

ПРОГНОЗИРОВАНИЕ НАГРУЗКИ ЭЭС НА БАЗЕ НОВЫХ ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ¹

Шумилова Г.П., Готман Н.Э., Старцева Т.Б.

Институт социально-экономических и энергетических проблем Севера
Коми научного центра УрО РАН

Прогнозирование режимов электропотребления (электрической нагрузки) необходимо для решения практически всего спектра задач текущего планирования и оперативного управления режимами функционирования ЭЭС². Прогнозирование нагрузки проводится в следующих временных диапазонах иерархии управления ЭЭС [3]:

- оперативном (в пределах текущих суток);
- краткосрочном (сутки-неделя-месяц);
- долгосрочном (месяц-квартал-год).

Первые публикации по методам прогнозирования электрической нагрузки ЭЭС появились на рубеже десятых-двадцатых годов прошлого века [1]. Казалось бы за 80 с лишним лет эта проблема должна быть решена. Тем не менее поток публикаций не убывает, а увеличивается. Основной причиной этого являются все более высокие требования к показателям качества прогнозных расчетов (точности, достоверности, информативности, автоматизируемости, быстродействию и т.п.) и непрерывное развитие самих ЭЭС.

До настоящего времени разработано большое число методов и моделей прогнозирования нагрузки ЭЭС. Их обзор приведен в [1, 9]. Традиционные статистические модели могут быть условно разделены на регрессионные модели и модели на основе временных рядов. Подробное обсуждение этих моделей приведено в [9].

С развитием теории искусственного интеллекта в последнее десятилетие было предложено решение задачи прогнозирования нагрузки с использованием моделей на основе экспертных систем и искусственных нейронных сетей [7, 8, 11, 12, 13]. Предпочтение их традиционным моделям обусловлено тем, что не требуется построения модели объекта, не теряется работоспособность при неполной входной информации. Они обладают устойчивостью к помехам, имеют высокое быстродействие. В большинстве публикаций по прогнозированию нагрузки используется конфигурация ИНС прямого распространения (персептроны) с обучением по методу обратного распространения ошибки [12].

¹ В книге: *Новые информационные технологии в задачах оперативного управления электроэнергетическими системами* / Н.А.Манов, Ю.Я.Чукреев, М.И.Успенский и др. Екатеринбург: УрО РАН, 2002. С.127-156.

² См. на данном сайте статью Ю.Я.Чукреева «Прототип экспертной системы советчика диспетчера региональной ЭЭС»

Здесь необходимо заметить, что при выборе структуры ИНС важно учитывать ее размерность, т.е. количество скрытых слоев и количество нейронов в этих слоях. При недостаточном размере сети для решения поставленной задачи ИНС будет плохо обучаться и неправильно работать, а при размере сети, который превышает сложность решаемой задачи, процесс обучения ИНС будет очень длительным, или сеть вообще может быть непригодна для решения данной задачи. Этот вопрос в каждом конкретном случае решается экспериментальным путем, о чем будет сказано в разделах данной главы.

Внутрисуточное прогнозирование нагрузки ЭЭС с применением искусственных нейронных сетей. Внутрисуточное или оперативное в течение текущих суток прогнозирование нагрузки (в дальнейшем просто прогнозирование нагрузки) относится к такому классу задач, где зависимость между входными и выходными переменными достаточно многогранная и сложная. Поэтому нахождение закономерностей в больших информационных объемах требует нетривиальных алгоритмов и так или иначе, связано со значительными затратами времени.

В данном разделе рассматривается задача прогнозирования нагрузки с упреждением от 10–15 минут до 4 часов (время набора мощности турбогенератора тепловой электростанции из холодного состояния). Необходимость такого прогноза возникла в связи с введением двухставочных тарифов при взаиморасчетах между субъектами Федерального оптового рынка электроэнергии и мощности (ФОРЭМ), когда даже при однократном превышении региональными АО-энерго заявленной по договорам с субъектами рынка и в частности с РАО «ЭЭС России» мощности, на них накладываются штрафные санкции. Такой временной уровень прогнозирования нагрузки позволяет диспетчерскому персоналу осуществить оперативные изменения параметров режима с учетом инерционности основного оборудования ЭЭС. Для региональных ЭЭС, не имеющих в своем составе маневренных генерирующих агрегатов (гидро- или газотурбинных), к которым относится и Коми ЭЭС, внутрисуточное, оперативное прогнозирование нагрузки должно осуществляться с указанным выше упреждением.

Конфигурация нейронной сети и алгоритм ее обучения. Конфигурация ИНС для прогнозирования нагрузки по энергоузлам Коми ЭЭС, полученная в результате проведенных исследований, приведена на рис. 3¹. Нейронная сеть представляет собой трехслойный персептрон, во входном слое которого находится 24 нейрона, в скрытом – 5, в выходном – 1. Кроме того, на входы нейронов скрытого и выходного слоев

¹ См. на данном сайте статью Н.А.Манова и др. «Информационные технологии и совершенствование оперативного управления региональными ЭЭС»

подано смещение (параметр правдоподобия). Входными переменными являются значения нагрузки P_1, \dots, P_{24} , полученные на основе решения задачи оценивания состояния системы по данным телеметрических измерений. Первоначальное обучение ИНС (на-

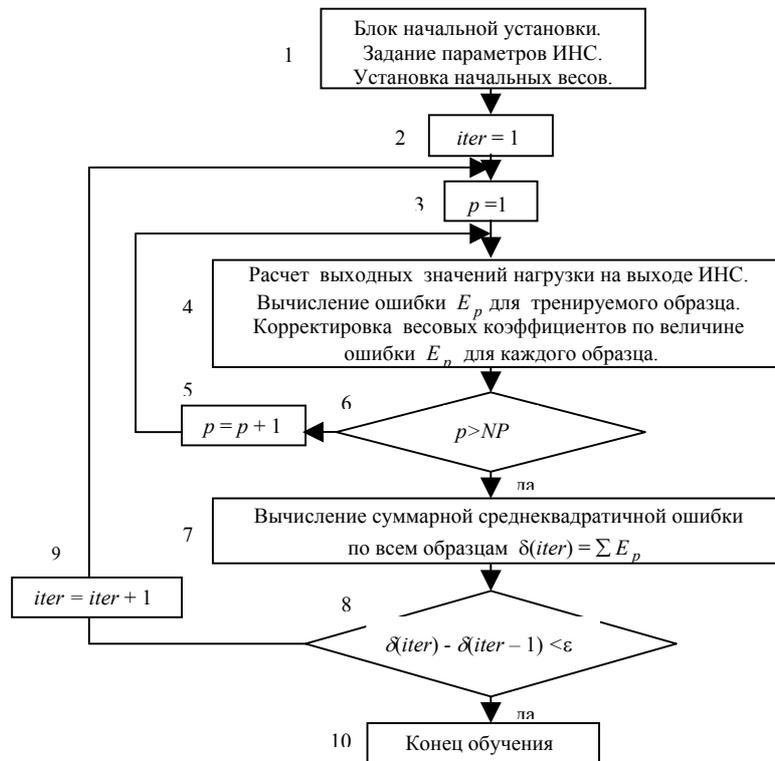


Рис.1. Алгоритм обучения нейронной сети

хождение значений весовых коэффициентов) проводится в течение суток.

Алгоритм обучения, по методу обратного распространения ошибки представлен на рис.1. После пуска и установки начальных условий в блоках 1-3 (начальных значений весовых коэффициентов, количества обучающих образцов NP , параметров ИНС η и α , заданной малой величины ε , определяющей точность прогноза) считываются значения нагрузки P_1, \dots, P_{24} и нормализуются (т.е. преобразуются в относительные величины O_i , находящиеся в пределах $0 \leq O_i \leq 1$, где $1 \leq i \leq 24$).

В блоке 4 рассчитываются значения сигналов на входах и выходах нейронов скрытого слоя j и выходного слоя k по следующим формулам:

– входы нейронов j -го слоя $net_j = \sum_{i=1}^{24} W_{ji} \cdot O_i, \quad j=1, 2, \dots, 5;$

– выходы нейронов j -го слоя $O_j = 1/(1 + e^{-(net_j + \Theta_j)});$

– вход нейрона k -го слоя $net_k = \sum_{j=1}^5 W_{kj} \cdot O_j, \quad k=1;$

– выход нейрона k -го слоя ($P_{\text{прог}}$) $O_k = 1/(1 + e^{-(net_k + \Theta_k)}).$

Здесь W_{ji} и W_{kj} - весовые коэффициенты соответственно между нейронами j -го и i -го слоя и k -го и j -го слоя, Θ_j - смещение. Затем вычисляется ошибка $E_p = \frac{1}{2} (d_k - O_k)^2$ для каждого тренируемого образца. Здесь d_k - желаемое значение нагрузки на выходе, а O_k - расчетное значение. Также рассчитываются градиентные спуски в пространстве весов W_{ji} и W_{kj} и на их основании производится корректировка весов по следующим формулам:

$$\Delta W_{kj}(p) = \eta \delta_k O_j + \alpha \Delta W_{kj}(p-1);$$

$$\Delta W_{ji}(p) = \eta \delta_j O_i + \alpha \Delta W_{ji}(p-1);$$

$$\delta_k = (d_k - O_k) O_k (1 - O_k);$$

$$\delta_j = O_j (1 - O_j) \sum_k \delta_k W_{kj};$$

$$W_{ji}^{\text{нов}} = W_{ji}^{\text{стар}} + \Delta W_{ji}(p);$$

$$W_{kj}^{\text{нов}} = W_{kj}^{\text{стар}} + \Delta W_{kj}(p).$$

В этих соотношениях: p – номер образца; η – коэффициент скорости обучения; α – момент, определяющий ускорение обучения. В данном алгоритме $\eta = 0,3$; $\alpha = 0,7$; $\varepsilon = 10^{-6}$.

Блок 6 (рис. 1) определяет, все ли образцы использованы. Если все, то вычисляется суммарная ошибка по всем образцам в блоке 7 и проверяется условие в блоке 8. В случае выполнения условия процесс обучения заканчивается, в противном случае процесс повторяется.

Определение входных переменных нейронной сети. Для решения задачи прогнозирования нагрузки воспользуемся моделью, описывающей изменения во времени фактических значений нагрузки, которая в общем виде представляется нелинейной функцией [1]:

$$P_t = f(P_{t-n}, T_{t-n}, \varepsilon_t), \quad (1)$$

где P_t – фактическая нагрузка системы в момент времени t ; t – текущее время; P_{t-n} – предшествующие наблюдения нагрузки; T_{t-n} – предшествующие наблюдения внешних факторов (в частности, температуры), влияющих на нагрузку; n – индекс ретроспективы данных; ε_t – случайная составляющая, представляющая ненаблюдаемые эффекты, влияющие на нагрузку.

Согласно этой функции, для определения входных переменных ИНС необходимо определиться с ретроспективным периодом изменения нагрузки и учитываемыми внешними факторами. Рассматривались три варианта изменения ретроспективного периода о режимах поведения нагрузки:

1. Использовались изменения величины нагрузки только текущих суток (значения нагрузки в течение часа, предшествующему текущему моменту времени);

2. Использовались значения нагрузки текущих (как в п.1) и предыдущих суток (значения нагрузки в течение часа, предшествующему времени прогноза);

3. Использовались значения нагрузки текущих суток (как в п.1) и двух предыдущих (значения нагрузки в течение часа, предшествующему времени прогноза);

В качестве входных переменных $P_1 \dots P_n$ (n в зависимости от варианта равно 12, 24 или 36) использовались усредненные за 5 мин. значения нагрузки. Пятиминутное усреднение данных явилось наиболее оптимальным вариантом из исследованных пяти- и десятиминутного усреднения по количеству входных переменных и быстродействию.

В табл.1 приведены результаты влияния длительности периода ретроспективных данных на точность прогнозирования нагрузки в течение часа для различного времени суток. В качестве примера использован график нагрузки за 14 ноября 1997 г. В табл.1 представлены результаты для плохого (с 18 до 19 часов), хорошего (с 15 до 16 часов) и среднего (с 8 до 9 часов) вариантов прогноза. Многочисленные подобные исследования и анализ таблицы показывают, что из рассмотренных трех вариантов использования ретроспективной информации предпочтительным является второй, т.е. вариант с использованием ретроспективных данных текущих и предыдущих суток. Следует заметить, что этот вывод получен для рабочих дней недели.

Таблица 1

Влияние ретроспективных данных о нагрузке на точность прогноза для рабочих дней

Время Прогноза	Вариант	Погрешность прогноза (%) при упреждении			
		15 мин.	30 мин.	45 мин.	1 час
с 8 до 9 ч.	1	0,132	0,949	1,708	2,074
	2	0,216	0,878	1,245	1,689
	3	0,226	0,873	1,720	2,169
с 18 до 19 ч.	1	1,889	1,245	2,148	2,337
	2	1,875	1,223	2,124	2,218
	3	1,276	0,896	1,796	2,907
с 15 до 16 ч.	1	0,168	0,039	0,155	0,476
	2	0,250	0,006	0,081	0,210
	3	0,155	0,326	1,246	1,049

При прогнозировании нагрузки в выходные и праздничные дни имеются некоторые особенности использования ретроспективных данных. Для выходных дней обучение ИНС проводится на данных двух последних выходных, а расчет прогноза нагрузки производится на данных текущего и последнего предыдущего выходного дня. Для примера, если необходимо получить прогноз для субботнего дня, то используются данные о нагрузке этой субботы и последнего воскресенья. Для праздничных дней обуче-

ние ИНС проводится на основе данных о нагрузке последних двух выходных, а прогноз делается по данным этого праздничного дня и последнего выходного.

Для выходных дней погрешность прогноза меньше при учете данных только текущего дня в случае, если нагрузка изменяется плавно. А при резких изменениях большую точность дает учет предыдущего дня. Результаты исследования для выходных дней (в качестве примера для 16 ноября 1997 г.) приведены в табл. 2.

Таблица 2

Влияние ретроспективных данных о нагрузке на точность прогноза для выходных дней

Время прогноза	Вариант	Погрешность прогноза (%) при упреждении			
		15 мин.	30 мин.	45 мин.	1 час.
С 18 до 19 ч.	1	0,256	0,122	0,028	0,153
	2	0,681	0,296	0,021	0,237
С 15 до 16 ч.	1	0,484	0,903	1,315	3,889
	2	0,886	0,599	0,888	2,926

Внешние факторы. К внешним факторам, влияющим на нагрузку относятся, главным образом, метеорологические: температура, облачность, относительная влажность воздуха. В условиях Республики Коми достаточно учитывать только влияние температуры, причем только при долгосрочных прогнозах нагрузки (на сутки вперед и более).

Учет случайной составляющей. Для учета ε_i в модель краткосрочного прогноза нагрузки введен контур адаптации (рис.2), назначение которого заключается в проведении коррекции весовых коэффициентов W_{ji} и W_{kj} по ошибке прогноза постоянно до текущего момента времени.

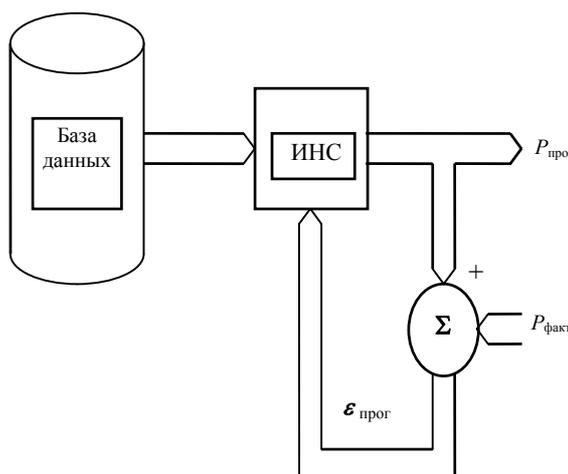


Рис. 2. Адаптивная модель внутрисуточного прогнозирования нагрузки на основе искусственной нейронной сети

Введение адаптивной обратной связи позволило снизить среднеквадратичную погрешность прогноза примерно на 1,5% (с 2,7 до 1,2%). Правда, в случаях резких изменений графиков нагрузки введение этого контура не позволяет довести погрешность до

желаемой. Постоянная коррекция весовых коэффициентов делает прогноз независимым от сезонных изменений нагрузки.

Нормирование данных. Важным фактором, кроме вышперечисленных, влияющим на точность прогнозирования нагрузки, является нормирование входных данных. Неправильный подход к нормированию данных может перечеркнуть все другие меры, принимаемые для увеличения точности прогноза.

Нормирование данных необходимо для того, чтобы каждое значение, подаваемое на вход ИНС, находилось в интервале $[0, 1]$. Расчеты показали, что погрешность прогноза существенно зависит от способа нормирования входных данных. Этому вопросу уделяется внимание во многих работах, например [2, 4], посвященных как прогнозированию нагрузки, так и использованию ИНС в других задачах, где данные по модулю превышают единицу.

Простейшее решение вопроса – это нормирование данных по формуле $P_i^H = P_i/P_{\max}$ (P_i – значение нагрузки, подаваемое на i -ый входной нейрон; P_{\max} – максимальное значение нагрузки в рассматриваемой выборке; P_i^H – нормированное значение). В этом случае для нашей задачи все данные после нормирования находятся, как правило, в интервале $[0,85; 1]$.

Для того чтобы сдвинуть нормированные данные от единицы, можно применить формулу $P_i^H = P_i / (P_{\max} + K)$ (K может быть постоянным или переменным значением для каждой выборки). Например, при определении ретроспективы данных о нагрузке и учете внешних факторов, влияющих на нагрузку, расчеты проводились при $K = 400$ (при этом использовались нагрузки по всей Коми ЭЭС, которые в настоящее время изменяются от 850 до 1200 *МВт*).

Следующая формула нормирования позволяет растянуть данные, подаваемые на вход ИНС, от 0 до 1:

$$P_i^H = \frac{P_i - P_{\min}}{P_{\max} - P_{\min}}, \quad (2)$$

где P_{\min} – минимальное значение нагрузки в каждой выборке.

В работе [4] рассматривается краткосрочное прогнозирование нагрузки при горизонте планирования $t_{\text{прог}} = 7,5$ мин. с использованием формулы нормирования:

$$P_i^H = \frac{P_i - (1 - H)P_0}{2HP_0}, \quad (3)$$

где $H = 0,35$; P_0 - нагрузка в начале периода времени, соответствующего рассматриваемой выборке. Формула (3) получена из (2) при условиях: $P_{\min} = (1 - H)P_0$, $P_{\max} = (1 + H)P_0$.

Другая, довольно часто встречающаяся, формула нормирования [2]:

$$P_i^H = \frac{P_i - M(P_i)}{\sigma(P_i)}. \text{ Здесь } M(P_i) - \text{выборочная оценка математического ожидания } P_i \text{ (сред-$$

нее значение для i -ой компоненты); $\sigma(P_i)$ - оценка среднего квадратичного отклонения. Эта формула достаточно проста, но тем не менее она требует больших затрат, связанных со сбором и обработкой данных для определения среднего значения нагрузки в определенные моменты времени.

С целью определения оптимального нормирования данных для краткосрочного прогнозирования нагрузки были исследованы варианты, использующие различные

формулы нормирования: $P_i^H = \frac{P_i}{P_{\max} + 400}$ (вариант 1); $P_i^H = \frac{P_i}{P_{\max} + 25}$ (вариант 2); $P_i^H =$

$P_i^H = \frac{P_i}{P_{\max} + 0,45P_{\min}}$ (вариант 3); формула (3) (вариант 4) и формула (2) (вариант 5).

Причем минимальное значение P_{\min} и максимальное значение P_{\max} определялись для каждой выборки данных, состоящей, как указано выше, из 12 значений нагрузки текущего дня и 12 значений нагрузки предыдущего дня. Для 3, 4 и 5-го вариантов нормирования данные перед расчетом сглаживались. Кроме того, для пятого варианта особым образом учитывались рост и снижение нагрузки в предыдущий день.

В качестве примера проводились расчеты для 12 ноября 1997 года с учетом нагрузки 11 ноября для наиболее характерных периодов времени, когда происходит рост нагрузки (с 6 до 8 часов), ее снижение (с 18 до 22 часов) и когда нагрузка мало меняется (с 11 до 13 часов и с 15 до 17 часов). Среднеквадратичные ошибки расчета прогноза на час и два часа вперед приведены в табл. 3.

Из проведенных расчетов невозможно однозначно отдать предпочтение какой-либо одной формуле нормирования данных. Если рассматривать максимальный период прогноза (2 часа), то для первого промежутка времени (с 6 до 8 часов) и третьего (с 15 до 17 часов) лучшими оказались два первых варианта нормирования данных. При прогнозе с 11 до 13 часов и с 18 до 20 часов неплохие результаты расчета получены по всем пяти вариантам, но среди них пятый наиболее предпочтителен. Проведенный анализ показал, что для получения минимальных погрешностей при прогнозировании нагрузки необходимо применять не один способ нормирования данных, а несколько с учетом времени суток, дня недели и сезона года.

**Сравнение среднеквадратичных ошибок прогноза нагрузки на 12.11.97
при использовании различных формул нормирования данных**

Время прогноза	Среднеквадратичная ошибка при нормировании (%), по вариантам				
	1	2	3	4	5
С 6 до 7 ч	2,631	0,630	3,640	2,225	2,757
С 6 до 8 ч	2,254	0,746	5,550	3,740	3,424
С 11 до 12 ч	0,854	1,030	0,623	0,490	0,450
С 11 до 13 ч	0,857	1,192	0,813	0,698	0,637
С 15 до 16 ч	0,858	0,859	2,321	3,551	0,576
С 15 до 17 ч	0,684	1,001	3,350	7,003	1,077
С 18 до 19 ч	0,879	0,633	0,785	0,737	0,596
С 18 до 20 ч	1,302	0,907	1,244	1,048	0,924

Большая погрешность при утреннем росте нагрузки (с 6 часов) связана с локальными пиками и провалами нагрузки в этот период времени. Их можно объяснить как сбоем устройств телемеханики, так и фактическими ростом и падением нагрузки. Для того, чтобы уменьшить влияние скачков нагрузки, нужно применить сглаживающие фильтры. При нормировании по трем последним вариантам использовалось сглаживание по формуле $P_i = (P_{i-1} + P_i + P_{i+1}) / 3$. Для нагрузок за 11 и 12 ноября 1997 г. это сглаживание оказалось приемлемым для всего расчетного времени, кроме утренних часов. Поэтому для этого промежутка времени необходимо применить более сильный фильтр.

При использовании трех первых способов нормирования погрешность была приемлемой для прогноза нагрузки от 5 минут до 1 часа. Две другие формулы нормирования позволяют получать прогноз нагрузки на более длительные периоды времени, но при условии, что изменение нагрузки односторонне, т.е. либо она только растет, либо только убывает, либо мало меняется в этот период времени и предшествующий час.

На рис.3 для сравнения приведены графики фактической и спрогнозированной нагрузки с 4-х часовым упреждением (с 18 до 22 часов) при использовании четвертого и пятого вариантов нормирования входных данных. График прогноза для четвертого варианта (2) имеет много локальных пиков и провалов из-за большей чувствительности к данным. График прогноза для пятого варианта (3) более сглаженный и особенно для первых полутора часов прогнозируемого периода близок к сглаживающей кривой графика фактической нагрузки (1). Поэтому именно ему и можно отдать предпочтение для возможного длительного прогноза при падении нагрузки. Один из примеров использования при прогнозе в течение суток нескольких способов нормирования приведен ниже. Рассматривая график нагрузки за предыдущие сутки можно выделить периоды:

роста, падения и относительно небольшого изменения нагрузки. При прогнозе для каждого временного периода предлагается использовать следующие, рассмотренные выше, варианты нормирования данных: при росте нагрузки – первый, при падении – пятый,

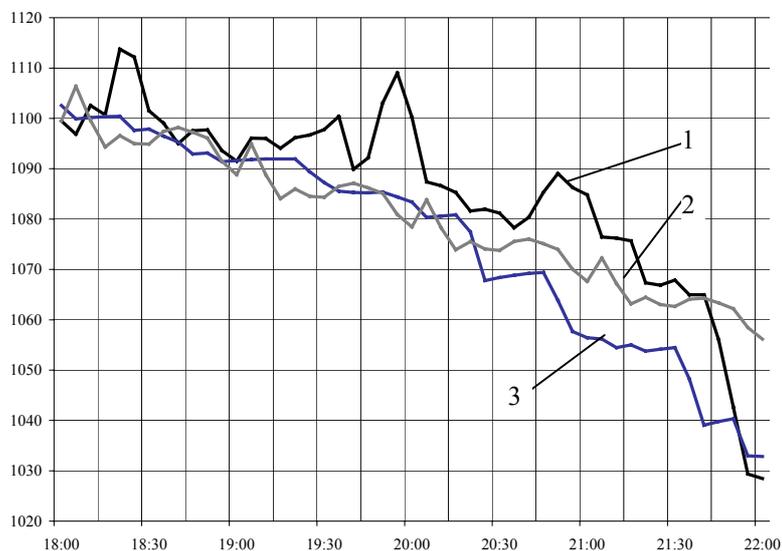


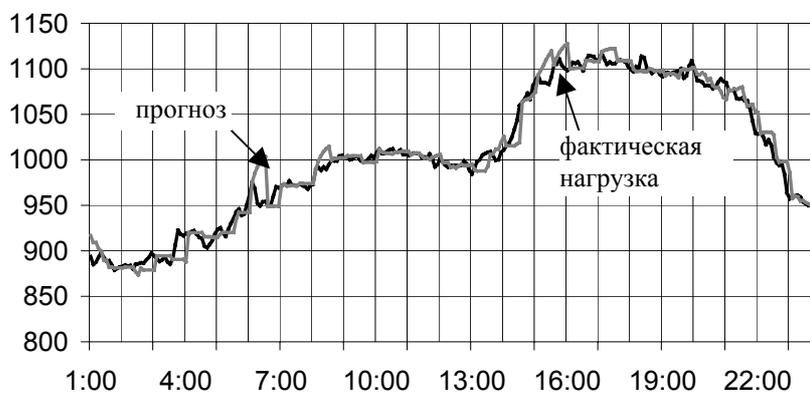
Рис. 3. Графики фактической нагрузки (1) и прогноза для периода с 18 до 22 часов с использованием четвертого (2) и пятого (3) вариантов нормирования данных

при небольшом изменении, когда график вогнутый, – второй, если же график выпуклый – третий.

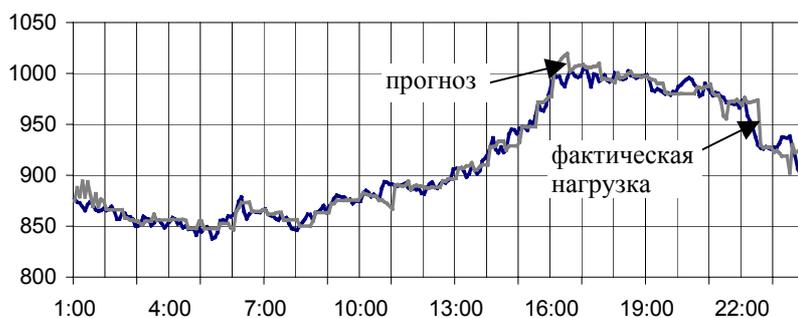
Для рассматриваемого примера предыдущий день - это 11 ноября. Для него к первому периоду можно отнести интервалы с 6 до 10 часов и с 14 до 17 часов; ко второму периоду - с 11 до 13 часов и с 18 до 24 часов; к третьему - с 0 до 6 часов, с 10 до 11 часов и с 17 до 18 часов. Сравнение фактической нагрузки и прогноза за 12 ноября по предложенной методике дано на рис.4, а. Каждый временной период поделен на полу-часовые отрезки, для которых проводился расчет прогноза нагрузки. При этом максимальная относительная погрешность составила 5,1% при прогнозе с 6 часов до 6 часов 30 мин., а среднеквадратичная ошибка для всех расчетов за сутки равна 1,25%.

Восстановление входных данных. В процессе работы модели прогнозирования нагрузки могут встретиться случаи, когда на вход ИНС поступают плохие данные (неправильно замеренные или вообще отсутствующие) по причине сбоя системы телеметрии, что приводит к большим погрешностям прогноза. Поэтому был разработан способ восстановления входных данных с использованием отдельной ИНС. Были исследованы два подхода: статический и динамический. Предпочтение было отдано динамическому, когда нагрузка восстанавливается последовательно, используя предшествующее по вре-

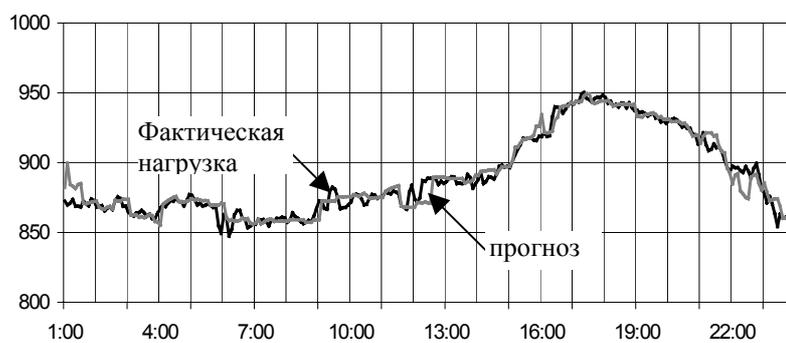
мени восстановленные значения. В этом случае рассчитывается меньшее количество весовых коэффициентов, а, следовательно, имеем большее быстродействие (при одинаковой погрешности восстановления). ИНС для восстановления данных подобна сети, изображенной на рис. 3¹. На рис.5 показан пример восстановления данных.



а)



б)



в)

Рис.4. Графики фактической нагрузки и прогноза:
 а - на среду 12 ноября, б - на воскресенье 16 ноября,
 в - на праздничный день 7 ноября.

¹ См. на данном сайте статью Н.А.Манова и др. «Информационные технологии и совершенствование оперативного управления региональными ЭЭС»

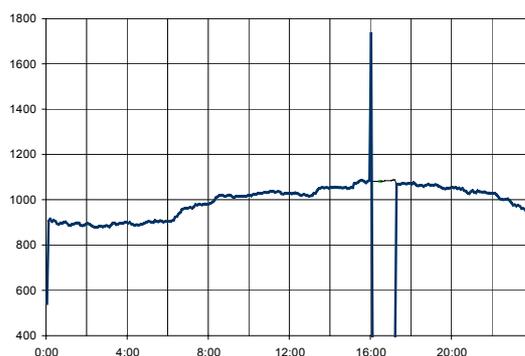


Рис.5. Восстановление графика нагрузки

Формирование расчетных нагрузок энергоузлов. Формирование расчетных нагрузок энергоузлов осуществляется разнесением нагрузок энергоузлов на основе взаимосвязи между суммарной нагрузкой группы и нагрузкой каждого узла. Пропорциональное распределение нагрузки по энергоузлам является наиболее простой моделью. Точность такого прогноза зависит от степени подобия графиков узловой и групповой нагрузок. Если график нагрузки i -й группы и график нагрузки j -го узла подобны, то для любого момента времени должно выполняться соотношение:

$$K_{ij} = \frac{P_{ij}}{\sum_j P_{ij}} = \frac{P_{ij}}{P_i} = const, \quad (4)$$

где P_{ij} – нагрузка j -го узла i -ой группы; P_i – суммарная нагрузка i -ой группы; K_{ij} – коэффициент пропорциональности между нагрузкой j -го узла и суммарной нагрузкой i -й группы узлов (района ЭЭС).

Если условие (4) не выполняется, то пропорциональная модель вносит дополнительную погрешность в прогнозирование нагрузок энергоузлов. В этом случае необходимо прибегать к более сложным моделям. Анализ суточных графиков нагрузок Коми ЭЭС показал, что в пределах одного часа условие (4) практически всегда выполняется. Тогда нагрузка энергоузла каждой группы определится по выражению $P_{ij}^{t+\tau} = K_{ij}^t \cdot P_i^t$ (K_{ij} – коэффициент пропорциональности, определяемый для t -го момента прогнозирования по результатам работы модели оценивания состояния).

Радиальная структура Коми ЭЭС с пятью четко выраженными энергорайонами (рис.1) ¹ позволяет проводить агрегирование расчетных нагрузок по признаку подобия не на уровне групп, а на уровне районов. Многочисленные исследования электрических

¹ См. на данном сайте статью Ю.Я.Чукреева «Прототип экспертной системы советчика диспетчера региональной ЭЭС»

режимов, в том числе и оптимальных, по тому или иному критерию показали, что даже при несоблюдении принципа пропорционального распределения нагрузок по энергоузлам района режимы загрузки системообразующих связей, соединяющих основные узловые подстанции этих районов, практически не меняются.

Одной из серьезных проблем задачи прогнозирования режимов загрузки электростанций является проблема задания реактивной нагрузки энергоузлов. Ее знание является необходимым условием правильной оптимизации режима. Однако достаточно низкая достоверность телеизмерений о перетоках реактивной мощности, объясняющаяся на нынешнем этапе формирования ОИК АСДУ отношением к ней со стороны диспетчерского персонала, службы режима и Отдела АСУ как к второстепенной, вынуждает применять другие подходы к ее определению. В разработанной методике используется модель, основанная на угловой зависимости между активной и реактивной нагрузками энергоузлов. Эта зависимость определяется в момент прогнозирования по результатам модели оценивания состояния. При прогнозировании режимов на достаточно малые интервалы времени (до одного часа) такое упрощение вполне оправдано.

Краткосрочное и долгосрочное прогнозирование нагрузки на базе методов искусственных нейронных сетей и нечетких множеств. Нетрадиционный подход к решению задачи краткосрочного и долгосрочного прогнозирования нагрузки дает преимущества по сравнению с традиционно используемыми регрессионными моделями, заключающиеся в возможности использования большого количества разнообразных входных переменных (ретроспективных данных о нагрузке, температуре воздуха, времени суток, типе дня, долготе светового дня, количестве праздничных дней и др.). При этом функция зависимости выходных параметров модели от входных переменных может быть какой угодно сложной и даже неизвестной. Такие модели обладают высоким быстродействием, устойчивы к помехам и независимы от состава потребителей узла нагрузки.

Краткосрочное прогнозирование нагрузки. Краткосрочное (суточное, недельное) прогнозирование электрической нагрузки составляет основную исходную информацию для принятия решений в процессе планирования режимов ЭЭС и оперативно-диспетчерского управления. Прогнозы суточных графиков нагрузки ЭЭС и их узлов используются для расчета оптимальных режимов ЭЭС по активной мощности, планирования ремонтов силового оборудования, оценки режимной надежности и живучести, оценки предельных режимов и т.п. Поэтому в комплексе задач, решаемых при управлении ЭЭС, краткосрочное прогнозирование нагрузки занимает одно из центральных мест.

Суточное прогнозирование нагрузки. Рассмотрим две модели суточного прогнозирования нагрузки с целью выявления особенностей каждой и перспектив их дальнейшего использования. В первой используются обычные нейронные сети, во второй – ИНС с элементами нечеткой логики [6, 11, 14] (или кратко, нечеткие нейронные сети – ННС).

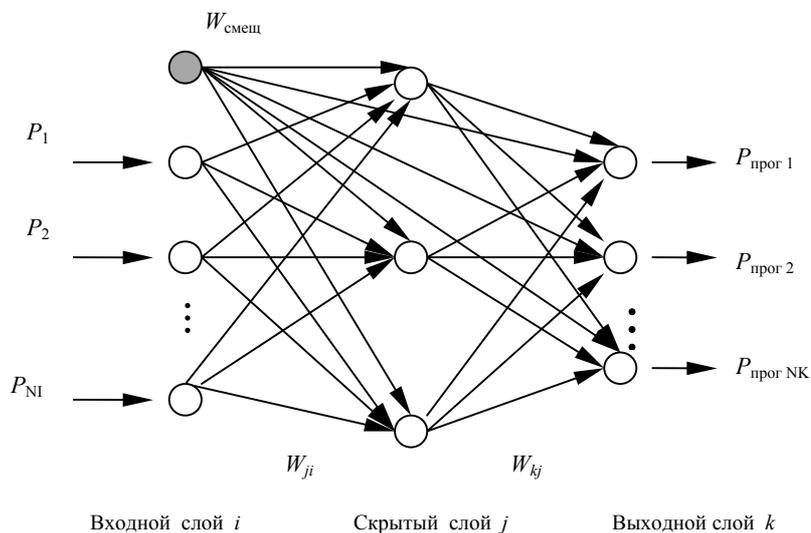


Рис.6. Структура ИНС, используемая для суточного прогнозирования нагрузки

Модель суточного прогнозирования нагрузки с использованием ИНС. Разработанная конфигурация ИНС для суточного прогнозирования нагрузки, приведена на рис.6. Она представляет собой трехслойный персептрон с весовыми коэффициентами связи W_{ji} и W_{kj} ($i = 1, 2, \dots, 48; j = 1, 2, \dots, 5; k = 1, 2, \dots, 24$) между нейронами соответственно входного, скрытого и выходного слоев. Во входном слое сети находится 48 нейронов (количество входных переменных), в скрытом слое – 5 (определены экспериментальным путем при настройке сети), в выходном – 24 (соответствует количеству часов в сутках). Входными переменными являются почасовые значения нагрузки P_i ($i = 1, \dots, 48$) для суток, предшествующих прогнозируемому (24 значения), и для суток недельной давности (24 значения). Алгоритм обучения сети по методу обратного распространения ошибки в соответствии с теорией нейронных сетей идентичен алгоритму внутрисуточного прогнозирования (рис.1). Исследованиями авторов установлено, что первоначальное обучение ИНС в данном случае целесообразно проводить на ретроспективных данных о нагрузке двухнедельного периода давности.

С целью увеличения точности прогноза и независимости его от сезона года перед выполнением каждого прогнозирования нагрузки проводится дообучение сети, т.е. коррекция весовых коэффициентов W_{ji} и W_{kj} . Такое дообучение снижает погрешность прогнозирования. При обучении сети соответствующим образом учитываются рабочие, выходные и праздничные дни. Так, для рабочих дней, в качестве входных переменных

используются ретроспективные значения почасовых нагрузок только рабочих дней. Для понедельника в качестве переменных предыдущего дня берутся значения нагрузки за последнюю пятницу, поскольку она является его предыдущим рабочим днем.

Для выходных, праздничных дней, рабочих суббот и т.п. с целью приближения периода обучения к настоящему моменту времени обучение, дообучение и прогнозирование предложено проводить на значениях нагрузки всех дней недели, но с той особенностью, что при переходе с рабочего дня на выходной или наоборот вводится псевдо-выходной или псевдорбочий день в качестве предыдущего прогнозируемому дня. Почасовые значения нагрузки этого дня рассчитываются по средним почасовым коэффициентам соотношения нагрузки рабочего дня к выходному (или наоборот) за некоторый промежуток времени (например, за четыре предыдущих недели).

Модель суточного прогнозирования нагрузки с использованием ННС. Применением теории нечетких множеств для прогнозирования нагрузки стали активно заниматься с начала 90-х годов за рубежом. Сначала это были экспертные системы с использованием нечетких множеств [11], так называемые Fuzzy Expert Systems. В дальнейшем начали появляться гибридные системы (экспертная система плюс нейронная сеть) [14] и нейронные сети с нечеткой логикой - Fuzzy Neural Networks (FNN) [6]. Отечественные публикации по этой проблеме нам неизвестны.

Конфигурация ННС. Разработанная конфигурация ННС для суточного прогнозирования нагрузки представлена на рис.7. Сеть состоит из трех слоев: входного, скрыто-

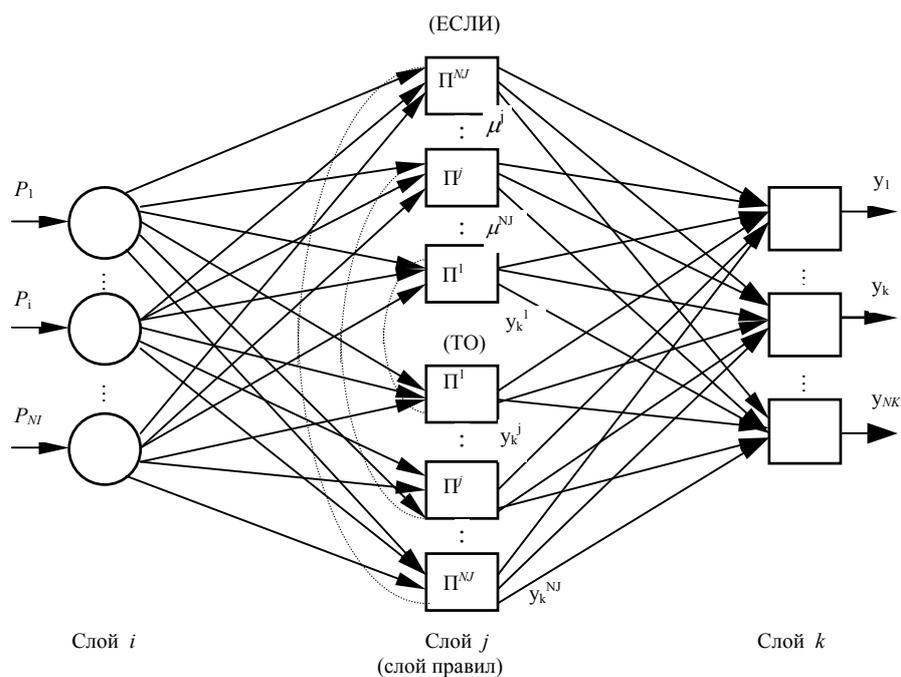


Рис. 7. Структура ИНС с элементами нечеткой логики для суточного прогнозирования нагрузки

го (слоя правил вида ЕСЛИ – ТО) и выходного слоя. На схеме нейроны, изображенные в виде кругов, представляют собой один узел, а нейроны в виде квадратов имеют большее количество узлов. На рис.8 дана их расшифровка. Входными переменными являются почасовые значения нагрузки P_i ($i = 1, \dots, 48$) для суток, предшествующих прогнозируемым (24 значения), и для суток недельной давности (24 значения). Во входном слое они нормализуются, т.е. преобразуются в относительные величины x_i , находящиеся в пределах $[0, 1]$. Каждая пара нейронов в скрытом слое составляет нечеткое правило. Выбрана следующая форма правил, в которой нечеткие множества включаются только во вступительную часть правил:

$$\mathbf{П}^j: \text{ЕСЛИ } x_1 = A_1^j, x_2 = A_2^j, \dots, x_i = A_i^j, \text{ ТО } y_k^j = C_{0k}^j + C_{1k}^j x_1 + \dots + C_{ik}^j x_i, \quad (5)$$

где $\mathbf{П}^j$ – j -ое правило; x_i – входные переменные; y_k^j – значение k -го выхода, вычисленные по j -му правилу; A_i^j – логические члены, характеризующиеся функциями принадлежности μ_i^j .

В подслое “ЕСЛИ” (рис. 8, а) вычисляется значение функции принадлежности для каждой входной переменной по формуле:

$$\mu_i^j = \exp \left[-\frac{1}{2} \left(\frac{x_i - x_i^j}{\sigma_i^j} \right)^2 \right]. \quad (6)$$

Эта функция имеет колоколообразную форму с центром x_i^j и отклонением σ_i^j . Результирующее значение функции принадлежности по каждому правилу (выход узла j в подслое “ЕСЛИ”) в литературе [6, 10] определяется как:

$$\mu^j = \prod_i \mu_i^j, \quad (7)$$

или

$$\mu^j = \min_i \{ \mu_i^j \}. \quad (8)$$

Были применены обе формулы и сделан вывод, что при отсутствии блока достоверизации данных формула (7) в некоторых случаях совершенно неприемлема: она оказалась очень жестким условием принадлежности к j -му правилу. Поэтому в разработанной модели использована формула (8).

Нейрон j в подслое “ТО” представляет из себя двухслойную нейронную сеть (рис. 8, б), в которой весовыми коэффициентами являются коэффициенты C_{ik}^j из уравнения (5), а C_{0k}^j – коэффициент смещения. Выход нейрона j в этом подслое будет

$$y_k^j = C_{0k}^j + C_{1k}^j x_1 + \dots + C_{NI k}^j x_{NI} \quad (9)$$

В выходном слое (рис.8, *с*) на основании результатов, полученных в слое правил, формируется четкий выход как взвешенное среднее по формуле

$$y_k = \frac{\sum_j^{NJ} (y_k^j \mu^j)}{\sum_j^{NJ} \mu^j} = P_{\text{прог}}^k,$$

где $k = 1, \dots, NK$ (для нашей задачи $NK = 24$), NJ - количество правил.

Обучение ННС. Параметрами, которые должны быть определены в процессе обучения, являются x_i^j , σ_i^j , C_{ik}^j (для $i = 1, \dots, NI$; $j = 1, \dots, NJ$; $k = 1, \dots, NK$) и C_{0k}^j . Алгоритм обучения ННС приведен на рис.9. В отличие от обычных ИНС, здесь началь-

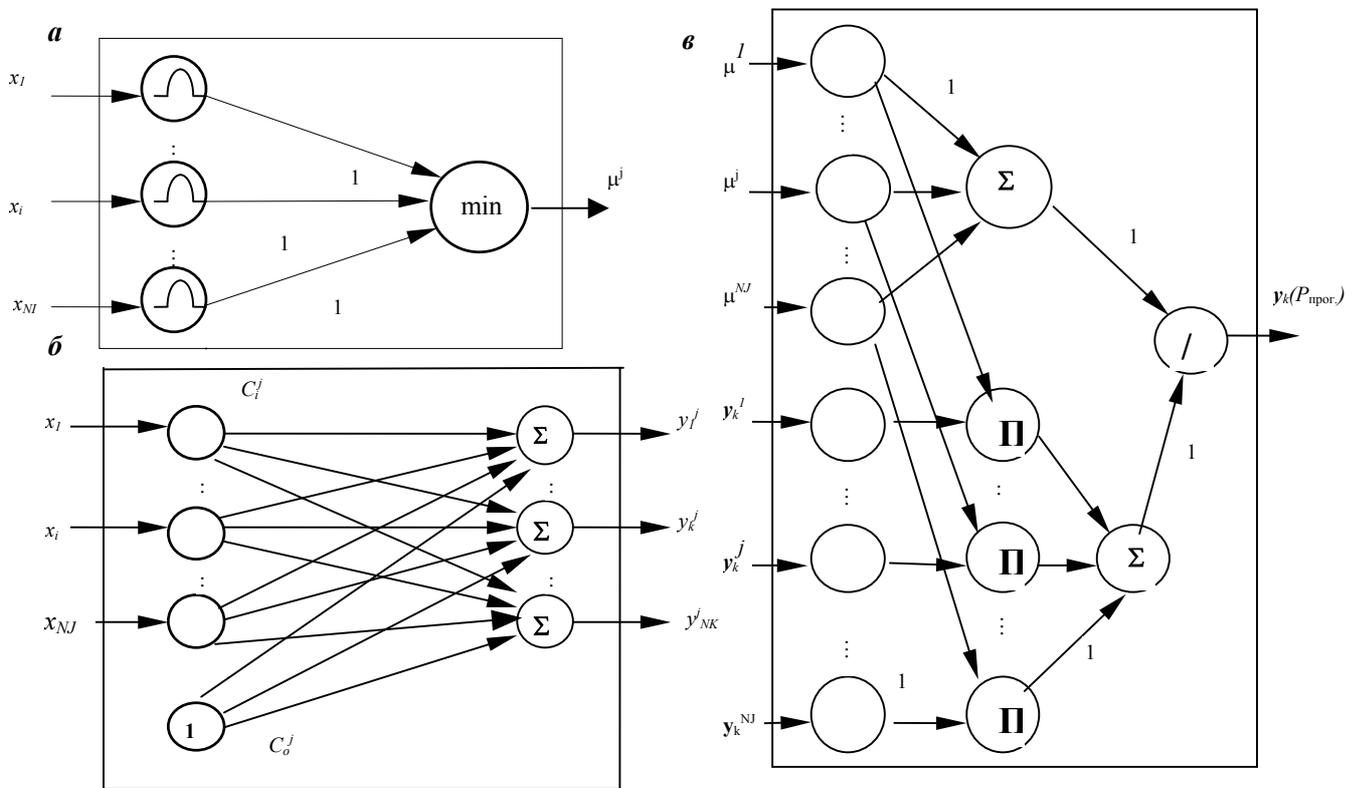


Рис. 8. Внутренняя структура нейронов ННС для суточного прогнозирования нагрузки: *а* – подслоя “ЕСЛИ”; *б* – подслоя “ТО”; *в* – выходной слой, Π / Σ - операции умножения, деления и суммирования соответственно

ные значения параметров сети выбираются не произвольно, а задаются максимально близкими к их реально возможному значениям, на основании специальных расчетов, что дает преимущество по скорости обучения.

Работа алгоритма обучения ННС начинается с инициализации базы правил (блок 1). На основе нескольких первых образцов включаются NJ нечетких правил (минимальное количество $NJ = 1$). Тогда $x_{i_{нач}}^j = x_i^j$ (i -е значение входной переменной по j -му

правилу): $\sigma_{нач.}^j = \frac{1}{2 \cdot NJ} \left[\max_{i=1 \div NI, j=1 \div NJ} (x_i^j) - \min_{i=1 \div NI, j=1 \div NJ} (x_i^j) \right]$; $C_{0k}^j = y_k$ ($k=1, 2, \dots, NK$); $C_{ik}^j = 0$ ($i=1, 2, \dots, NI$; $j=1, 2, \dots, NJ$).

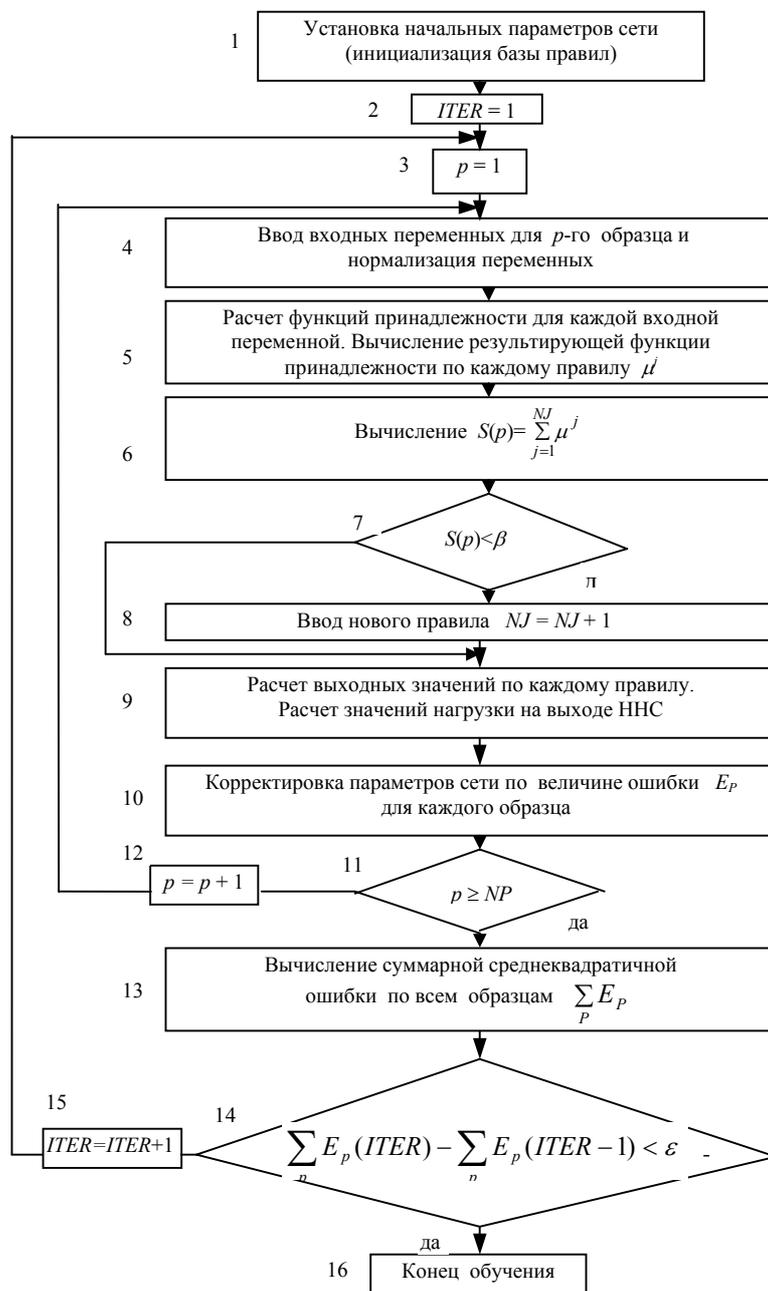


Рис. 9. Алгоритм обучения нечеткой нейронной сети

После выполнения процедуры инициализации вводятся новые обучающие образцы p , количество которых задается величиной NP . При этом вектор входных переменных отражается в множества с нечеткой логикой, характеризующиеся функциями принадлежности (блок 5), вычисляемыми по формулам (6), (8). В случае, когда новый обучаемый образец не инициирует какое-либо из существующих нечетких правил, то создается новое правило (блок 8). Параметрами сети при вводе нового правила будут:

$$x_i^j = x_i(p), \quad \text{где } p \text{ – номер образца;}$$

$$\sigma_i^{NJ+1} \gamma [x_i(p) - \bar{x}_i];$$

$$\bar{x}_i : \|\bar{x}_i(p) - x_i\| = \min_{j=1-NJ} \|x_i^j - x_i(p)\|.$$

Параметр C_{ik}^j ($i = 1, 2, \dots, NJ$) определяется также как при инициализации базы правил. В блоке 7 параметр β означает наименьшую приемлемую степень возбуждения существующей базы нечетких правил. Если $S(p) = \sum_j \mu^j < \beta$, то вводится новое правило. Величина β определяется экспериментальным путем при обучении модели. В блоке 9 рассчитываются значения сигналов на выходе нейронов подслоя “ТО” и нейронов выходного слоя по формулам (8), (9).

Для корректировки параметров сети используется метод градиентного спуска, при котором минимизируется среднеквадратичная ошибка $E_p = \frac{1}{2} \sum_{k=1}^{NK} (y_k - d_k)^2$ для каждого обучаемого образца (d_k – желаемое значение нагрузки на выходе сети, y_k – расчетное значение).

Корректировка параметров сети при вводе очередного образца производится следующим образом:

$$x_i^j(p) = x_i^j(p-1) + \alpha_1 \frac{\partial E_p}{\partial x_i^j};$$

$$\sigma_i^j(p) = \sigma_i^j(p-1) + \alpha_2 \frac{\partial E_p}{\partial \sigma_i^j};$$

$$C_{ik}^j(p) = C_{ik}^j(p-1) + \alpha_3 \frac{\partial E_p}{\partial C_{ik}^j},$$

где $\alpha_1, \alpha_2, \alpha_3$ – коэффициенты скорости обучения. В данном алгоритме эти коэффициенты определены экспериментальным путем при обучении модели: $\alpha_1 = \alpha_2 = 0,1$; $\alpha_3 = 0,05$; $\varepsilon = 10^{-6}$.

Блок 11 определяет, все ли образцы использованы. Если все, то вычисляется суммарная ошибка по всем образцам в блоке 13 и проверяется условие в блоке 14. В случае выполнения условия процесс обучения заканчивается, в противном случае процесс повторяется (по переменной *ITER*). При каждом требовании прогнозирования с целью увеличения точности прогноза и независимости его от сезона года проводится дообучение сети, в процессе которого могут быть введены новые правила.

Результаты исследований. Предлагаемые модели суточного прогнозирования нагрузки были исследованы на ретроспективных данных о режимах электропотребления Коми ЭЭС за 1997 г. Результат одного из прогнозов представлен на рис.10. В табл. 4 приведено сравнение точности прогнозирования моделей ИНС и ННС для одной недели марта месяца (с понедельника 17 марта по воскресенье 23 марта).

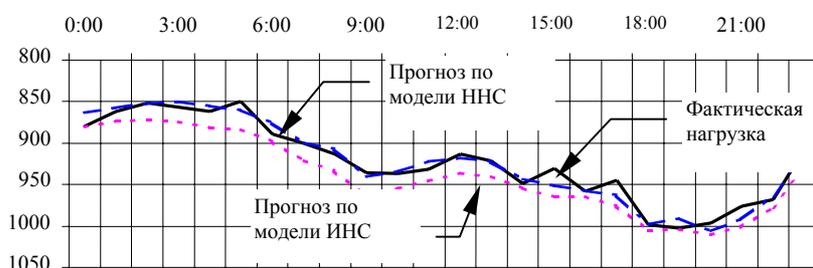


Рис.10. Графики фактической нагрузки и прогноза, полученного моделям ИНС и ННС для среды 19 марта 1997 г.

Для рабочих дней обучение и прогнозирование в обеих моделях проводилось с использованием ретроспективных данных о нагрузке только рабочих дней. Для прогноза на выходные использовались данные как рабочих, так и выходных дней. При этом в модели ИНС, в случае необходимости, входные переменные вводились с учетом псевдодней. В модели ННС такой необходимости нет, так как при переходе от рабочего к выходному дню либо наоборот автоматически вводится новое правило, характеризующее такой переход.

Таблица 4

Сравнение суточного прогнозирования нагрузки с использованием ИНС и ННС

День недели	Модель ИНС			Модель ННС		
	Средняя погрешность (%)	Средняя квадратичная погрешность (%)	Погрешность при максимальной нагрузке (%)	Средняя погрешность (%)	Средняя квадратичная погрешность (%)	Погрешность при максимальной нагрузке (%)
Пн	1,3	1,58	2,78	1,09	1,41	0,23
Вт	1,86	2,27	1,64	1,33	1,69	0,11
Ср	1,89	2,16	0,2	1,15	1,46	0,08
Чт	1,77	2,19	4,68	1,66	2,10	4,24
Пт	1,61	1,88	0,44	2,12	2,64	1,34
Сб	1,56	1,91	1,7	1,81	2,17	1,73
Вс	3,43	4,49	1,3	2,92	3,23	0,52

Недельное прогнозирование нагрузки. Конфигурация модели для прогнозирования нагрузки на неделю вперед полностью соответствует структуре сети, приведенной на рис.7, поэтому описание ее в данном разделе не дается. Прогноз на первый день

недели выполняется по модели суточного прогнозирования нагрузки. При прогнозировании нагрузки на последующие дни недели входными переменными являются почасовые прогнозные значения нагрузки для суток, предшествующих прогнозируемым (24 значения) и фактические почасовые значения нагрузки для суток недельной давности (24 значения). Предлагаемая модель прогнозирования электрической нагрузки на неделю вперед исследована на ретроспективных данных о нагрузке Коми ЭЭС за 1997 г. В табл.5 даны погрешности прогнозирования нагрузки на неделю вперед для различных сезонов года. Для сравнения рассчитаны погрешности прогнозирования на то же самое время за сутки раньше. Из табл.5 видно, что предложенная модель прогнозирования нагрузки на неделю вперед дает сопоставимые результаты с моделью суточного прогнозирования.

Долгосрочное прогнозирование нагрузки. Долгосрочное прогнозирование, согласно [3, 5], производится во временных диапазонах месяц – квартал – год. В данной работе рассматривается месячное прогнозирование электропотребления. В современных условиях оно необходимо для обоснования технико-экономических показателей работы энергетической компании и ее тарифной политики, а также для составления графиков ремонтов основного оборудования.

Прогнозируемыми показателями являются месячное электропотребление (P_{Σ}), минимальная и максимальная нагрузки за месяц (P_{\max} и P_{\min}) и коэффициенты, характеризующие неравномерность электропотребления: коэффициент неравномерности месячного графика нагрузки $\alpha_M = P_{\min} / P_{\max}$ и коэффициент заполнения месячного графика нагрузки $\beta_M = P_{\text{cp}} / P_{\max}$ ($P_{\text{cp}} = W_M / 24 \cdot K_{\text{дм}}$; W_M – месячное электропотребление; $K_{\text{дм}}$ – количество дней в месяце).

Конфигурация моделей и входные переменные. Как и при суточном прогнозировании нагрузки рассматриваются две модели прогноза: с использованием ИНС и ННС. Выбор конфигурации сети с ИНС, т.е. выбор количества слоев и нейронов в этих слоях, значений η и α и подбор преобразующих функций для скрытого и выходного слоев проводился таким же образом, как и при построении моделей оперативного и краткосрочного прогнозирования. В результате получен оптимальный вариант модели прогноза с одним скрытым слоем с тремя нейронами. Значения коэффициентов η и α равны соответственно 0,1 и 0,9. Преобразующие функции логистические.

Конфигурация модели месячного прогнозирования на основе ННС такая же, как на рис.7. Значения параметров, определяемых при настройке модели, равны: $\gamma=1,5$; $\beta=0,9$; $\alpha_1=0,1$; $\alpha_2=0,1$; $\alpha_3=0,05$. Количество нейронов во входном и выходном

слоях обеих моделей, определяемое числом входных и выходных переменных равно, соответственно, 9 и 3.

Таблица 5

**Погрешности расчета прогноза электрической нагрузки на сутки вперед
и на неделю вперед на основе ретроспективных данных за 1997 г.**

Дата	День Недели	Прогноз на сутки вперед		Прогноз на неделю вперед	
		Средняя Погрешность	Среднеквадра- тичная погрешность	Средняя погрешность	Среднеквадра- тичная погрешность
20.01 - 27.01	Пн	1.77	2.01	1.77	2.01
	Вт	2.29	2.63	2.30	2.63
	Ср	1.15	1.45	1.13	1.43
	Чт	1.65	2.02	1.66	2.03
	Пт	1.49	1.84	1.47	1.82
	Сб	2.00	3.38	2.50	3.03
	Вс	2.35	2.79	3.61	3.91
03.02 - 09.02	Пн	3.60	3.97	3.60	3.97
	Вт	1.47	1.83	1.27	1.82
	Ср	2.68	3.13	3.50	3.98
	Чт	2.60	3.04	2.95	3.52
	Пт	1.93	2.24	3.36	3.98
	Сб	1.37	1.69	1.10	1.37
	Вс	2.71	3.26	1.53	1.89
17.03 - 23.03	Пн	1.09	1.41	1.09	1.41
	Вт	1.33	1.69	1.26	1.59
	Ср	1.15	1.46	1.62	2.01
	Чт	1.66	2.10	1.48	2.07
	Пт	2.12	2.64	2.94	3.44
	Сб	1.81	2.17	1.69	2.43
	Вс	2.92	3.23	3.02	3.49
21.04 - 27.04	Пн	2.21	2.89	2.21	2.89
	Вт	1.18	1.53	1.18	1.53
	Ср	2.28	2.61	2.56	2.85
	Чт	1.62	2.22	2.15	2.58
	Пт	1.50	1.91	1.89	2.41
	Сб	1.92	2.16	2.30	2.77
	Вс	1.92	2.19	1.57	1.84
26.05 - 01.06	Пн	1.98	2.42	1.98	2.42
	Вт	2.20	2.77	2.21	2.79
	Ср	1.84	2.27	1.86	2.30
	Чт	2.20	2.75	2.22	2.81
	Пт	2.39	3.17	3.14	4.16
	Сб	2.37	2.91	2.42	2.92
	Вс	3.49	4.07	4.00	4.66

Подбор входных переменных проводился на основании выражения (1). В результате определено, что на входы моделей подаются следующие переменные, дающие наименьшую погрешность прогноза: электропотребление за месяц, предшествующий прогнозируемому (P_{Σ}^{-1}); максимальная и минимальная нагрузки (P_{\max}^{-1} и P_{\min}^{-1}), средняя температура (T_{cp}^{-1}), долгота дня ($ДД^{-1}$), количество праздничных дней ($ПД^{-1}$) того же месяца; прогнозное значение средней температуры на прогнозируемый месяц

($T_{\text{ср}}^{\text{прог}}$); долгота дня ($ДД^{\text{прог}}$), количество праздничных дней ($ПД^{\text{прог}}$) в прогнозируемом месяце. Всего девять переменных.

Обучение. Алгоритмы обучения ИНС и ННС для месячного прогнозирования нагрузки не отличаются от алгоритмов, приведенных на рис.9 и рис.11 для суточного прогнозирования. Особенности обучения заключаются в выборе обучающих образцов. Для обучения данные берутся с таким расчетом, чтобы их сезон совпадал с тем сезоном, на который планируется делать прогноз, т.е. если нужен прогноз на декабрь месяц 2001 г., то для обучения берутся данные за октябрь и ноябрь 2001 г. и за ноябрь и декабрь 2000 г. При прогнозировании на осенние месяцы для обучения можно брать данные за весенние месяцы того же года.

Результаты исследований. Модель месячного прогнозирования была исследована на ретроспективных данных о нагрузке Коми ЭЭС за 1998 и 1999 годы. Результаты прогноза на 6 месяцев 1999 г. сведены в табл. 6. Из таблицы видно, что модели на основе ИНС и ННС в целом дают приемлемые результаты, но модель с ННС дает большую точность прогноза за счет более гибкого принятия решения.

На основе спрогнозированных параметров P_{Σ} , P_{max} и P_{min} рассчитываются коэффициенты неравномерности месячных графиков нагрузки α_M и β_M . Результаты расчета для июля-декабря 1999 г. приведены в табл. 7.

Таблица 6

Погрешности прогнозирования месячного электропотребления, месячных максимума и минимума нагрузки на июль-декабрь 1999 г.

Месяц года	Погрешность прогноза в %					
	Модель ИНС			Модель ННС		
	P_{Σ}	P_{max}	P_{min}	P_{Σ}	P_{max}	P_{min}
Июль	-1,019	3,712	-0,806	-1,653	3,128	2,392
Август	0,6	-2,6	-3,4	-2,298	-1,652	-1,115
Сентябрь	-1,5	0,7	-3,4	-2,67	1,452	-0,692
Октябрь	1,62	-1,12	5,05	-0,401	-0,156	3,311
Ноябрь	0,13	-2,79	0,19	-0,371	-2,125	1,206
Декабрь	-0,55	0,59	-1,19	0,367	2,918	0,001
Среднеквадратичная погрешность, %	1,14	2,45	3,12	1,21	2,26	1,76
Максимальная погрешность, %	1,62	3,712	5,05	2,67	3,128	3,311

**Расчетные значения коэффициентов неравномерности
месячных графиков нагрузки α_M и β_M .**

Месяц года	Фактические значения		Прогнозируемые значения с использованием моделей			
			ИНС		ННС	
	α_M	β_M	α_M	β_M	α_M	β_M
Июль	0,592	0,861	0,561	0,814	0,588	0,820
Август	0,596	0,780	0,592	0,803	0,599	0,775
Сентябрь	0,717	0,850	0,687	0,830	0,702	0,815
Октябрь	0,718	0,860	0,763	0,884	0,743	0,858
Ноябрь	0,725	0,864	0,747	0,890	0,750	0,879
Декабрь	0,742	0,862	0,729	0,852	0,721	0,841

Погрешности расчета коэффициентов определяются погрешностями прогнозирования P_Σ , P_{\max} и P_{\min} и находятся в пределах: 1) среднеквадратичная погрешность расчета коэффициентов по модели с ИНС составляет для α_M - 4,37%, для β_M - 3,53%; 2) по модели с ННС – для α_M - 2,7%, для β_M - 2,48%.

Литература

1. Бэнн Д.В., Фармер Е.Д. Сравнительные модели прогнозирования электрической нагрузки: Пер. с англ. М.: Энергоатомиздат, 1987. 200 с..
2. Горбань А.Н., Россиев Д.А. Нейронные сети на персональном компьютере. Новосибирск: Наука. Сибирск. издательская фирма РАН, 1996. 276 с.
3. Меламед М.А. Современные методы анализа и прогнозирования режимов электропотребления в электроэнергетических системах // Итоги науки и техники. Серия Энергетические системы и их автоматизация. 1988., Т.4. С.4-111.
4. Методы управления физико-техническими системами энергетики в новых условиях / Н.И. Воропай, Н.Н. Новицкий, Е.В. Сеннова и др. Новосибирск: Наука, сибирская издательская фирма РАН, 1995. 335 с.
5. Тимченко В.Ф. Колебания нагрузки и обменной мощности энергосистем. Под ред. В.А.Веникова. М.: Энергия, 1975. 208 с.
6. Bakirtzis A.G., Theocharis J.B., Kiartzis S.J. Satsios K.J. Short term load forecasting using fuzzy neural networks // IEEE Trans. on Power Systems, Vol. 10, №3, 1995. P. 1518 - 1523.
7. Chen S.T., David C.Y., Moghaddamjo A.R. Weather sensitive short-term load forecasting using non fully connected artificial neural network // IEEE Trans. on Power Systems, Vol. 7, №3, 1992. P. 1098 – 1105.

8. Dash P.K., Ramakrishna G., Liew A.C., Rahman S. Fuzzy neural networks for time-series forecasting of electric load // IEE Proc. - Gener. Transm. Distrib, Vol. 142, N5, 1995. P. 535 - 544.
9. Gross G. and Galiana F.D. Short term load forecasting // Proc. IEEE, Vol.75, №12, 1987. P. 1558-1573.
10. Hiroshi Kitajima and Masafumi Hagiwara. Generalized fuzzy inference neural network using a self-organizing feature map // Electrical Engineering in Japan, Vol. 125, №3, 1998. P. 40-49.
11. Hsy Y., Ho K. Fuzzy expert systems: An application to short term load forecasting // IEE Proceedings – C, Vol. 139, № 6, 1992. P. 471-477.
12. Lee K.Y., Park J.H. Short-term load forecasting using an artificial neural network // IEEE Trans. on Power Systems, Vol. 7, №1, 1992. P.124 - 130.
13. Peng T.M., Hubele N.F., Karady G.G. An adaptive neural network approach to one - week ahead load forecasting // IEEE Trans. on Power Systems, Vol. 8, №3, 1993. P. 1195-1201.
14. Srinivasan D., Liew A.C. Chang C.S. Forecasting daily load curves using a hybrid fuzzy-neural approach // IEE Proc - Generat. Transmiss. Distrib., Vol. 141, №6, 1994. P. 561 - 567.