



Рисунок 1 – Длительности работы соединений

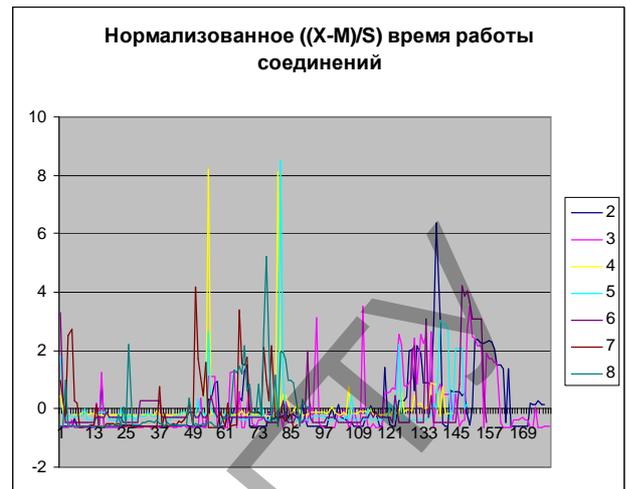


Рисунок 2 – Нормированные длительности

### Литература

1. S. T. Brugger. Data Mining Methods for Network Intrusion Detection. <http://www.bruggerink.com/~zow/Projects.html>
2. П. Кочурко. Нейросетевой детектор аномалий. Известия Белорусской инженерной академии, № 1(19)/2'2005 – с. 78-81.
3. Vladimir Golovko, Pavel Kochurko. *Intrusion Recognition Using Neural Networks*. In Proc. of IDAACS'2005, September, Sofia, Bulgaria, 2005

## НЕЛИНЕЙНАЯ МНОГОСЛОЙНАЯ НЕЙРОННАЯ СЕТЬ В ЗАДАЧЕ ПРОГНОЗИРОВАНИЯ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ.

Кочурко Ю.В., БГТУ, Брест

### Введение

Предсказание потребления электроэнергии является актуальной задачей и играет ключевую роль в технико-экономическом функционировании объектов энергосистемы. Так, владение предварительными данными о нагрузке, с экономической стороны, позволяет значительно усовершенствовать тарифную политику для объектов энергопотребления и, тем самым, снизить коммерческие потери, а с технической – обеспечивает экономный и безопасный режим работы энергосистемы.

Начиная с 1990 года, активно рассматриваются возможности применения нейронных сетей для решения задачи предсказания нагрузки путем прогнозирования. В настоящее время имеется множество научных публикации, в которых рассматривается возможность прогнозирования нагрузок с помощью нейрокомпьютеров [1-3]. Также рассматривается задача построения краткосрочных предсказаний нагрузок с повышенной точностью. Исследована релевантность нескольких известных моделей. Предложен новый метод прогнозирования, основанный на использовании трехслойных искусственных нейронных сетей с комбинированной структурой, объединяющих линейные и нелинейные схемы.

### 1. Описание нейронной сети для решения задачи прогнозирования

Для решения задачи прогнозирования потребления электроэнергии использовалась нелинейная многослойная нейронная сеть (многослойный персептрон), поскольку ее

способность к аппроксимации любой непрерывной нелинейной функции обеспечивает хороший результат прогнозирования. Обобщенная структура данной сети представлена на рисунке 1.

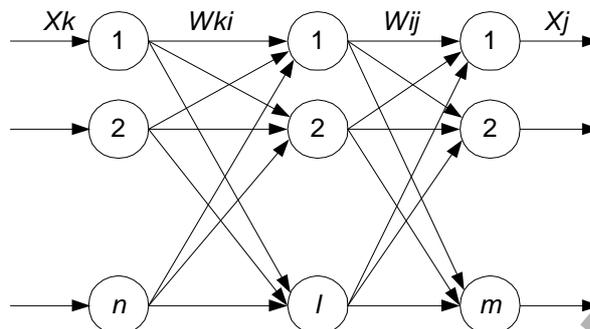


Рис. 1. Трехслойная нейронная сеть

В качестве исходных использовались реальные данные, полученные путем измерений на электростанциях за период времени с 1.01.2004 по 1.10.2004 года.

С помощью программного пакета Tisean 2.1 была исследована обучающая выборка и определены такие параметры временных рядов, как размерность пространства вложения и временная задержка, т.к. наличие этих показателей позволяет значительно снизить затраты времени на формирование модели прогнозирования. Исследовались входные данные за июль и сентябрь. Поскольку временная задержка временного ряда для этих периодов получилась различной, то целесообразно тестировать систему не на всей выборке, а именно на выборках за различный период.

Значение параметра пространства вложения говорит о том, что для хорошего прогноза необходимо, чтобы количество нейронных элементов входного и скрытого слоя было больше чем значение данного параметра.

Учитывая вышеупомянутые параметры, была выбрана архитектура нейронной сети, состоящая из трех слоев: входного, скрытого и выходного, а количество нейронных элементов в каждом слое составляло 6–5–2 соответственно. В качестве алгоритма обучения использовался алгоритм обратного распространения ошибки, а в качестве функции активации нейронных элементов – сигмоидная функция.

Для оценки качества прогнозирования воспользуемся показателем процентной погрешности MAPE (англ.: Mean Absolute Percentage Error), определяемой в виде

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|P_t - P'_t|}{P_t} * 100\%, \quad (1)$$

где  $P'$  – прямое спрогнозированное значение,  $P$  – фактическая нагрузка системы, а  $n$  число часов, на которые составляется прогноз.

Рассмотрим результаты 96-часового прогноза нагрузки и температуры, полученные с помощью разработанной сети. На вход сети последовательно подавались нагрузка и температура  $W(t)$ ,  $T(t)$ ,  $W(t-1)$ ,  $T(t-1)$ ,  $W(t-2)$ ,  $T(t-2)$ , ...,  $W(t-n)$ ,  $T(t-n)$ , а на выходе получали нагрузку и температуру в следующий момент времени  $W(t+1)$ ,  $T(t+1)$ .

Результаты прогноза нейронной сети с описанной выше архитектурой имели достаточно высокую погрешность, поэтому для ее снижения было увеличено количество нейронных элементов во входном и скрытом слоях, количество которых было подобрано экспериментально и составило: 22 – 22 – 2 нейронных элемента соответственно.

Сеть обучалась с использованием данных за июль и сентябрь 2004 года и показала достаточно хороший результат. Минимальная погрешность MAPE для этих периодов составила 3 – 4%.

На рисунке 2 представлен результат прогнозирования нагрузки и температуры за сентябрь.

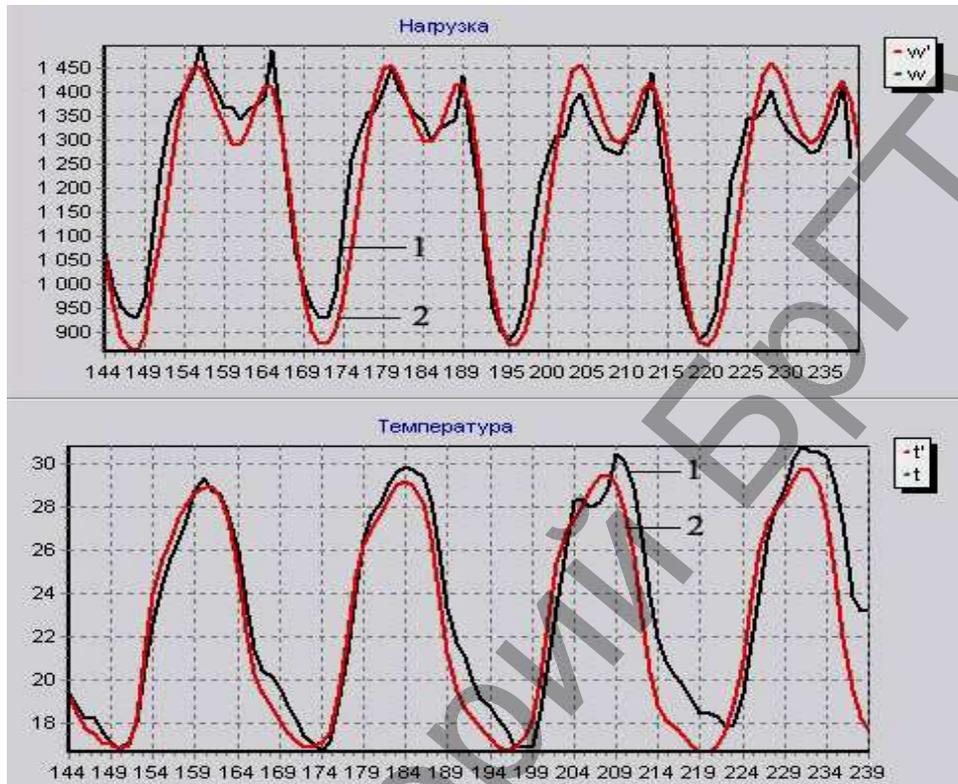


Рис. 2. Результаты прогноза (1 – эталонные значения, 2 – спрогнозированные значения)

### Заключение

В работе рассмотрена возможность применения многослойного персептрона для прогнозирования потребления электроэнергии. Как показали эксперименты, использование нейронной сети с такой архитектурой и алгоритма обратного распространения ошибки, как алгоритма обучения, позволяет эффективно прогнозировать нагрузку.

### Литература

1. Peng T.M., Hubele N.F., Karady G.G. Conceptual approach to the application neural networks for short-term load forecasting. / IEEE Int. Symp. Circuits and Syst., May 1-3, vol.4, 1990 p.2942-2945.
2. Bakirtzis A.G. Short term load Forecasting Using Fuzzy neural networks. / IEEE Power Eng. Review, vol.10, N3, Aug. 1995.
3. Станислав Осовский. Нейронные сети для обработки информации: пер. с пол. – М.: Финансы и статистика, 2004.
4. Головкин В.А. Нейрокомпьютеры и их применение: книга 4. Нейронные сети: обучение, организация и применение/ Под редакцией А.И. Галушкина.- М.: ИПРЖР, 2001.