

- многоэтапные модели.

Для решения задач управления энергетическим предприятием с применением моделей искусственного интеллекта также разрабатываются решающие компоненты информационно-управляющей системы. В программных модулях формализуются знания экспертов для задания лингвистических и нечетких переменных, а также правил вывода решений. Руководителю будет предоставлена возможность для существующей ситуации получить рекомендуемое решение.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Иванченко Л.А.* Основы теории и практики менеджмента. – Ростов-на-Дону: АО «Книга», 1996. – 207 с.
2. *Мексон М.Х., Альберт М., Хедоури Ф.* Основы менеджмента. – М.: Дело, 1992.
3. *Затылкин В.В., Финаев В.И.* Подбор кадров для современной проектной деятельности. Материалы Международной научной конференции «Проектирование новой реальности» (ПНР-2007). Ч. 1. – Таганрог.

УДК 681.5: 681.3(075.8)

И.С. Коберси, В.В. Шадрина

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ УПРАВЛЕНИЯ ЭНЕРГОПОТРЕБЛЕНИЕМ

Основой энергетики являются тепловые электростанции (ТЭС), на которых производится большая часть электрической и почти вся тепловая энергия. Однако современный этап развития энергетики характеризуется прогрессивно увеличивающейся долей атомных электростанций (АЭС), а также заметным увеличением роли гидроэлектростанций (ГЭС) в общем производстве электроэнергии.

Тенденции и особенности развития энергетики обуславливают большие масштабы автоматизации технологических процессов на электростанциях. Как составные части этой сложной и многофункциональной системы в нее должны входить подсистемы управления отдельных электростанций, энергосистем и энергообъединений [1]. Управление энергетическими предприятиями в большой степени зависит от объемов потребления электроэнергии.

Опыт создания и внедрения многих современных автоматических и автоматизированных систем управления показывает, что достижение высокой эффективности этих систем возможно только на основе рационально выбранного и правильно заложенного математического фундамента, адекватно отображающего процесс управления и способы решения задач.

Наиболее эффективным подходом для решения проблемы прогнозирования электропотребления является использование гибридных нейронных сетей (нейронечеткие системы).

Рассмотрим вопрос прогнозирования электропотребления с помощью нейронечеткой сети.

Известно, что решение вопроса прогнозирования электропотребления, в первую очередь, связано с определением наиболее выгодных условий покрытия графика нагрузки при краткосрочном планировании режима энергосистемы. Успешное решение этой проблемы во многом зависит от эффективности прогнози-

рования текущего и среднего значений нагрузки, соответствующих этим нагрузкам прогнозов расхода топлива, а также объемов покупки и продаж мощности по внешним (межсистемным) связям. При этом данные прогнозируемых нагрузки и расхода топлива, и дальнейший контроль за соблюдением заданных параметров представляют основную информацию для оптимального ведения режима на прогнозируемый период.

Обычно в электроэнергетике для прогнозирования параметров, определяющих техническое и экономическое состояние энергосистемы осуществляется на основе статистических данных о генерации и потреблении электрической энергии, с учетом энергии мощностей межсистемных связей. Получив эти данные за предыдущие периоды, прогнозные величины электропотребления и расхода топлива устанавливаются путем экстраполяции этих данных на будущее.

Для решения задачи прогнозирования необходимо построить такую математическую модель временного ряда, экстраполяция которой за правый предел интервала наблюдения позволяла бы с некоторой вероятностью предсказывать значения совокупности указанных параметров энергосистемы на сутки или несколько дней вперед. Процессы суточного изменения мощности нагрузки энергосистемы и обменов потоков мощности зависят от многих факторов, в том числе, в основном, от структуры включенной генерирующей мощности на каждые сутки, объемов договорной покупки и продажи электроэнергии от других энергосистем, суточной периодичности графика нагрузки, дня недели, температурного фактора и др. Случайный и неопределенный характер этих факторов не позволяет получать достаточно точные оценки прогнозных значений и провести анализ и учет влияния каждого из них при составлении планируемых суточных режимов.

Для построения модели прогнозирования электропотребления можно использовать нейронные сети, поскольку они позволяют устанавливать функциональные зависимости между различными параметрами, задаваемыми в виде совокупности входных и выходных величин модели, а также автоматически определять параметры этих зависимостей, а затем по новым значениям входа и выхода самонастраиваться.

Известны следующие виды нейронных сетей:

- многослойные персептроны (сети с прямой передачей сигнала);
- сети на радиальных базисных функциях;
- самоорганизующиеся карты Кохонена;
- вероятностные (байесовские) нейронные сети;
- обобщенно-регрессионные нейронные сети;
- сети главных компонент;
- сети для кластеризации;
- линейные сети.

Проведем анализ эффективности использования нейронных и нейро-нечетких сетей для прогнозирования энергопотребления.

Наиболее выгодным режимом работы энергосистемы, с экономической точки зрения, называется такой, при котором потребители получают необходимую энергию допустимого качества при наименьших народнохозяйственных затратах на ее производство, передачу и распределение.

Для прогнозирования значений мощностей нагрузки и межсистемных обменов и расхода топлива в энергосистеме на каждые сутки вперед может быть использована модель, реализованная в виде многослойной нейронной сети. Теоре-

тически число слоев и число нейронов в каждом слое может быть произвольным. Однако, как показывает опыт использования нейронных сетей для задач краткосрочного прогнозирования нагрузки [3], достаточна модель двух-, трехслойной нейронной сети.

В общем случае схема модели краткосрочного прогнозирования мощностей нагрузки энергосистемы и их обменов между энергосистемами, а также суточного расхода топлива представлена на рис.1.



Рис.1. Общая схема модели для прогнозирования мощности нагрузки и межсистемного обмена и расхода топлива в энергосистеме

Для построения модели прогнозирования энергопотребления необходимо осуществить выбор структуры нейронной сети, то есть, определить число входных, выходных и промежуточных слоев и число нейронов в каждом из них.

Для модели нейронной сети, предназначенной для прогноза суточного электропотребления, входами являются:

- $R_n(k-n)$ – нагрузки в предыдущие периоды (дни);
- T – среднесуточная температура;
- D – тип дня недели (рис.2).




Рис.2. Структура нейронной сети для прогнозирования нагрузки

Количество параметров $P_{n(k-n)}$ определяется объемом обучающей выборки [2].

Таким образом, количество нейронов в первом слое будет зависеть от объема обучающей выборки (параметр $P_{n(k-n)}$) и входным параметрам системы (параметры D и T). Число нейронов в промежуточных слоях устанавливается опытным путем на этапе предварительного обучения. Обучение искусственной нейронной сети является автоматическим процессом определения весовых характеристик связей между нейронами ($f(S)$):

$$f(s) = \frac{1}{1 - e^{-as}}$$

где S – текущее состояние нейрона.

Для обучения искусственной нейронной сети используются архивные данные, фрагмент обучающей выборки представлен в табл. 1.

Таблица 1

Архивные данные, фрагмент обучающей выборки

Параметры	Суммарные суточные значения								
Дата	01.12	02	03	04	05	06	07	08	09
Суммарная генерация Бакы-1 ТЭС,(МВт)	16370	14890	17560	18870	18675	19080	19280	19200	19100
Параметры	1. Суммарные суточные значения								
Суммарный переток, (МВт)	1195	1315	1420	1530	2580	2306	2212	2195	3204
Расход условного топлива на Бакы-1ТЭС, (т)	171	159	172	177	178	179	240	354	375

табл. 1,а

Параметры	Суммарные суточные значения								
дата	01.01	02	03	04	05	06	07	08	09
Суммарная генерация Бакы-1 ТЭС,(МВт)	36180	35950	34485	34215	34015	34410	33590	34203	30600
Суммарный переток, (МВт)	3745	3892	3615	3247	3015	2971	2610	2850	3520
Расход условного топлива на Бакы-1 ТЭС, (т)	328	341	396	378	206	198	199	196	202

Как видно из табл.1, для обучения искусственной нейронной сети необходимо учитывать большое количество параметров и объем информации. Это приводит к усложнению построения модели.

Устранить данный недостаток можно за счет построения нейронечетких систем, которые относятся к классу гибридных систем, в основе которых лежат нечеткая логика, нейронные сети и генетический алгоритм.

Рассмотрим класс адаптивных сетей функционально эквивалентных системам нечетких рассуждений. Подобная архитектура носит название ANFIS (Adaptive Neuro-Fuzzy Inference System – адаптивная нейронечеткая система заключений) [1,3].

Нейронечеткая система имеет пять слоев и описывается следующим способом (рис. 3).

1. Выходы узлов первого слоя представляют собой значения функций принадлежности при конкретных значениях входных параметров:

$$O_i^1 = \mu A_i(x),$$

где x - входной сигнал узла i , A_i – лингвистическая переменная, связанная с данной узловой функцией, $\mu A_i(x)$ – функция принадлежности переменной A_i , определяющей степень, с которой данный x удовлетворяет A_i .

Немаловажной задачей является определение входов нейронов первого слоя. Основными независимыми переменными являются:

- Ретроспективные данные фактического потребления.
- Тип дня (день недели, праздник).
- Наличие теплоснабжения и наличие горячего водоснабжения.

Анализ источников литературы показал, что наилучший временной диапазон выборки для обучения – это две недели, входные переменные все перечисленные выше за сутки и неделю назад от прогнозируемых. Отметим, что увеличение количества входных переменных больше четырех, приводит к увеличению во много раз времени обучения.

На основании вышесказанного, определим параметры, значения которых будут подаваться на входы нейронов первого слоя:

- x_1 (нейроны P_1^{-1} , P_2^{-1} , P_3^{-1}) – значение энергопотребления за сутки до прогнозируемых;
- x_2 (нейроны P_1^{-7} , P_2^{-7} , P_3^{-7}) – значение энергопотребления за неделю до прогнозируемых;
- x_3 (нейроны T_1 , T_2 , T_3) – значение среднесуточной температуры;
- x_4 (нейроны D_1 , D_2) – день недели.

2. Выходами нейронов второго слоя являются степени истинности предпосылок каждого правила базы знаний системы.

$$w_i = \mu P_i(x_1) \times \mu P_i(x_2) \times \mu T_i(x_3) \times \mu D_j(x_4); i=1,2,3; j=1,2.$$

3. Нейроны третьего слоя вычисляют величины \bar{W}_i , которые определяют отношение веса i -го правила к сумме весов всех правил:

$$\bar{W}_i = \frac{W_i}{W_1 + W_2 + \dots + W_{72}}.$$

4. Нейроны четвертого слоя выполняют операции вычисления значений для функций принадлежности выходного параметра. Для модели типа Сугено:

$$z_i = \bar{W}_i f_i,$$

где f_i – функции принадлежности выходных переменных.

5. Единственный узел данного слоя является фиксированным узлом, в котором вычисляется полное выходное значение адаптивной сети как сумма всех входных сигналов

$$z = \bar{w}_1 z_1 + \bar{w}_2 z_2 + \dots + \bar{w}_{72} z_{72}.$$

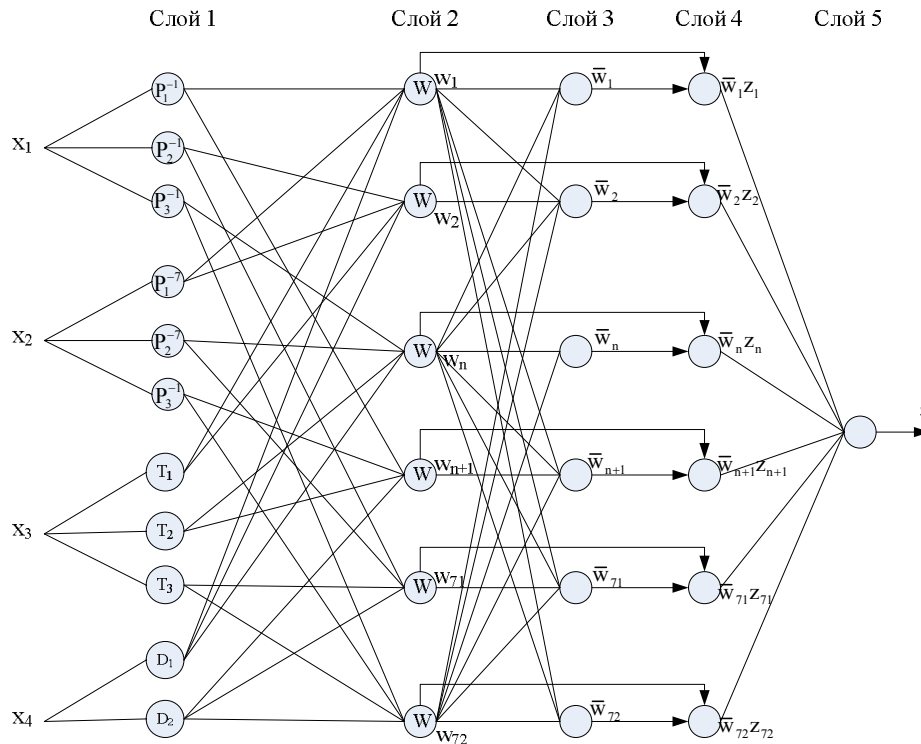


Рис. 3. Архитектура ANFIS

В результате проведенного исследования предложен метод прогнозирования электропотребления, основанный на построении моделей в виде нейронечетких сетей, обучаемых на выборках реальных данных по электропотреблению. Особенностью предложенной модели является то, что она позволяет делать краткосрочные прогнозы, обеспечивая требуемую точность при малом объеме входной информации.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Глебов А.А., Петрова И.Ю. Прогнозирование электропотребления с помощью нейронечеткой системы ANFIS. 2005.
2. Петрова И.Ю., Глебов А.А. Прогнозирование электропотребления с помощью нейронечеткой системы ANFIS. Алгоритм отбора данных входных переменных.
3. Круглов В.В. Нечеткая логика и искусственные нейронные сети.