

ПРИМЕНЕНИЕ КЛАСТЕРИЗАЦИИ ДАННЫХ ОБУЧАЮЩЕЙ ВЫБОРКИ ПРИ ПРОГНОЗИРОВАНИИ ЭЛЕКТРОНАГРУЗОК ПРОМЫШЛЕННЫХ ПРЕДПРИЯТИЙ

И.В. Мошенский, инженер; В.С. Ноздренков, канд. техн. наук;
А.Ю. Хатунцев, канд. техн. наук,
Сумський державний університет, г. Суми

В данной работе используется модель прогнозирования получасовых электрических нагрузок предприятия ОАО «Сумыхимпром», основанная на использовании самоорганизующихся нейронных сетей с предварительной кластеризацией данных обучающей выборки. Программным путем на ЭВМ был выполнен прогноз электропотребления, при этом полученные результаты представлены в графическом виде. Точность прогнозируемых значений составила в большинстве случаев 0,5-2,8 %, в худшем случае 3,65-5 %.

Ключевые слова: кластеризация данных, электронагрузка, промышленное предприятие.

У даній роботі використовується модель прогнозування електрических навантажень підприємства ВАТ «Сумихімпром», що базується на використанні самоорганізованих нейронних мереж з початковою кластеризацією даних навчальної вибірки. Шляхом програмування на ЕОМ був виконаний прогноз електроспоживання, при цьому отримані результати, наведені у графічному вигляді. Точність прогнозних значень досягала в більшості випадків 0,5-2,8 %, у найгіршому випадку 3,65-5 %.

Ключові слова: кластеризація даних, електричне навантаження, промислове підприємство.

ПОСТАНОВКА ПРОБЛЕМЫ

При управлении энергопотреблением промышленного предприятия (ПП) с целью экономии целесообразно проводить краткосрочные прогнозирования получасовых электрических нагрузок. Это дает возможность иметь некоторую информацию о потреблении электроэнергии ПП на небольшой период упреждения, после чего диспетчерская служба может более точным образом реагировать на управление нагрузкой ПП. Существует много методов прогнозирования, наиболее удачным и точным считается прогнозирование с помощью искусственных нейронных сетей (ИНС). Один из вариантов этого метода рассматривается в данной работе.

ОСНОВНАЯ ЧАСТЬ ИССЛЕДОВАНИЯ

Одним из распространенных методов прогнозирования электрических нагрузок промышленных предприятий является метод прогнозирования на основании нейронной сети типа многослойный персепtron (МСП), суть которого описана в работах [1,2]. Он заключается в том, что на основании данных обучающей выборки (ОВ) производится обучение сети МСП с последующим использованием для прогнозирования. При этом данные ОВ при обучении подаются путем поочередного единичного их представления на вход и выход МСП без предварительной обработки. Авторами этой статьи была проделана работа по обучению и прогнозированию с помощью МСП, при этом краткая теория, результаты, графики, погрешности вычислений представлены в работе [1].

В работе [3] предложена идея предварительной кластеризации данных ОВ, заключающейся в разбиении большого множества данных на группы (кластеры), определении центров этих кластеров и использование

полученных результатов в дальнейшем прогнозировании с помощью нейронной сети. Для кластеризации данных можно применять самоорганизующиеся нейронные сети [3]. Основу самоорганизации нейронных сетей составляет закономерность, что глобальное упорядочение нейронной сети становится возможным благодаря самоорганизующимся операциям, независимо друг от друга проводящихся в различных локальных сегментах сети. В соответствии с поданными входными сигналами осуществляется активация нейронов, которые вследствие изменения значений синаптических весов адаптируются к поступающим обучающим выборкам. В процессе обучения наблюдается тенденция к росту значений весов, из-за которой создается своеобразная положительная обратная связь: более мощные возбуждающие импульсы – более высокие значения весов – большая активность нейронов. При этом происходит естественное расслоение нейронов на различные группы. Отдельные нейроны или их группы сотрудничают между собой и активизируются в ответ на возбуждение, создаваемое конкретными ОВ, подавляя своей активностью другие нейроны. При этом можно говорить как о сотрудничестве между нейронами внутри группы и между различными группами.

Среди механизмов самоорганизации можно выделить два основных класса:

- самоорганизация на ассоциативном правиле Хебба;
- механизм конкуренции между нейронами на базе обобщенного правила Кохонена.

Широкий спектр обучающих данных, включающий многократные повторения похожих друг на друга выборок, образует базу знаний для обучения сети, из которой путем соответствующих сопоставлений выводятся решения по формированию на выходе сети определенного откласифицированного вектора.

Для обучения вышеуказанных сетей самоорганизации применяются соответствующие алгоритмы. Например, алгоритм Кохонена предусматривает [4] самообучение по правилу «победитель забирает все». Структура сети представлена на рис. 1 .




Рисунок 1 - Структура сети Кохонена

Критерий подстройки весов сети (все векторы должны быть нормализованы, т.е. иметь единичную длину - $\|w_i\| = 1$, $i = 1, 2, \dots, m$) выглядит следующим образом:

$$\|x - w_r\| = \min_{i=1,2,\dots,m} \|x - w_i\|, \quad (1)$$

где индекс r обозначает нейрон-победитель, соответствующий вектору весов w_r , который ближе всех расположен к текущему входному вектору x .

После выявления нейрона-победителя его выход устанавливается равным единице (у остальных нейронов устанавливаются нулевые выходы), а веса корректируются по следующей формуле:

$$w_r := w_r + \eta(x - w_r), \quad (2)$$

где η -коэффициент скорости обучения.

Помимо алгоритмов типа «победитель забирает все» (англ.: WTA), в которых в каждой итерации может обучаться только один нейрон, для обучения сетей с самоорганизацией широко применяются алгоритмы типа «победитель забирает больше» (англ.: WTM), в которых, кроме победителя, уточняют значения своих весов и нейроны из его ближайшего окружения. При этом чем дальше находится нейрон от нейрона-победителя, тем меньше уточняются его веса. Процесс уточнения вектора определяется зависимостью в виде

$$w_i := w_i + \eta_i G(i, x)[x - w_i], \quad (3)$$

для всех i нейронов, находящихся в окрестности победителя. В зависимости от формы функции $G(i, x)$ существует множество вариантов алгоритма WTM.

В данной работе проделаны исследования по прогнозированию электрических нагрузок промышленного предприятия, используя предварительную кластеризацию данных ОВ. При этом для кластеризации данных использовались саморганизующиеся нейронные сети. Организовав на вход сети данные ОВ и задав необходимое количество эпох обучения и количество нейронов сети (равняется количеству кластеров), получаем разбиение данных ОВ на кластеры. Программа кластеризации и прогнозирования была написана средствами пакета MATLAB 6.5, имеющая встроенные процедуры создания и обучения нейронных сетей разных типов, в том числе и самоорганизующихся. Данные на вход сети подавались в виде большого количества p -размерных векторов, где p одновременно является количеством входов каждого нейрона самоорганизующейся сети (рис.2). После обучения нейронной сети весовые коэффициенты каждого нейрона представляют из себя координаты центров кластеров:

$$w_{ij} = c_{ij}, \quad i = 1 \dots p, \quad j = 1 \dots n,$$

где n – количество кластеров.

После кластеризации данных и получения центров кластеров создается дополнительная нейронная сеть такого же типа как и первая с количеством входов $p-1$. При этом $p-1$ значений весовых коэффициентов каждого нейрона первой сети присваиваются соответствующим значениям весовых коэффициентов второй сети:

$$w_{ij}^{(2)} = w_{ij}^{(1)}, \quad i = 1 \dots p-1, \quad j = 1 \dots n, \quad (4)$$

где $w_{ij}^{(1)}$ – весовые коэффициенты нейронов первой сети;

$w_{ij}^{(2)}$ – весовые коэффициенты нейронов второй сети.




Рисунок 2 - Структура сети, использованная при кластеризации данных ОВ, где x_1, x_2, \dots, x_p - входной вектор данных ОВ; y_1, y_2, \dots, y_n - выходы нейронов сети

На вход второй сети подаются новые данные электрических нарушек в виде вектора $x = (x_1, x_2, \dots, x_{p-1})$ с $p-1$ координатой, для которых нужно получить прогнозные значения. При этом значение $p-1$ является длиной предыстории. Вторая нейронная сеть определяет принадлежность вектора x к какому-нибудь кластеру по единичному сигналу с выходов сети $y = (y_1, y_2, \dots, y_n)$: номер нейрона, который выдал значение, равное единице, является номером кластера, к которому принадлежит вектор x . Неиспользованные весовые коэффициенты нейронов первой сети $w_{pj}^{(1)}$ используются как прогнозные значения вектора x , попавшего в кластер j после подачи его на вход второй сети. Алгоритм описанной процедуры представлен на рис. 3.




Рисунок 3 - Блок-схема работы программы обучения нейронной сети и прогнозирования электрических нагрузок


Результаты работы программы получали в числовом виде и виде графиков сравнений реального значения электрической нагрузки и

прогнозного значения для каждого вектора $x = (x_1, x_2, \dots, x_{p-1})$ из предыстории данных. Графики представлены на рис.4,5.

Чтобы получить более точные результаты, проделывались вычисления с разными начальными установочными параметрами, а именно: увеличивалось количество эпох обучения самоорганизующейся нейронной сети при кластеризации данных ОВ, изменялось количество данных предыстории p . В итоге можно сказать следующее: точность результатов улучшается с увеличением количества эпох обучения и с изменением в сторону увеличения количества данных предыстории p до некоторого значения. На рис. 4 представлены результаты вычислений при $p=6$ точек предыстории, а на рис. 5 при $p=7$ при одинаковом числе эпох обучения нейронной сети, равное 2000. На рис. 6 показаны графики средней точности прогноза в зависимости от количества точек предыстории, где имеется минимум погрешности при $p=7$.



*Рисунок 4 -- Графики зависимостей реального и прогнозного значений активной получасовой нагрузки ОАО «Сумыхимпром» при прогнозировании с помощью ИНС при $p=6$ точек предыстории
(1—прогнозируемое значение, 2—реальное значение)*



*Рисунок 5 - Графики зависимостей реального и прогнозного значений активной получасовой нагрузки ОАО «Сумыхимпром» при прогнозировании с помощью ИНС при $p=7$ точек предыстории
(1—прогнозируемое значение, 2—реальное значение)*



Рисунок 6 - Средняя точность прогнозирования в зависимости от количества точек предыстории

Числовые результаты показывают, что точность вычислений между реальным и прогнозным значением составляет:

- для случая $p=6$ в наихудшем варианте - 4,12%, а в большинстве случаев лежит в пределах 0,5 – 2,93 %;
- для случая $p=7$ в наихудшем варианте – 3,36%, а в большинстве случаев лежит в пределах 0,5 – 2,8 %.

Эти опыты имеют немного лучшую точность вычислений, чем в случае прогнозирования с помощью нейронной сети МСП [1] по одним и тем же данным ОВ.

ВЫВОДЫ

Итак, в проделанной работе получены результаты прогнозирования с помощью самоорганизующейся нейронной сети, которые включали в себя кластеризацию данных ОВ. Эксперимент обладал следующими преимуществами по сравнению с МСП:

- нейронные сети Кохонена и самоорганизующиеся нейронные сети имеют значительно меньшее время обучения, чем МСП. Это позволяет увеличить количество эпох обучения, что положительно сказывается на конечном результате;
- применение самоорганизующихся нейронных сетей делает систему прогнозирования более гибкой в плане дополнения ее новыми идеями прогнозирования, например, дополнить ее нечеткими нейронными сетями [3];
- приведенная методика может быть использована для прогнозирования электронагрузок промышленных предприятий с непрерывным циклом производства;
- как уже было сказано, опыты имеют более точные результаты прогнозирования;
- недостатком данного метода является намного большая размерность самоорганизующейся нейронной сети по сравнению с МСП.

SUMMARY

THE ELECTRIC DEMAND PREDICTION OF JSC «SUMYKHPROM»

*I.V. Moshenskii, V.S. Nozdrenkov, A.U. Khatuntsev,
Sumy State University, Sumy*

In the given operation the model of prediction of half-hour electrical loads of firm of Open Society JSC “SumyKhimprom”, set up on usage of self-organizing neural webs with preliminary of the data of learning sampling is used. The program way on the computer had been carried out the prognosis of a power consumption, thus the

obtained outcomes represented in a graphics aspect. The exactitude of predicted values has made in most cases 0,5÷2,8 %, at worst 3,65 ÷ 5 %.

Key words: clusterization of the data, power consumption, electric demand.

СПИСОК ЛИТЕРАТУРЫ

1. Мошенский И.В., Ноздренков В.С., Хатунцев А.Ю. Прогнозирование электрических нагрузок ОАО «СУМЫХИМПРОМ» с помощью искусственных нейронных сетей // Вестник СумГУ. – 2009. - №2.
2. Васильев Д.А., Иващенко В.А., Резчиков А.Ф., Курышова Е.С. Выбор модели электрической нагрузки предприятий с непрерывным характером производства // Электротехнические комплексы и силовая электроника. Анализ, синтез и управление: Межвуз. науч. сб. - Саратов, 2001. - С. 36-39.
3. S. Kuusisto, M. Lehtokangas, J. Saarinen. Short Term Electric Load Forecasting Using a Neural Network with Fuzzy Hidden Neuron. Neural Comput & Applic (1997) Springer-Verlag London Limited.
4. Осовский С. Нейронные сети для обработки информации. - М.: Финансы и статистика, 2002. – 344 с.: ил.
5. Рутковская Д., Пилинский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечеткие системы.- М.: Горячая линия –Телеком, 2006. - 452 с.
6. Круглов В.В., Дли М.И., Голунов Л.Ю. Нечеткая логика и искусственные нейронные сети: учеб. пособ. для высшей школы (ВУЗы). - Изд-во «Физматлит», 2001 – 224 с.

Поступила в редакцию 2 марта 2010 г.