

ТЕХНИЧЕСКИЕ НАУКИ

Кретов Дмитрий Алексеевич

канд. техн. наук, доцент

Рузанов Роман Витальевич

магистрант

ФГБОУ ВПО «Тольяттинский государственный университет»

г. Тольятти, Самарская область

**ОЦЕНКА ВОЗМОЖНОСТИ ПРИМЕНЕНИЯ ИСКУССТВЕННОЙ
НЕЙРОННОЙ СЕТИ ДЛЯ ПРОГНОЗИРОВАНИЯ
ЭЛЕКТРОПОТРЕБЛЕНИЯ ЭНЕРГОСБЫТОВОЙ КОМПАНИИ**

Аннотация: в данной статье рассматривается возможность применения искусственной нейронной сети для прогнозирования электропотребления энергосбытовой компании, возможные способы ее создания и обучения, а также возможные проблемы при ее использовании на практике.

Ключевые слова: оптовый рынок электроэнергии, искусственная нейронная сеть, база данных электропотребления, модель регрессионного анализа, архитектура сети, обучение Левенберга-Марквардта, регуляризация Байеса.

Прогнозирование объемов почасового потребления электроэнергии – серьезная проблема, с которой сталкиваются предприятия, работающие на оптовом рынке электроэнергии (мощности) (ОРЭ(М)). В условиях функционирования ОРЭ(М) для энергосбытовых компаний важно с максимальной точностью прогнозировать объемы потребления электроэнергии. В противном случае, компания несет дополнительные финансовые затраты, перекладываемые на конечного потребителя, теряя за счет этого свою привлекательность на рынке. В данной ситуации необходим прогноз «на сутки вперед» в разрезе часовых (получасовых) интервалов. Точность напрямую зависит от методик расчета, позволяющих минимизировать покупку/продажу энергии в рамках балансирующего рынка.

Необходимость точного прогнозирования значений электропотребления в последние годы стала особенно острой. Главным образом это вызвано реформированием электроэнергетической отрасли и созданием конкурентного рынка электроэнергии и мощности, в результате чего от точности прогнозирования зависит финансовое благополучие предприятий. В России процессы либерализации электроэнергетики несколько отстают от западных стран. Поэтому у нас дефицит современных методик прогнозирования, специализированных программных продуктов для работы на ОРЭМ, а также специалистов в данной области. Проблема осложняется еще и тем, что предприятия не готовы делиться собственными методиками прогнозирования, которые приносят им прибыль в условиях рыночной конкуренции.

Для решения задач прогнозирования электропотребления в электроэнергетике широко применяются различные программные комплексы, основанные на статистических и нейросетевых методах прогнозирования временных рядов. Существует большое количество программных комплексов, позволяющих составлять прогнозные модели на базе искусственных нейронных сетей (ИНС). Одним из таких программных продуктов является MATLAB.

В состав MATLAB входит модуль Neural Network Toolbox для создания и обучения ИНС. К преимуществам данного программного пакета можно отнести:

- широкий выбор различных видов архитектур ИНС, а также алгоритмов обучения, что позволяет создать наиболее адекватную нейронную сеть, исходя из поставленных практических задач;
- возможность соединения различных нейронных сетей между собой, что позволяет создавать ИНС, учитывающую влияние нескольких факторов на конечный выходной параметр;
- возможность генерации исходного кода искусственной нейронной сети;
- доступность программного комплекса для широкого круга пользователей.

Все вышеперечисленные достоинства и определили выбор именно этого программного комплекса для решения поставленной задачи.

Необходимым условием адекватной работы ИНС является наличие как можно более глубокой [4] ретроспективной базы данных о почасовом электропотреблении. Это необходимо для выявления закономерностей изменения графика электропотребления как в краткосрочной, так и в долгосрочной перспективе, поскольку форма графиков электропотребления в различных месяцах значительно отличается друг от друга. Также это объясняется еще и тем, что особенностью электропотребления энергосбытовой компании является значительная доля населения во всем объеме потребления (50% и более). В результате этого возрастает зависимость электропотребления от погодных условий (температуры, освещенности, наличия или отсутствия осадков) и продолжительности светового дня. Минимальным требованием к размерам ретроспективной базы является наличие данных об электропотреблении за 3 года. Однако наличие более обширной базы данных будет только способствовать увеличению точности прогноза. Также необходимо отметить, что описание погодных условий должно быть как можно более подробным за каждый час суток, информация о которых содержится в базе. При составлении модели ИНС была доступна база данных почасового электропотребления с 2010 по 2015 год включительно. Такой объем данных является достаточным для обучения и последующей адекватной работы сети на тестовых выборках данных.

Искусственная нейронная сеть представляет собой частный случай регрессионной модели. Данный термин используется в разделе «проверка статистических гипотез» в математической статистике. В общем случае, регрессионная модель является гипотезой, которая должна быть подвергнута статистической проверке, после чего она принимается или отвергается (обучение и тестирование ИНС).

Регрессионная модель $f(\omega, x)$ – это параметрическое семейство функций, задающее отображение

$$f: \times WX \rightarrow Y,$$

где $\omega \in W$ – пространство параметров, $x \in X$ – пространство свободных переменных, Y – пространство зависимых переменных. Данная модель фактически является моделью искусственного нейрона, в котором W – вес синаптической функции, на который умножается входное числовое значение.

Обученной можно считать модель, в которой зафиксированы ее параметры, то есть она задает отображение

$$f: X \rightarrow Y$$

для фиксированного значения ω .

Для обучения ИНС были выбраны два алгоритма, которые наиболее часто используются при прогнозировании временных рядов [3, с. 114].

Первым использовался алгоритм Левенберга-Марквардта [6, с. 89–102], который предназначен для оптимизации параметров регрессионных моделей. В качестве критерия оптимизации используется среднеквадратическая ошибка модели на обучающей выборке. Алгоритм заключается в последовательном приближении начальных значений параметров (весов синаптических функций) к искомому оптимуму.

Второй алгоритм обучения ИНС – алгоритм, основанный на регуляризации Байеса. В нашем случае, целью алгоритма обучения на основе регуляризации Байеса является прекращение изменения весов синаптических функций при достижении наименьшей среднеквадратической ошибки. Обучение по данному алгоритму занимает больше времени по сравнению с алгоритмом Левенберга-Марквардта, но при этом достигается минимальная среднеквадратическая ошибка. Также при прогнозировании временных рядов, ошибка на тестовой выборке становится меньше, чем на обучающей.

Эти факты обуславливают выбор данного метода для дальнейшего построения модели ИНС.

На начальном этапе исследования для прогнозирования электропотребления использовалась сеть [5, с. 56] прямого распространения данных и обратного распространения ошибки (Feed-forward backprop) [1, с. 15–19]. При такой архитектуре сети для ее обучения необходимо задать целевые значения временного ряда, которые являются эталоном при составлении прогноза и входные данные, которые подлежат обработке. После обучения, ИНС подбирает весовые коэффициенты таким образом, чтобы среднеквадратическое отклонение выходных значений от эталона было минимальным.

Недостатками такой сети является низкая точность и невозможность использования для повторного обучения весовых коэффициентов, полученных при первичном обучении сети.

Данного недостатка лишена сеть, представляющая собой модель нелинейной авторегрессии [2, с. 304] с внешними входами (NARX). При такой архитектуре сети необходимо задавать как входные значения функции, так и целевые. Данные на входе, проходя через сеть, обрабатываются в соответствии с весовыми коэффициентами, а затем снова попадают на вход сети, тем самым заменяя собой обратное распространение ошибки. Это дает возможность применения полученных после первичного обучения весовых коэффициентов при повторном обучении сети, что в свою очередь повышает точность ее работы.

При использовании всех вышеперечисленных способов построения ИНС удается достичь суммарной ошибки 2,5% за операционные сутки, что в свою очередь является достаточно хорошим результатом, учитывая, что современные системы прогнозирования способны работать с точностью порядка 6–7%.

Список литературы

1. Аксенов С.В. Организация и использование нейронных сетей (методы и технологии) / С.В. Аксенов, В.Б. Новосельцев. – Томск: НТЛ, 2006. – С. 15–19.

2. Бодянский Е.В. Искусственные нейронные сети: архитектуры, обучение, применение / Е.В. Бодянский, О.Г. Руденко. – Харьков: Телетех, 2004. С. 304.

3. Боровиков В.П. Нейронные сети. Statistica Neural Networks. Методология и технологии современного анализа данных. – 2 изд. – М.: Горячая линия – Телеком, 2008. – С. 114.

4. Галушка В.В. Формирование обучающей выборки при использовании искусственных нейронных сетей в задачах поиска ошибок баз данных / В.В. Галушка, В.А. Фатхи // Инженерный вестник Дона. – 2013. – №2 [Электронный ресурс]. – Режим доступа: www.ivdon.ru/ru/magazine/archive/n2y2013/1597/

5. Галушкин А.И. Нейронные сети: основы теории. – М.: Горячая Линия – Телеком, 2010. – С. 56.

6. Хайкин С. Нейронные сети: полный курс. – 2 изд. – М.: Вильямс, 2006. – С. 89–102.