

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ И СОВЕРШЕНСТВОВАНИЕ ОПЕРАТИВНОГО УПРАВЛЕНИЯ РЕГИОНАЛЬНЫМИ ЭЭС^{*)}

**Н.А. Манов, М.В. Хохлов, Г.П. Шумилова, М.И. Успенский,
Ю.Я. Чукреев, И.В. Кызродев**

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

Задачи интеллектуализации управления режимами ЭЭС. Управление режимами функционирования ЭЭС делится на автоматическое и оперативное. Оба временных разреза управления характеризуются недостаточной информационной обеспеченностью, несовершенством методов обработки информации и выработки решений, ограниченным временем для принятия управляющих воздействий. Развитие математических методов и средств вычислительной техники, появление микропроцессоров и их совершенствование позволяют в значительной степени снять ограничения на качество управления режимами ЭЭС. В практике управления ЭЭС возможен качественно новый подход к принятию решения – от условий наихудшего, самого тяжелого случая к оптимальной дозировке управляющих воздействий в соответствии с характером возмущения в темпе процесса, прогнозированию развития аварийных процессов и адаптации механизма управления к текущему режиму ЭЭС.

Решению этих задач содействует интеграция систем управления, как объектная, так и функциональная на единой технической и в значительной мере информационной и модельно-программной основе. Можно говорить о взаимосвязях, в том числе информационных, автоматизированных систем диспетчерского управления (АСДУ) разных уровней (региональная ЭЭС, ее сетевой филиал, район электрической сети, электростанция), АСУ ТП объектов, систем защиты, управления и контроля, средств управления в нормальных и аварийных режимах и т.д. По существу можно говорить о наложении на электрическую сеть ЭЭС информационной сети с интеллектуальными узлами, в которых осуществляется обработка информации и принятие локальных решений. Основу информационной сети в задачах оперативного управления режимами ЭЭС в реальном времени составляют телеметрические измерения о перетоках мощности по линиям электропередачи, инъекциях и уровнях напряжения в узлах и телесигналы о состоянии основного оборудования ЭЭС. Именно цикл их обновления определяет темп обработки информации. Такая сеть должна развиваться в русле «интернетизации» человеческой деятельности, то есть заимствовать все передовое, что накапливается в идеологии и средствах «Интернет» и специализированных видах информационных сетей и пригодно для управления режимами ЭЭС. Методологические аспекты интеллектуализации управления в энергетике наиболее полно рассмотрены в [53].

Система управления режимами ЭЭС изначально строилась на принципах распределенного разума, дозировки воздействий, обратной связи и т.д. Однако текущий момент развития технологий представляет совершенно другие возможности как в отношении обмена информацией между узлами управления, так и методов ее переработки. Понимая масштабность задачи интеллектуализации режимов ЭЭС, авторы монографии внесли следующие ограничения в представленные ниже исследования:

- рассматривалась районная (региональная) ЭЭС и апробация новых результатов исследований осуществлялась применительно к Коми ЭЭС;
- более дробный, чем для региональной ЭЭС уровень управления рассматривался на примере распределительной электрической сети;
- рассматривались только нормальные установившиеся режимы ЭЭС;
- рассматривались отдельные задачи оперативного управления ЭЭС, наиболее доступные в настоящее время для приложения методов искусственного интеллекта.

^{*)} В книге: *Новые информационные технологии в задачах оперативного управления электроэнергетическими системами / Н.А. Манов, Ю.Я. Чукреев, М.И. Успенский и др. - Екатеринбург: УрО РАН, 2002. С. 6 - 42.*

Совокупность реальных процессов, которые могут возникнуть при текущем управлении функционирования ЭЭС и, особенно в связи с аварийными ситуациями, существенно шире и богаче, нежели выразительные средства, свойственные численному моделированию. Поэтому большего успеха, в задачах оперативного управления режимами ЭЭС, по-видимому, можно достичь комбинируя широко используемые математические методы с возможностями новых информационных технологий, поддерживаемых средствами искусственного интеллекта таким образом, чтобы достоинства одних компенсировать недостатки других в рамках комплекса задач АСДУ ЭЭС на разных ее территориальных уровнях.

В последнее время достаточно часто для этого привлекаются не численные модели управляемых процессов, а дедуктивные методы, с помощью которых удается создать средства поддержки диспетчерского персонала ЭЭС при формировании управляющих решений в реальном времени. К их числу относятся, например, логико-лингвистические модели, модели использующие аппарат нечеткой логики, искусственных нейронных сетей, генетических алгоритмов и т.п.

Управление режимами начинается с прогнозирования будущего состояния объекта. Неопределенность прогноза определяется случайной составляющей нагрузки потребителя, аварийностью оборудования, возмущениями в системе топливо- и водоснабжения, погодными и социальными условиями, рыночными отношениями и т.п. Из перечисленных факторов неопределенности в монографии рассматривается только случайная величина электропотребления, на которую влияют также погодные и социальные условия. Рынок электроэнергии с прямыми отношениями потребителя и поставщика электроэнергии и текущим формированием цен с учетом потребительской стоимости в Республике Коми в настоящее время не существует и данный фактор является предметом изучения в перспективе. Незапланированные отключения оборудования и непрогнозируемые отклонения нагрузки рассматриваются как возмущения.

В зависимости от решаемых задач прогноз электропотребления может осуществляться на период от года до нескольких минут. В данной работе рассматриваются все циклы прогнозирования режимов, однако, основное внимание уделено суточному и внутрисуточному прогнозированию нагрузки как основы оперативного управления. Применение методов искусственного интеллекта для этой задачи и таких средств как экспертные системы, ИНС, нечеткая логика и генетические алгоритмы характерно для многих стран, как развитых – США, Западная Европа, Япония и др., так и развивающихся – в первую очередь Китая. Как правило, отмечается повышение точности прогноза с использованием методов искусственного интеллекта по сравнению с регрессионными моделями. В некоторых случаях строят гибридные модели, сочетающие оба подхода. Поскольку конкретная технология моделей прогноза нагрузок в публикациях обычно не раскрывается и соответственно воссоздание программных продуктов не возможно, то одна из целей данной работы в апробации созданных в ее ходе программ с использованием методов ИНС и нечеткой логики для условий нестабильного электропотребления в Республике Коми.

Помимо задач прогнозирования в монографии рассмотрены задачи оперативного управления с использованием ИНС. Это – задачи оценивания состояния и расчеты установившихся режимов региональной ЭЭС. Выработка рекомендаций диспетчеру в случае приближения установившихся режимов ЭЭС к опасной черте осуществляется с помощью экспертной системы, аккумулирующей решения отдельных задач.

На уровне диспетчера распределительной электрической сети с использованием методов искусственного интеллекта (ИНС, экспертные системы) решены задачи управления нормальными режимами с учетом послеаварийных ограничений и восстановления электроснабжения потребителей при аварийных отключениях элементов сети. Для обоих уровней оперативного управления (системный, сетевой) разработки доведены до прототипа экспертной системы – советчика диспетчера для рассмотренных задач.

В этой главе монографии приводятся общие вопросы теории искусственных нейронных сетей и особенности их применения для решения задач управления режимами региональной ЭЭС и оперативных переключений в распределительной сети.

Отдельные вопросы теории новых информационных технологий.

Понятие «новая информационная технология» было введено в обиход академиком Г.С. Поспеловым [41] и сразу стало широко использоваться, когда речь заходила о создании новых систем обработки информации в рамках научного направления «искусственный интеллект». Последний термин, напротив, с трудом пробивал себе дорогу в жизнь, поскольку определенно намекал на попытку создания технических систем, заменяющих человеческий мозг, хотя в свое время «отцы» искусственного интеллекта неоднократно подчеркивали недопустимость такого толкования.

Сегодня, благодаря многочисленным популярным и сугубо теоретическим публикациям в области искусственного интеллекта [16-19], это направление ни у кого не вызывает неверного толкования. Искусственный интеллект – это теоретическое направление, в рамках которого исследуются вопросы создания прикладных интеллектуальных систем, или, иначе, систем, ориентированных на обработку и использование знаний в той проблемной области, где решается данная задача. Другими словами, систем, поведение которых напоминало бы разумное поведение человека, а новая информационная технология – это всего лишь средства достижения этих целей.

Современная информационная технология сегодня стала основным инструментальным средством, используемым при создании систем интеллектуального управления, разрабатываемых в рамках теории, появившейся в последние годы на стыке двух теоретических дисциплин – традиционной теории автоматического управления и теории искусственного интеллекта. Под системами интеллектуального управления подразумеваются системы, в контуре управления которых, при формировании управляющих воздействий используются устройства обработки информации, построенные с использованием современных информационных технологий. Интеллектуальные системы управления характеризуются многоуровневой архитектурой, на нижних уровнях иерархии которой используются формальные модели традиционной теории автоматического управления. Управляющие структуры систем такого класса строятся в соответствии с принципом: более высокому уровню в иерархической структуре соответствует более высокая степень интеллектуальности и наоборот [128]. Поскольку понятие интеллектуальность в общепринятом смысле является неформализуемым, обычно под интеллектуальностью системы подразумевается ее способность работать с базой внешних событий (ситуаций), а под степенью интеллектуальности – степень развитости используемых средств преодоления неопределенности используемой информации и знаний закономерностей проблемной среды или внешнего мира, в котором функционирует данная управляющая система. Поэтому нижний уровень иерархической структуры (уровень формальных моделей), называемый в теории интеллектуального управления исполнительным, относится к уровню с нулевой степенью интеллектуальности, а вся обработка неполной и неопределенной информации, связанной с анализом внешних и внутренних ситуаций, осуществляется на более высоких уровнях с использованием таких средств, как логический вывод, правдоподобные рассуждения, обучение и т.п.

Изначально под «новой информационной технологией» подразумевались средства обработки информации, не связанные с алгоритмическими вычислениями, т.е. с вычислительным процессом, который основан на разработанном заранее алгоритме. Оставаясь в рамках этого не совсем точного определения в [22] уточняется, что же представляет современная информационная технология на сегодняшний день и приводится характеристика шести ее важнейших направлений.

Первое направление (обработка знаний и рассуждения на знаниях) используется при создании интеллектуальных систем управления на базе экспертных систем, включенных в их архитектуру на высших уровнях иерархии. Второе направление (обработка нечеткой информации и нечеткий вывод) используется при создании нечетких систем

управления [43]. Третье направление (мягкие вычисления) используется при разработке самообучающихся нечетких систем. Четвертое направление (нейросетевая обработка информации) также используется при создании самообучающихся нейросетевых систем управления. Методы эволюционного моделирования (пятое направление) применяются при настройке и поиске функций принадлежности в нечетких системах управления. И, наконец, шестое направление (многоагентные системы) используется при создании распределенных интеллектуальных управляющих систем.

Подчеркнем, что ниже в этом разделе рассматриваются только те направления, которые уже сегодня нашли широкое применение в практике построения систем автоматического управления режимами функционирования ЭЭС, конкретно это третье и четвертое направления современных информационных технологий.

Искусственные нейронные сети. Первые работы, относящиеся к моделированию искусственных нейронных сетей (ИНС), появились более пяти десятков лет тому назад. В 1943 г. В. Мак-Каллок и В.Питтс впервые рассмотрели модель формального нейрона и показали, что объединения таких элементов в сети могут вычислить любую задачу, доступную машине Тьюринга [107]. В конце 50-х г. Ф.Розенблаттом была сформулирована идея, ставшая основой современной теории искусственных нейронных сетей: структура сети должна, как и в живых организмах, формироваться путем обучения на примерах [47]. Эти исследования представлялись весьма перспективными благодаря удивительным свойствам, присущим искусственным нейронным сетям, напоминающим работу мозга (способность к обобщению воспринимаемой информации, к извлечению существенных свойств из зашумленных данных, к обучению и самообучению на основе собственного опыта функционирования и т.п.). Однако вскоре наступила пора разочарований и затишья, возможно из-за недостаточно развитой в то время полупроводниковой технологии и переключения внимания исследователей на новые модели и методы обработки и использования знаний.

После многих лет почти полного забвения интерес к методам нейросетевой обработки информации возник снова несколько лет тому назад, в частности, в связи с развитием микроэлектронной технологии и разработкой принципиально новых физических принципов реализации элементов и фрагментов нейронных сетей, в том числе сетей с очень большим числом нейронов. Это в свою очередь резко активизировало исследования в области нейроматематики (методов решения задач в нейросетевом базисе) и в области архитектур компьютеров нового типа – нейрокомпьютеров. Основное отличие нейрокомпьютеров от традиционных вычислительных машин состоит в том, что основой вычислений является здесь не алгоритм в классическом его понимании и представлении (например, в виде граф-схемы алгоритма или в виде логической схемы алгоритма), а некий способ вычислений в нейросетевом логическом базисе, т.е. в виде нейронной сети определенной структуры определенной схемы настройки предварительной или в процессе решения задачи [11]. Именно эта особенность и позволяет рассматривать нейросетевую обработку информации в качестве отдельного направления современной информационной технологии.

Искусственную нейронную сеть можно определить как систему, состоящую из большого числа простых вычислительных элементов, имеющих нейронную основу и работающих параллельно, которая способна приобретать, запоминать и использовать опытное знание.

Нейрон. Основной функциональной и структурной единицей нервной системы биологического организма является нервная клетка – нейрон. Нейрон обладает множеством качеств и функций, среди которых уникальной является прием, обработка и передача электрохимических сигналов по нервным волокнам, образующим коммуникационную систему мозга. В нервной системе можно найти множество типов нервных клеток, но большинство из них имеют одну и ту же структуру (рис.1).

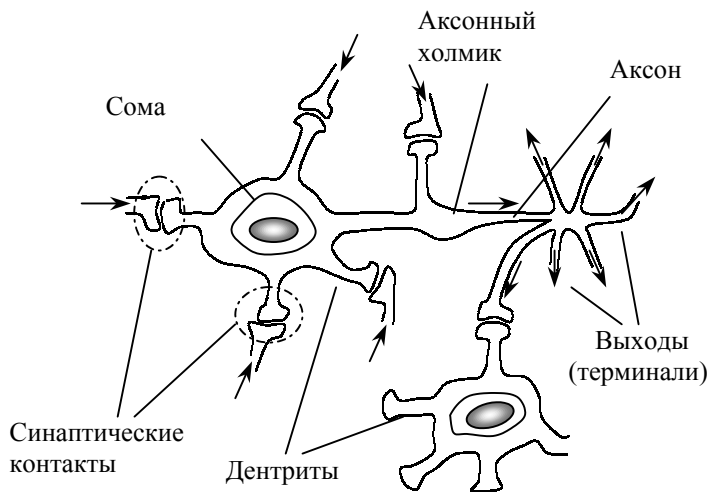


Рис. 1. Биологический нейрон

Отдельные синапсы могут иметь различную эффективность в отношении передачи сигнала от аксона к дендриту, определяемую количеством химического вещества. Чем больше химического вещества, тем сильнее воздействует сигнал на мембрану. В зависимости от степени возбуждения, нейрон генерирует выходные сигналы в области аксонного холмика. Считается, что зависимость интенсивности выходного сигнала от потенциала клетки близка к линейной. Такая весьма упрощенная схема функционирования биологического нейрона положена в основу структуры искусственного нейрона.

Формальная модель нейрона схематично представлена на рис. 2. Здесь x_i - входной сигнал, w_i - весовой коэффициент синаптической связи, θ - параметр смещения, соответствующий фоновой активности бионейрона, net - состояние нейрона (аналог степени возбуждения нейрона), $f(net)$ - передаточная функция нейрона или функция активации, y - выходной сигнал.

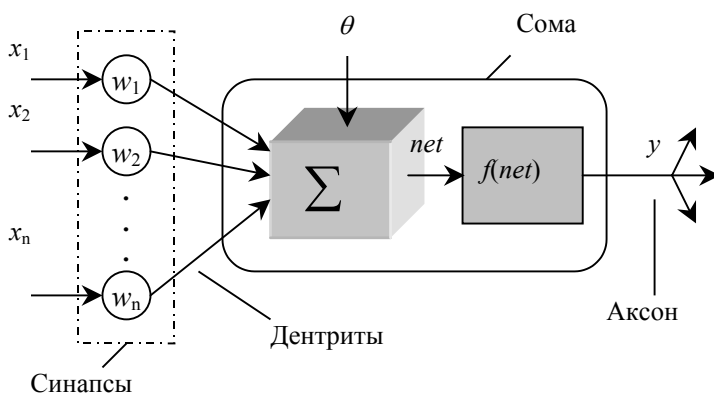


Рис. 2. Формальный нейрон

Каждый входной сигнал x_i умножается на соответствующий вес w_i , реализуя принцип синаптической передачи – чем эффективнее синапс, тем сильнее воздействие сигнала на клетку. Суммирующий блок Σ определяет состояние нейрона, обусловленное воздействием n входных сигналов:

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

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

Выходной сигнал формируется в соответствии с заданной функцией активации (табл.1.1), более или менее точно описывающей передаточную характеристику биологического нейрона $y = f(net)$. Такая модель нейрона является основной при построении искусственных нейронных сетей. Однако находят применение и другие типы

нейронов, использующие квадратичные (и более высокого порядка) сумматоры, радиально-симметричные, тригонометрические, булевы и др. функции активации, а так же расстояние между векторами $\mathbf{x} = \{x_i\}$ и $\mathbf{w} = \{w_i\}$ в какой-либо метрике вместо суммирующего блока.

Искусственная нейронная сеть. Несмотря на то, что модель нейрона довольно простая, организация их в нейронные структуры (ансамбли, сети) обладает свойствами, не характерными отдельному элементу. Именно с нейронными структурами, так или иначе, связаны функции памяти и обработки информации биологических организмов. Изучение различных отделов нервной системы обнаруживает наличие различных нейронных структур. Соответственно это привело к появлению различных моделей ИНС [57,105]. Среди них можно выделить три типа сетей, обладающих существенно различными свойствами и принципами функционирования: сети прямого распространения, сети Кохонена и рекуррентные сети Хопфилда.

1. *Многослойные сети прямого распространения*, называемые также слоистые сети или перцептронные, находят наибольшее применение при решении прикладных задач. Нейроны в сети организованы по слоям и взаимодействуют лишь с нейронами предыдущего и последующего слоя (рис. 3). Установлено, что слоистые структуры образуют нейроны на высших уровнях центральной нервной системы, где вероятно локализованы память и высшие функции обработки информации.




Рис. 3. Многослойная нейронная сеть прямого распространения

Выделяют входной слой, служащий для распределения входных сигналов между нейронами следующего слоя, выходной слой и один или несколько скрытых слоев, расположенных между входным и выходным. Входной сигнал, подаваемый на сеть, поступает на нейроны первого скрытого слоя, проходит по очереди 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 функции активации нейронов и величин весовых коэффициентов связей.

В укрупненном виде многослойная сеть представляет собой функциональный преобразователь и используется для решения задач распознавания и классификации, прогнозирования, идентификации и т.д.

2. *Сети Кохонена* состоят из одного слоя нейронов (слоя Кохонена) и входного слоя, предназначенного для распределения входных сигналов между нейронами (рис.4). В слое Кохонена нейроны располагаются чаще всего на прямоугольной или гексагональной решетке. Каждому нейрону сопоставляется множество объектов входного пространства, обладающих близкими свойствами. При предъявлении сети входного вектора результатом работы сети будет наиболее возбужденный нейрон (нейрон-победитель):

Таблица 1.1

Функции активации

Тип функции	Вид
Пороговая $f(net) = \begin{cases} 1, net > 0, \\ 0, \text{ иначе.} \end{cases}$	
Сигмоид $f(net) = \frac{1}{1 + e^{-net/c}}$	
Гиперболический тангенс $f(net) = \frac{1 - e^{-net/c}}{1 + e^{-net/c}}$	

$$i(\mathbf{x}) = k, \quad \text{где } \|\mathbf{w}_k - \mathbf{x}\| < \|\mathbf{w}_j - \mathbf{x}\|, \quad j = 1, 2, \dots, n,$$

где $i(\mathbf{x})$ - индекс “нейрона-победителя”, \mathbf{x} - входной вектор, \mathbf{w}_j - вектор весов j -го нейрона, n - число нейронов на решетке. Этот нейрон определяет класс, к которому принадлежит входной объект.




Рис. 4. Нейронная сеть Кохонена

В самоорганизующихся сетях Кохонена (картах особенностей) нейроны на решетке упорядочены таким образом, что классам, расположенным близко (в заданной метрике) во входном пространстве, соответствуют нейроны расположенные рядом на решетке. Таким образом, говорят, что сеть выполняет отображение входного многомерного пространства на двумерную решетку с сохранением топологической упорядоченности входных объектов. Упорядоченность нейронов на решетке достигается в процессе обучения сети за счет механизма латерального

взаимодействия нейронов. В основу такого механизма Т.Кохонен положил процессы, происходящие в зрительной коре головного мозга. Сети Кохонена используются при решении задач кластеризации, распознавания образов и классификации и др.

3. *Сеть Хопфилда* относится к классу рекуррентных нейронных сетей, т.е. сетей имеющих обратные связи. Она состоит из одного слоя нейронов, связанных каждый друг с другом (рис. 5). Все нейроны являются одновременно и входными и выходными. Состояние k -го нейрона в момент $t+1$ определяется как

$$net_k(t+1) = \sum_{j \neq k} y_j(t) w_{jk} + \theta_k,$$

где $y_j(t)$ - выходной сигнал j -го нейрона в предыдущий момент, получаемый после применения функции активации. В простейшей пороговой сети:

$$y_j(t) = \begin{cases} +1, & \text{при } net_j(t) > 0, \\ -1, & \text{при } net_j(t) < 0, \\ y_j(t-1), & \text{иначе.} \end{cases}$$




Рис. 5. Нейронная сеть Хопфилда

Концепция сети Хопфилда основана на сходстве полносвязной нейронной сети со спиновым стеклом – мультиустойчивой системой, которая будучи выведена из равновесия, совершает колебания, завершающиеся переходом (конвергенцией) в ближайшее устойчивое состояние (аттрактор), отвечающее минимуму потенциальной энергии. Д.Хопфилдом доказано, что сеть с ограниченной функцией активации (пороговой или сигмоидной) имеет устойчивые состояния, если $w_{ij} = w_{ji}$. Проводя аналогию между аттракторами спинового стекла и следами памяти, Д.Хопфилд пришел к выводу, что конвергенция является аналогом ассоциативного поиска информации. При подаче на вход сети некоторого вектора данных $y(0) = \mathbf{x}$ или

части его, сеть начинает релаксировать в ближайший аттрактор, соответствующий одному из запомненных ранее состояний. После чего на выходе сети устанавливается вектор реакции, ассоциируемый с входным стимулом.

Д.Хопфилду удалось так же показать, что предложенная им модель ИНС обладает еще одним ценным качеством. При конвергенции она выполняет поиск минимума энергетической функции. Устанавливая определенным образом веса связей в начальное состояние, можно использовать это свойство для решения сложных оптимизационных

задач. Меньше внимания с практической точки зрения получили рекуррентные сеть Хэмминга и сеть Коско.

Обучение ИНС. Обучение заключается в настройке параметров ИНС с тем, чтобы при подаче на вход сети некоторого набора сигналов, она могла воспроизводить на выходе требуемую реакцию. На сегодняшний день общепринятой является синаптическая теория памяти и обучения, основанная на результатах исследований нейропсихолога Д.О.Хебба. Это означает, что информация, закладываемая в ИНС в процессе обучения, должна храниться в межнейронных соединениях – синапсах. Таким образом, обучение заключается в модификации синаптических весов нейронов w_{ij} . Этот искусственный процесс имеет некоторый биологический аналог. В процессе интеллектуального развития человеческой личности наблюдаются метаболические изменения в синаптической передаче. Такие функциональные изменения могут приводить к структурным изменениям. Природа функциональных и структурных изменений до сих пор до конца не исследована. Если некоторые алгоритмы обучения ИНС хоть отдаленно, но воспроизводят реальный процесс образования памяти, то большинство из них являются абсолютно искусственными. Не затрагивая вопросы структурной самоорганизации, рассмотрим алгоритмы обучения ИНС, описанных выше.

1. *Обучение многослойной сети* супервизорное, требует наличие обучающей выборки, состоящей не только из множества входных векторов, но и множества соответствующих откликов. Цель обучения – найти функцию, обобщающую примеры, т.е. научиться реагировать схожим образом в схожих ситуациях. Математически задача заключается в нахождении таких значений весовых коэффициентов (при фиксированной структуре), чтобы минимизировалась ошибка рассогласования между реакцией сети и требуемым откликом для всех примеров обучающей выборки. Например:

$$\min E = \sum_{i=1}^p E_p = \sum_{i=1}^p \sum_{j=1}^m (y_{ij} - d_{ij})^2,$$

где y_{ij} , d_{ij} - соответственно фактическая и желаемая реакция j -го нейрона выходного слоя на i -й входной вектор, p – число примеров в обучающей выборке, m – число нейронов в выходном слое.

Все существующие методы обучения можно классифицировать на детерминистские и стохастические. В первом случае процедура коррекции весов использует информацию о градиенте функции ошибки E и требует дифференцируемости функции активации. Простейший вариант реализует градиентный спуск в пространстве весовых коэффициентов, осуществляемый последовательно для всех примеров обучающей выборки:

$$\Delta w_{ij}^{(k)}(t) = -\eta \frac{\partial E_p}{\partial w_{ij}^{(k)}}, \quad k = 1, 2, \dots, K,$$

где $w_{ij}^{(k)}$ - весовой коэффициент j -й связи i -го нейрона в слое k , η - скорость обучения, K – число слоев нейронов в сети.

Используя правило дифференцирования сложной функции

$$\frac{\partial E_p}{\partial w_{ij}^{(k)}} = \frac{\partial E_p}{\partial y_i^{(k)}} \frac{\partial y_i^{(k)}}{\partial net_i^{(k)}} \frac{\partial net_i^{(k)}}{\partial w_{ij}^{(k)}}$$

где $y_i^{(k)}$ и $net_i^{(k)}$ - соответственно выходной сигнал и состояние i -го нейрона k -го слоя ($y_i^{(0)} = x_i$), и проведя некоторые преобразования можно получить рекурсивный алгоритм коррекции весов, начинающийся на выходных нейронах и возвращающийся к первому слою:

$$w_{ij}^{(k)}(t+1) = w_{ij}^{(k)}(t) - \eta \delta_i^{(k)} y_j^{(k-1)}$$

Дельта ошибка $\delta_i^{(k)}$ i -го нейрона для выходного слоя определяется как

$$\delta_i^{(k)} = (y_i^{(k)} - d_i) f'(net_i^{(k)})$$

и затем рекурсивно пересчитывается для всех слоев:

$$\delta_i^{(k)} = f'(net_i^{(k)}) \sum_{j=1}^{h^{(k+1)}} \delta_j^{(k+1)} w_{ji}^{(k+1)}, \quad k = 1, 2, \dots, K-1,$$

где $h^{(k)}$ - число нейронов в k -ом слое, $f'(\cdot)$ - производная функции активации по ее аргументу.

Эти соотношения называются формулами обратного распространения ошибки и были получены Д.Е.Румельхартом [115]. В настоящее время разработаны как различные модификации алгоритма обратного распространения ошибки [57,105,111], так и более мощные процедуры обучения ИНС, реализующие такие методы поиска, как метод сопряженных градиентов, квазиньютоновские методы и т.п. [16,18].

Стохастические методы обучения выполняют псевдослучайные изменения значений весов, сохраняя те изменения, которые ведут к уменьшению функции ошибки. Для этого привлекаются методы адаптивного случайного поиска, имитация отжига, генетические алгоритмы и др. [57,111,124].

Обучение сетей Кохонена несупервизорное [100]. Обучающая выборка представлена лишь входными векторами. Сети предлагается самой найти скрытые закономерности в массиве исходных данных. Так в самоорганизующейся карте особенностей Кохонена необходимо определить такие значения весов, чтобы при отображении входного пространства на двухмерную решетку в выходном пространстве сохранялась топологическая упорядоченность. Обучение основано на правиле Кохонена:

$$w_{jk}(t+1) = \begin{cases} w_{jk}(t) + \eta(t)(x_k - w_{jk}(t)), & \text{при } j \in \Lambda_{i(x)}(t), \\ w_{jk}(t), & \text{иначе,} \end{cases}$$

где w_{jk} - весовой коэффициент k -й связи j -го нейрона, η - скорость обучения, $\Lambda_{i(x)}$ - функция соседства, определяющая множество нейронов, расположенных в окрестности нейрона-победителя $i(x)$.

Обучение самоорганизующейся карты особенностей имеет две фазы. В первой фазе имеет место глобальное топологическое упорядочивание векторов весов: множество подвергаемых обучению нейронов первоначально включает все нейроны слоя $\Lambda_{i(x)}(0) = \max$, ограничиваясь в конце фазы ближайшими нейронами вплоть до нейрона победителя $\Lambda_{i(x)} = 0$. Во второй фазе вектора весов сходятся к точному значению центров классов.

Обучение сети Хопфилда как таковое не выполняется. Сеть скорее конструируется под поставленную задачу. Используя сеть в качестве автоассоциативной памяти надо определить такие значения весов, чтобы устойчивые состояния системы соответствовали образцам, которые требуется хранить в сети. Расчет весовых коэффициентов основывается на правиле Хебба:

$$w_{ij} = \begin{cases} \sum_{k=1}^p x_i^k x_j^k, & \text{при } i \neq j, \\ 0, & \text{иначе,} \end{cases}$$

где x_i^k , x_j^k - элементы вектора k -го образца, p - число образцов. Сеть фактически просто запоминает образцы до того, как на ее вход поступают реальные данные.

Для решения оптимизационных задач сеть конструируется так, чтобы минимизация исходной целевой функции соответствовала минимизация энергетической функции сети. Весовые коэффициенты тогда непосредственно вытекают из условия решаемой задачи. Д.Хопфилдом показано, как организовать на сети вычисления, связанные с решением задач линейного программирования [95].

Нечеткие множества. Выделение методов и средств обработки нечеткой информации [37, 123, 127] в отдельное направление современной информационной технологии оправдано тем, что эта технология является базой для построения всевозможных интеллектуальных программных систем, получивших название нечетких систем или нечетких множеств [43]. 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, контролирующего управляемый процесс, переводятся в значения лингвистических переменных в специальном блоке, получившем название «фазификатор». 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 «дефазификатор». 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 переменных. 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 [53]. Не всегда оправданы по смыслу используемые методы дефазификации 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.

Понятие нечеткого множества 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».

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, приведенные в пятой главе монографии. 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 [103].

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

Нечеткой переменной называется $\langle A, X, C_A \rangle$, 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) [30].

Лингвистической переменной называется $\langle B, T, X, G, M \rangle$, 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 [30]. 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 [37, 103] $A = \{(x, \mu_A(x)) | x \in X\}$, где μ_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 μ_A и μ_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 [103] $\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\}$.

Пересечение: Функция принадлежности $\mu_{A \cap B}$ при пересечении A и B определяется как [103] $\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\}$.

Существует несколько способов 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 $\mu_{\bar{A}}(x) = 1 - \mu_A(x)$ [103]. 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 [2, 30, 103].

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:

P_1 = ЕСЛИ x есть A , ТО y есть B ;

P_2 = ЕСЛИ x есть A , ТО y есть B ИНАЧЕ C ;

P_3 = 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 [126]. 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 [30].

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 вероятностное субъективное измерение нечеткости и что она отличается от вероятностной меры [33]. 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 [33] 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 [103]: 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 $\mu_f(x) = \sum_{i=1}^5 a_i / x_i$, где $a = [0,3; 0,7; 1,0; 0,7; 0,3]$.

2. *Функциональный метод определения.* Функция принадлежности в функциональной форме типично описывается либо колоколообразной, либо треугольной, либо трапецевидной 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

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

Если нормализованное универсальное множество меняется,

то, соответственно, должны быть изменены и параметры u_f и σ_f .

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 [102].

Схема управления на основе нечеткой логики. Рассмотрим схематически, как воплощаются в практику рассмотренные ранее теоретические положения нечетких множеств. На рис. 6 изображена основная конфигурация схемы управления на основе нечеткой логики. Она включает в себя четыре основных блока [103]: блок фаззификации (*fuzzification*), база знаний, блок логики принятия решения и блок дефаззификации (*de-fuzzification*).

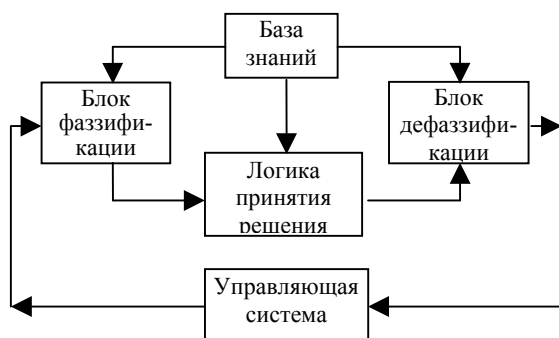


Рис. .6. Конфигурация схемы управления на основе нечеткой логики

Блок фаззификации выполняет следующие функции:

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

База знаний. Она содержит базу дан-

ных и базу лингвистических (нечетких) правил управления.

Блок логики принятия решения. Этот блок является как бы сердцевиной схемы. 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*).

Особенности применения информационных технологий для решения задач оперативного управления ЭЭС Предпосылки к применению нейронных сетей. При решении задач управления функционированием ЭЭС необходимо исходить из специфики рассматриваемого объекта – большой сложной системы кибернетического типа, характеризуемой стохастичностью поведения и быстротечностью протекающих в ней процессов, наличием весьма глубоких внутренних связей и большим числом взаимосвязанных и взаимодействующих между собой элементов. В настоящее время основным формализованным средством анализа функционирования и управления режимами ЭЭС является математическое моделирование, основу которого составляет совокупность математических моделей, адекватно отражающих исследуемые процессы в ЭЭС [3].

Повышение сложности ЭЭС, тенденция к комплексному рассмотрению процессов, происходящих в них, и ужесточение требований к оперативности расчетов приводит к объективным трудностям построения и использования математических моделей, использующих язык традиционной математики, т.е. системы дифференциальных и алгебраических уравнений. Создание таких математических моделей предполагает наличие априорных знаний основных функциональных связей в изучаемых процессах и всех особенностей среды, в которой действует моделируемый объект. При этом область моделирования, множество переменных и основные уравнения должен указать сам исследователь в результате глубокого изучения объекта. Если для простых систем имеются достаточно хорошо разработанные традиционные точные методы построения их адекватных моделей, то для сложных систем нужные связи часто неизвестны, недостоверны или нестабильны. Это вызвано тем, что при изучении характеристик сложных систем достаточно трудно расчленять их на независимые составляющие, в силу того, что сложная система в целом обладает новыми качествами, не свойственными отдельным ее элементам. Но даже зная нужные связи, задачу не всегда удается формализовать или затраты на формализацию и программирование оказываются чрезмерно большими. И, наконец, если указанные препятствия все же преодолены, то ресурсов времени, как правило, не хватает не только для работы в реальном масштабе времени, но и для завершения «счета» в приемлемое время. Отсюда вытекает основное противоречие современного моделирования, а именно противоречие между необходимостью учета действия большого числа факторов для обеспечения адекватности модели реальным процессами функционирования сложных ЭЭС и необходимостью быстрого получения надежных

результатов. В результате применение традиционных многомерных нелинейных моделей, реализуемых численными методами, при решении задач оперативного управления функционированием ЭЭС, требующих многократных и многовариантных расчетов, оказывается малоэффективным, а зачастую невозможным.

Можно выделить две взаимно дополняющих друг друга тенденции развития, которые позволяют преодолеть трудности, возникающие в моделировании сложных систем в силу указанного выше противоречия:

1. Быстрое развитие вычислительной базы, позволяющее повысить максимальную размерность решаемых задач, а так же сократить время, затрачиваемое на их решение. Это происходит благодаря как увеличению вычислительной мощности ЭВМ, так и наметившейся тенденции к созданию параллельных вычислительных систем высокой производительности.

2. Разработка принципиально новых концепций и прогрессивных подходов к решению задач моделирования, отвечающих специфике ЭЭС как сложной кибернетической системы и вытекающим отсюда особенностям решаемых задач. В основном здесь понимается проблема построения адекватных моделей в условиях отсутствия априорных знаний законов, лежащих в основе моделируемого процесса.

Особенности нейросетевого моделирования. В настоящее время, в рамках изучения принципов функционирования структур мозга, выделился новый подход в решении задач моделирования сложных систем на базе искусственных нейронных сетей. Известно, что мозг является самой мощной «вычислительной системой», существующей в природе. Обладая высокой степенью параллелизма обработки информации, способностью находить едва уловимые взаимосвязи и скрытые закономерности между данными, выделяя и удерживая при этом множество влияющих факторов, мозг способен создавать внутренние модели достаточно сложных явлений и процессов окружающего мира и решать не поддающиеся формализации сложные задачи с высоким быстродействием. Аппарат искусственных нейронных сетей, кратко изложенный в разделе 1.2 монографии, достаточно отдаленно воспроизводит реальные процессы функционирования мозга. Тем не менее, ИНС наследуют чрезвычайно важное для моделирования свойство биологического прототипа, а именно – высокую способность к обучению, т.е. к созданию внутренней модели.

Содержательное обучение формирует в нейронной сети связи, с помощью которых, как и в случае математической модели, можно имитировать изучаемые объекты и процессы. В своей основе методы нейросетевого моделирования реализуют один из фундаментальных кибернетических принципов, согласно которому изучение системы основывается на наблюдении состояний выхода системы при известных воздействиях, поступающих на вход. Модель системы строится при этом как описание ее в виде функционального преобразователя вектора входных переменных в вектор выходных, т.е. как внешнее описание, абстрагирующееся от механизмов внутренних процессов. Такой подход принципиально отличается от классического подхода, применяемого при моделировании ЭЭС, в основе которого лежит воспроизведение процессов «внутри» моделируемой системы. Принцип ассоциативного связывания входных (исходных) и выходных (расчетных) параметров моделируемой системы или объекта может облегчить или полностью исключить этапы изучения и формализации задачи.

Исходя из вышеизложенного можно сформулировать основные преимущества использования ИНС в решении задач управления режимами ЭЭС:

1. Возможность построения моделей сложных процессов, трудно поддающихся или не поддающихся вовсе аналитическому описанию. Наглядным примером могут служить задачи прогнозирования электрической нагрузки и оценки оперативной надежности.

2. Возможность получения моделей более простого вида, что позволяет упростить многие процедуры и повысить эффективность алгоритмов принятия решений. Традиционные методы моделирования при решении задач предусматривают вычисление всех

переменных, связанных с полученной первичной моделью. В то же время с точки зрения построения вычислительной модели особое значение имеет тот факт, что зачастую требуется только часть полного вектора переменных. Так для определения степени устойчивости или неустойчивости ЭЭС в аварийной ситуации необходимо полностью промоделировать процесс перехода системы из исходного состояния в послеаварийное. Используя принцип ассоциативного связывания удается построить модель, устанавливающую соответствие между совокупностью некоторых зафиксированных параметров, характеризующих аварийную ситуацию в ЭЭС (т.е. схему, режим и возмущение) и показателем устойчивости.

3. Высокая надежность получения результата в силу формирования явной зависимости искомых параметров от заданных. Традиционные модели, представляющие собой в большинстве случаев системы неявных функций, требуют применения итерационных методов, с необходимостью обеспечения гарантированной сходимости в условиях реального времени.

Построение любой нейросетевой модели требует выполнения следующих этапов:

1. Формулировка задачи в нейросетевом базисе.
2. Формирование выборки обучения.
3. Выбор архитектуры ИНС, в том числе параметров элементов нейронной сети (идентификация структуры модели).
4. Обучение ИНС (оценивание параметров модели).
5. Тестирование ИНС с целью установления адекватности полученной модели исследуемому объекту.

Содержание этапов 3 – 5 раскрыто в многочисленных работах по теории нейронных сетей и частично отражено в разд. 1.2. Теоретические разработки достигли определенного уровня реализации в большом количестве создаваемых исследовательских и промышленных как программных продуктов, так и аппаратных средств (нейрокомпьютеров). В контексте данного раздела наибольший интерес представляет решение первого и второго этапов построения нейросетевой модели.

Формулировка задач в нейросетевом базисе. Особенности нейросетевого моделирования инициировали множество исследований его применения при решении различных задач оперативного управления ЭЭС. Пальма первенства принадлежит работам зарубежных авторов, достигшим значительных результатов в данном направлении исследований. Об этом свидетельствует большое количество публикаций в центральных изданиях и материалах постоянно действующих конференций и семинаров по проблемам использования ИНС в электроэнергетике [85]. Несмотря на различие решаемых задач, алгоритмических подходов и реализаций, большинство из них отталкиваются от одной и той же постановки: найти функцию зависимости между наблюдаемыми исходными данными, характеризующими состояние моделируемого объекта, и выходными расчетными параметрами в классе функций, реализуемых нейронной сетью, с последующим использованием построенной функции для быстрого отображения входных сигналов в выходные в рамках решения задачи реального времени:

$$\mathbf{Y} = f(\mathbf{X}), \quad (1.1)$$

где \mathbf{X} – вектор входных параметров; \mathbf{Y} – вектор выходных параметров; $f(\mathbf{X})$ – преобразующая вектор-функция.

Математически (1.1) представляет собой уравнение множественной непараметрической нелинейной регрессии. В случае целочисленности величин \mathbf{Y} получается задача классификации. К постановке (1.1) могут быть сведены в принципе все задачи оперативного управления ЭЭС. По своей природе ИНС относятся к системам распознавания образов. В отличие от параметрических (статистических) методов распознавания образов нейросетевые методы не ограничены классом решающих функций и являются универсальными. Это позволяет предполагать, что ИНС найдут должное место при решении таких задач, где уже оказались эффективными алгоритмы распознавания на основе методов теории статистических решений.

Оперативное прогнозирование параметров режима. Прогнозирование электрической нагрузки ЭЭС с помощью ИНС как частный случай прогнозирования параметров режима лежит в центре внимания многих исследователей, рассматривающих применение ИНС в электроэнергетике. Согласно [85], это приложение занимает наибольшую долю (свыше 20 %) всех приложений ИНС для решения электроэнергетических задач. Следует заметить, что, судя по всему, первая попытка использования нейроразнообразной системы прогнозирования суточных графиков нагрузок была выполнена А.П. Резниковым в 1969 году [46].

Возможность прогнозирования нагрузки обусловлена наличием объективных закономерностей процессов потребления электроэнергии, в частности периодичностью изменения нагрузки (в недельном и суточном цикле) и инерционностью процессов изменения на малых интервалах времени. Это позволяет прогнозировать значения нагрузки по прошлым зафиксированным значениям. В таком случае нейросетевая модель прогнозирования нагрузки вида (1.1) имеет в качестве входных переменных X уровни нагрузки за предшествующий период, а в качестве выходных переменных Y прогнозные уровни нагрузки на заданный интервал упреждения. Включение в вектор X различных дополнительных факторов, влияющих на поведение режимных параметров, наиболее важными из которых представляются метеорологические условия и признаки характерных дней, в ряде случаев позволяет добиться большей адекватности модели динамическому процессу изменения нагрузки.

Другая задача прогнозирования параметров режима заключается в определении значений одних параметров в функции от других, например, нагрузок узлов как функции от суммарной нагрузки ЭЭС или от нагрузки других узлов. Такая задача возникает при оценивании состояния ЭЭС, когда текущая телеметрическая информация не обеспечивает наблюдаемость некоторого района системы, однако имеется тесная зависимость между наблюдаемыми и ненаблюдаемыми параметрами. В этом случае первые являются входными переменными нейросетевой модели (1.1), а последние – выходными. Такой подход представлен в работе [26].

Анализ установившихся режимов. Управление нормальным функционированием ЭЭС в условиях реального времени так или иначе связано с задачами расчета установившегося режима и его оптимизации по тем или иным критериям. При этом часто возникает задача принятия решения о необходимости коррекции параметров режима и выработке соответствующих управляющих воздействий. Традиционный подход требует выполнения многократных расчетов установившегося режима для оценки допустимости того или иного режима и решения общесистемной сложной многопараметрической задачи на экстремум по дооптимизации режима.

В условиях реального времени для быстрой оценки режима используются методы теории распознавания образов. Для описания области допустимых режимов в пространстве характерных параметров X , определяющих режим работы и схему ЭЭС, строится решающая гиперповерхность, разделяющая множество возможных состояний на два класса – допустимых и недопустимых режимов. Построение этой поверхности осуществляется с помощью той или иной обучающей процедуры. После этого оценка допустимости режима осуществляется очень быстро по знаку решающей функции Y в точке, соответствующей исследуемому режиму [7].

Для оценки степени неоптимальности режима и установления необходимости его оперативной коррекции в [5] предлагается совокупность регрессионных и статистических методов распознавания образов. Решение о выполнении коррекции принимается в случае выхода исследуемого режима за пределы зоны равноэкономичных режимов, фиксируемого системой распознавания. Кроме оценочных моделей возможно построение моделей, связывающих регрессионной зависимостью совокупность режимных параметров X и управляющих воздействий Y по вводу режима, как в допустимую область, так и в зону равноэкономичных режимов. Для реализации описанных моделей могут оказаться эффективными нейросетевые методы распознавания образов. Обладая

высокими аппроксимирующими свойствами, они способны обеспечить более качественное построение решающих функций и меньшую ошибку распознавания.

Использование ИНС непосредственно для расчета установившихся режимов сводится к построению явной функции зависимости между заданными параметрами, характеризующими режим и состояние ЭЭС X и искомыми параметрами Y в качестве которых выступают обычно комплексы узловых напряжений. Такой подход не требует решения систем линейных уравнений и в отличие от упрощенных методов расчета нейросетевая модель отражает полную нелинейную модель установившегося режима. В качестве входных параметров ИНС для представления всего возможного схемно-режимного многообразия состояний ЭЭС могут выступать активные и реактивные узловые мощности, состав оборудования и др.

В ряде случаев требуется быстрая оценка только ограниченного числа наиболее важных параметров, например, перетоков мощности по основным системообразующим связям, модулей напряжения в контрольных точках сети и т.п. Тогда целесообразнее использовать модель более простого вида, не требующую полного расчета всех параметров режима. В таких случаях выходными переменными ИНС являются непосредственно искомые параметры режима. В общем случае, в качестве выходных переменных ИНС могут выступать любые характеристики, ассоциируемые с заданным на входе установившимся режимом, а именно, предельные перетоки мощности в связях, предельные уровни напряжений в узлах и другие показатели надежности и экономичности режима.

Оценивание состояния. Формулировка задачи оценивания состояния ЭЭС в нейросетевом базисе почти аналогична вышерассмотренной задаче расчета установившихся режимов за исключением того, что вектор исходных данных (телеизмерений) является избыточным и содержит случайные ошибки. Соответственно выходными переменными нейросетевой модели являются сбалансированные оценки параметров режима, минимизирующие ошибки входных данных. Впервые возможность такой постановки задачи оценивания состояния ЭЭС с использованием ИНС, как и упомянутой выше задачи прогнозирования суточных графиков нагрузок, была показана в 1969 году в работе А.П.Резникова, разработавшим нейроподобную обучающуюся систему ДВОИС [46]. Среди современных работ авторам известна лишь одна публикация по этой теме, где исследуется линейная нейронная сеть с расширенным входным базисом [82].

Актуальным приложением ИНС является распознавание различных аномальных ситуаций при оценивании состояния ЭЭС, когда традиционные методы решения отсутствуют или они не эффективны: сбоя в телеметрических каналах (измерение – верное/неверное), внезапных изменений состояния элементов сети (ЛЭП – включена/отключена), изменений положения отводов регулируемых трансформаторов и т.п. В этом случае ИНС устанавливает функциональную зависимость между классом события и наиболее значимыми входными переменными, являющимися либо измерениями некоторых параметров режима, либо изменениями их величины с момента предыдущего замера [122].

Оперативная оценка надежности. Оперативная оценка надежности ЭЭС требует моделирования множества отказов оборудования системы, анализа последствий данных отказов путем проведения расчетов установившихся и переходных режимов (с учетом корректирующих действий) и вычисления некоторого показателя надежности. В качестве показателя надежности может выступать величина суммарной отключаемой противоаварийной автоматикой мощности нагрузки и/или генерации по отдельным узлам и ЭЭС в целом, взвешенной по вероятности i -го отказа. Расчет показателя надежности может производиться как для заданной точки графика нагрузки, так и для заданного отрезка графика нагрузки. Показатели надежности являются неаналитическими функциями исследуемых на множестве отказов режимов ЭЭС, поэтому основной способ последующего их использования заключается в организации интерактивного режима работы диспетчера с пакетом программ оперативной оценки надежности [34].

Очевидно, что реализация этой задачи в оперативном режиме управления не представляется возможной.

Задача оперативной оценки надежности может быть решена путем формирования обучающей выборки с последующим построением нейросетевой модели (1.1), представляющей явную функцию зависимости показателя надежности от параметров, характеризующих состояние ЭЭС на исследуемый момент. С целью дальнейшего использования информации о показателе надежности для выработки корректирующих воздействий важно включить в состав входного вектора X регулируемые переменные. Достоинство нейросетевого подхода к оценке надежности по сравнению с традиционным, помимо быстродействия, состоит в том, что становится возможным (в силу аналитической функции зависимости) перейти к эффективному решению оптимизационных задач по обеспечению требуемого уровня надежности. Подобный подход ранее был разработан в Отделе энергетики ИСЭиЭПС Коми НЦ УрО РАН к задаче оценки и оптимизации надежности ЭЭС на этапе планирования их развития [78].

Наибольшее развитие нейросетевые методы оперативной оценки надежности получили за рубежом. Согласно [85] объем проводимых исследований в этом направлении достигает 20% всех приложений ИНС в электроэнергетике, занимая второе место после прогнозирования нагрузки. В работах в основном исследуются отдельные аспекты надежности ЭЭС: анализ статической надежности, анализ динамической надежности, в котором выделяют анализ устойчивости по напряжению, анализ статической устойчивости и анализ динамической устойчивости. В нашей стране большое внимание уделялось методам быстрой оценки динамической устойчивости. Эффективными оказались алгоритмы диагностики опасных состояний ЭЭС на базе регрессионных методов и теории распознавания образов [4, 5].

В зависимости от задачи и вида расчетного показателя надежности, начиная от простейшего качественного, типа устойчива/неустойчива, и заканчивая количественными, отражающими запасы устойчивости, предельное время отключения короткого замыкания и т.п., нейронная сеть выполняет различные функции. При использовании качественного показателя, в процессе обучения ИНС формируется уравнение гиперповерхности, разделяющей устойчивые и неустойчивые режимы в пространстве входных переменных, характеризующих состояние ЭЭС. Для количественного показателя, ИНС воспроизводит функцию зависимости этого показателя от характерных переменных. Особый интерес представляет использование несупервизорных нейронных сетей типа самоорганизующихся карт особенностей Кохонена, выполняющих отображение многомерного входного пространства в двухмерное с сохранением топологической упорядоченности режимов. С помощью таких ИНС в пространстве функционирования ЭЭС выделяется ограниченное множество наиболее характерных режимов, с которыми ассоциируются соответствующие значения показателя надежности Y . Отображение вектора входных переменных X , характеризующих состояние системы, на двухмерную сетку, узлы которой соответствуют типовым режимам, позволяет классифицировать исследуемый режим по принадлежности к одному из типовых. Достоинством такого подхода является возможность визуализации состояния ЭЭС в виде точки на двухмерном экране с отслеживанием значения показателя надежности вдоль траектории протекания режима [121].

Очевидно, что список задач оперативного управления ЭЭС, сводящихся к регрессионной задаче (1.1), далеко не ограничен приведенными примерами и может быть продолжен. Высокие аппроксимационные свойства ИНС позволяют реализовать любые сколь угодно нелинейные функции зависимости одних параметров режима от других. Нейросетевой подход можно использовать для распознавания аварийных ситуаций, в системах диагностики состояния оборудования, для формирования решающих правил в задаче оперативной коррекции параметров режима, при создании самоорганизующихся адаптивных систем управления и др. В каждом случае для обоснования использования нейросетевых моделей требуется проведение многочисленных исследований и

экспериментальных расчетов на тестовых и реальных схемах ЭЭС. Основным критерием применимости нейросетевых моделей, несомненно, должен служить сравнительный анализ с традиционными подходами.

Вопросы формирования выборки обучения. Основой для построения нейросетевой модели является набор взаимосвязанных входных и выходных переменных, характеризующих моделируемый объект, образующий выборку обучения. От качества исходной обучающей выборки зависит не только адекватность формируемой модели реальному объекту, но и принципиальная возможность ее построения. В таких областях приложения ИНС как экономика, бизнес, задачи военно-промышленного комплекса и т.п. стоимость обучающих выборок зачастую превышает стоимость самих нейросетевых средств.

В отличие от других областей приложения нейронных сетей современный уровень развития информационного обеспечения в электроэнергетике позволяет получить обучающие выборки для всех перечисленных выше задач. Архивы режимов, формируемые энергокомпаниями в течение многих лет, отражают основные характеристики и законы функционирования ЭЭС, обеспечивая нейросетевые модели необходимыми исходными статистическими данными. Кроме того, достигнут высокий уровень методического и модельного обеспечения для решения задач анализа функционирования ЭЭС на этапе планирования режимов. В силу неэффективности использования точных математических моделей при решении задач реального времени они, тем не менее, могут служить основой для построения нейросетевых моделей. В этом случае данные, необходимые для обучения ИНС и отражающие взаимосвязь переменных, характеризующих объект, определяются на основе численных экспериментов с исходными моделями объектов.

Аппаратная поддержка нейросетевых моделей. Способность ИНС к обучению и построению внутренних моделей является, несомненно, ключевым фактором в новой концепции моделирования сложных систем. Но нейронные сети это прежде всего вычислительные системы с массово-параллельной архитектурой, унаследованной от биологического прототипа. Именно с такими системами связывают в настоящее время перспективы наращивания производительности и надежности ЭВМ, и особое место здесь занимают нейрокомпьютерные системы.

Большинство реализаций нейросетевых систем эмулируют работу ИНС на обычных компьютерах. Такой подход не использует преимуществ присущего нейровычислениям параллелизма и ориентируется исключительно на способность нейросетей решать трудно формализуемые задачи. Однако в условиях реального времени становится актуальным рассмотрение вопросов, связанных с решением задач (в том числе хорошо формализуемых) в нейросетевом базисе исключительно за счет возможности организации параллельных вычислений с высоким уровнем быстродействия.

Построение вычислительных систем, интерпретирующих нейросетевые алгоритмы, осуществляется в настоящее время на традиционной элементной базе: микроэлектронных СБИС [27]. Большинство из них представляют собой специализированные матричные ускорители, использующие матричный послойный характер обработки сигналов в нейросетях и имеющие производительность порядка 10^8 CPS¹. Это позволяет обрабатывать десятки, а то и сотни тысяч векторов в секунду. Наибольший эффект ожидается от выполнения нейронных сетей на аналоговой элементной базе за счет реализации базисной операции (вычисления скалярного произведения) в физической среде-носителе сигнала. Работы по созданию аналоговых нейрочипов широким фронтом развернуты на Западе.

Высокая вычислительная эффективность ИНС способна стать решающим аргументом для их использования при решении задач реального времени в рамках оперативного управления ЭЭС, где скорость обработки данных критична. Оснащение персональных компьютеров и рабочих станций нейроускорителями позволит реально перейти

¹ Принятая в нейрокомпьютерной области единица измерения производительности - число умножений с суммированием в секунду

к выработке корректирующих воздействий через систему автоматического управления. Такая перспектива несомненно требует, преломления существующих методических подходов и разработки впрок параллельных, по-новому структурированных алгоритмов решения задач на ИНС.

Возможности использования аппарата искусственных нейронных сетей для выбора оперативных переключений.

Большинство потребителей распределительной сети может получать электроэнергию по нескольким различным цепям. При отказе одной или группы питающих связей с учетом существующего режима в сети необходимо быстро найти резервную цепь для подачи электроэнергии к отключенному потребителю. При этом должны быть учтены следующие требования:

а) уровни тока элементов связи и отклонение напряжения у потребителя не должны превышать допустимых значений;

б) при необходимости ограничения нагрузки в первую очередь отключаются менее ответственные потребители.

Восстановление распределительной сети относится к задачам комбинаторной оптимизации, отличающимся большим временем поиска результата. Существующие методы восстановления питания потребителей распределительной сети в России [24, 30, 59–63, 84] и за рубежом [89, 90, 96, 99, 101, 113, 118–121, 125, 130] можно условно объединить в три группы: 1) на основе теории графов и комбинаторной математики; 2) с созданием базы знаний при обучении и последующей выборкой из нее образа состояния схемы для конкретного события; 3) на основе методов искусственного интеллекта, в том числе, с использованием аппарата искусственных нейронных сетей. Каждый из указанных подходов имеет свои плюсы и минусы, рассматриваемые в разделе 6.2.

Применительно к восстановлению распределительных сетей ИНС могут использоваться следующим образом. На некоторой модели распределительной сети с учетом опыта обслуживающего персонала набираются решения для различных режимов и конфигураций сети, т.е. формируется база знаний для поставленной задачи. Затем на этой выборке проводится процесс обучения ИНС. При возникновении некоторой режимной и конфигурационной ситуации, требующей восстановления распределительных сетей, ее параметры вводятся в ИНС на выходе которой считывается решение, определяющее необходимые для конкретного режима состояния выключателей связей сети.

Достоинствами использования ИНС для рассматриваемых целей являются:

- быстрое нахождение решения;
- возможность получения решения на промежутке между решениями, известными из процесса обучения;
- дообучение ИНС в реальном режиме с получением нового, не входившего в обучающую выборку, решения.

К недостаткам можно отнести:

- возможность приблизительных и не всегда соответствующих допустимому режиму решений;
- необходимость управления нейронной сетью при ее дообучении в реальном времени;
- дообучение ИНС на всей, включая новые значения, обучающей выборке.

Определенную сложность представляет выбор состава входных сигналов для ИНС, а также определение ее внутренней структуры (число слоев и нейронов во внутренних слоях) для получения оптимальных решений. Структура ИНС в значительной степени определяет время получения решения и устойчивость его нахождения.

Отметим, что ИНС позволяет быстро определять схему восстановления распределительной сети в послеаварийном режиме, однако в ряде случаев необходимы дополнительные меры, позволяющие проверять и, при необходимости корректировать решения ИНС в направлении допустимости режимов распределительной сети.

Литература

1. Автоматизация диспетчерского управления в электроэнергетике / В.А.Баринов, А.З.Гамм, Ю.Н.Кучеров и др.; Под общей ред. Ю.Н.Руденко, В.А.Семенова. М.: МЭИ, 2000. 648 с.
2. Алиев Р.А., Церковный А.Э., Мамедова Г.А. Управление производством при нечеткой исходной информации. М.: Энергоатомиздат, 1991. 240с.
3. Баринов В.А., Савалов С.А. Режимы энергосистем: методы анализа и управления. М.: Энергоатомиздат, 1990. 440 с.
4. Бартоломей П.И. Алгоритм случайного поиска оптимального режима энергосистемы // Изв. АН СССР. Энергетика и транспорт, 1971. №4.
5. Бартоломей П.И. Голубин Е.А., Зайцева М.В., Порошин В.И. Эффективность оперативной коррекции режима электроэнергетических систем // Изв. АН СССР. Энергетика и транспорт, 1982. №3. С.42-49.
7. Богатырев Л.Л. Диагностика аварийных состояний электроэнергетических систем. Свердловск: УПИ, 1983. 80 с.
11. Галушкин А.И. О работах по нейрокомпьютерам в Научном центре нейрокомпьютеров Российской Академии наук // Новости искусственного интеллекта. 1992. № 4.
16. Горбань А. Н. Обучение нейронных сетей. М.: СП ПараГраф, 1990. с.
17. Горбань А.Н. Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей // Сибирский журнал вычисл. матем. Новосибирск: РАН Сиб. отд., 1998. Т.1, №1. С.11-24.
18. Горбань А.Н., Россиев Д.А. Нейронные сети на персональном компьютере. Новосибирск: Наука. Сибирск. издательская фирма РАН, 1996. 276 с.
19. Гордиенко Е.К., Лукьяница А.А. Искусственные нейронные сети. Основные определения и модели // Техническая кибернетика. 1994, № 5. С. 79-92.
22. Захаров В.Н. Современная информационная технология в системах управления // Изв. АН Теория и системы управления. 2000, №1. С. 70-78.
24. Идельчик В.И. Расчеты установившихся режимов электрических систем. М.: Энергия, 1977. 192 с.
26. Колосок И.Н., Глазунова А.М. Достоверизация телеизмерений в ЭЭС с помощью искусственных нейронных сетей // Электричество, №10, 2000. С. 18-24.
27. Корнеев В.В., Кисилев А.В. Современные микропроцессоры. М.: НОЛИДЖ, 2000. 320 с.
30. Малышев Н.Г., Берштейн П.С., Боненюк А.В. Нечеткие модели для экспертных систем в САПР. М.: Энергоатомиздат, 1991. 136 с.
33. Мелихов А.Н., Бернштейн Л.С., Коровин С.Я. Ситуационные советующие системы с нечеткой логикой. М.: Наука, 1990. 272 с.
34. Методы решения задач реального времени в электроэнергетике / А.З. Гамм, Ю.Н.Кучеров, С.И.Паламарчук и др. Новосибирск: Наука. сиб. отд., 1991. 294 с.
37. Нечеткие множества в моделях управления и искусственного интеллекта/Под ред. Д.А. Пospelова. М.: Наука, 1986. 206 с.
41. Пospelов Г.С. Искусственный интеллект - основа новой информационной технологии. М.: Наука, 1988. 168 с.
43. Прикладные нечеткие системы: Пер. с японского / Под ред. Т. Тэрано, К. Асаи, М. Сугено.. М.: Мир, 1993.
46. Резников А.П. Детерминированно-вероятностная обучающаяся информационная система (ДВОИС) // Изв. АН СССР. Энергетика и транспорт, №3. 1969. С. 20-30.
47. Розенблатт Ф. Принципы нейродинамики. Перцептрон и теория механизмов мозга. М.: Мир. 1965. 480 с.
53. Тарасов В.Б. От искусственного интеллекта к искусственной жизни: новые направления в науках об искусственном // Новости искусственного интеллекта. 1995. №4. С. 24-30.

57. Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика: Пер. с англ. М.: Мир, 1992. 240 с.
59. Успенский М.И. Поиск схемы обеспечения нагрузок в распределительной сети // Информационные технологии в электротехнике и электроэнергетике. Чебоксары: Чуваш. ун-т, 1998. С.32-34.
60. Успенский М.И., Старцева Т.Б., Шумилова Г.П. Компьютеризация управления режимами на подстанциях. Сыктывкар: Коми НЦ УрО РАН, 1996. 77 с.
61. Успенский М.И., Кызродев И.В. Совместное использование искусственных нейронных сетей и алгоритмов обработки графов при поиске схемы питания потребителей распределительной сети // Методические вопросы исследования надежности больших систем энергетики. Вып. 51. Сыктывкар: Коми НЦ УрО РАН, 2000. С.274-278.
62. Успенский М.И., Кызродев И.В. Восстановление питания потребителей в распределительной сети на основе искусственных нейронных сетей // Информационные технологии в электротехнике и электроэнергетике. Чебоксары: Чуваш. ун-т, 2000. С.313-314.
63. Фокин Ю.А., Хозяинов Н.А. Об одном из способов решения задачи корректирующих переключений в послеаварийных режимах // Надежность при управлении развитием и функционированием электроэнергетических проблем. Иркутск: СЭИ СО РАН, 1988. С. 149 – 155.
78. Чукреев Ю.Я. Хохлов М.В. Применение методов искусственных нейронных сетей в задачах обеспечения надежности ЭЭС при управлении их развитием // Современные проблемы надежности систем энергетики: модели, рыночные отношения, управление реконструкцией и развитием – М.: ГУП Изд. «Нефть и газ» РГУ нефти и газа им. И.М.Губкина, 2000. С. 154-160.
82. Alves da Silva A.P., Quantana V.H., Pang G.K.H. Associative memory models for data processing // *Electrical Power & Energy Systems*, Vol. 14, №1, 1992. P. 23-32.
84. A new algorithm for swervice restoration in distribution systems / K.Aoki, K.Nara, M.Itoh et al. // *IEEE Trans. on Power Delivery*, Vol. 4, №3, 1989. P. 1832 – 1839.
85. Artificial neural networks for power systems / D. Neubor et al. // *CIGRE TF 38.06.06, Electra*, №159, 1995. P.77-101.
89. Dabbaghchi Iraj, Gursky Richard J. An abductive expert system for interpretation of real-time data// *IEEE Trans. on Power Delivery*. Vol. 8, №3, 1993. P.1061-1069.
90. Dai Seub Choi, Hasegawa J. Improvement of genetic algorithm convergence characteristics for distribution system loss minimization reconfiguration// *IEE Japan Power and Energy 94. Proc. of 5th Annual Conf.*, Tokio, 1994, Vol. 1. P.19-24.
95. Hopfield J., Tank D. Simple “neural” optimization networks: an A/D converter, signal decision circuit, and a linear programming circuit // *IEEE Trans. on Circuits and Systems*, Vol. CAS-33, №5, 1986. P. 533-541/
96. Hsu Yuan-Yih, Li-Ming Chen, Jiann-Liang Chen. Application of a microcompute-based database management system to distribution system reliability evaluation// *IEEE Trans. on Power Delivery*, Vol. 5, №1, 1990. P. 343-350.
99. Integrating genetic algorithm with expert system for service restoration in distribution system / Siqing Sheng, Youjiang Sun et al. // *Intern. Conf. on Power System Techn. Proc.*, Vol 1, 1998. Beijng, China. P. 265-269.
100. Kohonen T. Self-organizing maps. Berlin etc: Springer, 1995. XV. 362 p. (Springer ser. in inform. sciences; 30).
101. Kolcum L., Benc R., Szathmary P. Genetic algorithms in power system // *Proc. of 8th intern. Scien. Conf. EE 96*, Stara Lesna, 1996. P.165-170.
102. Larkin L.I. A fuzzy logic controller for aircraft flight control // *Industrial applications of fuzzy control*. Amsterdam: North-Holland, 1985, P. 87-104.

103. Lee C.C. Fuzzy logic in control systems: fuzzy logic controller-part I, II // IEEE Trans. on Systems, Man and Cybernetics, Vol. 20, №2, 1990. P. 404-435.
105. Lippmann R.P. An introduction to computing with neural nets // IEEE ASSP Magazin, April, 1987. P.4-20.
107. McCulloch W.A., Pitts W. A logical calculus of ideas immanents in nervous activity // Bull. Math. Biophys, Vol. 5, 1943. P.115-133.
111. Pandua A.S., Macy R.B. Pattern recognition with neural networks in C++. Boca Raton: CRC Press: 1996. 410 p.
113. Random adaptive optimizer restores distribution service / Siqing Sheng, Youjiang Sun et al. // IEEE Comp. Appl. in Power, Vol. 13, №2, 2000. P.48-51.
115. Rumelhart D.E., Hinton G.E., Williams R.J. Learning integral representations by error propagation // Parallel Distributed Processing, Vol. 1, № 8, 1986. P.318-362.
118. Sarma N.D.R., Ghoch Soumer, Prakasa Rao K.S., Srinivas Manda. Real-time service restoration in distribution networks - a practical approach// IEEE Trans. on Power Delivery, Vol. 9, №4, 1994. P.2064-2070.
119. Schweppe F.C., Wildes J., Rom D.B. Power system static-state estimation, Part I: exact model; Part II: approximate model; Part III: implementation // IEEE Trans. on Power and Apparatus Systems, Vol. PAS-89, №1, 1970. P. 120-135.
120. Singh H., Alvarado F.L. Weighted least absolute value state estimation using interior point methods. // IEEE Trans. on Power Systems, Vol. 9, №3, 1994. P. 1478-1484.
121. Sobajic D.J., Pao Y.H. Artificial neural-net based dynamic security assessment for electric power systems // IEEE Trans. on Power Systems, Vol.4, №4, 1989. P.220-228.
122. Souza J.C.S., Leite da Silva A.M., Alves da Silva A.P. Online topology determination and bad data suppression in power system operation using artificial neural networks // IEEE Trans. on Power Systems, Vol. 13, №3, 1998. P. 796-803.
123. Srinivasan D., Liew A.C. Chang C.S. Forecasting daily load curves using a hybrid fuzzy-neural apporoach // IEE Proc - Generat. Transmiss. Distrib., Vol. 141, №6, 1994. P. 561 - 567.
124. Whitley D., Starkweather T., Bogart C. Genetic algorithms and neural networks: optimizing connections and connectivity // Parallel Computing, Vol. 14, 1990. P. 347-361.
125. Yehsaki P.D. and Dabbaghchi I.A. F topology-based algorithm for tracking network connectivity // IEEE Trans. on Power System, Vol. 10, №1, 1995. P. 339-346.
126. Zadeh L.A. Fuzzy sets // Information and control. 1965. Vol. 8, №3, 1965. P. 338-353.
127. Zadeh L.A. Fuzzy algorithms // Information and control. Vol. 12, №2, 1968. P233-238.
128. Zakharov V.N. Intelligent control systems: Principal concepts and definitions // Journal of computer and systems sciences international, Vol. 36, № 3, 1997. P. 88-95.
130. Zhang Z.Z., Hope G.S., Malik O.P. A knowledge-based approach to optimize switching in substations // IEEE Trans. on Power System, Vol. 5, №1, 1990. P. 103-109.