей школы(ВУЗы) / Круглов В.В., Длин М.И., Голунов Л.Ю. - М.: Физматлит, 2001. - 224 с.

Поступила в редакцию 31 января 2011 г.