

РОССИЙСКАЯ АКАДЕМИЯ НАУК  
УРАЛЬСКОЕ ОТДЕЛЕНИЕ

КОМИ НАУЧНЫЙ ЦЕНТР

ИНСТИТУТ СОЦИАЛЬНО-ЭКОНОМИЧЕСКИХ  
И ЭНЕРГЕТИЧЕСКИХ ПРОБЛЕМ СЕВЕРА

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

ПРОГНОЗИРОВАНИЕ ЭЛЕКТРИЧЕСКИХ НАГРУЗОК  
ПРИ ОПЕРАТИВНОМ УПРАВЛЕНИИ  
ЭЛЕКТРОЭНЕРГЕТИЧЕСКИМИ СИСТЕМАМИ  
НА ОСНОВЕ НЕЙРОСЕТЕВЫХ СТРУКТУР

СЫКТЫВКАР, 2008

УДК 621.311.016.3:004.032.26

**Прогнозирование электрических нагрузок при оперативном управлении электроэнергетическими системами на основе нейросетевых структур.**  
Сыктывкар: КНЦ УрО РАН, 2008.

Монография посвящена вопросам прогнозирования электрических нагрузок ЭЭС с использованием аппарата искусственных нейронных сетей и нечеткой логики. Кратко изложена теория новых информационных технологий, применяемых для построения нейросетевых моделей прогнозирования нагрузок. Рассмотрены два типа моделей оперативного, краткосрочного и долгосрочного прогнозирования нагрузки по энергосистеме в целом, реализованные на персональных ЭВМ, дан их сравнительный анализ по точности прогноза, а также модель сбалансированного прогноза узловых нагрузок в двух временных диапазонах – внутрисуточном и суточном. Приведены результаты тестирования разработанных нейросетевых моделей на графиках нагрузки ОДУ Урала и, в связи с этим, даны рекомендации по использованию данных моделей в других энергосистемах.

Книга предназначена для специалистов и исследователей, занимающихся вопросами оперативного управления режимами электроэнергетических систем.

Табл. 16. Ил. 31. Библиогр. 77 назв.

А в т о р ы: Г.П.Шумилова, Н.Э.Готман, Т.Б.Старцева

О т в е т с т в е н н ы й   р е д а к т о р  
доктор технических наук **П.И.Бартоломей**

Р е ц е н з е н т ы:  
доктор технических наук **В.Л.Никитенков**,  
кандидат технических наук **М.И.Успенский**

## Введение

Прогнозирование электрических нагрузок является важной областью исследования в электроэнергетике. Оно необходимо для решения практически всего спектра задач текущего планирования и оперативного управления режимами функционирования электроэнергетической системы (ЭЭС). На его основе рассчитываются исходные и оптимальные электрические режимы ЭЭС, оценивается их надежность, экономичность, качество электроэнергии [2]. Точность прогноза нагрузок влияет на экономичность загрузки генерирующего оборудования, и, следовательно, на стоимость электроэнергии.

Прогнозирование нагрузки проводится в различных временных диапазонах. В работе [24], например, временные диапазоны прогнозирования классифицируются следующим образом: в пределах текущих суток – оперативный прогноз; вперед на сутки-неделю-месяц – краткосрочный; на месяц-квартал-год – долгосрочный. Авторы [31] реализуют временные периоды прогнозирования в несколько иных вариантах, а именно: очень краткосрочный прогноз (от нескольких секунд до часа вперед); краткосрочный прогноз (от часа до недели вперед); среднесрочный прогноз (от недели до года вперед); долгосрочный прогноз (от года до 20 лет вперед). В [2] предложены только две градации временных диапазонов прогнозирования. Интервал времени от предстоящих суток до недели – краткосрочное прогнозирование, а от месяца до года – долгосрочное. Как видно, пока не существует точной классификации временных периодов прогнозирования. Авторы данной работы придерживаются классификации из работы [24].

Первые публикации по методам прогнозирования электрических нагрузок ЭЭС появились на рубеже десятых-двадцатых годов прошлого века [6]. Казалось бы, почти за вековой период проблема должна быть решена. Тем не менее поток публикаций по прогнозированию электрических нагрузок продолжает расти. Основная причина этого явления заключается в более высоких требованиях рынка электроэнергии к показателям качества прогнозных расчетов (точности, достоверности, быстродействию и т.п.), достижение которых возможно при современном уровне информационной обеспеченности ЭЭС.

К настоящему времени разработано большое число методов и моделей прогнозирования электрических нагрузок как традиционных, так и нетрадиционных. Их обзор дан в [2, 6, 53]. Традиционные статистические модели могут быть условно разделены на регрессионные модели и модели на основе временных рядов. Подробное обсуждение этих моделей приведено в [53].

С развитием теории новых информационных технологий в последнее десятилетие было предложено решение задачи прогнозирования нагрузки нетрадиционными метода-

ми, а именно, с использованием моделей на основе экспертных систем и искусственных нейронных сетей [47, 48, 56, 63, 67]. Предпочтение таких моделей традиционным обусловлено тем, что не требуется построения модели объекта, не теряется работоспособность при неполной входной информации. Они обладают устойчивостью к помехам, имеют высокое быстродействие.

В работе представлены результаты исследований прогнозирования электрических нагрузок ЭЭС с применением искусственных нейронных сетей и нечеткой логики как одних из наиболее совершенных и перспективных направлений решения данной задачи. Теоретический подход к рассмотренным вопросам сочетается с результатами экспериментальных исследований, проведенных с использованием графиков нагрузки региональных энергосистем.

В первой главе рассмотрены отдельные вопросы теории новых информационных технологий, используемых для совершенствования методов и моделей прогнозирования электрических нагрузок, а именно: искусственные нейронные сети (ИНС), нечеткие множества, нечеткие нейронные сети (ННС) и инверсия нейронных сетей.

Во второй главе даны методы и нейросетевые модели оперативного (в пределах часа), краткосрочного (на сутки и неделю вперед) и долгосрочного (на месяц) прогнозирования нагрузки ЭЭС на основе ИНС и ННС. Приведены результаты тестирования разработанных моделей на графиках нагрузки ОДУ Урала, даны рекомендации по применению разработанных моделей прогнозирования в других энергосистемах.

В третьей главе представлен метод прогнозирования нагрузки ЭЭС и ее узлов, основанный на инверсии ИНС и позволяющий получить сбалансированный прогноз нагрузки по энергосистеме в целом и ее узлам, а также результаты внутрисуточного и суточного прогнозирования нагрузок узлов по нейросетевым моделям.

Основное содержание монографии изложено в работах [17, 28, 34-43, 70].

## Глава 1

# Новые информационные технологии для прогнозирования электрических нагрузок ЭЭС

### 1.1. Искусственные нейронные сети

Термин «нейронные сети» сформировался в 40-х годах XX в. в сфере исследователей, изучавших принципы организации и функционирования биологических нейронных сетей [13]. В настоящее время в этой области науки разработан ряд моделей, названных искусственными нейронными сетями (ИНС) или просто нейронными сетями (НС).

Обычно под ИНС понимается набор элементарных нейроподобных преобразователей информации – нейронов, соединенных друг с другом каналами обмена информацией для их совместной работы. В настоящее время сформировались две ветви исследований [13]. Первая, нейробиологическая, основывается на моделировании работы живого мозга, имея целью объяснить, каким образом в нем отображаются сложные объекты и связи между ними, как устанавливается соответствие между хранящейся и поступающей извне информацией, как мозг обучается и другие вопросы, касающиеся функционирования мозга. Второе направление исследований направлено на решение с помощью ИНС задач переработки информации в различных областях знаний, особенно в плохо формализуемых, где существующие модели субъективны и неадекватны. Наиболее впечатляющие результаты использования ИНС достигнуты при распознавании образов [например, 7, 8, 11, 14, 15], при создании самообучающихся экспертных систем [например, 1, 13], при построении ассоциативной памяти [например, 13, 19, 22, 33] и при решении оптимизационных задач большой размерности [13]. При разработке нейросетевых методов решения таких задач необязательно добиваться строгого соблюдения биологического правдоподобия, хотя сложившаяся терминология в основном заимствована из нейробиологии [13].

Исследования по ИНС находятся в стадии интенсивного развития. Ежегодно проводится ряд международных конференций и форумов по нейросетям. С 1992 г. в России начал выпускаться журнал «Нейрокомпьютер».

Рассмотрим более подробно, что представляют собой искусственные нейроны и нейронные сети.

**Нейрон.** Так как ИНС состоит из совокупности нейронов, определим, что такое нейрон и как он работает.

Биологический нейрон (рис.1.1) - нервная клетка - имеет тело, называемое сомой. От тела отходят многочисленные отростки нервных волокон двух типов – тонкие, густо ветвящиеся дендриты, и более толстый аксон. Входные сигналы поступают в клетку через синапсы, а выходной сигнал отводится аксоном через его многочисленные нервные окончания. Те, в свою

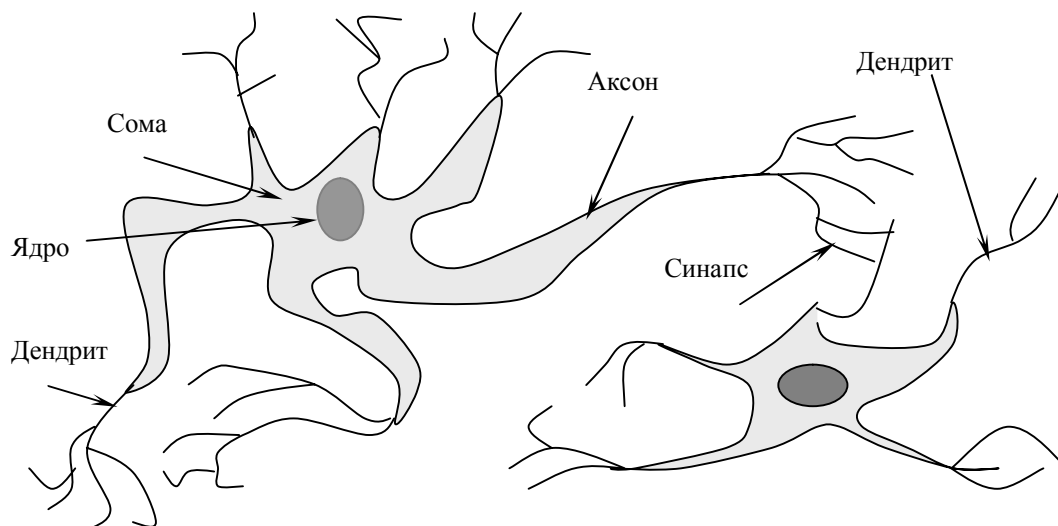


Рис.1.1. Биологический нейрон

очередь, контактируют с сомой и дендритами других нейронов, образуя очередные синапсы [29]. Нервный импульс от одного нейрона по аксону достигает синаптического контакта с другим нейроном и приводит к высвобождению некоторого количества медиатора (химического вещества), который достигает мембраны другой клетки. Медиатор воздействует на клеточную мембрану, вызывая изменение ее электрического потенциала. Чем больше химического вещества, тем сильнее изменение потенциала. Синапсы отличаются друг от друга размерами и возможностью концентрации медиатора. Поэтому импульсы одинаковой величины, поступающие на входы нервной клетки через различные синапсы, могут возбуждать ее в разной степени. Можно сказать, что каждому входу клетки соответствуют численные коэффициенты (веса), пропорционально количеству медиатора, выделяемого на соответствующем синапсе. Далее в зависимости от степени возбуждения нейрон генерирует выходные сигналы. Такая упрощенная схема функционирования биологического нейрона положена в основу структуры искусственного.

Формальный нейрон (рис.1.2), отражающий основные свойства биологического нейрона – это элементарный преобразовательный элемент, имеющий множество входов, на которые




Рис.1.2. Модель формального нейрона

поступают сигналы  $x_1, x_2, \dots, x_n$ , суммирующий блок, блок преобразования сигнала с помощью передаточной функции (или функции активации)  $f(net)$  и один выход  $y$ . Каждому входу приписан свой «вес»  $w_i$ ,  $\theta$  - параметр смещения.

Функционирует нейрон в два такта. На первом такте в суммирующем блоке вычисляется величина возбуждения, полученного нейроном:

$$net = \sum_{i=1}^n w_i x_i + \theta .$$

С точки зрения реализации модели нейрона параметр смещения  $\theta$  часто представляют в виде единичного входа  $x_{n+1} = 1$  с весом  $w_{n+1} = \theta$ .

На втором такте суммарное возбуждение пропускается через активационную (преобразующую) функцию, в результате чего определяется выходной сигнал  $y = f(net)$ . Преобразующая функция, как правило, должна удовлетворять двум условиям: 1)  $f(net)$  – монотонная (обычно неубывающая) функция; 2)  $|f(net)| \leq 1$ .

Наиболее часто используются следующие преобразующие функции (табл. 1.1).

Таблица 1.1

### Преобразующие функции

Тип функции	Формула	Вид
Пороговая	$f(net) = \begin{cases} 1, \text{ если } net > 0 \\ 0, \text{ в противном случае} \end{cases}$	
Сигмоидная	$f(net) = \frac{1}{1 + e^{-\alpha net}}$	
Гиперболический тангенс	$f(net) = \frac{1 - e^{-\alpha net}}{1 + e^{-\alpha net}}$	

Параметр  $\alpha$  подбирается пользователем. Его значение влияет на форму функции активации. Графики сигмоидной функции и гиперболического тангенса сильно зависят от значения  $\alpha$ . При малых величинах графики будут достаточно пологими, но по мере роста значения  $\alpha$  крутизна графиков увеличивается. При  $\alpha \rightarrow \infty$  сигмоидная функция превращается в функцию ступенчатого типа.

График сигмоидной функции качественно близок к изображению передаточной характеристики биологического нейрона. Очевидно, пороговая функция более удобна при аппаратной реализации нейрона, тогда как сигмоидная предпочтительна в аналитических исследованиях, поскольку она монотонна, всюду дифференцируема и имеет непрерывные производные любого порядка. Кроме этого, ценным свойством сигмоидной функции является простое выражение для ее производной:

$$f'(net) = \alpha \cdot f(net) \cdot (1 - f(net)).$$

Таким образом, каждый нейрон характеризуется вектором весовых множителей и параметрами преобразующей функции. Нейрон способен получать сигналы и в зависимости от их интенсивности и собственных характеристик выдавать выходной сигнал. При этом, если выходной сигнал нейрона близок к единице, то говорят, что нейрон возбужден.

**Нейронная сеть.** К настоящему времени предложено большое количество способов для объединения нейронов в нейронную сеть. Обычно нейроны в сети расположены слоями. Слой может состоять из одного нейрона. Выделяют входной слой, на который подается возбуждающий сигнал, выходной слой, с которого снимают переработанный сетью сигнал и промежуточные или скрытые слои (называют скрытыми поскольку они «не видны» пользователю).

Рассмотрим более подробно основные типы нейронных сетей.

**1. Сети прямого распространения (персептроны).** Сети этого типа состоят из нескольких слоев нейронов: входного слоя, выходного слоя и нескольких «скрытых» слоев. Нейроны каждого слоя не связаны между собой и взаимодействуют лишь с нейронами предыдущего и последующего слоев (рис.1.3).




Рис.1.3. Многослойная нейронная сеть прямого распространения

Функционирование сети прямого распространения очень простое. Входной сигнал, подаваемый на сеть, поступает на нейроны входного слоя, проходит по очереди через все слои и выделяется с выходов нейронов выходного слоя. По мере распространения сигнала по сети он претерпевает ряд преобразований, которые зависят от его начального значения, от преобразующей функции и величин весов связей.



Выходной сигнал  $y_j$  некоторого нейрона в  $j$ -том слое в сети прямого распространения может быть выражен с помощью следующей формулы:

$$y_j = f\left(\sum_{i=1}^n w_{ij}y_i + \theta_j\right),$$

где  $y_i$  – выходной сигнал  $i$ -го нейрона предыдущего слоя,  $w_{ij}$  – весовой коэффициент, выражающий степень влияния, оказываемого выходным сигналом  $i$ -го нейрона предыдущего слоя на  $j$ -ый нейрон рассматриваемого слоя;  $\theta_j$  – смещение в  $j$ -ом слое,  $n$  – количество нейронов в предыдущем слое.

Такая сеть используется для решения задач распознавания и классификации, прогнозирования, идентификации и т.д.

**2. Самоорганизующиеся карты Кохонена (kohonenmap).** Сеть, которую предложил Т. Кохонен [60], состоит из двух слоев (рис.1.4). Первый выполняет функцию распределения входного сигнала между нейронами второго слоя. Нейроны второго слоя (называемого иногда слоем Кохонена) расположены на плоскости и связаны с нейронами своего слоя связями, величина которых зависит от расстояния между нейронами и обычно имеет вид «мексиканской шляпы» (рис.1.5).

Этот вид связей обеспечивает взаимное усиление сигнала близкими нейронами и ослабление влияния далеких нейронов, что делает более контрастной границу раздела возбужденных нейронов от остальных, ложное возбуждение которых этим подавляется.




Рис.1.4. Нейронная сеть Кохонена




Рис.1.5. Вид функции взаимного влияния нейронов в слое Кохонена

Результатом работы сети Кохонена при подаче на входной слой некоторого вектора является определение нейрона, который возбужден более других (нейрон-победитель). Этот нейрон бо-

лее других близок к предъявленному образу, поскольку выход каждого нейрона второго слоя определяется как сумма взвешенных входов сети. В своей простейшей форме сеть Кохонена функционирует по принципу: «Победитель берет все». Это означает, что для данного входного вектора только один нейрон второго слоя сети выдаст на выходе логическую единицу, все остальные выдают ноль. Однако после выделения победителя происходит скрытая от пользователя операция коррекции весов между первым и вторым слоями. Дело в том, что сеть Кохонена обучается без учителя, т.е. сеть сама вырабатывает правила обучения путем выделения особенностей из набора входных данных. Поэтому, каждый новый образ, предъявленный сети, может изменить силы связей. После предъявления сети достаточного количества образов все нейроны как бы разбиваются на подмножества, каждое из которых «откликается» на образы соответствующего класса (т.е. сеть способна осуществлять классификацию предъявляемых образов), причем переход от одного подмножества к другому происходит непрерывно. В этом заключается свойство сети к обобщению, т.е. достаточно правильно распознавать объекты, которые ранее сети не предъявлялись, но в какой-то мере обладающие свойствами известных классов.

Сети Кохонена используются при решении задач кластеризации, распознавания образов, классификации и др.

### **3. Сети Хопфилда (Hopfield net).**

Сеть Хопфилда [57] – однослойная сеть. Все нейроны связаны друг с другом связями  $w_{ij}$  (рис.1.6); причем сигнал с выхода нейрона может подаваться на его же вход и необязательно  $w_{ij} = w_{ji}$ . Каждая компонента входного вектора  $x_i$  подается на соответствующий  $i$ -ый нейрон. Поскольку сигнал с выхода каждого нейрона подается на входы всех остальных, входной вектор начинает циркулировать, преобразуясь, по сети до тех пор, пока сеть не придет в устойчивое состояние (т.е. когда все нейроны на каждом последующем цикле будут вырабатывать тот же сигнал, что и на предыдущем). Очевидно, возможны случаи бесконечной циркуляции входного вектора без достижения устойчивого состояния.

Авторами [57] были найдены достаточные условия сходимости сети Хопфилда к устойчивому состоянию. Оказывается, если матрица весов связей между нейронами симметрична (т.е. для каждой пары нейронов  $i$  и  $j$  выполняется условие  $w_{ij} = w_{ji}$ ) и имеет нули на главной диагонали  $w_{ij} = 0$  (т.е. сигнал с выхода нейрона не должен подаваться на его вход), то у сети существует устойчивое состояние.

Сети Хопфилда имеют многочисленные применения. Ряд из них связан со способностью этих же сетей запоминать, а затем восстанавливать даже по неполной входной информации различные образы. Другие применения связаны с возможностью использования сетей Хопфилда для решения оптимизационных задач.




Рис.1.6. Нейронная сеть Хопфилда

менения весов связей между нейронами.

Существуют различные методы и правила обучения ИНС [13].

**Методы обучения ИНС.** Первое направление классификации методов обучения сетей – по способам использования учителя.

*С учителем.* Сети предъявляются примеры входных данных и выходных. Сеть преобразует входные данные и сравнивает свой выход с желаемым. После этого проводится коррекция весов с целью получить лучшую согласованность выходов.

*Без учителя.* (Обучение с последовательным подкреплением знаний). В этом случае сети не дается желаемое значение выхода, а вместо этого сети ставится оценка, хорош выход или плох. Сети сами вырабатывают правила обучения путем выделения особенностей из набора входных данных.

Второе направление классификации методов обучения – по использованию элементов случайности.

*Детерминистические методы.* В них шаг за шагом осуществляется процедура коррекции весов сети, основанная на использовании текущих их значений, входов сети, выходов нейронов и некоторой дополнительной информации, например, значений желаемых выходов сети. Рассматриваемый далее алгоритм обучения, основанный на обратном распространении ошибки, является примером детерминистического обучения.

*Стохастические методы обучения.* Они основываются на использовании случайных изменений весов в ходе обучения. Рассматриваемый далее алгоритм Больцмановского обучения является примером стохастического обучения.

Таким образом, выше описаны три основных способа организации слоистых структур нейронов в сети. Используя различные сочетания элементов этих структур, можно построить сеть с практически любой из известных к настоящему времени топологий.

**Обучение ИНС.** Процесс обучения нейронной сети состоит в настройке параметров этой сети. При этом, как правило, топология сети считается неизменной, а к подстраиваемым параметрам обычно относятся параметры нейронов и величины весов. К настоящему моменту в литературе принято под обучением понимать процесс изменения

**Правила обучения ИНС.** Правила обучения определяют закон, по которому сеть должна изменять свои веса в процессе обучения.

*Правило Хебба (D.Hebb).* Большинство методов обучения основываются на общих принципах обучения нейросетей, развитых Дональдом Хеббом [54]. Принципы Хебба можно сформулировать следующим образом [13]: «Если два нейрона одновременно активны, увеличьте силу связи между ними», что можно записать как

$$\Delta w_{ij} = gf(y_i)f(y_j),$$

где  $\Delta w_{ij}$  – величина изменения веса  $w_{ij}$ ;  $y_i$  – уровень возбуждения  $i$ -го нейрона;  $y_j$  – уровень возбуждения  $j$ -го нейрона;  $f$  – преобразующая функция;  $g$  – константа, определяющая скорость обучения. Большинство обучающих правил основаны на этой формуле.

*Дельта-правило.* Оно известно, как правило снижения квадратичной ошибки и было предложено в [74]. Дельта-правило используется при обучении с учителем

$$\Delta w_{ij} = g(d_j - y_j)y_i,$$

где  $d_j$  – желаемый выход  $j$ -го нейрона.

Изменения силы связей происходит в соответствии с ошибкой выходного сигнала  $(d_j - y_j)$  и уровнем активности входного элемента  $y_i$ .

Дельта-правило, называемое еще обратным распространением ошибки (Back-Propagation), используется в ИНС с двумя и более слоями.

*ART-правило.* Теория адаптического резонанса (ART) была разработана в [46]. ART – это обучение без учителя, когда самоорганизация происходит в результате отклика на набор входных образцов. ART-сеть способна к классификации образов. ART использует концепцию долговременной и кратковременной памяти для обучения ИНС. В долговременной памяти хранятся реакции на образы, которым сеть была обучена, в виде векторов весов. В кратковременную память помещается текущий входной образ, ожидаемый образ, классификация входного образа. Ожидаемый образ выбирается из долговременной памяти всякий раз, когда на вход ИНС подается новый паттерн (образец). Если они схожи в соответствии с определенным критерием, сеть классифицирует его как принадлежащий к существующему классу. Если они различны, формируется новый класс, в котором входной вектор будет первым членом класса.

Такое обучение называют состязательным обучением. Простейший тип состязательного обучения определяется правилом «победитель берет все». Элемент с наилучшим уровнем активации называют «победителем». Когда он выбран, ИНС добавляет черты вводимого образа в члены долговременной памяти путем повторного прогона вперед-назад через веса долговременной памяти. Этот процесс назван резонансом.

*Правило Кохонена.* Т.Кохонен из Хельсинского технологического института использовал концепцию состязательного обучения для развития обучающего правила «без учителя» в ИНС типа карты Кохонена (см. рис.1.3).

Правило Кохонена заключается в следующем. Сначала выбирается победитель по стратегии «победитель берет все». Поскольку выход  $j$ -го нейрона определяется скалярным произведением  $(X, W_j)$  входного вектора  $X$  с вектором весов связей между входным слоем и  $j$ -м нейроном, то он зависит от угла между векторами  $X, W_j$ . Поэтому выбирается нейрон, вектор весов  $W_j$  которого наиболее близок к входному вектору  $X$  (другими словами, выбирается наиболее активный нейрон). Далее конструируется новый вектор  $W_j$  так, чтобы он был ближе ко входному вектору  $X$ , т.е.

$$w_{ij}^{нов.} = w_{ij}^{стар.} + g(x_i - w_{ij}), \quad i = 1, 2, \dots, k,$$

где  $k$  – количество входов сети,  $g$  – константа обучения (зависит от топологии расстояния до центрального нейрона и уменьшается с количеством входов).

*Больцмановское обучение.* Суть его состоит в подкреплении обученности в соответствии с целевой функцией изменения выхода ИНС. Это обучение использует вероятностную функцию для изменения весов, которая традиционно имеет вид распределения Гаусса, хотя могут использоваться и другие распределения.

Правило Больцмана – это новая концепция обучения, которая часто называется «правилом отжига» – по аналогии со способом обработки металла. Металл нагревается до высокой температуры, а затем медленно охлаждается, позволяя каждой молекуле занять положение с минимальной энергией. Перед началом обучения начальные веса сети распределяются случайным образом.

Больцмановское обучение обычно выполняется в несколько этапов.

1. Искусственной «температуре»  $T$  придают большое начальное значение.
2. Через сеть пропускают входной вектор, и по выходу вычисляют целевую функцию.
3. Случайным образом изменяют вес в соответствии с распределением Гаусса:

$P(z) = \exp(-z^2 / T^2)$ , где  $z$  – изменение веса. Заметим, что величина случайного изменения веса может определяться различными способами, например, с использованием распределения Коши.

4. Снова вычисляют выход и целевую функцию.

5. Если значение целевой функции уменьшилось (улучшилось), то сохраняют изменение веса. Если же нет, и величина ухудшения целевой функции составляет  $\Delta C$ , то вероятность сохранения изменения веса вычисляется следующим образом. Величина  $P(\Delta C)$  – вероятность изменения  $\Delta C$  в целевой функции, определяется с использованием распределения Больцмана

$$P(\Delta C) \approx \exp(-\Delta C / KT),$$

где  $K$  – константа, аналогичная константе Больцмана, выбирается в зависимости от условий задачи,  $T$  – искусственная температура. Затем выбирают случайное число  $U$ , используя равномерное

распределение от нуля до единицы. Если  $P(\Delta C) > U$ , то изменение веса сохраняется, иначе изменение веса равно нулю.

Шаги 3–5 повторяют для каждого из весов сети, при этом постепенно уменьшают температуру  $T$ , пока не будет достигнуто приемлемо низкое значение целевой функции. После этого повторяют весь процесс обучения для другого входного вектора. Сеть обучается на всех векторах, пока целевая функция не станет допустимой для всех них.

В [51] показано, что изменение температуры должно быть обратно пропорционально логарифму времени (чтобы обеспечить сходимость целевой функции к глобальному минимуму).

$$T(t) = T(0) / \log(1 + t),$$

где  $t$  - искусственное время. Этот результат означает, что скорость сходимости целевой функции не велика. Следовательно, время обучения может быть очень большим.

**Алгоритмы обучения ИНС.** Рассмотрим алгоритмы обучения трех основных типов ИНС, описанных выше.

*Обучение сетей прямого распространения.* Для обучения сети нужно знать значение  $d_j$  ( $j = 1, 2, \dots, n$ ) - желаемые выходы, которые сеть должна выдавать при поступлении на ее вход возбуждающего вектора  $X$ .

Согласно методу наименьших квадратов ошибка функционирования сети при этих данных определяется как

$$E_p = \frac{1}{2} \sum_{j=1}^n (y_j - d_j)^2,$$

где  $y_j$  - выход сети,  $p$  - индекс образца в обучающей выборке.

Математическая задача заключается в нахождении таких значений весовых коэффициентов, при которых ошибка функционирования сети для обучающей выборки была бы минимальной:

$$\sum_{i=1}^p E_p \rightarrow \min.$$

Для уменьшения ошибки следует изменить веса сети по следующему правилу:

$$w_{нов.} = w_{стар.} - \eta \frac{\partial E_p}{\partial w}, \quad (1.1)$$

где  $\eta$  - константа, характеризующая скорость обучения ( $0 < \eta < 1$ ). Формула (1.1) описывает процесс градиентного спуска в пространстве весовых коэффициентов. В ней используется градиент функции ошибки и необходима дифференцируемость преобразующей функции.

Значение коррекции весовых коэффициентов в слое  $k$  можно записать в виде:

$$\Delta w_{ij}^{(k)} = -\eta \frac{\partial E_p}{\partial w_{ij}^{(k)}},$$

где  $w_{ij}^{(k)}$  - весовой коэффициент синаптической связи, соединяющей  $i$ -тый нейрон  $(k-1)$  слоя с  $j$ -тым нейроном слоя  $k$ ,  $k = 1, 2, \dots, K$ .

В соответствии с правилом дифференцирования сложной функции:

$$\frac{\partial E_p}{\partial w_{ij}^{(k)}} = \frac{\partial E_p}{\partial y_j^{(k)}} \frac{\partial y_j^{(k)}}{\partial net_j^{(k)}} \frac{\partial net_j^{(k)}}{\partial w_{ij}^{(k)}},$$

где  $y_j^{(k)}$  - выходной сигнал  $j$ -того нейрона  $k$ -го слоя,  $net_j^{(k)}$  - состояние (взвешенная сумма входных сигналов)  $j$ -того нейрона  $k$ -го слоя.

Введем новую переменную

$$\delta_j^{(k)} = \frac{\partial E_p}{\partial y_j^{(k)}} \frac{\partial y_j^{(k)}}{\partial net_j^{(k)}}.$$

Тогда для  $j$ -го нейрона выходного  $K$ -го слоя получаем

$$\delta_j^{(K)} = (y_j^{(K)} - d_j) f'(net_j^{(K)}), \quad (1.2)$$

затем, используя полученный результат, можно пересчитать  $\delta_j^{(k)}$  младших слоев:

$$\delta_j^{(k)} = f'(net_j^{(k)}) \left[ \sum_{m=1}^{N^{(k+1)}} \delta_m^{(k+1)} w_{jm}^{(k+1)} \right], \quad k=1, 2, \dots, K-1 \quad (1.3)$$

где  $N^{(k+1)}$  - число нейронов в  $(k+1)$  слое,  $m$  - номер нейрона в  $(k+1)$  слое.

Теперь записываем формулу для коррекции весовых коэффициентов:

$$\Delta w_{ij}^{(k)} = -\eta \delta_j^{(k)} y_i^{(k-1)}. \quad (1.4)$$

Эти соотношения называются формулами обратного распространения ошибки (Back-Propagation). Если при прямом функционировании входной сигнал распространяется по сети от входного слоя к выходному, то при подстройке весов ошибка сети распространяется от выходного слоя ко входному.

Алгоритм обучения нейронной сети при этом строится следующим образом [20]:

Шаг 1: Подать на входы сети один из образцов входного вектора и рассчитать значения выходных сигналов скрытых и выходного слоев.

Шаг 2: Вычислить для выходного слоя  $\delta_j^{(K)}$  по формуле (1.2) и изменения весов  $\Delta w_{ij}^{(K)}$  по формуле (1.4) при  $k = K$ .

Шаг 3: Рассчитать  $\delta_j^{(k)}$  и  $\Delta w_{ij}^{(k)}$  по формулам (1.3), (1.4) для всех остальных слоев начиная с  $(k-1)$ -го и кончая входным слоем.

Шаг 4: Скорректировать все весовые коэффициенты в нейронной сети:

$$w_{ij}^{(k)}(t) = w_{ij}^{(k)}(t-1) + \Delta w_{ij}^{(k)}(t),$$

где  $t$  - номер итерации.

Шаг 5: Найти ошибку для рассматриваемого образца и добавить к сумме ошибок всей выборки. Если есть еще образцы, то повторить все вычисления с шага 1. Иначе, если все образцы рассмотрены и суммарная ошибка существенна, то повторить все вычисления с шага 1 для обучающей выборки, начиная с первого образца, в противном случае – конец алгоритма.

*Обучение сетей Кохонена (построение карт признаков).* Для построения карты Кохонена требуется достаточно представительная выборка обучающих векторов признаков  $\{X\}$ . Пусть каждый вектор  $X$  множества  $\{X\}$  имеет размерность  $k$ :  $X=(x_1, x_2, \dots, x_k)$ . Тогда первый (распределительный) слой сети Кохонена должен иметь  $k$  нейронов;  $n$  нейронов второго слоя (карты) располагаются на плоскости в какой-либо регулярной конфигурации, например, на квадратной прямоугольной сетке (см. рис.1.4). Настраиваемым связям между нейронами первого и второго слоев  $w_{ij}$  присваиваются случайные значения. Здесь индекс  $i$  обозначает номер нейрона первого слоя, индекс  $j$  - номер нейронов второго слоя. До начала обучения задают функцию влияния нейронов второго слоя друг на друга  $g(r,t)$ , где  $r$  - расстояние между нейронами,  $t$  - параметр, характеризующий время обучения. Эта функция традиционно имеет вид «мексиканской шляпы» (см. рис. 1.5), которую в процессе обучения по мере увеличения параметра  $t$  делают более «узкой». Однако часто используют более простые функции, например

$$g(r,t) = \begin{cases} 1, & r < D/t, t=1,2,3,\dots \\ 0, & \text{в противном случае} \end{cases},$$

где  $D$  - константа, характеризующая начальный радиус положительного пика «мексиканской шляпы». Каждый цикл обучения заключается в поочередном предъявлении сети векторов обучающего множества с последующей корректировкой весов  $w_{ij}$ . Корректировка осуществляется следующим образом:

1) при появлении на входе сети очередного обучающего вектора  $X$  сеть вычисляет отклик нейронов второго слоя:

$$y_j = \sum_{i=1}^k w_{ij} x_i, \quad j=1,2,\dots,n;$$

2) выбираем нейрон-победитель (т.е. нейрон с наибольшим откликом). Его номер  $C$  определяется как

$$C = \arg \max y_j, \quad j=1,2,\dots,n;$$

3) корректировка весов связей  $w_{ij}$  осуществляется по следующей формуле:

$$w_{ij}^{\text{нов}} = w_{ij}^{\text{стар}} + a \cdot g(r,t)(x_i - w_{ij}^{\text{стар}}), \quad i=1,2,\dots,k; \quad j=1,2,\dots,n.$$

Здесь  $a$  - константа, характеризующая скорость обучения. Если после очередного цикла обучения процесс изменения весов замедлился, увеличивают параметр  $t$ .



*Обучение сетей Хопфилда.* Здесь следует выделить два случая, связанные с последующим использованием сети.

1. Сеть будет использоваться как ассоциативная память [74].

Пусть имеется набор из  $m$  двоичных сигналов  $V^k$ ,  $k = 1, 2, \dots, m$  размерности  $n$ :  $V^k = \{v_1^k, v_2^k, \dots, v_n^k\}$ . Сеть должна из зашумленного сигнала  $X = \{x_1, x_2, \dots, x_n\}$ , представленного на ее вход, определить соответствующий образец или сделать вывод, что входной сигнал не отвечает ни одному из образцов. Если сеть распознает («вспомнит»)  $k$ -ый образец, ее выходы будут содержать именно его, т.е.  $Y = V_k$ , где  $Y$  – вектор выходных значений сети  $Y = \{y_1, y_2, \dots, y_n\}$ .

Для рассматриваемой сети формула Ляпунова может иметь следующий вид:

$$E_h = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} y_i y_j - \sum_{j=1}^n x_j y_j + \sum_{j=1}^n \theta_j y_j, \quad (1.5)$$

где  $E_h$  – «энергия» сети Хопфилда,  $w_{ij}$  – весовой коэффициент от выхода  $i$ -го нейрона ко входу  $j$ -го нейрона,  $x_j$ ,  $y_j$  – вход и выход  $j$ -го нейрона,  $\theta_j$  – смещение  $j$ -го нейрона.

После очередной итерации изменение энергии сети [20] составит

$$\Delta E_h = -\sum_{j=1}^n \left[ \sum_{i \neq j} (w_{ij} y_i) + X_j - \Theta_j \right] \Delta y_j,$$

где  $\Delta y_j$  – изменение выхода  $j$ -го нейрона. Отсюда следует, что изменение состояния нейронов либо уменьшит значение  $E$ , либо оставит его без изменения. Во втором случае сеть достигает устойчивого состояния и «вспоминает» образец, соответствующий входному вектору.

2. Сеть будет использоваться для решения задачи оптимизации. Это возможно в случае, когда задачу можно сформулировать как поиск минимума энергетической функции (1.5).

Главное свойство функции энергии сети состоит в том, что при изменении состояния нейронной сети она уменьшается и достигает локального минимума, в котором сохраняет постоянную энергию. Чтобы сети Хопфилда понесли глобальный минимум, рассматриваются статические сети Хопфилда [20].

Задача исследователя состоит в формулировке исходной оптимизационной проблемы в терминах нейросети и затем минимизируемого функционала  $E_h$ . Полученное для  $w_{ij}$  выражение дает значение весовых множителей. В результате функционирования сеть придет в равновесное состояние, которое соответствует локальному минимуму функционала  $E_h$ . Величины возбужденности нейронов при этом соответствуют значениям аргументов, на которых достигается минимум.

Следует заметить, что модель Хопфилда имеет два ограничения. Во-первых, ограничено количество хранимых и вызываемых образов. Во-вторых, связи между хранимыми образами могут привести к определению распознаваемого образа, не совпадающему с искомым. Этот эффект называется проблемой ложного локального минимума.

Итак, в результате рассмотрения основных типов нейронных сетей, можно дать краткую характеристику этим сетям с точки зрения областей их применения. Сети прямого распространения (персептроны) можно использовать для решения задач распознавания, классификации, прогнозирования и идентификации. Самоорганизующиеся карты Кохонена – для задач кластеризации, распознавания и классификации. Применение однослойных сетей Хопфилда связано со способностью этих сетей запоминать, а затем восстанавливать различные образы, даже по неполной входной информации, а также для решения оптимизационных задач.

## 1.2. Нечеткие множества

Понятие нечеткого множества было введено Л. Заде в 1965 г. Оно основывается на предположении о том, что любой элемент лишь в некоторой степени принадлежит данному множеству, поэтому одним из основных способов математического описания нечеткого множества является определение степени такой принадлежности некоторым числом, например, из интервала  $[0,1]$ . При этом границы интервала, т.е. 1 и 0, означают, соответственно, «принадлежит» и «не принадлежит». Заде определил также ряд операций над нечеткими множествами и предложил обобщение некоторых методов логического вывода.

Математическая теория нечетких множеств позволяет описывать нечеткие понятия, оперировать нечеткими знаниями и делать нечеткие выводы. Обработка нечеткой информации и нечеткий вывод давно применяются в различных интеллектуальных системах, однако наиболее широкое распространение нечеткие множества получили в области управления.

Общая схема обработки нечеткой информации выглядит следующим образом. Точные исходные данные с датчиков, контролирующих управляемый процесс, переводятся в значения лингвистических переменных в специальном блоке, получившем название «фаззификатор». Далее реализуются процедуры нечеткого вывода на множестве продукционных правил, составляющих базу знаний системы управления, в результате чего формируются выходные лингвистические значения. Последние переводятся в точные значения результатов вычислений в специальном блоке, получившем название «дефаззификатор». На выходе последнего формируются управляющие воздействия на исполнительные механизмы. Эта концептуальная схема лежит в основе так называемого нечеткого контроллера, используемого в интеллектуальных системах обработки неопределенной информации, в частности, в системах интеллектуального управления.

Несмотря на кажущуюся простоту и удобство этой схемы вычислений, получаемые результаты не всегда являются удовлетворительными. Главная причина состоит в том, что с помощью операций нечеткой алгебры не всегда удается построить эффективные вычислительные процедуры на множестве нечетких величин. Трудности возрастают с увеличением числа лингвистических пе-

ременных. Применение тех или иных операций нечеткой алгебры в ряде случаев зависит от используемых входных данных. Кроме того, операторы нечеткой алгебры недостаточно полно отражают смысл многозначных лингвистических преобразований термов лингвистических переменных [36]. Не всегда оправданы по смыслу используемые методы дефаззификации и результаты выполнения соответствующих процедур. Отмеченные недостатки приводят к тому, что результатам обработки нечеткой информации часто ставится в соответствие лишь область подходящих значений, а не конкретные величины. Поэтому полученные результаты обработки нечеткой информации (так же как и используемые механизмы нечеткого вывода) подлежат дальнейшему уточнению на этапе моделирования.

В течение последнего десятилетия проводятся активные исследования по применению теории нечетких множеств в системах автоматического управления, к одному из направлений которых можно отнести и наши исследования по прогнозированию нагрузки. Количество литературы по нечеткому управлению растет очень быстро, поэтому очень трудно сделать исчерпывающий обзор из-за большого разнообразия применения нечеткой логики в системах управления. Наиболее важные исторические вехи в развитии нечеткого управления приведены в [63].

**Основные понятия теории нечетких множеств.** Рассмотрим вначале понятия нечеткой и лингвистической переменных, которые используются при описании сложных объектов и явлений.

*Нечеткая переменная* описывается набором из трех элементов  $\langle A, X, C_A \rangle$ , где  $A$  – наименование нечеткой переменной;  $X = \{x\}$  – область ее определения (универсальное множество);  $C_A = \{\langle \mu_A(x)/x \rangle\}$  – нечеткое множество на  $X$ , описывающее ограничения на возможные значения нечеткой переменной  $A$  (ее семантику) [23].

*Лингвистическая переменная* описывается набором из пяти элементов  $\langle B, T, X, G, M \rangle$ , где  $B$  – наименование лингвистической переменной;  $T$  – множество ее значений (терм-множество), представляющих собой наименования нечетких переменных, областью определения каждой из которых является множество  $X$ . Множество  $T$  называется базовым терм-множеством лингвистической переменной;  $G$  – синтаксическая процедура (грамматика), позволяющая оперировать элементами терм-множества  $T$ , в частности, генерировать новые осмысленные термы;  $M$  – семантическая процедура, позволяющая превратить каждое новое значение лингвистической переменной, образуемое процедурой  $G$ , в нечеткую переменную, т.е. приписать ему нечеткую семантику путем формирования соответствующего нечеткого множества [23]. Например, если *напряжение* интерпретируется как лингвистическая переменная, то ее терм-множество  $T$  (*напряжение*) может быть  $T$  (*напряжение*) = {низкое, среднее, высокое, очень низкое, более или менее высокое, ...}, где каждый терм в  $T$  (*напряжение*) характеризуется нечетким множеством в универсальном множестве  $X = [0, 100]$ . Мы можем интерпретировать «низкое» как «напряжение ниже 40 В», «среднее» как «напряжение близкое к 55 В» и «высокое» как «напряжение выше 70 В».

*Нечетким множеством*  $A$  на множестве  $X$  называется совокупность пар вида [27, 63]  $A = \{ (x, \mu_A(x)) | x \in X \}$ , где  $\mu_A$  – функция принадлежности, принимающая значения в интервале  $[0, 1]$ , т.е.  $\mu_A : X \rightarrow [0, 1]$ . Когда  $X$  непрерывно, то нечеткое множество  $A$  может быть кратко описано как  $A = \int_x \mu_A(x) / x$ . В случае дискретного  $X$ , нечеткое множество  $A$  представляется как  $A = \sum_{i=1}^n \mu_A(x_i) / x_i$ .

*Носителем нечеткого множества*  $A$  называется множество таких точек в  $X$ , для которых величина  $\mu_A(x)$  положительна. Точкой перехода нечеткого множества  $A$  называется такой элемент множества  $X$ , степень принадлежности которого множеству  $A$  равна 0,5, т.е.  $\mu_A(x) = 0,5$ . Высотой нечеткого множества  $A$  называется величина  $\sup_{x \in X} \mu_A(x)$ .

*Нечеткое множество*  $A$  называется *нормальным*, если выполняется условие  $\sup_{x \in X} \mu_A(x) = 1$ .

Далее будем рассматривать только нормальные нечеткие множества, так как если нечеткое множество не нормально, то его всегда можно превратить в нормальное, разделив все значения функции принадлежности на ее максимальное значение.

Операции над нечеткими множествами. Пусть  $A$  и  $B$  – два нечетких множества, заданных на универсальном множестве  $X$  с функциями принадлежности  $\mu_A$  и  $\mu_B$ . Рассмотрим основные операции над нечеткими множествами, которые будут использоваться в дальнейшей работе по построению моделей прогнозирования нагрузки.

*Объединение:* Функция принадлежности  $\mu_{A \cup B}$  при объединении  $A$  и  $B$  для всех  $x \in X$  определяется как [62]  $\mu_{A \cup B}(x) = \max \{ \mu_A(x), \mu_B(x) \}$ .

*Пересечение:* Функция принадлежности  $\mu_{A \cap B}$  при пересечении  $A$  и  $B$  определяется как [62]  $\mu_{A \cap B}(x) = \min \{ \mu_A(x), \mu_B(x) \}$ .

Существуют другие способы определения объединения и пересечения. Например, для операции пересечения – использование алгебраического произведения их функций принадлежности  $\mu_{A \cap B}(x) = \mu_A(x) \times \mu_B(x)$ ,  $x \in X$ , и среднего геометрического  $\mu_{A \cap B}(x) = \sqrt{\mu_A(x) \times \mu_B(x)}$ ,  $x \in X$ .

*Дополнение или отрицание:* Функция принадлежности  $\mu_{\bar{A}}$  дополнения нечеткого множества  $A$  для всех  $x \in X$  будет  $\mu_{\bar{A}}(x) = 1 - \mu_A(x)$  [62]. Эта операция удобна, например, для перехода от нечеткого множества допустимых режимов к нечеткому множеству недопустимых режимов.

Для практических задач большое значение приобретает введение понятия *нечеткого отношения*. Пусть  $X_1, X_2, \dots, X_n$  некоторые множества. Тогда отношение  $Q$  между ними определяется как подмножество их декартового произведения. При  $X_1 = X_2 = \dots = X_n$  это определение совпадает с

определением обычного  $n$ -мерного ( $n$ -арного) отношения  $Q$  на  $X$ , интерпретируемого как подмножество декартового произведения  $X_n$ .

*Декартово произведение нечетких множеств.* Если  $A_1, A_2, \dots, A_n$  - нечеткие множества, определенные, соответственно, на  $X_1, X_2, \dots, X_n$ , то декартовым произведением нечетких множеств  $A_1, A_2, \dots, A_n$  называется множество с функцией принадлежности  $\mu_{A_1 \times \dots \times A_n}(x_1, x_2, \dots, x_n) = \min\{\mu_{A_1}(x_1), \dots, \mu_{A_n}(x_n)\}$  или

$$\mu_{A_1 \times \dots \times A_n}(x_1, x_2, \dots, x_n) = \mu_{A_1}(x_1) \times \mu_{A_2}(x_2) \times \dots \times \mu_{A_n}(x_n).$$

Другие операции над нечеткими множествами достаточно подробно описаны в [3, 23, 62].

**Логика принятия решения.** Нечеткая логика, на которой основываются разработки, приведенные в этой монографии, по своей характеристике более близка человеческим мыслям, чем традиционные логические системы. Существенную часть ее занимают правила нечеткого условного вывода, называемого F-Conditional Rules Inference. Это обстоятельство связано с тем, что в семантике обычного языка присутствует определенное число нечетких понятий (F-понятий), поэтому делаются логические выводы, в которых предпосылки и следствие включают такие F-понятия. Формализация правил для таких выводов может быть чрезвычайно разнообразна. Однако подобные выводы не могут быть удовлетворительно формализованы, базируясь на классической булевой логике, т.е. для этой цели становится необходимым использование многозначных логических систем. Правила условного логического вывода охватывают, в основном, три вида условных предложений:

$P1 =$  ЕСЛИ  $x$  есть  $A$ , ТО  $y$  есть  $B$ ;

$P2 =$  ЕСЛИ  $x$  есть  $A$ , ТО  $y$  есть  $B$  ИНАЧЕ  $C$ ;

$P3 =$  ЕСЛИ  $x_1$  есть  $A_1$  и  $x_2$  есть  $A_2$  и ...  $x_n$  есть  $A_n$ , ТО  $y$  есть  $B$ .

Концептуальной основой формализации правил условного логического вывода является правило отделения (*modus ponens*), гласящее:

ЕСЛИ  $(A \rightarrow B)$  истинно и  $A$  истинно, ТО  $B$  истинно.

В свою очередь, методологической основой такой формализации является композиционное правило, предложенное Л.Заде [73]. Используя это правило, он сформулировал некоторые правила вывода, в которых логические предпосылки и следствия являются условными предложениями, включающими  $F$ -концепцию. Иными словами, рассматривается  $F$ -условный вывод следующей формы:

Предпосылка 1: ЕСЛИ  $x$  есть  $A$ , ТО  $y$  есть  $B$ ;

Предпосылка 2:  $x$  есть  $A'$ ;

Следствие:  $y$  есть  $B'$ ,

где  $A$  и  $A'$  –  $F$ -концепции, представленные как  $F$ -множества в универсуме  $U$ ;  $B$  –  $F$ -концепция или  $F$ -множество в универсуме  $V$ . Откуда  $B'$  является следствием, представленным как  $F$ -множество в  $V$ .

Исследование свойств и формализация правил  $F$ -условного логического вывода для условных предложений вида  $P_1, P_2$  и  $P_3$  приведено в [23].

**Определение функций принадлежности.** Прежде чем рассматривать предложенные к настоящему времени основные способы определения функций принадлежности нечетких множеств, задающих ограничения на возможные значения нечетких переменных, кратко остановимся на содержательной интерпретации степени принадлежности элемента нечеткому множеству.

Существует несколько точек зрения на содержательную интерпретацию функции принадлежности. В большинстве известных работ по исследованию и применению теории нечетких множеств считается, что функция принадлежности – это некоторое невероятностное субъективное измерение нечеткости и что она отличается от вероятностной меры [25]. В противовес этому в отдельных работах на основании формального определения функции принадлежности и операции дополнения нечеткого множества дана следующая ее интерпретация: величина  $\mu_A(x)$  есть условная вероятность наблюдения события  $A$  при наблюдении  $x$ . Однако о происхождении величин  $\mu_A(x)$  ничего не говорится. Кроме этого, не указывается, какой именно тип вероятности (т.е. какая именно интерпретация) имеется в виду.

В работе [25] степень принадлежности  $\mu_A(x)$  элемента  $x$  нечеткому множеству  $A$  интерпретируется как субъективная мера того, насколько элемент  $x \in X$  соответствует понятию, смысл которого формализуется нечетким множеством  $A$ . Под субъективной мерой, как правило, понимается определенная опросом экспертов степень соответствия элемента  $x$  понятию, формализуемому нечетким множеством  $A$ .

Более или менее обоснованное построение функции принадлежности нечеткого подмножества  $A$  множества  $X$  возможно лишь при условии смысловой интерпретации этого множества. Существуют два метода определения функции принадлежности [62]: числовой и функциональный (в зависимости от того, какое нечеткое множество, дискретное или непрерывное).

1. *Числовой метод определения.* В этом случае функция принадлежности нечеткого множества изображается как вектор чисел, размерность которого зависит от степени дискретизации. Функция принадлежности нечеткого множества в этом случае имеет примерный вид

$$\mu_f(x) = \sum_{i=1}^5 a_i / x_i, \text{ где } a = [0,3; 0,7; 1,0; 0,7; 0,3].$$

2. *Функциональный метод.* Функция принадлежности в функциональной форме типично описывается либо колоколообразной, либо треугольной, либо трапециевидной функциями. Такие

функции широко используются в нечетких системах управления. Функциональное определение может быть легко адаптировано к изменению универсального множества.

Примером функционального метода может быть функция принадлежности, выраженная колоколообразной функцией:

$$\mu_f(x) = \exp \left\{ - \left( \frac{x - u_f}{\delta_f} \right)^{2b_f} \right\}.$$

Это обобщенная функция Гаусса, которая оперирует тремя параметрами  $u_f$ ,  $\sigma_f$  и  $b_f$ . Параметр  $u_f$  определяет центр нечеткого множества, его изменение соответствует смещению функции по горизонтальной оси (рис. 1.7а). Параметр  $\sigma_f$  влияет на форму функции: чем меньше его значение, тем уже график функции (рис. 1.7б). Значение параметра  $b_f$  также влияет на форму кривой (рис. 1.7в) [29]. Часто применяется на практике и симметричная треугольная функция (рис.1.8):

$$\mu_f(x) = \begin{cases} 1 - \frac{|x - u_f|}{d} & \text{для } x \in [u_f - d, u_f + d] \\ 0 & \text{в остальных случаях} \end{cases}.$$

Эта функция нормирована и принимает единичное значение при  $x = u_f$  (в центральной точке графика). Треугольную функцию можно получить из трапецевидной (рис. 1.9) при  $t = 0$ , которая описывается следующей зависимостью:

$$\mu_f(x) = \begin{cases} 0 & \text{для } x > z \text{ или } x < y \\ 1 & \text{для } c - \frac{t}{2} \leq x \leq c + \frac{t}{2} \\ s(z - x) & \text{для } c + \frac{t}{2} \leq x \leq z \\ s(z - y) & \text{для } y \leq x \leq c - \frac{t}{2} \end{cases},$$

где  $s$  - угол наклона,  $y = u_f - \frac{t}{2} - \frac{1}{s}$ ,  $z = u_f + \frac{t}{2} + \frac{1}{s}$  [29].

Для определения степени принадлежности к нечеткому множеству может быть использован и числовой, и функциональный методы. Выбор степени принадлежности основывается на субъективном критерии принятия решения. Если измеряемые данные могут быть искажены шумом, функцию принадлежности следует значительно расширить, чтобы уменьшить чувствительность к шуму. Более детально этот вопрос обсуждается в [61].

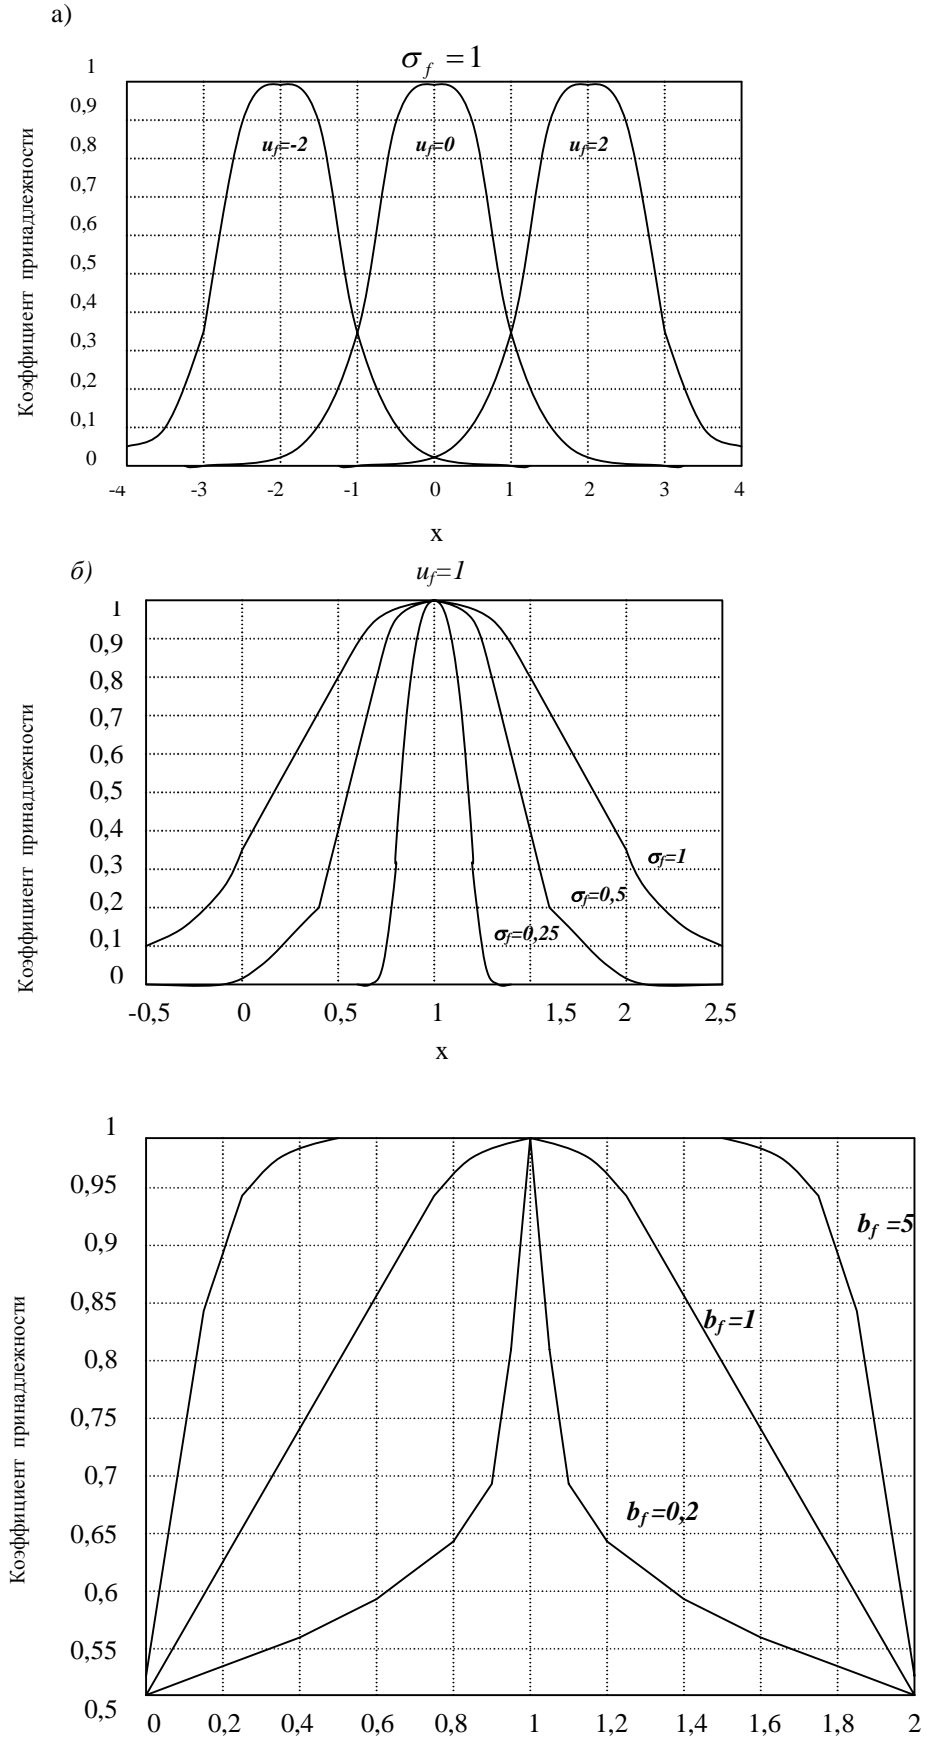


Рис.1.7. Влияние параметров гауссовской функции на ее форму:  
 а) влияние  $u_f$  при  $\sigma_f = 1$ ; б) влияние  $\sigma_f$  при  $u_f = 1$ ;  
 в) влияние  $b_f$  при  $u_f = 1, \sigma_f = 1$ .






Рис.1.8 Треугольная функция принадлежности




Рис. 1.9. Трапецевидная функция принадлежности

### 1.3. Нечеткие нейронные сети

*Нечеткие нейронные сети* (ННС) или так называемые Fuzzy Neural Network, получили свое название в силу того, что в них используются выражения, заимствованные из нечетких систем, оперирующих нечеткими множествами. Рассмотрим схематически, как воплощаются в практику рассмотренные ранее теоретические положения нечетких множеств. На рис.1.10 изображена основная конфигурация схемы управления на основе нечеткой логики. Она включает в себя четыре основных блока [61]: блок фаззификации (*fuzzification*), база знаний, блок логики принятия решения и блок дефаззификации (*de-fuzzification*).

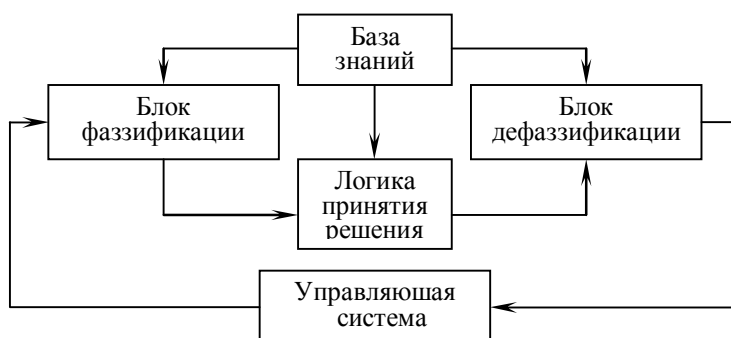


Рис.1.10. Конфигурация схемы управления

*Блок фаззификации* выполняет следующие функции:

- измерение значений входных переменных;
- нормализация (или масштабирование) входных переменных;
- осуществление непосредственно самой функции фаззификации, т.е. преобразование входных данных в лингвистические переменные, которые могут быть представлены как нечеткие множества, используя функцию принадлежности.

*База знаний.* Содержит базу данных и базу лингвистических (нечетких) правил управления.

*Блок логики принятия решения.* Этот блок является как бы сердцевинной схемой. Он обладает способностью принимать решение, основанное на использовании правил нечеткого условного вывода.

*Блок дефаззификации* выполняет следующие функции:

- преобразование нормализованных выходных значений в реальные;
- дефаззификация, которая из нечеткого (*fuzzy*) действия делает четкое (*nonfuzzy*).

Известно несколько нечетких нейронных сетей, таких как сети Мамдани-Заде, Такаги-Сугено-Канга, Ванга-Менделя [29] и др. [20, 66].

За основу ННС для прогнозирования нагрузок была взята наиболее простая, с точки зрения реализации, трехслойная сеть, предложенная Н. Kitajima, М. Nagiуara [55], структура которой приведена на рис. 1.11. Первый слой - «вход-выход», второй - слой правил «ЕСЛИ», третий – слой правил «ТО». Каждая пара узлов в слоях правил представляет собой нечеткое правило. Узлы, изображенные в виде квадратов, представляют собой операционные узлы, состоящие из более, чем одного узла. Из таких операционных узлов состоят выходная часть в слое «вход-выход» и оба слоя правил. Рассмотрим, какие операции выполняются в этих операционных узлах.

*Слой «ЕСЛИ»* (рис. 1.12, а). Вычисление функции принадлежности для каждой входной переменной и результирующей по каждому правилу.

*Слой «ТО»* (рис. 1.12, б). Вычисление результатов каждого нечеткого правила.

*Выходная часть слоя «вход-выход»* (рис. 1.12, в). Вычисление результата по всей системе (формирование четкого вывода).

## 1.4. Инверсия нейронной сети прямого распространения

Инверсия нейронной сети – процесс нахождения входного вектора для получения желаемого выхода при установленном наборе синаптических весов. Имеется много методов для выполнения инверсии нейронной сети. В работе [59] дан обзор существующих методологий инверсии ИНС, которая используется в качестве инструмента для решения различных проблем.

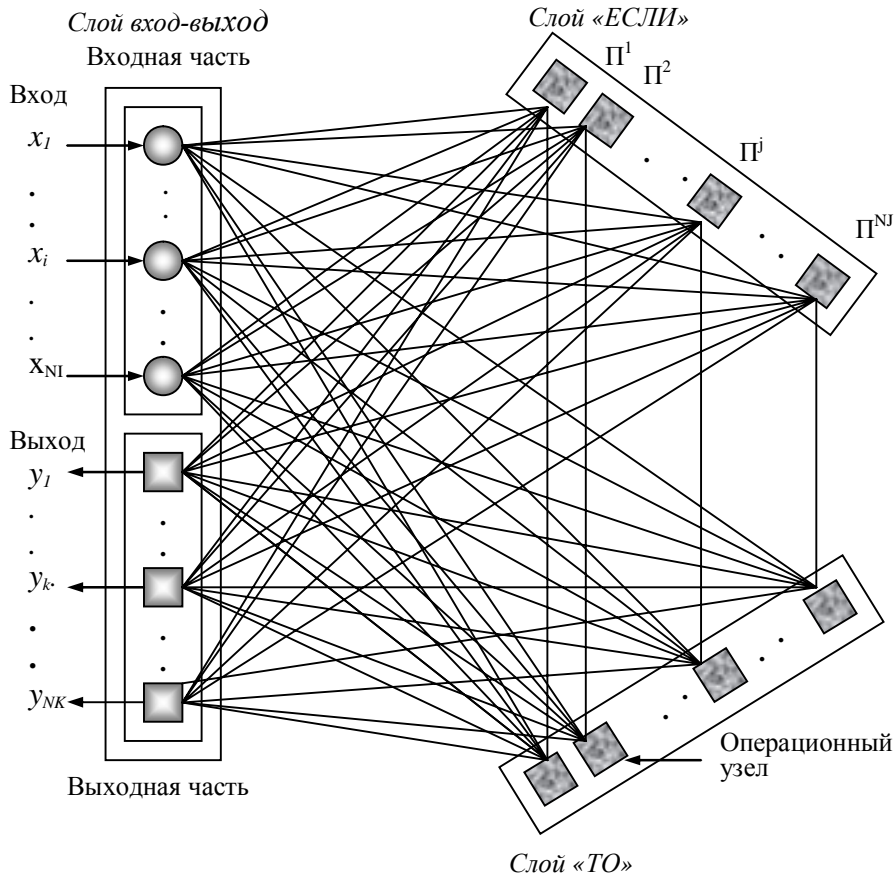


Рис. 1.11. Структура нечеткой нейронной сети

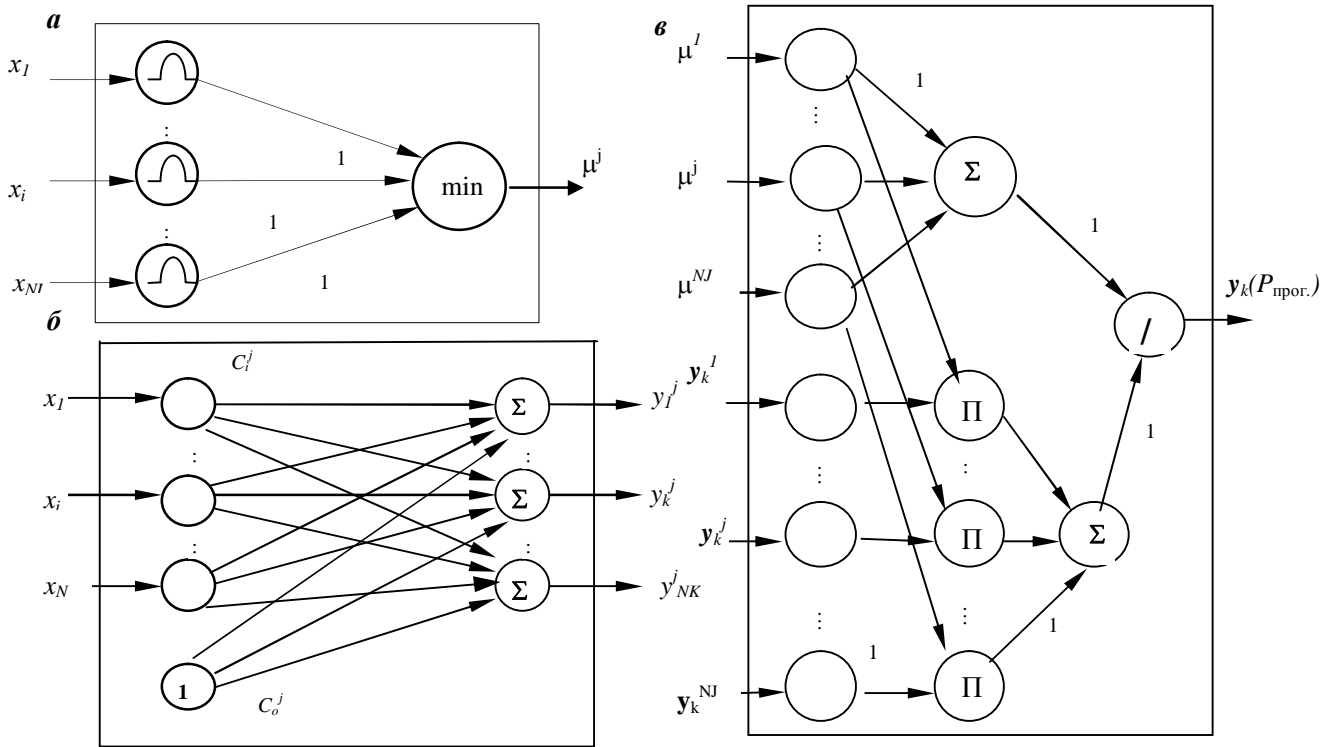


Рис. 1.12. Внутренняя структура операционных узлов: а) операционный узел  $j$  в слое «ЕСЛИ»; б) операционный узел  $j$  в слое «ТО»; в) операционный узел  $k$  в выходной части слоя «Вход-Выход»

Работа обученной нейронной сети может быть описана выражением

$$Y_k = f_k(X, W), \quad (1.6)$$

где  $Y_k$  -  $k$ -ый выход нейронной сети, соответствующий входному вектору  $X$ ,  $W$  – вектор весовых коэффициентов и  $f_k(\cdot)$  – функция преобразования входного вектора при прохождении его через сеть от входа до  $k$ -го выхода.

Применение метода инверсии нейронной сети состоит из двух этапов:

- 1) обучение ИНС для получения весовых коэффициентов;
- 2) непосредственно инверсия ИНС.

На первом этапе нейронную сеть обучают, устанавливая вход и выход и пересчитывая веса до тех пор, пока приемлемый результат не будет достигнут. Если рассматривают задачу с единственным скалярным выходом, то  $Y_k$  может быть заменено на  $Y$  и  $f_k(\cdot)$  на  $f(\cdot)$  в уравнении (1.6).

Для второго этапа веса нейронной сети принимаются фиксированными, и теперь функция  $f(\cdot)$  будет зависимостью только от входного вектора  $X$ .

В общем, как проиллюстрировано на рис.1.13 для двух входов  $x_1$  и  $x_2$  ( $X = [x_1, x_2]^T$ ) и одного выхода  $f(X)$ , многочисленные различные входы могут генерировать тот же самый выход. Каждый контур графика на рис.1.13 соответствует  $f(X)=D$  для различных постоянных  $D$ . Инверсия обычно не является единственной, когда размерность входа больше, чем размерность выхода. Она состоит для данного  $D$  в нахождении одного или более элементов входного множества  $\Lambda$  на контуре (или множестве непересекающихся контуров), где

$$\Lambda = \{X : f(X) = D\}.$$

В зависимости от применения инверсия нейронной сети прямого распространения сосредоточена на нахождении: 1) какой-либо точки решения в  $\Lambda$ ; 2) точки или точек в  $\Lambda$ , которая или которые подчиняются одному или более ограничений, или 3) ряда равномерно рассеянных точек в  $\Lambda$ .




Рис.1.13. Инверсия нейронной сети с множеством решений

Задачу инверсии для единичной выборки можно сформулировать следующим образом:

$$E = \frac{1}{2}(f(X) - D)^2 \rightarrow \min .$$

Необходимо найти  $\Lambda$  или его подмножество, которое дает наименьшую погрешность  $E$  для указанного  $D$ . Алгоритм второго этапа инверсии представлен на рис. 1.14.

Алгоритмы инверсии нейронной сети могут быть разделены на три широких класса:

- исчерпывающий поиск [49];
- методы поиска единственного элемента [58, 62, 68];
- эволюционные методы [50, 65].

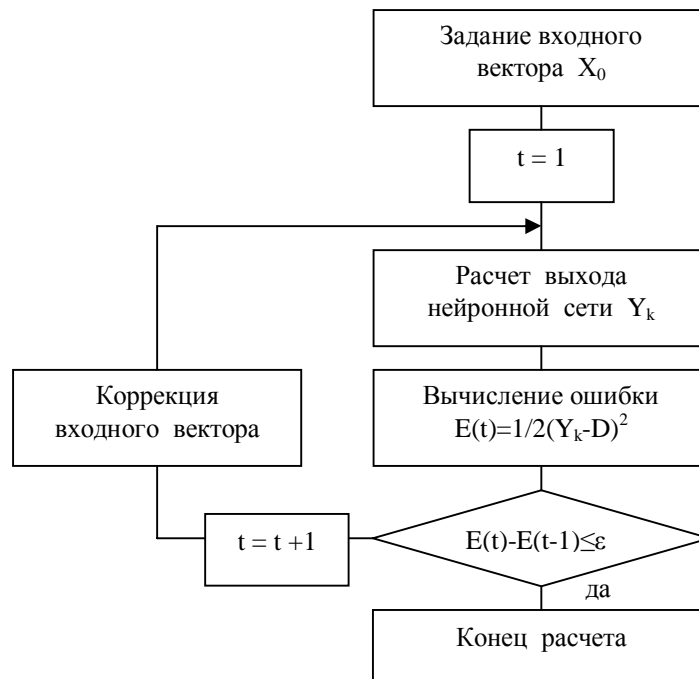


Рис.1.14. Алгоритм инверсии нейронной сети

При выборе методов инверсии исчерпывающий поиск следует рассматривать, когда и размерность входа и допустимый диапазон каждой входной переменной малы. Простота подхода, связанная с быстротой, с которой персептрон может работать, делает этот подход даже более привлекательным. В поиске единственного элемента решением является только одна точка на  $\Lambda$ , которая при этом обычно зависима от инициализации. Эволюционные методы стремятся минимизировать целевую функцию, используя множество точек поиска на  $\Lambda$  или близлежащие к  $\Lambda$ .

Для прогнозирования нагрузки хорошо подходит инверсия сети с единственным элементом через градиентный подход, предложенный Williams [68] и позже Linden и Kinderman [69]. Эти методы используют стандартную оптимизацию по методу обратного распространения ошибки.

Поиск начинается с входного вектора  $X^0$ . Если  $x_k^t$  –  $k$ -ая компонента вектора  $X^t$ , то градиентный спуск предлагает рекурсию:

$$x_k^{t+1} = x_k^t - \eta \frac{\partial E}{\partial x_k^t},$$

где  $\eta$  – размер шага и  $t$  – индекс итерации.

Обозначим  $\delta_k^t = \frac{\partial E}{\partial x_k^t}$ . Тогда для входного и скрытых слоев

$$\delta_k = Y_k(1 - Y_k) \cdot \sum_j \delta_j w_{kj}, \quad (1.7)$$

где  $Y_k$  –  $k$ -ая компонента выхода нейронов в рассматриваемом слое;  $w_{kj}$  – весовые коэффициенты между нейронами рассматриваемого и последующего слоев.

Для выходного слоя:

$$\delta_j = (D_j - Y_j)Y_j(1 - Y_j). \quad (1.8)$$

Выходы нейронов каждого слоя вычисляются по формулам:

$$Y_k = 1/(1 + e^{-(net_k + \theta_k)}),$$

$$net_k = \sum_j w_{kj} Y_j,$$

где  $\theta_k$  – смещение,  $Y_j$  – выходы предыдущего слоя.

Заметим, что производные  $\delta_j$  нейронов в (1.7, 1.8) должны быть вычислены в обратном порядке – от выхода к входу, подобно стандартному алгоритму обратного распространения.

## Глава 2

### Методы и модели прогнозирования электрических нагрузок ЭЭС с применением искусственных нейронных сетей

Анализ типов нейронных сетей, приведенный в 1-й главе, показывает, что для решения задач прогнозирования наиболее приемлемыми (и наиболее используемыми) являются сети прямого распространения (многослойные персептроны), изображенные в общем виде на рис.1.3. Здесь следует заметить, что авторы не претендуют на полноту проведенного анализа, предполагая, что возможно использование и других типов нейронных сетей для целей прогнозирования электрических нагрузок. Например, есть примеры использования сети Кохонена для краткосрочного прогнозирования нагрузки [31, 45], для классификации типов дней по нагрузке [18, 31]. Сети Хопфилда, по их принципу действия, можно использовать для восстановления графиков нагрузки и т.д.

При выборе структуры ИНС важно учитывать ее размерность, т.е. количество 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, превышающем сложность решаемой задачи, процесс обучения ИНС будет длительным или сеть вообще может быть непригодна для решения данной задачи. Этот вопрос в каждом конкретном случае решается экспериментальным путем, с использованием в качестве критерия минимальной погрешности прогноза.

#### 2.1. Внутрисуточное прогнозирование

Временной диапазон прогнозирования в пределах суток выбран с учетом того, что с 1 сентября 2006 г. запущена новая либерализованная модель оптового и розничных рынков электроэнергии / мощности (НОРЭМ) [76]. Одним из ключевых механизмов торговли по свободным ценам является спотовый «рынок на сутки вперед» (РСВ), в основе которого – конкурентный отбор ценовых заявок поставщиков и покупателей за сутки до реальной поставки электроэнергии, проводимый Некоммерческим Партнерством «Администратор торговой системы оптового рынка электроэнергии Единой энергетической системы (НП «АТС»)). В то же время, стоимость электроэнергии на РСВ имеет суточную дифференциацию. В течение всего времени работы нового рынка цены в часы минимума нагрузки (в основном от 0:00 до 4:00 часов) в 2-3 раза ниже цен в часы максимума нагрузки [76]. Отсюда следует, что для приведения в соответствие динамики цен на РСВ и динамики спроса и предложения необходим внутрисуточный прогноз.

Рассмотренные модели внутрисуточного (а также суточного, недельного и месячного) прогнозирования нагрузки выполнены с привязкой к региональной энергосистеме.

**Конфигурация нейронной сети.** Конфигурация ИНС для внутрисуточного прогнозирования суммарной нагрузки региональной ЭЭС приведена на рис.2.1. Она представляет трехслойный персептрон с сигмоидной активационной функцией, полученный в результате проведенных исследований, которые заключались в варьировании количества скрытых слоев, количества нейронов в этих слоях  $NJ$ , значений скорости обучения  $\eta$ , значений момента, определяющего ускорение обучения  $\alpha$ , по критерию минимизации погрешности прогноза  $\varepsilon_{\text{прог.min}}$ . Результаты исследований сведены в табл. 2.1.

Таблица 2.1

Погрешности прогнозирования нагрузки при различных сочетаниях  $NJ$ ,  $\eta$ ,  $\alpha$ 

$NJ$	$\eta$	$\alpha$	$\varepsilon_{\text{прог}}$
5	0,3	0,7	3,64
10	0,3	0,7	3,90
15	0,3	0,7	31,99
10	0,25	0,9	4,26
1	2,5	0,9	13,44

На вход сети подаются 24 переменные, которыми являются значения нагрузки  $P_1, \dots, P_{24}$ , полученные, как будет показано далее, при рассмотрении вариантов использования ретроспективного периода графиков нагрузки. Скрытый слой содержит 5 нейронов, выходной – 1 (значение  $P_{\text{прог}}$ ). Кроме того, на входы нейронов скрытого и выходного слоев подано смещение (параметр правдоподобия). Первоначальное обучение ИНС (нахождение значений весовых коэффициентов) проводится в течение суток.

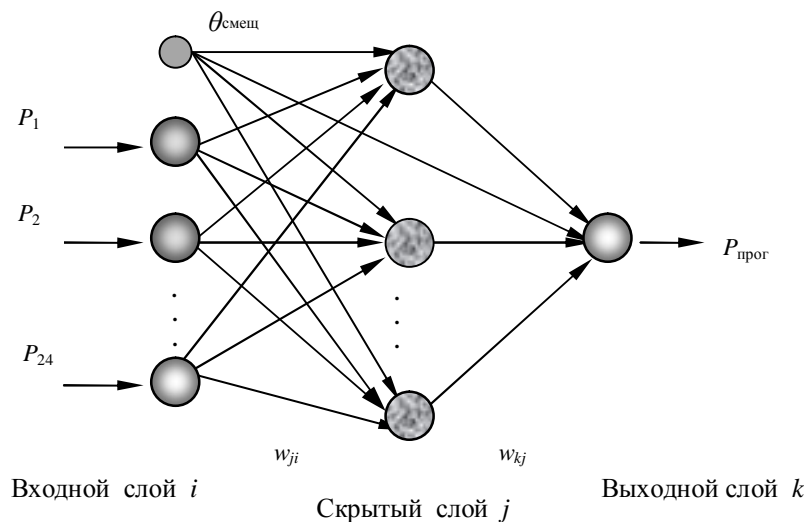


Рис. 2.1. Структура ИНС, используемая для внутрисуточного прогнозирования нагрузки



**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 [6]:

$$P_t = f(P_{t-n}, T_{t-n}, \varepsilon_t), \quad (2.1)$$

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;  $\varepsilon_t$  – случайная составляющая, представляющая ненаблюдаемые эффекты, влияющие на нагрузку. Подобную математическую модель изменения нагрузки используют и авторы работы [64].

Согласно функции (2.1), для определения входных переменных ИНС необходимо определиться с учетом ретроспективного периода графика нагрузки и внешних факторов. Для определения  $P_{t-n}$  рассматривалось несколько вариантов учета ретроспективных наблюдений нагрузки, в том числе три наиболее оптимальных по объему входной информации, быстрдействию и точности прогноза:

- 1) учет значений графика нагрузки только текущих суток (значения нагрузки в течение часа, предшествующему текущему моменту времени);
- 2) учет значений графика нагрузки текущих (как в п.1) и предыдущих суток (значения нагрузки в течение часа, предшествующему времени прогноза);
- 3) учет значений графика 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.

Таблица 2.2

### 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

В табл. 2.2 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 один из рабочих дней ноября. Из рассмотренных трех вариантов использования ретроспективной информации предпочтительным является второй, т.е. вариант с использованием ретроспективных данных текущих и предыдущих суток.

При прогнозировании нагрузки на выходные и праздничные дни в качестве предыдущих суток берется последний выходной (или праздничный) день. Для примера, если необходимо получить прогноз для субботнего дня, то используются данные о нагрузке этой субботы и последнего воскресенья. Для выходных дней погрешность прогноза меньше при учете данных только текущего дня в случае, если нагрузка изменяется плавно. При резких изменениях большую точность дает учет предыдущего дня. Результаты исследования для выходного дня ноября месяца приведены в табл. 2.3.

Таблица 2.3

**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, температурные колебания. Причем, как показали исследования авторов [64], для внутрисуточного прогнозирования их можно не учитывать, поскольку они начинают оказывать влияние на нагрузку только на следующие сутки.

*Учет случайной составляющей.* Составляющая  $\varepsilon_t$  учитывает случайные отклонения нагрузки, вызванные различными факторами. Как утверждают авторы [64], случайную составляющую можно описать ожидаемым отклонением и нормально распределенным некоррелированным остаточным отклонением (белым шумом), дополненными пиковыми отклонениями нагрузки, и, используя *ARIMA* – модель, определить значение случайного отклонения во временном интервале.

Однако, при прогнозировании нагрузки с помощью нейронных сетей, возможен другой, более простой, подход к учету случайного отклонения нагрузки. Это – введение контура адаптации, назначение которого в данном случае заключается в коррекции весовых коэффициентов  $w_{ji}$  и  $w_{kj}$  по ошибке прогноза нагрузки  $\varepsilon_{\text{прог}}$  (рис.2.2), причем коррекция проводится постоянно, на каждом ша-

ге, до текущего момента времени. Определение ошибки прогноза  $\varepsilon_{\text{прог}}$  проводится по значениям  $P_{\text{факт}}$  и  $P_{\text{прог}}$  на предыдущем шаге, т.е. когда известны и факт и прогноз.

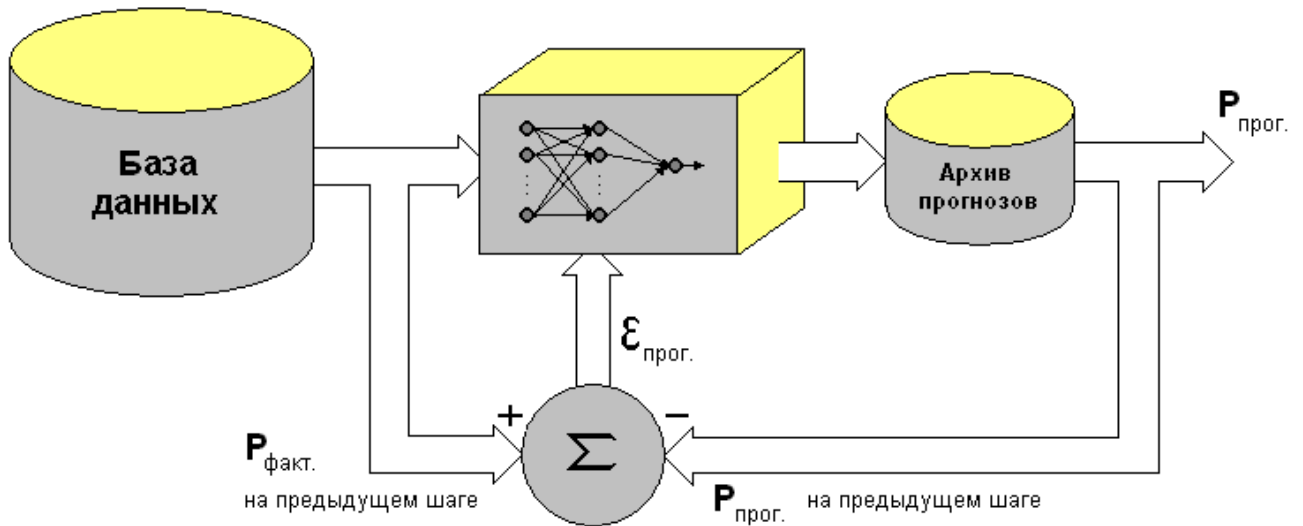


Рис.2.2 Адаптивная модель внутрисуточного прогнозирования нагрузки на основе искусственной нейронной сети

Введение адаптивной обратной связи позволило снизить среднеквадратичную погрешность прогноза примерно на 1,5% (т.е. 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.

**Алгоритм обучения нейронной сети.** Для обучения нейронной сети необходимо прежде всего сформировать обучающую выборку. Известно, что чем больше обучающая выборка, тем точнее модель. В то же время чрезмерное увеличение объема выборки приводит к затягиванию процесса обучения ИНС. На сегодняшний день не существует универсального правила, в соответствии с которым можно установить достаточный объем выборки [28]. В большинстве работ предлагается использовать количество образцов, превышающее количество регулируемых параметров ИНС ( $w_{ij}$ ,  $w_{jk}$ ) как минимум в два раза. В других работах, наоборот, утверждают, что количество весов  $w_{ij}$ ,  $w_{jk}$  должно быть больше размерности выборки. Поэтому целесообразнее решить эту проблему экспериментально. В результате эксперимента определено, что размерность выборки должна составлять не менее 50 образцов.

Алгоритм обучения по методу обратного распространения ошибки представлен на рис.2.3. После пуска и установки начальных условий в блоках 1-3 (начальных значений весовых коэффициентов, количества обучающих образцов  $NP$ , параметров ИНС  $\eta$  и  $\alpha$ , заданной малой величины  $\varepsilon$ , определяющей точность прогноза) считываются значения нагрузки  $P_1, \dots, P_{24}$  и норма-

лизуются (т.е. преобразуются в относительные величины  $Y_i$ , находящиеся в пределах  $0 \leq Y_i \leq 1$ , где  $1 \leq i \leq 24$ ) (о нормализации входных данных см. в следующем разделе).

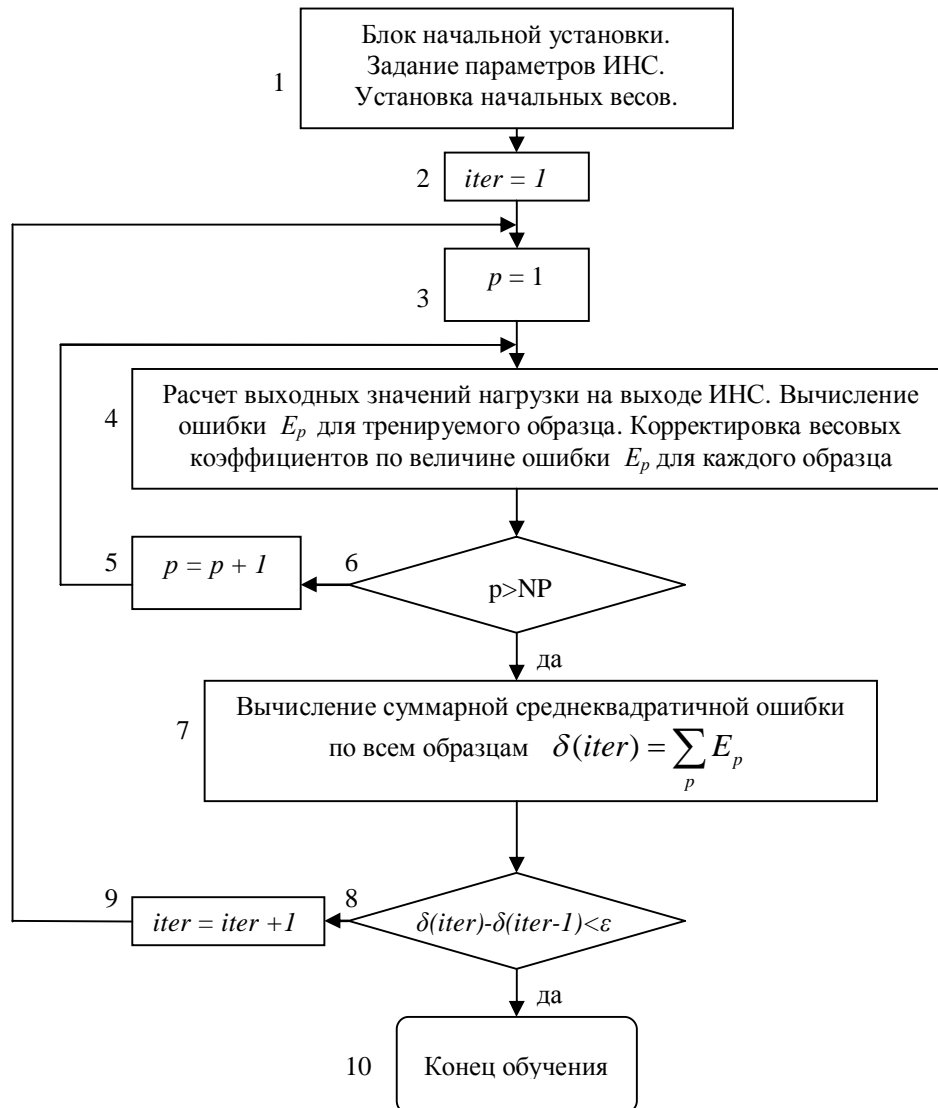


Рис.2.3. Алгоритм обучения нейронной сети

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  $net_j = \sum_{i=1}^{24} w_{ji} \cdot Y_i, \quad j=1, 2, \dots, 5;$

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

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

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

Здесь  $w_{ji}$  и  $w_{kj}$  – весовые коэффициенты соответственно между нейронами  $j$ -го и  $i$ -го слоя и  $k$ -го и  $j$ -го слоя,  $\Theta_j$  – смещение. Для ограничения пространства поиска при обучении минимизируется целевая функция ошибки, которая находится по методу наименьших квадратов [29]:

$$E_p = \frac{1}{2} \sum_{k=1}^{KN} (d_k - Y_k)^2,$$

где  $d_k$  – желаемое значение нагрузки на выходе,  $Y_k$  – расчетное значение,  $KN$  – число нейронов в выходном слое. Поскольку в выходном слое один нейрон, то ошибка  $E_p = \frac{1}{2} (d_k - Y_k)^2$  для каждого обучаемого образца  $p$ .

Далее рассчитываются градиентные спуски в пространстве весов  $w_{ji}$  и  $w_{kj}$  и на их основании производится корректировка весов по следующим формулам [29]:

$$\begin{aligned} \Delta w_{kj}(p) &= \eta \delta_k Y_j + \alpha \Delta w_{kj}(p-1); \quad \Delta w_{ji}(p) = \eta \delta_j Y_i + \alpha \Delta w_{ji}(p-1); \\ \delta_k &= (d_k - Y_k) Y_k (1 - Y_k); \quad \delta_j = Y_j (1 - Y_j) \sum_k \delta_k w_{kj}; \\ w_{ji}^{\text{нов}} &= w_{ji}^{\text{стар}} + \Delta w_{ji}(p); \quad w_{kj}^{\text{нов}} = w_{kj}^{\text{стар}} + \Delta w_{kj}(p). \end{aligned}$$

В этих соотношениях:  $p$  – номер образца;  $\eta$  – коэффициент скорости обучения, значение которого, как правило, выбирают в интервале  $[0, 1]$ ;  $\alpha$  – момент, определяющий ускорение обучения, который также выбирается в интервале  $[0, 1]$ . В данном алгоритме  $\eta = 0,3$ ;  $\alpha = 0,7$ ;  $\varepsilon = 10^{-6}$  (выбраны по критерию минимизации погрешности прогноза).

Блок 6 (рис.2.3) 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.

**Нормирование входных данных.** Важным фактором, кроме вышеперечисленных, 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 адекватного применения математических моделей и компьютерных расчетов при вычислениях, связанных с большими и малыми величинами, для равномерного их распределения, для представления значений в области  $[0,1]$ . В конечном итоге, нормирование увеличивает информативность данных. Использование нормирующих функций ведет к отображению входных значений в единичном гиперкубе [77]. Если они будут сосредоточены в небольшой гиперокрестности, то такие данные малоинформативны, и прогнозирование будет неточ-

ным. Наибольшей информативностью (в смысле получения более точного прогноза) будут обладать данные, имеющие равномерное распределение [77].

Расчеты показали, что погрешность прогноза существенно зависит от способа нормирования входных данных. Этому вопросу уделяется внимание во многих работах, например [16, 26], посвященных как прогнозированию нагрузки, так и использованию ИНС в других задачах, где данные по модулю превышают единицу.

Простейшее решение вопроса – нормирование данных по формуле

$$P_i^H = P_i / P_{\max}, \quad (2.2)$$

где  $P_i$  – значение нагрузки, подаваемое на  $i$ -ый вход;  $P_{\max}$  – максимальное значение нагрузки в рассматриваемой выборке;  $P_i^H$  – нормированное значение. При решении задачи прогнозирования нагрузки для рассматриваемой региональной системы с  $P_{\min} = 850$  МВт и с  $P_{\max} = 1200$  МВт, в таком случае, все данные после нормирования будут находиться, как правило, в интервале  $[0,71;1]$ , т.е. сосредоточены в небольшой гиперокрестности.

Для того чтобы сдвинуть нормированные данные от единицы, можно применить формулу

$$P_i^H = P_i / (P_{\max} + K), \quad (2.3)$$

где  $K$  может быть постоянным или переменным значением для каждой выборки.

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

$$P_i^H = \frac{P_i - P_{\min}}{P_{\max} - P_{\min}}, \quad (2.4)$$

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

В работе [26] рассматривается краткосрочное прогнозирование нагрузки при горизонте планирования  $t_{\text{прог}} = 7,5$  мин. с использованием формулы нормирования:

$$P_i^H = \frac{P_i - (1 - H)P_0}{2HP_0}, \quad (2.5)$$

где  $P_0$  – нагрузка в начале периода времени, соответствующего рассматриваемой выборке. Формула (2.5) получена из (2.4) при условиях:  $P_{\min} = (1 - H)P_0$ ,  $P_{\max} = (1 + H)P_0$ .

Другая, довольно часто встречающаяся, формула нормирования [17] –  $P_i^H = \frac{P_i - M(P_i)}{\sigma(P_i)}$ .

Здесь  $M(P_i)$  – выборочная оценка математического ожидания  $P_i$  (среднее 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.

В целях определения оптимального нормирования данных для внутрисуточного прогнозирования нагрузки были исследованы варианты, использующие различные формулы нормирования, в том числе три варианта формулы (2.3):  $P_i^H = \frac{P_i}{P_{\max} + 400}$  (вариант 1);  $P_i^H = \frac{P_i}{P_{\max} + 25}$  (вариант 2);  $P_i^H = \frac{P_i}{P_{\max} + 0,45P_{\min}}$  (вариант 3); формула (2.5) (вариант 4) и формула (2.4) (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 третьего, четвертого и пятого 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 одного из дней ноября месяца с учетом нагрузки предыдущего дня 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. 2.4.

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.

Таблица 2.4

**Сравнение среднеквадратичных ошибок прогноза нагрузки на один из рабочих дней ноября 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 сбоям 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 ноября месяца это сглаживание оказалось приемлемым для всего расчетного времени, кроме утренних часов. Поэтому для этого промежутка времени необходимо применить более сильный фильтр.

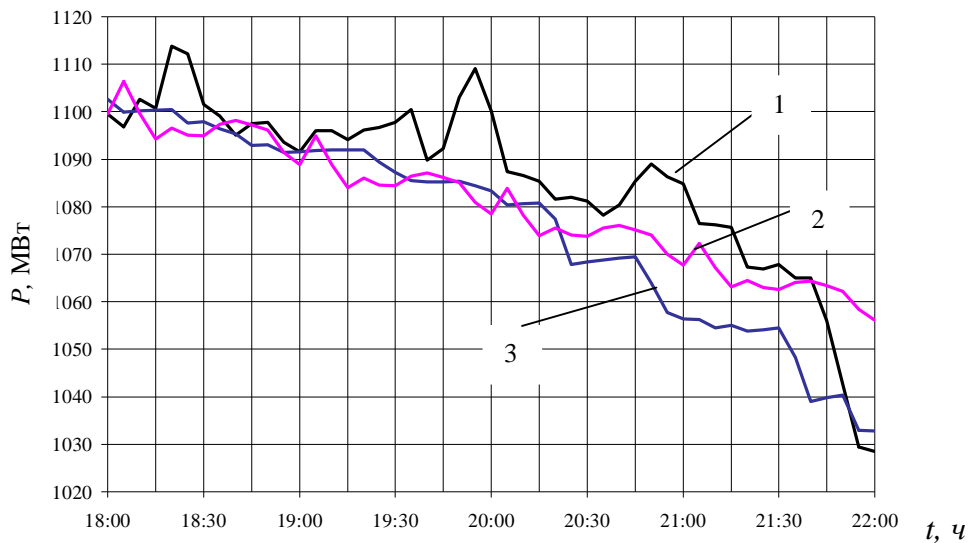


Рис. 2.4. Графики фактической нагрузки (1) и прогноза для периода с 18 до 22 часов с использованием четвертого (2) и пятого (3) вариантов нормирования данных

При использовании трех первых способов нормирования погрешность была приемлемой для прогноза нагрузки от 5 мин вперед 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.2.4 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, при небольшом изменении, когда график вогнутый, – второй, если же график выпуклый – третий.

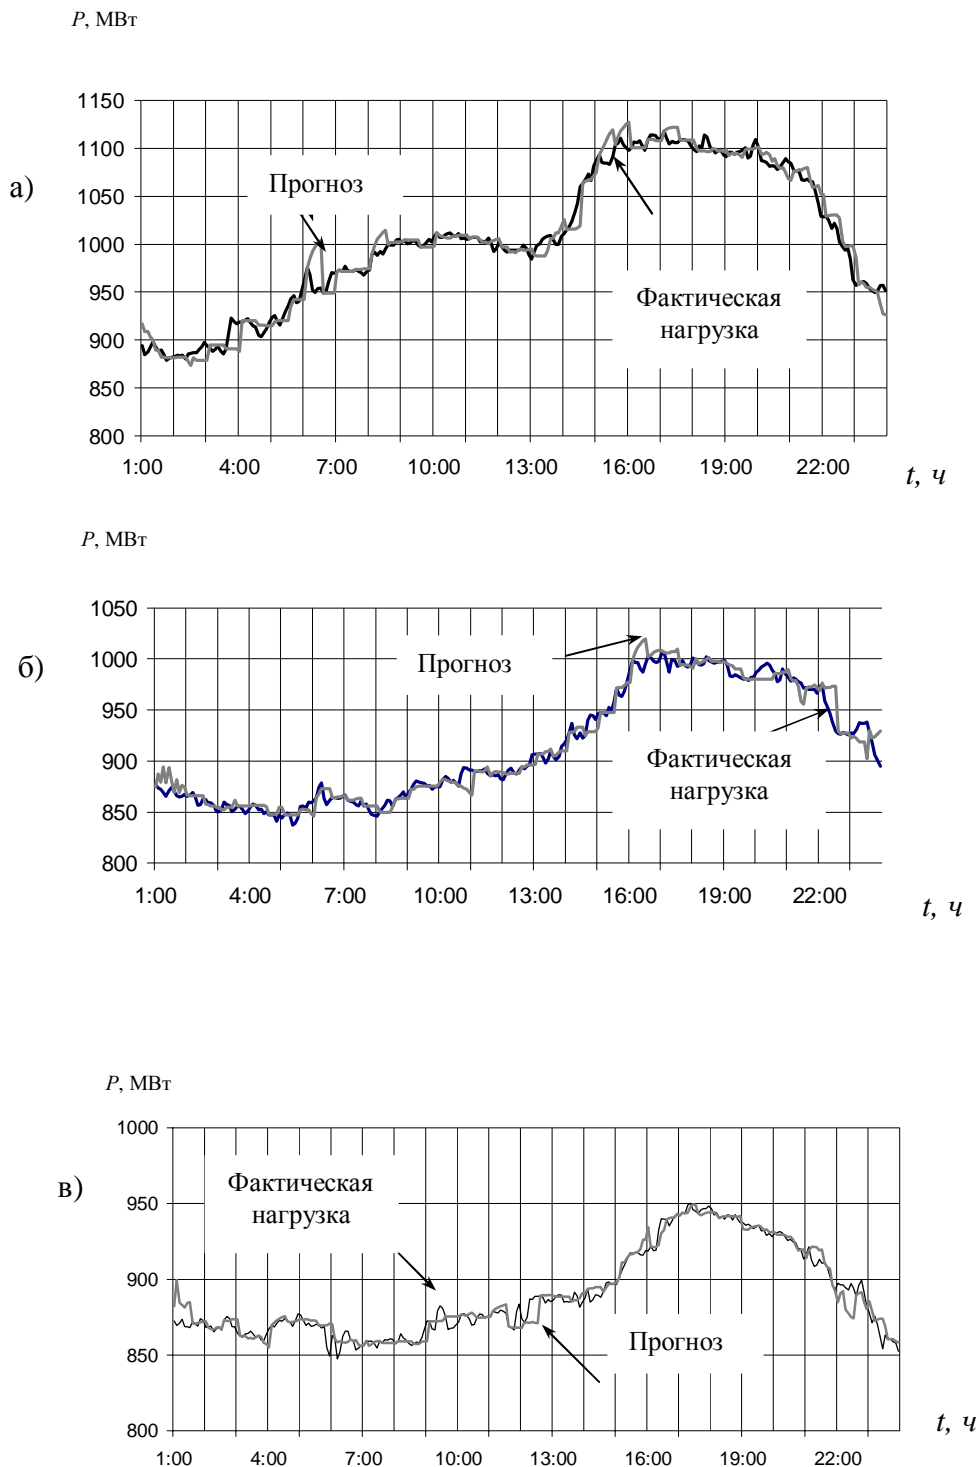


Рис. 2.5. Графики фактической нагрузки и прогноза:  
 а) - на среду 12 ноября, б) – на воскресенье 16 ноября,  
 в) – на праздничный день 7 ноября

Для рассматриваемого примера к первому периоду, т.е. росту нагрузки, можно отнести интервалы с 6 до 10 часов и с 14 до 17 часов; ко второму периоду - падению нагрузки, - с 11 до 13 часов и с 18 до 24 часов; к третьему, относительно небольшому изменению нагрузки, - с 0 до 6 часов, с 10 до 11 часов и с 17 до 18 часов.

Сравнение фактической нагрузки и прогноза за один из дней ноября по предложенной методике дано на рис.2.5, а. Каждый временной период поделен на получасовые 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%.

## 2.2. Краткосрочное прогнозирование

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 [12, 44, 52, 56, 71] (или кратко ННС).

**Модель суточного прогнозирования нагрузки с использованием ИНС.** Разработанная конфигурация ИНС для суточного прогнозирования нагрузки, приведена на рис.2.6. 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.2.3). Исследованиями авторов установлено, что первоначальное обучение ИНС в данном слу-

чае 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.




Рис.2.6. Структура ИНС, используемая для суточного прогнозирования нагрузки

Для выходных, праздничных дней, рабочих суббот и т.п. с целью приближения периода обучения к настоящему моменту времени обучение и дообучение предложено проводить на значениях нагрузки всех дней недели, но с той особенностью, что при переходе с рабочего дня на выходной, или наоборот, вводится псевдовыходной или псевдорабочий 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 [56], так называемые Fuzzy Expert Systems. В дальнейшем начали появляться гибридные

системы (экспертная система плюс нейронная сеть) [71] и нейронные сети с нечеткой логикой - Fuzzy Neural Networks (FNN) [44].

*Конфигурация ННС.* Разработанная конфигурация ННС для суточного прогнозирования нагрузки представлена на рис.2.7. Сеть состоит из трех слоев: входного, скрытого (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.1.12 дана их расшифровка. 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). Во входном слое они нормируются (о нормировании см. раздел 2.1), т.е. преобразуются в относительные

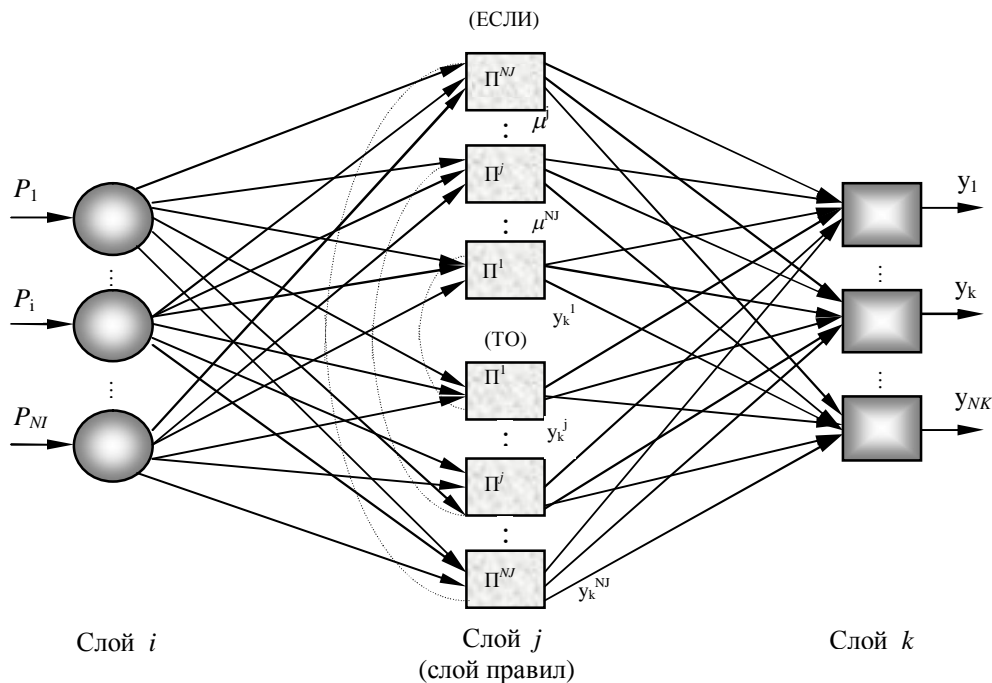


Рис. 2.7. Структура ИНС с элементами нечеткой логики для суточного прогнозирования нагрузки

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:

$$\mathbf{\Pi}^j: \text{ЕСЛИ } x_1 = A_1^j, x_2 = A_2^j, \dots, x_i = A_i^j, \text{ ТО } y_k^j = C_{0k}^j + C_{1k}^j x_1 + \dots + C_{ik}^j x_i, \quad (2.6)$$

где  $\mathbf{\Pi}^j$  –  $j$ -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  $\mu_i^j$ .

В подслое “ЕСЛИ” (рис. 1.12, а) вычисляется значение функции принадлежности для каждой входной переменной по формуле:

$$\mu_i^j = \exp \left[ -\frac{1}{2} \left( \frac{x_i - x_i^j}{\sigma_i^j} \right)^2 \right]. \quad (2.7)$$

Эта функция имеет колоколообразную форму с центром  $x_i^j$  и отклонением  $\sigma_i^j$ . Результирующее значение функции принадлежности по каждому правилу (выход узла  $j$  в подслое “ЕСЛИ”) в литературе [40, 49] определяется как:

$$\mu^j = \prod_i \mu_i^j, \quad (2.8)$$

или

$$\mu^j = \min_i \{ \mu_i^j \}. \quad (2.9)$$

Были применены обе формулы и сделан вывод, что при отсутствии блока достоверизации данных формула (2.8) в некоторых случаях совершенно неприемлема: она оказалась очень жестким условием принадлежности к  $j$ -му правилу. Поэтому в разработанной модели использована формула (2.9).

Нейрон  $j$  в подслое “ТО” представляет из себя двухслойную нейронную сеть (рис. 1.12, б), в которой весовыми коэффициентами являются коэффициенты  $C_{ik}^j$  из уравнения (2.6), а  $C_{0k}^j$  - коэффициент смещения. Выход нейрона  $j$  в этом подслое будет

$$y_k^j = C_{0k}^j + C_{1k}^j x_1 + \dots + C_{NI k}^j x_{NI}. \quad (2.10)$$

В выходном слое (рис.2.8, в) на основании результатов, полученных в слое правил, формируется четкий выход как взвешенное среднее по формуле

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

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

*Обучение ННС.* Параметрами, которые должны быть определены в процессе обучения, являются  $x_i^j$ ,  $\sigma_i^j$ ,  $C_{ik}^j$  (для  $i = 1, \dots, NI$ ;  $j = 1, \dots, NJ$ ;  $k = 1, \dots, NK$ ) и  $C_{0k}^j$ . Алгоритм обучения ННС приведен на рис.2.8. В отличие от обычных ИНС здесь начальные значения параметров сети выбираются не произвольно, а задаются максимально близкими к их реально возможным значениям, на основании специальных расчетов, приведенных далее, 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):

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

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 (2.8), (2.10). В случае, когда новый обучаемый образец не инициирует какое-либо из существующих нечетких правил, то создается новое правило (блок 8).

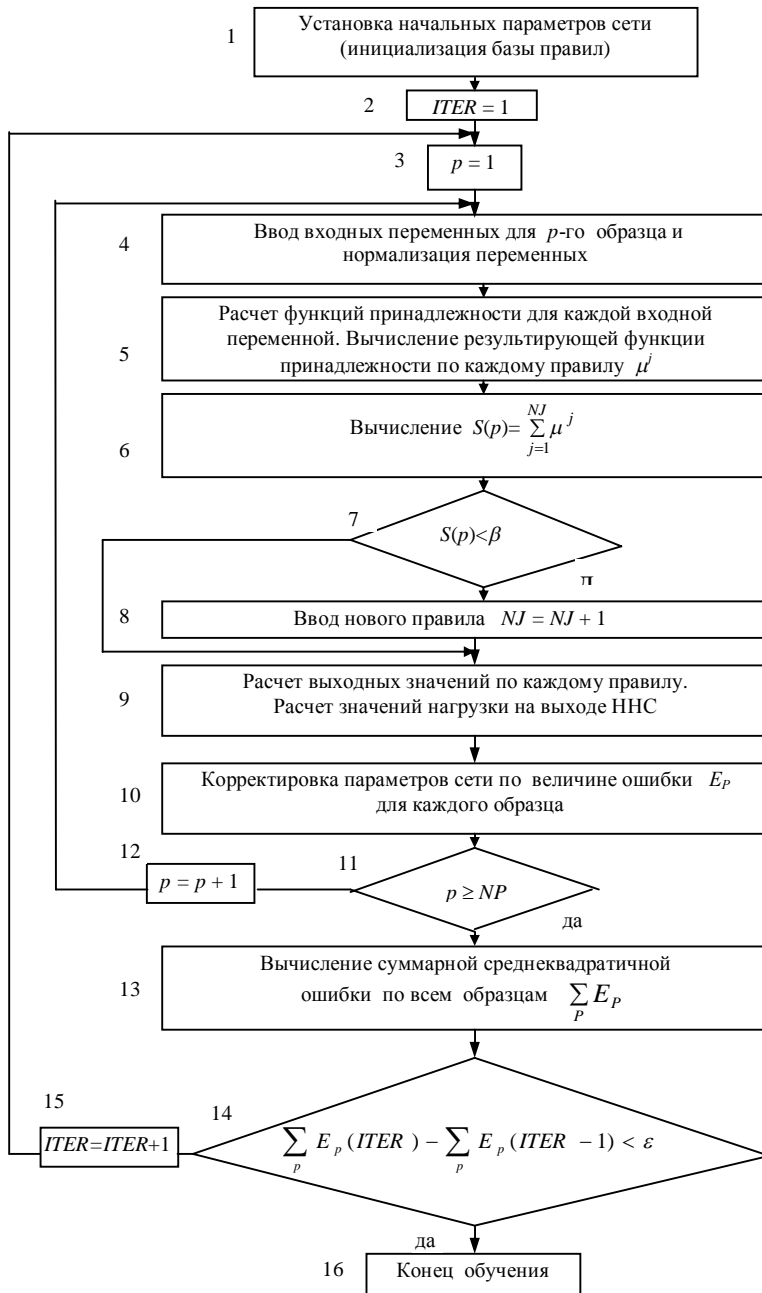


Рис. 2.8. Алгоритм обучения нечеткой нейронной сети

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  $C_{ik}^j$  ( $i = 1, 2, \dots, NI$ ) определяется также как при инициализации базы правил. В блоке 7 параметр  $\beta$  означает наименьшую приемлемую степень возбуждения существующей базы нечетких правил. Если  $S(p) = \sum_j \mu^j < \beta$ , то вводится новое правило. Величина  $\beta$  определяется экспериментальным путем при обучении модели по критерию минимизации погрешности прогноза. В блоке 9 рассчитываются значения сигналов на выходе нейронов подслоя “ТО” и нейронов выходного слоя по формулам (2.9), (2.10).

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:

$$x_i^j(p) = x_i^j(p-1) + \alpha_1 \frac{\partial E_p}{\partial x_i^j}; \quad (2.11)$$

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

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

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.

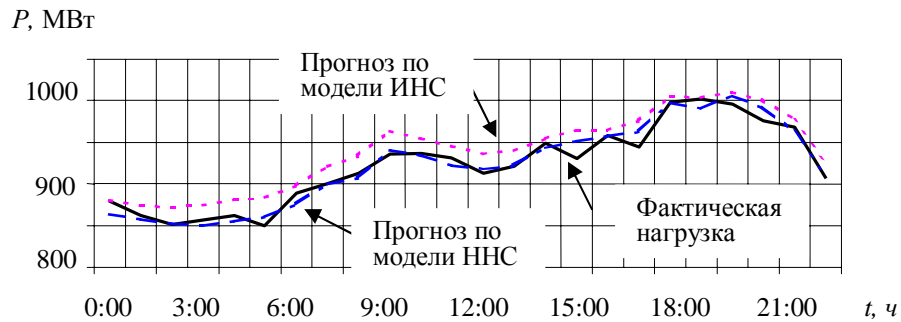


Рис.2.9. Графики фактической нагрузки и прогноза, полученного по моделям ИНС и ННС для одного из рабочих дней марта (— - фактическая нагрузка; - - - - прогноз по модели ННС; ..... - прогноз по модели ИНС)

**Результаты исследований.** Предлагаемые модели суточного прогнозирования нагрузки были исследованы на ретроспективных данных о режимах электропотребления региональной ЭЭС с нормированием входных данных по формуле (2.4). Результат одного из прогнозов представлен на рис.2.9. Как видно из рисунка, график нагрузки, полученной по модели ННС, более близок к графику фактической нагрузки, чем график прогноза нагрузки по модели ИНС.

В табл. 2.5 приведено сравнение точности прогнозирования моделей ИНС и ННС для одной недели марта месяца (с понедельника по воскресенье).

Таблица 2.5

#### 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

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 2.6

**Погрешности расчета прогноза электрической нагрузки на сутки вперед  
и на неделю вперед на основе ретроспективных данных**

Дата	День недели	Прогноз на сутки вперед		Прогноз на неделю вперед	
		Средняя погрешность	Среднеквадратичная погрешность	Средняя погрешность	Среднеквадратичная 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

**Недельное прогнозирование нагрузки.** Конфигурация модели для прогнозирования нагрузки на неделю вперед полностью соответствует структуре сети, приведенной на рис.2.6, 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 региональной ЭЭС. В табл.2.6 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.2.6 видно, что предложенная модель прогнозирования нагрузки на неделю вперед дает сопоставимые результаты с моделью суточного прогнозирования.

На рис.2.10 для наглядности приведены график фактической нагрузки, графики прогноза на неделю вперед и суточного прогноза для одной недели мая месяца (26.05 - 1.06).

### 2.3. Долгосрочное прогнозирование нагрузки.

Долгосрочное прогнозирование, согласно [24, 32], производится во временных диапазонах месяц – квартал – год. В данной работе рассматривается месячное прогнозирование нагрузки. 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.

$P$ , МВт




Рис. 2.10. Прогнозирование графика нагрузки на неделю с 26 мая по 1 июня: 1 – фактическая нагрузка; 2 – прогноз, полученный по недельному прогнозированию; 3 – прогноз, полученный по суточному прогнозированию

Прогнозируемыми показателями являются месячное электропотребление ( $P_{\Sigma}$ ), минимальная и максимальная нагрузки за месяц ( $P_{\max}$  и  $P_{\min}$ ) и коэффициенты, характеризующие неравномер-

ность 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  $\eta$  и  $\alpha$  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  $\eta$  и  $\alpha$  равны соответственно 0,1 и 0,9. Преобразующие функции логистические.

Конфигурация модели месячного прогнозирования на основе ННС такая же, как на рис.2.7. 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.

Подбор входных переменных проводился на основании выражения (2.1). В результате определено, что на входы моделей подаются следующие переменные, дающие наименьшую погрешность прогноза: электропотребление за месяц, предшествующий прогнозируемому ( $P_{\Sigma}^{-1}$ ); максимальная и минимальная нагрузки ( $P_{\max}^{-1}$  и  $P_{\min}^{-1}$ ), средняя температура ( $T_{\text{cp}}^{-1}$ ), долгота дня ( $ДД^{-1}$ ), количество праздничных дней ( $ПД^{-1}$ ) того же месяца; прогнозное значение средней температуры на прогнозируемый месяц ( $T_{\text{cp}}^{\text{прог}}$ ); 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.2.3 и рис.2.8 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 2008 г., то для обучения берутся данные за октябрь и ноябрь 2008 г. и за ноябрь и декабрь 2007 г.

*Результаты исследований.* Модель месячного прогнозирования была исследована на ретроспективных данных о нагрузке региональной ЭЭС за 1998 и 1999 годы. Результаты прогноза на 6 месяцев 1999 г. сведены в табл. 2.7. 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  $P_{\Sigma}$ ,  $P_{\max}$  и  $P_{\min}$  рассчитываются коэффициенты неравномерности месячных графиков нагрузки  $\alpha_M$  и  $\beta_M$ . Результаты расчета для июля-декабря 1999 г. приведены в табл. 2.8.

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

Таблица 2.7

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

Месяц	Погрешность прогноза в %					
	Модель ИНС			Модель ННС		
	$P_{\Sigma}$	$P_{\max}$	$P_{\min}$	$P_{\Sigma}$	$P_{\max}$	$P_{\min}$
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

Таблица 2.8

**Расчетные значения коэффициентов неравномерности месячных графиков нагрузки  $\alpha_M$  и  $\beta_M$**

Месяц	Фактические значения		Прогнозируемые значения с использованием моделей			
	$\alpha_M$	$\beta_M$	ИНС		ННС	
			$\alpha_M$	$\beta_M$	$\alpha_M$	$\beta_M$
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

## **2.4. Реализация нейросетевых моделей для прогнозирования электрических нагрузок ЭЭС (на примере ОДУ Урала)**

Для подтверждения полученных результатов и оценки возможности использования разработанных моделей прогнозирования электрических нагрузок в других энергосистемах, была исследована модель на основе ННС (как более точная модель из исследованных) для прогнозирования нагрузки ОДУ Урала по заявке ОАО «СО-ЦДУ ЕЭС» для целей балансирующего рынка электроэнергии и мощности. Была поставлена задача получения внутрисуточного прогноза нагрузки с 1 до 24 часов, с последующим уточнением прогноза в периоды: с 8 до 24 часов, с 16 до 24 часов и с 20 до 24 часов.

Для оценки модели проведено сравнение полученных результатов с результатами прогноза, рассчитанными по методике, применяемой в ОАО «СО-ЦДУ ЕЭС» [5, 21, 30,75] (далее Методика).

**Основные положения Методики прогнозирования графиков электропотребления для технологий краткосрочного планирования.** Методом моделирования электропотребления, положенным в основу Методики, является декомпозиция исходного процесса на регулярную (тренд) и нерегулярную составляющие. Выделенная в результате декомпозиции траектория, используется в дальнейшем в качестве прогнозирующей математической модели. Определение вида и параметров модели выполняется путем аппроксимации известных значений нагрузки на ретроспективном интервале времени и на интервале упреждения. В общем случае, модель может включать в себя элементарные функции от любых независимых переменных, принимаемых в качестве факторов, влияющих на величину потребления, по которым имеются достоверные фактические данные, а также прогнозы, получаемые из официальных источников. Методика допускает использование следующих независимых переменных или влияющих факторов: время; суточные графики метеорологических параметров (температуры, освещенности, влажности, осадков, скорости и направления ветра). В качестве основной модели прогноза рекомендуется использовать аддитивную модель, включающую в себя регрессионную модель и модель, представленную рядом Фурье.

Расчет прогнозной траектории электропотребления осуществляется одним из двух методов, различающихся способами формирования траектории притяжения [4] и адаптации коэффициентов математической модели прогноза.

Способ формирования точек притяжения по первому методу предполагает выполнение независимого прогнозирования отдельных точек графика потребления на интервале упреждения. Уточнение коэффициентов математической модели в этом методе осуществляется при каждом сеансе аппроксимации точек обучающей выборки. Использование данного метода позволяет рассчитывать график прогнозирования нагрузки с учетом всех влияющих факторов (времени суток, тем-

пературы и др.). Формирование траектории притяжения в соответствии с данным методом включает две модификации: 1) отдельное прогнозирование по характерным дням недели; 2) циклическое уточнение прогноза (скользящий прогноз [4]) на интервале упреждения. В случае первой модификации прогноз выполняется отдельно для каждых суток, попадающих в интервал упреждения. Такое разбиение позволяет учесть различия в конфигурациях графиков нагрузки по дням недели. Ретроспективные данные, включаемые в обучающую выборку, в данном случае формируются из записей, относящихся к одноименным дням предшествующего периода. Во второй модификации формирования траектории притяжения прогноз выполняется по следующему алгоритму:

1) Для заданного момента времени прогноза  $t = T_0$  составляется обучающая выборка, включающая фактические (ретроспективные) значения нагрузки на интервале  $[t - \Delta t_p, t]$ , а также точки притяжения на интервале  $[t, t + \Delta t_y]$ . Здесь  $\Delta t_p$  – интервал ретроспективных данных,  $\Delta t_y$  – интервал упреждения прогноза;

2) Выполняется прогноз нагрузки;

3) Архив фактических значений на интервале  $[t, t + \Delta t_y]$  дополняется рассчитанными прогнозными значениями;

4) Производится сдвиг времени прогнозирования на величину шага скользящего прогноза  $\Delta t_n$ , т.е.  $t = t + \Delta t_n, \Delta t_n \leq \Delta T_y$ .

Шаги 1) – 4) повторяются до тех пор, пока не будут рассчитаны все прогнозные значения нагрузки на интервале упреждения  $\Delta T_y$ . Значения параметров алгоритма по умолчанию:  $\Delta t_p$ ,  $\Delta t_y$ ,  $\Delta t_n$  – 24 часа,  $\Delta T_y$  – неделя.

Второй метод предполагает использование первого метода для формирования базовой прогнозирующей математической модели и предусматривает дополнительные способы уточнения значений коэффициентов этой модели с учетом выявленных статистических зависимостей между этими коэффициентами и независимыми параметрами прогноза (временем и метеорологическими параметрами). Применение этого метода наиболее целесообразно тогда, когда в качестве базовой траектории притяжения используется фактический график электропотребления за прошедшие интервалы времени.

Данный метод использует базовую и дополнительные математические модели прогнозирования. Каждый коэффициент базовой математической модели уточняется в соответствии с дополнительными моделями, формируемыми для каждого коэффициента базовой модели. Прогноз выполняется отдельно по дням недели, попадающим в интервал упреждения. Для прогнозирования

значений коэффициентов базовой модели используются упрощенные, по сравнению с основной, математические модели.

В качестве точек притяжения в данном методе могут использоваться ретроспективные значения коэффициентов модели, рассчитанные на основе значений нагрузки, получаемых статистическими методами краткосрочного прогнозирования.

**Сравнение результатов прогнозирования нагрузки по нейросетевой модели и по Методике.** С первых шагов стало ясно, что в чистом виде модель, обученную на одной энергосистеме, нельзя использовать для другой: погрешности прогноза оказались неприемлемыми. Основная причина – отличие графиков нагрузки.

Структура модели с ННС остается та же, как на рис.2.8, только изменяется количество нейронов в выходном слое (в зависимости от периода прогноза) и количество нейронов во входном слое (в зависимости от используемой ретроспективы входных данных).

Количество выходных параметров модели (а также количество нейронов в выходном слое) для периода прогнозирования с 1 до 24 часов составляет 24, с 8 до 24 часов – 17, с 16 до 24 часов – 9 и с 20 до 24 часов – 5.




Рис. 2.11, а. Графики нагрузки за рабочие дни с 20 марта по 24 марта 2006 года

$P$ , отн. ед.




Рис.2.11,б. Графики нагрузки за рабочие дни с 22 по 26 мая 2006 года

$P$ , отн. ед.




Рис. 2.12. Графики нагрузки в выходные дни



Для определения количества входных параметров были проанализированы графики нагрузки ОДУ Урала, представленные на рис.2.11а,б и рис.2.12. В них, в отличие от графиков нагрузки рассмотренной ранее региональной энергосистемы, нет необходимости выделять в отдельные группы понедельник и пятницу. Поэтому при обучении ННС и расчете прогноза на рабочие дни (с понедельника по пятницу) можно использовать все рабочие дни, исключая рабочие предпраздничные. Суббота и воскресенье выделены в одну группу, хотя уровень нагрузки в субботу выше, чем в воскресенье. Для обучения и расчета прогноза на субботу и воскресенье целесообразно использовать только эти дни недели, исключая предпраздничные и праздничные дни.

В результате проведенных исследований, для прогнозирования на рабочие и выходные дни были получены следующие входные параметры. Для прогноза на период с 1 до 24 часов в качестве входных данных нейронной сети необходимо использовать 6 последних часовых среза предшествующих суток и 24 часовых среза суток неделю назад; для остальных периодов прогноза – 5 последних часовых среза предшествующих суток, один часовой срез, предшествующий первому часу прогноза, и 24 часовых среза суток неделю назад. В каждом из этих вариантов количество входных параметров равно 30. Количество правил в «слое правил» для рабочих дней получилось равным 5, для выходных – 2.

В качестве эксперимента, для выходных дней проводились расчеты, когда одним из входных параметров была продолжительность светового дня. Введение этого параметра на точность прогноза никак не повлияло.

**Нормирование входных данных.** Как уже отмечалось в разделе 2.1, важным фактором, влияющим на погрешность прогноза, является нормирование входных данных. Как было отмечено, что выбор нормирующей формулы зависит от графика нагрузки, поэтому необходимо решить и эту задачу. Исследуем те же самые формулы, что и в разделе 2.1, дополнительно еще меняя коэффициент скорости обучения  $\alpha_1$  в формуле (2.11).

Для подбора значения  $K$  в формуле (2.3), проводились расчеты со следующими значениями  $K$ : 300, 500, 1000. Значения  $K$ , большие 1000 и меньшие 300, дают неприемлемо большие погрешности. По результатам расчета погрешности прогноза для рабочих дней недели (с 20 по 24 марта), приведенным в табл.2.9, наименьшая погрешность получена при  $K = 500$ .

В табл. 2.10 представлены результаты расчетов погрешностей прогноза при различных формулах нормирования за те же рабочие дни марта и дополнительно за два выходных дня (25 и 26 марта 2006 года). На основании данной таблицы, лучшей формулой по точности прогноза для нормирования входных данных, полученных по графикам нагрузки ОДУ Урала, является формула (2.2) при коэффициенте скорости обучения  $\alpha_1 = 0,1$ . Графики прогнозов по нейросетевой модели

(НСМ) и по Методике на 24 часа для 20 марта (как наилучший вариант) и 26 марта (как наилучший вариант) для рассматриваемой недели представлены на рис. 2.13 и 2.14.

Для подтверждения результатов исследований по выбору множества входных данных и формулы нормирования, были проведены расчеты для двух недель марта, апреля, мая и июня. Усредненные значения погрешностей для различных периодов прогноза на рабочие и выходные дни каждой недели приведены в табл. 2.11. Здесь, для краткости, нейросетевая модель прогнозирования нагрузки обозначена как НСМ, а методика, принятая в ОАО «СО-ЦДУ ЕЭС», как ОАО. Как можно видеть из таблицы, погрешности прогноза по нейросетевой модели и по Методике примерно одинаковы, хотя есть некоторые нюансы. Например, при прогнозировании на рабочие дни, погрешности меньше для большинства недель для нейросетевой модели, а для выходных дней - меньше при прогнозировании по Методике.

Таблица 2.9

**Средние относительные погрешности при нормировании по формуле (2.3) и двух значениях  $\alpha_1$  ( $\alpha_2 = 0.2, \alpha_3 = 0.05$ )**

Период прогноза	K=300		K=500		K=1000	
	$\alpha_1 = 0,01$	$\alpha_1 = 0,1$	$\alpha_1 = 0,01$	$\alpha_1 = 0,1$	$\alpha_1 = 0,01$	$\alpha_1 = 0,1$
20 марта						
1-24	0,62	0,52	0,66	0,51*	0,7	0,54
8-24	0,59	0,41*	0,58	0,41*	0,58	0,41*
16-24	0,36	0,34*	0,36	0,34*	0,36	0,34*
20-24	0,12*	0,19	0,12*	0,19	0,12*	0,19
21 марта						
1-24	1,02	0,88	0,95	0,86*	1,06	0,88
8-24	0,47	0,35	0,46	0,22*	0,45	0,34
16-24	0,37	0,35*	0,37	0,35*	0,37	0,35*
20-24	0,38*	0,4	0,38*	0,4	0,38*	0,4
22 марта						
1-24	0,87	0,93	0,86*	0,93	0,86*	0,92
8-24	1,63	1,45*	1,62	1,45*	1,6	1,45*
16-24	0,36	0,38	0,32*	0,38	0,33	0,35
20-24	0,34	0,31*	0,34	0,31*	0,35	0,33
23 марта						
1-24	0,63*	0,87	0,65	0,9	0,58	0,73
8-24	0,52*	0,83	0,53	0,82	0,52*	0,8
16-24	0,56*	0,58	0,56*	0,58	0,56*	0,58
20-24	0,68	0,67	0,67	0,67	0,67	0,66*
24 марта						
1-24	1,07*	1,14	1,07*	1,12	1,07*	1,14
8-24	0,56	0,6	0,56	0,59	0,54*	0,58
16-24	1,22	1,17	1,2	1,16	1,17	1,14*
20-24	0,43	0,34*	0,43	0,35	0,44	0,37
Средняя погрешность	0,64	0,6355	0,6345	0,627	0,6355	0,625
Количество *	6	6	6	8	7	6

Примечание: звездочкой (\*) отмечена наименьшая погрешность в строке.




Рис. 2.13. Графики фактической и прогнозируемой нагрузок на НСМ и по Методике на понедельник 20 марта 2006 г.




Рис. 2.14. Графики фактической и прогнозируемой нагрузок на НСМ и по Методике на воскресенье 26 марта 2006 г.

Таблица 2.10

**Средние относительные погрешности прогноза при различном нормировании данных  
и двух значениях  $\alpha_1$**

Период прогноза	Формула (2.4)		Формула (2.3)		Формула (2.2)		Погрешность прогноза по Методике
	$\alpha_1 = 0,01$	$\alpha_1 = 0,1$	$\alpha_1 = 0,01$	$\alpha_1 = 0,1$	$\alpha_1 = 0,01$	$\alpha_1 = 0,1$	
20 марта							
1-24	0,94	0,69	0,66	0,51*	0,82	0,64	0,85
8-24	0,41	0,46	0,58	0,41	0,26*	0,27	0,61
16-24	0,45	0,45	0,36	0,34	0,31*	0,38	0,83
20-24	0,54	0,55	0,12	0,19	0,07*	0,23	0,36
21 марта							
1-24	1,11	1,04	0,95	0,86*	1,23	1,0	1,48
8-24	0,45	0,46	0,46	0,22*	0,44	0,51	1,12
16-24	0,59	0,55	0,37	0,35*	0,53	0,63	1,06
20-24	0,84	0,8	0,38*	0,4	0,47	0,67	0,74
22 марта							
1-24	0,85*	0,93	0,86	0,93	0,88	0,86	1,2
8-24	1,15	1,25	1,62	1,45	1,13	1,08*	0,95**
16-24	0,23*	0,23*	0,32	0,38	0,47	0,35	0,78
20-24	0,4	0,42	0,34	0,31*	0,93	0,72	0,84
23 марта							
1-24	0,5*	0,58	0,65	0,9	0,53	0,69	0,41**
8-24	0,38*	0,44	0,53	0,82	0,44	0,42	0,28**
16-24	0,46	0,45*	0,56	0,58	0,58	0,57	0,71
20-24	0,37*	0,37*	0,67	0,67	0,65	0,43	0,19**
24 марта							
1-24	0,73*	1,11	1,07	1,12	0,99	1,06	0,92
8-24	0,53	0,51*	0,56	0,59	0,58	0,54	0,99
16-24	0,54	0,54	1,2	1,16	0,26*	0,31	0,53
20-24	0,65	0,62	0,43	0,35*	0,86	0,63	0,52
Средняя погрешность за рабочие дни	<b>0,606</b>	<b>0,6225</b>	<b>0,6345</b>	<b>0,627</b>	<b>0,6215</b>	<b>0,599</b>	<b>0,7685</b>
25 марта							
1-24	0,66*	0,75	0,67	1,35	0,66*	0,7	0,86
8-24	0,67	1,17	0,66*	1,12	0,69	0,7	0,6**
16-24	0,96	1,26	0,95	1,23	0,37*	0,57	0,64
20-24	0,18	0,15*	0,17	0,15*	0,29	0,16	0,66
26 марта							
1-24	1,53	1,59	1,49	2,0	1,48*	1,53	0,88**
8-24	1,92	2,09	1,91	2,05	1,46	1,38*	0,67**
16-24	1,68	1,71	1,68	1,71	1,69	1,67*	1,21**
20-24	2,23	2,13	2,22	2,14	2,18	1,82*	0,43**
Средняя погрешность за выходные	<b>1,229</b>	<b>1,356</b>	<b>1,219</b>	<b>1,469</b>	<b>1,102</b>	<b>1,066</b>	<b>0,744</b>
Средняя погрешность за неделю	<b>0,917</b>	<b>0,989</b>	<b>0,927</b>	<b>1,069</b>	<b>0,862</b>	<b>0,833</b>	<b>0,756</b>

Примечание: (\*) отмечена наименьшая в строке погрешность прогнозирования по нейросетевой модели; (\*\*) отмечена наименьшая погрешность прогнозирования по Методике.

Таблица 2.11

**Сравнение средних относительных погрешностей расчетов для различных периодов прогноза**

Дни прогноза	Прогноз с 1 по 24 ч		Прогноз с 8 ч до 24 ч		Прогноз с 16 ч до 24 ч		Прогноз с 20 ч до 24 ч		Среднее значение	
	НСМ	ОАО	НСМ	ОАО	НСМ	ОАО	НСМ	ОАО	НСМ	ОАО
Рабочие дни 20.03 – 24.03	0,89	0,972	0,57	0,79	0,43	0,782	0,596	0,53	<b>0,599</b>	0,768
Выходные 25.03, 26.03	1,115	0,87	1,04	0,635	1,12	0,925	0,99	0,545	1,066	<b>0,744</b>
Рабочие дни 27.03 – 31.03	0,898	1,376	1,058	1,804	0,806	1,538	0,918	0,576	<b>0,92</b>	1,324
Выходные 1.04, 2.04	1,245	1,01	0,875	1,125	0,82	0,795	0,69	0,935	<b>0,907</b>	0,966
Рабочие дни 17.04 – 21.04	1,38	1,134	0,614	1,146	0,574	1,238	0,55	1,326	<b>0,779</b>	1,211
Выходные 22.04, 23.04	1,97	1,975	1,385	2,155	0,74	0,51	0,575	0,53	<b>1,168</b>	1,293
Рабочие дни 24.04 – 28.04	1,1	0,986	1,13	0,836	0,884	0,65	0,788	0,684	0,975	<b>0,789</b>
Выходные 29.04, 30.04	2,05	0,83	0,85	0,705	0,61	0,86	0,77	0,95	1,07	<b>0,836</b>
Рабочие дни 22.05 – 26.05	0,938	1,064	0,732	0,968	0,666	0,778	0,468	0,488	<b>0,701</b>	0,824
Выходные 27.05, 28.05	2,05	0,905	1,22	0,775	1,09	0,96	0,685	0,875	1,261	<b>0,879</b>
Рабочие дни 29.05- 2.06	1,112	1,174	0,97	1,202	1,02	0,974	1,078	0,914	<b>1,045</b>	1,066
Выходные 3.06, 4.06	3,115	1,04	1,36	0,885	1,225	1,32	1,025	1,005	1,681	<b>1,062</b>
Рабочие дни 19.06 – 23.06	0,752	0,886	1,108	0,736	0,774	0,786	0,778	0,862	0,853	<b>0,817</b>
Выходные 24.06, 25.06	1,015	0,85	0,65	0,57	0,54	0,63	0,795	0,85	0,75	<b>0,725</b>
Рабочие дни 26.06- 30.06	0,602	0,842	0,518	0,682	0,474	0,5	0,682	0,5	<b>0,569</b>	0,631
Среднее значение за рабочие дни	<b>0,959</b>	1,054	<b>0,837</b>	1,021	<b>0,703</b>	0,921	<b>0,732</b>	0,735	<b>0,808</b>	0,933
Среднее значение за выходные	1,752	<b>1,069</b>	1,054	<b>0,979</b>	0,878	<b>0,857</b>	<b>0,79</b>	0,813	1,119	<b>0,93</b>
Среднее значение по столбцу	1,355	<b>1,061</b>	<b>0,939</b>	1,001	<b>0,785</b>	0,893	<b>0,759</b>	0,771	0,959	<b>0,93</b>

Примечание: жирным шрифтом выделена минимальная из двух погрешностей.

Таким образом, разработанную нейросетевую модель прогнозирования нагрузки, с некоторой корректировкой входного вектора данных и подбором нормирующей формулы, можно с приемлемой точностью использовать и для прогнозирования нагрузок в других энергосистемах.

### Глава 3.

## Прогнозирование узловых электрических нагрузок ЭЭС

В предыдущей главе рассмотрено решение задачи прогнозирования суммарной нагрузки по энергосистеме. Не менее актуальной остается задача получения сбалансированной информации о нагрузках в узлах ЭЭС. Под узлом понимается группа нагрузок, присоединенных к шинам подстанции, а суммарная нагрузка в узле для каждого момента времени определяется разницей между входящими в узел (за вычетом потерь по линиям) и выходящими из узла перетоками мощности.

Существующие подходы к решению задачи прогнозирования нагрузок в узлах определяются, в первую очередь, уровнем информационной обеспеченности этой задачи, а именно достаточностью и достоверностью телеметрических измерений режимных параметров. В практике зарубежных ЭЭС, где имеется достаточная ретроспективная информация о нагрузках в узлах, для их прогнозирования часто применяются те же алгоритмы, что и для прогнозирования суммарных нагрузок ЭЭС. Получаемая при этом точность прогнозирования является вполне достаточной при планировании режимов [24]. В случаях недостаточности телеизмерений режимных параметров, информацию для расчета узловых нагрузок составляют результаты контрольных измерений, осуществляемых обычно два раза в год (в июне и декабре месяце каждого года) для характерных интервалов графиков нагрузки ЭЭС.

В большинстве случаев, для прогнозирования активных узловых нагрузок в настоящее время применяются следующие методы [4, 9]: обработка данных контрольных измерений (расчет «базовых» электрических режимов ЭЭС); пропорциональное распределение суммарной нагрузки ЭЭС по узлам расчетной схемы замещения электрической сети [10, 13]; распределение суммарной нагрузки ЭЭС по узлам расчетной схемы замещения электрической сети методом главных компонент; идентификация электрического режима (оценивание состояния) на основании текущей телеметрии. Прогноз реактивных нагрузок в узлах сети выполняется по коэффициентам мощности, полученным либо по результатам обработки контрольных измерений, либо по программам оценивания состояния ЭЭС, либо по данным учета электроэнергии [4].

Неудовлетворительная точность используемых в эксплуатации методов прогнозирования электрических нагрузок по узлам приводит к тому, что если просуммировать прогнозные значения узловых нагрузок, то их сумма не совпадет с прогнозом нагрузки по энергосистеме в целом. Чтобы избежать этого, предлагается выполнить решение задачи прогнозирования узловых нагрузок с использованием инверсии искусственных нейронных сетей. Такой подход позволяет по величине прогноза суммарной нагрузки энергосистемы определить прогнозные значения нагрузок по ее энергоузлам, т.е. получить сбалансированный прогноз. В то же время, данный метод увеличивает

точность прогноза узловых нагрузок по сравнению, например, с традиционно используемым методом распределения нагрузки ЭЭС между узлами пропорционально величине их текущих значений.

Оперативное планирование и эффективное управление режимами функционирования ЭЭС невозможны без достоверного прогноза нагрузки в узлах расчетной схемы, проводимого с упреждением от нескольких минут до нескольких суток [2], поэтому рассмотрим эти временные периоды прогноза. Исследования по разработке нейросетевой модели прогнозирования узловых нагрузок проводились с использованием информации об узловых нагрузках региональной ЭЭС, расчетная схема которой изображена на рис.3.1. В качестве исходной информации использовались ретроспективные данные о телеизмерениях, по которым рассчитывались фактические нагрузки в узлах.




Рис. 3.1. Расчетная схема региональной ЭЭС

### 3.1. Прогнозирование узловых нагрузок на сутки вперед

Для определения структуры ИНС были проведены все те исследования, которые описаны в главе 2. В результате получена ИНС, представленная на рис. 3.2. Она представляет собой трехслойный персептрон, во входном слое которого находится 15 нейронов (соответствует количеству энергоузлов), в скрытом – 20 и выходном – 1. Входными переменными являются значения узловых нагрузок в определенный час суток. В выходном слое – суммарная нагрузка по энергосистеме в этот же час. Количество нейронов в скрытом слое определено по условию минимальной погрешности прогноза.

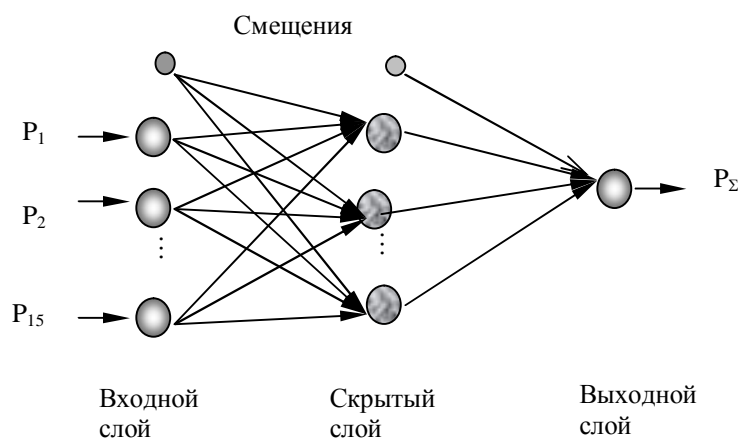


Рис.3.2. Структура ИНС для суточного прогнозирования узловых нагрузок (для каждого часа суток)

Нейронная сеть обучается в соответствии со стандартным алгоритмом обратного распространения ошибки, блок – схема которого приведена на рис. 2.3. Первоначальное обучение ИНС проводится на ретроспективных данных о нагрузке за две предшествующих прогнозу недели. Полученные в результате обучения значения весовых коэффициентов запоминаются и в дальнейшем используются для выполнения инверсии, в результате которой по величине суммарного прогноза нагрузки по энергосистеме  $P_{\Sigma i}^{прог}$ , где  $i$  – номер часа, определяются прогнозные значения нагрузки по узлам для каждого часового среза. Прогноз суммарной по энергосистеме нагрузки предварительно рассчитывается по модели суточного прогнозирования нагрузки на основе нечеткой нейронной сети, описанной в главе 2.

На каждой итерации цикла инверсии (см. алгоритм инверсии на рис. 1.14) получаем  $P_{\Sigma i}^{расч}$  по величине входного вектора и весовым коэффициентам. Цикл инверсии завершается при выполне-



нии условия  $E^t - E^{t-1} \leq \varepsilon$ , где  $t$  – номер итерации,  $\varepsilon$  - малая наперед заданная величина, равная  $10^{-6}$ , а  $E = \frac{1}{2}(P_{\Sigma i}^{прог} - P_{\Sigma i}^{расч})^2$ .

Чем ближе начальные входные переменные к решению, тем быстрее выполняется цикл. Поэтому имеет смысл в качестве начального вектора  $X_0$  для рабочего дня использовать узловую нагрузку того ближайшего дня, погода которого близка к прогнозу погоды на рассматриваемый день. Полезно учитывать и сам график нагрузки, например, график нагрузки за пятницу может существенно отличаться от графика любого другого рабочего дня. В связи с этим предлагается использовать в качестве входного вектора  $X_0$  либо значения узловых нагрузок предыдущего дня, либо рабочего дня неделю назад. Для выходных и праздничных дней в качестве начальных значений при инверсии можно применить значения соответствующего выходного дня неделю назад. В этом случае большую роль играет уже не температура, а график изменения нагрузки в течение суток.

Таблица 3.1

**Средние по узлам значения погрешностей расчета нагрузок по активной мощности**

Время	Погрешность с использованием инверсии нейронной сети		Погрешность с использованием коэффициента пропорциональности	
	абсолютная, МВт	относительная, %	абсолютная, МВт	относительная, %
0	2,18	3,41	1,65	4,91
1	2,45	4,30	1,82	5,00
2	2,27	4,85	2,23	5,33
3	2,63	4,37	2,33	4,82
4	1,85	4,49	1,93	5,41
5	1,85	4,08	2,17	5,35
6	1,60	3,82	1,16	5,48
7	2,07	4,81	1,90	5,41
8	2,57	5,00	1,66	4,34
9	2,25	4,45	1,37	7,18
10	1,90	3,37	1,45	8,93
11	1,63	3,54	1,86	10,05
12	1,99	3,81	2,09	6,59
13	2,11	4,36	2,18	8,36
14	2,26	5,05	2,34	9,77
15	1,91	2,92	2,04	4,16
16	1,54	3,01	1,83	4,98
17	1,68	3,64	1,75	5,09
18	2,19	3,31	1,70	4,11
19	2,50	3,94	1,62	3,18
20	1,86	2,50	2,05	4,27
21	1,44	3,44	1,70	3,50
22	1,81	4,19	1,35	3,23
23	1,68	2,67	2,04	4,60

Разработанная модель была опробована на расчете прогноза активной и реактивной нагрузок узлов региональной ЭЭС на один из дней марта месяца. В качестве начального входного вектора взяты нагрузки в узлах за предыдущий день. Результаты прогноза приведены в табл. 3.1.

Здесь же, для сравнения, представлены результаты прогноза с использованием коэффициентов пропорциональности. Как видно из табл. 3.1, относительная погрешность прогнозирования по нейросетевой модели находится в пределах от 2,67 до 5,05 %, а с использованием коэффициентов пропорциональности – от 3,18 до 10,05%.

В табл.3.2 приведены средние погрешности суточного прогноза для каждого узла энергосистемы для этого же дня марта. Значение абсолютной погрешности прямо пропорционально зависит от величины нагрузки в узле. Максимальную относительную погрешность прогноза имеет узел № 2 с наименьшей средней нагрузкой за сутки.

Таблица 3.2

### Погрешности краткосрочного прогнозирования нагрузок по узлам региональной ЭЭС

Средняя относительная погрешность прогнозов за сутки, %	Номера нагрузочных узлов														
	2	3	4	6	8	9	10	11	12	14	15	16	17	19	20
По активной мощности	5,48	2,29	1,51	3,70	4,46	3,35	2,40	4,90	4,11	5,40	3,30	4,51	4,89	5,44	2,65
По реактивной мощности	5,51	7,66	0,24	2,85	2,40	3,60	3,11	0,24	2,23	1,96	3,04	0,20	2,61	5,98	4,23

## 3.2. Внутрисуточное прогнозирование узловых нагрузок

Рассматривается применение инверсии ИНС для прогноза узловых нагрузок с заблаговременностью от 5 до 30 мин. Структура ИНС в этом случае представляет собой персептрон с двумя скрытыми слоями (рис.3.3). Количество нейронов во входном и выходном слоях остается прежним – 15 и 1, в скрытых слоях – 10 и 3. Как и при суточном прогнозировании, входными переменными являются нагрузки в узлах, выходной переменной – суммарная нагрузка по энергосистеме.

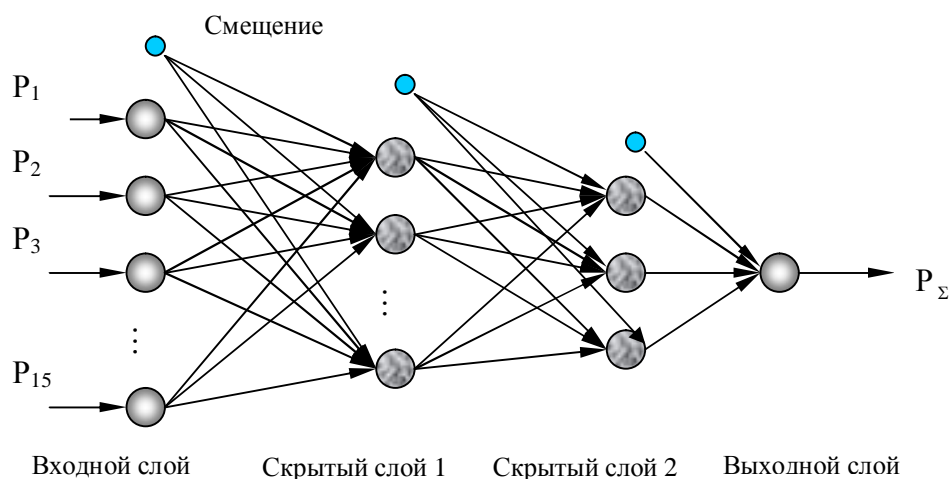


Рис.3.3. Структура ИНС для внутрисуточного прогнозирования узловых нагрузок

При прогнозировании на пятиминутный период упреждения в качестве входных переменных использовались фактические усредненные за 5 мин. значения узловых нагрузок, соответствующие предыдущему пятиминутному интервалу. Для получения прогноза на десятиминутный и более длительный период упреждения входными переменными являются полученные на предыдущем шаге прогнозные значения узловых нагрузок. Это позволяет приблизить входные переменные к искомому решению и сократить время выполнения цикла инверсии.

Для внутрисуточного прогнозирования проводится, как и при прогнозировании нагрузки по энергосистеме в целом (глава 2), постоянная коррекция весовых коэффициентов. Поэтому прежде чем применить инверсию для получения прогноза на ближайшие, например 30 мин., нужно провести дополнительное обучение за предыдущие 30 мин. Как правило, такое обучение проходит достаточно быстро и практически не влияет на общее время расчета, но повышает точность прогноза.

Данная нейросетевая модель проверена на расчетах прогнозов нагрузки по активной и реактивной мощности на осенних графиках нагрузки (ноября месяца). В табл. 3.3 приведены

Таблица 3.3

**Среднее значение погрешностей прогноза активной и реактивной мощностей по всем узлам**

Время	Активная мощность		Реактивная мощность	
	Относительная погрешность при использовании инверсии нейронной сети, %	Относительная погрешность при использовании коэффициента пропорциональности, %	Абсолютная погрешность при использовании инверсии нейронной сети, МВар	Абсолютная погрешность при использовании коэффициента пропорциональности, МВар
01:00	0,88	1,36	0,48	1,69
01:05	0,93	1,80	0,45	1,68
01:10	0,90	2,02	0,80	2,12
01:15	1,26	1,76	1,25	2,26
01:20	1,54	2,54	0,99	2,23
01:25	2,12	2,68	0,74	1,74
07:00	1,98	3,62	1,18	1,19
07:05	2,45	2,57	1,08	1,07
07:10	2,27	2,78	1,31	1,45
07:15	2,31	4,32	1,16	1,85
07:20	2,45	3,38	0,93	1,43
07:25	2,46	3,44	1,02	1,54
15:00	2,35	3,54	1,17	1,36
15:05	1,36	2,35	1,02	0,83
15:10	1,41	2,43	0,94	1,06
15:15	2,31	3,26	1,24	1,48
15:20	2,31	3,32	0,96	0,92
15:25	3,02	3,54	1,15	0,89
20:00	1,41	1,76	0,74	0,79
20:05	1,07	1,86	0,45	0,70
20:10	1,32	1,67	0,73	0,68
20:15	1,21	2,17	0,68	0,79
20:20	1,38	2,14	0,76	0,64
20:25	3,21	3,26	1,73	1,62

средние значения погрешностей расчета узловых нагрузок для интервалов ночного (с 01:00 до 01:25), утреннего (с 07:00 до 07:25), дневного (с 15:00 до 15:25) и вечернего (с 20:00 до 20:25) времени. Там же, для сравнения, даны значения погрешностей, полученные при пропорциональном распределении нагрузки между узлами. В указанных интервалах времени, относительная погрешность нейросетевой модели находится в пределах от 0,88 до 3,21, а при использовании коэффициентов пропорциональности она изменяется от 1,36 до 4,32%. В связи с постоянной коррекцией весовых коэффициентов перед фактом прогнозирования, на погрешность при внутрисуточном прогнозировании не оказывает влияние изменение погодных условий в различных нагрузочных узлах энергосистемы.

Таблица 3.4

**Средние погрешности расчета активной нагрузки по узлам энергосистемы при внутрисуточном прогнозировании для двух временных интервалов**

Интервал	Нагрузочные узлы	Относительная погрешность при использовании инверсии нейронной сети (%)	Относительная погрешность при использовании коэффициентов пропорциональности (%)
7:00 – 7:25	2	3,53	2,03
	3	1,44	0,98
	4	0,74	3,14
	6	2,81	0,83
	8	1,78	1,82
	9	3,95	3,13
	10	1,80	3,95
	11	0,44	3,75
	12	1,98	8,14
	14	1,02	2,42
	15	0,76	1,35
	16	7,87	3,88
	17	4,71	9,37
15:00 – 15:25	19	1,88	3,27
	20	0,14	2,21
	2	0,91	2,06
	3	0,85	0,86
	4	2,53	1,56
	6	1,72	1,93
	8	1,12	1,90
	9	5,60	6,29
	10	2,48	2,56
	11	1,02	7,39
	12	2,57	2,48
	14	2,44	1,93
	15	1,13	1,30
16	5,23	5,74	
17	3,00	5,90	
19	1,00	3,30	
20	0,41	0,88	

В таблице 3.4 представлены расчеты тех же погрешностей, но для каждого узла схемы и для двух временных интервалов. Для большинства узлов погрешности прогнозов, полученные с применением нейросетевой модели, меньше, чем при расчетах по коэффициентам пропорциональности.

## Заключение

Авторы текста не претендуют на исчерпывающее освещение широкого круга вопросов, прямо или косвенно связанных с решением задачи прогнозирования электрических нагрузок ЭЭС. В предлагаемом издании освещается лишь круг вопросов, связанных с применением аппарата искусственного интеллекта, в частности искусственных нейронных сетей, и нечеткой логики для решения данной задачи. Такой нетрадиционный подход широко обсуждается и применяется за рубежом. В России также есть работы по прогнозированию нагрузок с применением ИНС, но их еще не так много.

Высокие требования рынка электроэнергии к показателям качества прогнозных расчетов (точности, достоверности, быстрдействию и т. п.), обеспечение надежности энергосистем, заставляют искать новые подходы к прогнозированию нагрузок, т. е. такие, которые позволили бы, учитывая современный уровень информационной обеспеченности ЭЭС, давать не только точный прогноз, но и прогноз в режиме реального времени. Результаты исследований, представленные в монографии, а именно: выбор конфигурации нейронной сети, определение входного множества переменных, решение вопросов нормирования входных данных, учет случайных факторов, влияющих на точность прогнозирования нагрузки и др., позволили сделать вывод о том, что нейросетевые модели прогнозирования электрических нагрузок, наряду с другими достоинствами, дают вполне приемлемую точность прогноза.

Нейросетевые модели разработаны для прогнозирования нагрузок как по энергосистеме в целом, так и по энергоузлам, причем модель прогноза по энергоузлам выполнена по принципу инверсии нейронной сети, что позволило сделать прогноз сбалансированным, т. е. прогноз по энергосистеме в целом равен сумме прогнозов, полученных по энергоузлам (чего пока не позволяют получить традиционные методики прогнозирования узловых нагрузок).

Разработанные модели были протестированы на графиках нагрузки ОДУ Урала, т.е. на графиках не той региональной ЭЭС, на примере которой они разрабатывались и обучались. В связи с этим, даны рекомендации по использованию нейросетевых моделей в других энергосистемах. Суть рекомендаций в основном заключаются в необходимости дополнительно исследовать вопрос определения набора входных переменных для данной энергосистемы и выбора формул для их нормирования.

Дальнейшим развитием нейросетевой модели может служить автоматизация выбора оптимального набора ее входных переменных с помощью специально предназначенных для этой цели методов, что позволит без дополнительных исследований использовать мо-

дель в любой энергосистеме (в данной работе этот вопрос решался по принципу «проб и ошибок»). Также можно автоматизировать и подбор формул нормирования.

## Литература

1. Атаманчук Л.М. НЭКСИ – программная среда для создания обучающих нейросетевых экспертных систем // Труды Международной Академии информатизации. Отделение микроэлектроники и информатики. – М.: Зеленоград, 1994. Вып.1. – С. 93-100.
2. Автоматизация диспетчерского управления в электроэнергетике / Под общей ред. Ю.Н.Руденко и В.А.Семенова. – М.: Издательство МЭИ, 2000. – 648 с.
3. Алиев Р.А., Церковный А.Э., Мамедова Г.А. Управление производством при нечеткой исходной информации. - М.: Энергоатомиздат, 1991. - 240 с.
4. Бердин А.С., Крючков П.А.. Формирование параметров модели ЭЭС для управления электрическими режимами. – Екатеринбург: УГТУ, 2000. – 107 с.
5. Бердин А.С., Кузин П.А.. Суворов А.А. Особенности формирования моделей для прогнозирования электропотребления // Энергетика: состояние, проблемы, перспективы: Труды Всероссийской научно-технической конференции. Оренбург: ИПК ГОУ ОГУ, 2007. С.8-13.
6. Бэнн Д.В., Фармер Е.Д. Сравнительные модели прогнозирования электрической нагрузки: Пер. с англ. - М.: Энергоатомиздат, 1987. - 200 с.
7. Борзов С.М., Козик В.И., Потатуркин С.И. Распознавание образов в нейронных сетях с апостериорной обработкой корреляционных функций // Распознавание образов и анализ изображений: Новые информ. технологии / РОАИ-2-95/: Тез.докл. 2 Всероссийск. науч. конф. (28 авг.-1 сент. 1995 г., г. Ульяновск). – Изд-во Ул. ГТУ, 1995. – Ч.1. – С.39-41.
8. Борисов А.Н., Мордовина Е.В. Однослойная нейронная сеть для классификации нечетких образов // Непрерывнологические и нейронные сети и модели: Тр. междунар. науч.-техн. конф. (23-25 мая 1995 г., г. Ульяновск). – Изд-во Ул. ГТУ, 1995. – Т.1. – С.61-63.
9. Богданов В.Л., Денисенко Э.В. Сопоставление моделей оперативного прогноза узловых нагрузок // Изв. АН СССР. Сер. Энергетика и транспорт. - 1982. - № 3. - С.3-10.
10. Вальтин Ю.Ю., Разсаар П.Х., Треуфельдт Ю.Э. Уточнение прогнозов нагрузок электроэнергетической системы и ее узлов // Тр. Таллин. политех. ин-та. - 1985. - № 610. - С. 97-101.
11. Волгин Л.И. Распознавание образов и анализ изображений: Новые информ. технологии // РОАИ-2-95: Тез.докл. 2 Всероссийск. науч. конф. (28 авг.-1 сент.1995 г., г.Ульяновск). - Изд-во Ул. ГТУ, 1995.- 4.11. – С.42-44.
12. Глазунова А.М. «Нейросетевое прогнозирование нагрузки для обеспечения надежности ЭЭС». Российский научный симпозиум по энергетике. Материалы докладов семинара. Методические вопросы исследования надежности больших систем энергетики. Том 4. Казань, 2001. С. 96-99.



13. Гордиенко Е.К., Лукьяница А.А. Искусственные нейронные сети. 1. Основные определения и модели // Техническая кибернетика. – 1994. - № 5. – С.79-92.
14. Галушкин А.И. Многослойные системы распознавания образов. – М.: МИЭМ, 1970.
15. Галушкин А.И. Синтез многослойных систем распознавания образов. – М.: Энергия, 1974. – 367 с.
16. Горбань А.Н., Россиев Д.А. Нейронные сети на персональном компьютере.- Новосибирск: Наука. Сибирск. издательская фирма РАН, 1996. - 276 с.
17. Готман Н.Э., Шумилова Г.П., Старцева Т.Б. Прогнозирование узловых нагрузок электроэнергетической системы с использованием инверсии искусственных нейронных сетей // Труды Сыктывкарского лесного института. – Сыктывкар: СЛИ, 2002. – Т.3. – С.135-138.
18. Демура А.В. Применение нейронной сети Кохонена для классификации суточных графиков нагрузки // Техническая электродинамика. Энергетические системы и установки. – 1995. - №4. – С.76-77.
19. Касаткина Л.М., Кусскуль Э.М. Логический вывод в ассоциативно-проективных структурах // Нейроподобные сети и нейрокомпьютеры: Сб.науч.тр. – Киев, 1991. - С.11-18.
20. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. – 2-е изд., стереотип. – М.: Горячая линия – Телеком, 2002. – 382 с.
21. Кузин П.А., Суворов А.А. Исследование поведения моделей, используемых для прогнозирования энергопотребления // XIII международная научно-практическая конференция студентов, аспирантов и молодых ученых «Современные техника и технологии» (СТТ-2007, Россия, Томск, 26-30 марта 2007): Сборник трудов в 3 т. Томск: ТПУ, 2007. Т. 1. С.57-59.
22. Кусскуль Э.М. Ассоциативные нейроподобные структуры. – Киев: Наук.думка, 1992. – 144 с.
23. Малышев Н.Г., Бернштейн П.С., Боненюк А.В. Нечеткие модели для экспертных систем в САПР. - М.: Энергоатомиздат, 1991. - 136 с.
24. 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.
25. Мелихов А.Н., Бернштейн Л.С., Коровин С.Я. Ситуационные советующие системы с нечеткой логикой. - М.: Наука, 1990. - 272 с.
26. 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.
27. Нечеткие множества в моделях управления и искусственного интеллекта / Под ред. Поспелова. - М.: Наука, 1986. - 206 с.

28. Новые информационные технологии в задачах оперативного управления электроэнергетическими системами / Н.А.Манов, Ю.Я.Чукреев, М.И., Успенский, Г.П.Шумилова и др. – Екатеринбург: УрО РАН, 2002. - 205с.

29. Осовский С. Нейронные сети для обработки информации / Пер. с польского И.Д.Рудинского. - М.: Финансы и статистика, 2002. - 344 с.

30. Прогноз потребления электрической энергии в составе комплекса информационного обеспечения балансирующего рынка / А.С. Бердин, П.А. Крючков, А.А. Суворов, Н.Г. Шубин, С.И. Демидова, О.Д. Ермакова // Современные методы и программные средства анализа и планирования электропотребления, балансов мощности и энергии: Материалы III Всероссийского специализированного научно-практического семинара. М.: ЭНАС, 2005. С.1-7.

31. Прогноз электропотребления: анализ временных рядов, геостатистика, искусственные нейронные сети / Арутюнян Р.В., Богданов В.И., Большов Л.А. и др. – М., 1999 (Препр. Института проблем безопасного развития атомной энергетики РАН; № IBRAE-99-05).

32. Тимченко В.Ф. Колебания нагрузки и обменной мощности энергосистем / Под ред. В.А.Веникова. - М.: Энергия, 1975. - 208 с.

33. Фролов А.А., Муравьев И.П. Нейронные модели ассоциативной памяти. – М.: Наука, 1987. - 161 с.

34. Чукреев Ю.Я., Хохлов М.В., Готман Н.Э. Применение искусственных нейронных сетей в задачах оперативного управления режимами электроэнергетических систем // Новые научные методики. Сыктывкар: КНЦ УрО РАН, 2000. 23 с.

35. Шумилова Г.П., Готман Н.Э., Старцева Т.Б. Модели прогнозирования нагрузок ЭЭС на основе аппарата искусственных нейронных сетей // Методические вопросы исследования надежности больших систем энергетики. Вып.51: Сб.науч.тр.- Сыктывкар: Изд-во Коми НЦ УрО РАН, 2000.-С.268-273.

36. Шумилова Г.П., Готман Н.Э., Старцева Т.Б. Модель суточного прогнозирования нагрузок ЭЭС с использованием нечетких нейронных сетей // Известия РАН. Энергетика.- 2001.- № 4.-С.52-59.

37. Шумилова Г.П., Готман Н.Э., Старцева Т.Б. Краткосрочное прогнозирование электрических нагрузок с использованием искусственных нейронных сетей // Электричество. - 1999. - № 10. - С. 6-12.

38. Шумилова Г.П., Готман Н.Э., Старцева Т.Б.Краткосрочное прогнозирование электрических нагрузок с использованием методов искусственных нейронных сетей // Региональные энергетические исследования: 1953-1998 гг.: Сб.науч.тр. – Сыктывкар: Изд-во Коми НЦ УрО РАН, 1999. – С.160-166.

39. Шумилова Г.П., Готман Н.Э., Старцева. Прогнозирование активной и реактивной нагрузки узлов ЭЭС с использованием инверсии искусственной нейронной сети // Управление электроэнергетическими системами – новые технологии и рынок: Сб.науч.тр. – Сыктывкар: Изд-во Коми НЦ УрО РАН, 2004. – С. 115-122.
40. Шумилова Г.П., Готман Н.Э., Старцева. Прогнозирование электрических нагрузок ЭЭС с использованием методов искусственного интеллекта // РНСЭ, 10-14 сентября 2001. - Материалы докладов. Казань: Казан.гос.энерг.ун-т, 2001. – Т.П. – С.103-106.
41. Шумилова Г.П., Готман Н.Э., Старцева Т.Б. Оперативное и краткосрочное прогнозирование нагрузки узлов ЭЭС с использованием искусственной нейронной сети // Проблемы социально-экономического и инновационного развития энергетики Республики Коми: Сб.науч.тр. – Сыктывкар: Изд-во Коми НЦ УрО РАН, 2004. – С. 129-135.
42. Шумилова Г.П., Готман Н.Э., Старцева Т.Б. Прогнозирование нагрузки узлов электроэнергетической системы с использованием инверсии искусственной нейронной сети // Методические вопросы исследования надежности больших систем энергетики. Вып.57: Сб.науч.тр.- Киев: Знания Украины, 2007.- С.169-179.
43. Шумилова Г.П., Готман Н.Э., Старцева Т.Б. Прогнозирование нагрузки узлов электроэнергетической системы с использованием инверсии искусственной нейронной сети // Электричество. – 2007. - № 6. - С. 7-13.
44. 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. - 1995.- Vol. 10, No 3 - P. 1518 - 1523.
45. Baumann T., Germond A. Application of the Kohonen Network to Short-Term Load Forecasting. IEEE 0-7803-1217-1. - 1993. – P.407-412.
46. Carpenter G., Grossberg S. A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine // Computer Vision, Graphics and Image Processing. – 1987. - Vol.37.
47. 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. – 1992. - Vol. 7, No 3. - P. 1098 – 1105.
48. 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. -1995. - Vol. 142, No 5. - P. 535 - 544.
49. Eberhart R.C. and Dobbins R.W. Designing neural network explanation facilities using genetic algorithms // Proceedings of the International Joint Conference on Neural Networks. Singapore. – 1991. – Vol. L1. – P. 1758-1763.

50. Fogel D.B. Evolutionary computation: Toward a new philosophy of machine intelligence // IEEE Press. – 1995.
51. Geman S., Geman D. Stochastic relaxation, Gibbs distribution and Bayesian restoration of images // IEEE Transaction on Pattern Analysis and Machine Intelligence. – 1984. - Vol. 6.
52. Glazunova A.M. “Enhancement of Neural Network Forecasting Accuracy for Economically Efficient Electricity”. Proc. of the International Workshop «Liberalization and Modernization of Power Systems: Congestion Management Problems», Irkutsk, 2003, pp.210-213.
53. Gross G. and Galiana F.D. Short term load forecasting // Proc. IEEE. – 1987. - Vol.75, No 12. - P. 1558-1573.
54. Hebb D. The Organization of Behavior. – N.-Y.: Wiley. - 1949.
55. Hiroshi Kitajima and Masafumi Hagiwara. Generalized fuzzy inference neural network using a self-organizing feature map // Electrical Engineering in Japan. – 1998. - Vol. 125, No 3. - P. 40-49.
56. Hsy Y., Ho K. Fuzzy expert systems: An application to short term load forecasting // IEE Proceedings – C. – 1992. - Vol. 139, No 6. - P. 471-477.
57. Hopfield J., Tank D. Neural Computation of Decisions in Optimization Problems // Biological Cybernetics. – 1981. – V. 52.
58. IEEE Committee Report “Transient stability test systems for direct stability methods” // IEEE Trans. on Power Systems.- 1992. -Vol. 7, No 1, February. – P.37-44.
59. Jensen C.A., Reed R.D., Marks II R.J., El-Sharkawi M.A., Jung J-B. Miyamoto R.T., Anderson G.M., Eggen C.J. Inversion of feedforward neural networks: algorithms and applications // Accepted for publication in Proceedings of the IEEE. - 1999. - P.1-18.
60. Kohonen T. Self-Organization and Associative Memory. Berlin: Springer-Verlag, 1988.
61. Larkin L.I. A fuzzy logic controller for aircraft flight control // Industrial applications of fuzzy control. Amsterdam. - 1985. - P. 87-104.
62. Lee C.C. Fuzzy logic in control systems: fuzzy logic controller-part I, II // IEEE Trans. on Systems, Man and Cybernetics. - 1990. Vol. 20, No 2. - P.404-435.
63. Lee K.Y., Park J.H. Short-term load forecasting using an artificial neural network // IEEE Trans. on Power Systems. - 1992. Vol. 7, No 1. - P.124 - 130.
64. Meldorf M., Kilter J., Pajo R. Comprehensive Modelling of Load // CIGRE Regonal Meeting, June 18-20, 2007, Tallinn, Estonia. - 2007. – P.145-150.
65. Michalewicz Z. Genetic algorithms + Data structures = Evolution programs // 3<sup>rd</sup> Rev edition, Springer-Verlag. – 1996.
66. Nishina T. and Hagiwara M. A new fuzzy inference neural network with automatic extraction ability for fuzzy rules. Tech. Rep. I.E.I.C.E.. – 1993. - Vol. NC93-124, - P. 93-100 .

67. 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.-1993. - Vol. 8, No3. - P. 1195-1201.
68. Reed R.D. and Marks II R.J. An evolutionary algorithm for function inversion and boundary marking // IEEE International Conference on evolutionary computation (ICEC 95), Perth, Western Australia. – 1995. – P.794-797.
69. Reed R.D. and Marks II R.J. Neural smithing: supervised learning in feedforward artificial neural networks. MIT Press. – 1999.
70. Shumilova G.P., Gotman N.E., Startceva T.B. Electrical load forecasting using an artificial intelligent methods // RNSPE, 10-14 September, 2001, Proceedings. Kazan: Kazan State Power Eng. University, 2001. – Vol. I. - P. 440-442.
71. Srinivasan D., Liew A.C. Chang C.S. Forecasting daily load curves using a hybrid fuzzy-neural approach // IEE Proc - Generat. Transmiss. Distrib. – 1994. - Vol. 141, No 6.- P. 561 - 567.
72. Widrow B. Generalization and Information Storage in Networks of Adaline Neurons // Self-Organizing Systems / Eds Yovits M.C. et al. – Washington, DC: Spartan Books, 1962.
73. Zadeh L.A. Fuzzy sets // Information and control. 1965. - Vol. 8, No 3. - P. 338-353.
74. Zhuang X., Huang Y. Design of Hopfield Content-Addressable Memories // IEEE Intern. Conf on Networks March-April. San Francisco, 1993.
75. Методика прогнозирования графиков электропотребления для технологий краткосрочного планирования (авторы научной разработки А.С.Бердин, П.А.Крючков и П.А.Кузин): [<http://www.t-s-g.ru/cgi-bin/articles/view.cgi?id=1059>].
76. Реформирование компании. Реформирование электроэнергетики. Предпосылки реформирования электроэнергетики: [<http://www.rao-ees.ru>].
77. Технологии обработки данных в прогнозировании. Предварительная обработка данных: [<http://www.iissvit.narod.ru/rass/vip26.htm>].

## ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ .....	3
<i>Глава 1. НОВЫЕ ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ ДЛЯ ПРОГНОЗИРОВАНИЯ ЭЛЕКТРИЧЕСКИХ НАГРУЗОК ЭЭС.</i> .....	5
1.1. Искусственные нейронные сети .....	5
1.2. Нечеткие множества .....	18
1.3. Нечеткие нейронные сети .....	25
1.4. Инверсия нейронной сети прямого распространения .....	26
<i>Глава 2. МЕТОДЫ И МОДЕЛИ ПРОГНОЗИРОВАНИЯ ЭЛЕКТРИЧЕСКИХ НАГРУЗОК ЭЭС С ПРИМЕНЕНИЕМ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ</i> .....	31
2.1. Внутрисуточное прогнозирование .....	31
2.2. Краткосрочное прогнозирование .....	42
2.3. Долгосрочное прогнозирование .....	50
2.4. Реализация нейросетевых моделей для прогнозирования электрических нагрузок ЭЭС (на примере ОДУ Урала) .....	53
<i>Глава 3. ПРОГНОЗИРОВАНИЕ УЗЛОВЫХ ЭЛЕКТРИЧЕСКИХ НАГРУЗОК ЭЭС</i> .....	62
3.1. Прогнозирование узловых нагрузок на сутки вперед .....	64
3.2. Внутричасовое прогнозирование узловых нагрузок .....	66
ЗАКЛЮЧЕНИЕ .....	69
СПИСОК ЛИТЕРАТУРЫ .....	71