

Нечеткие знания, используемые в продукционных правилах, составляются в виде базы знаний. Кроме того, в нечетких суждениях, описываемых в предпосылках и заключениях каждого правила, имеется несколько членов. Следовательно, в общем случае рассматривается база знаний типа:

$$\text{если } A_{i1} = 0, A_{i2} = 0, \dots, A_{im} = 0,$$

$$\text{то } B_{i1} = \Delta, B_{i2} = \Delta, \dots, B_{in} = \Delta \Big|_{i=1}^I,$$

где I – число правил в предпосылке, m – число членов в предпосылке, n – число членов в заключении.

С использованием теории нечетких множеств решаются задачи согласования противоречивых критериев, создание нечетких логических регуляторов.

Нечеткие алгоритмы позволяют применять лингвистическое описание для моделирования сложных процессов, устанавливать нечеткие отношения между понятиями, описывать одни нечеткие понятия другими, уже определенными, прогнозировать поведение объекта управления, формировать множество альтернатив и производить формальное описание нечетких правил принятия решения.

Таким образом, достоинства нечеткой логики заключаются в том, что она позволяет удачно представить мышление человека, т.е. способы принятия решения человеком и способы моделирования сложных объектов, и, кроме того, пригодна для представления знаний.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Zadeh L. A. Fuzzy Algorithms//Inform. a. Control. 1965. – Vol. 12, № 2. – С. 94-102.
2. Асаи К., Вапада Д. и др. Прикладные нечеткие системы/ Под ред. Т. Тэрано, К. Асаи, М. Сугэно. – М.: Мир, 1993. – 368 с.
3. Борисов А. Н., Алексеев А. В., Меркурьева Г. В. и др. Обработка нечеткой информации в системах принятия решений. – М.: Радио и связь, 1989. – 304 с.
4. Нечеткие множества в моделях управления и искусственного интеллекта / Под ред. Поспелова Д. А. – М.: Наука, 1986. – 386 с.
5. Орловский С. А. Проблемы принятия решений при нечеткой исходной информации. – М.: Наука, 1981. – 208 с.
6. Симанков В.С., Буцацкий П.Ю., Шотин А.В. Методология моделирования физических процессов в энергетических комплексах с нетрадиционными источниками энергии и оптимизация их параметров // Труды ФОРА. 1998. – №3. – С. 18-26.
7. Твайделл Дж., Уэйр А. Возобновляемые источники энергии. – М.: Энергоатомиздат, 1990. – 391 с.
8. Экель П. Я., Попов В. А. Учет фактора неопределенности в задачах моделирования и оптимизации электрических сетей. // Изв. АН СССР. Энергетика и транспорт. 1985. – № 2.

УДК 62-50:004.032.26: 620.9

В.С. Пономарев, В.И. Финаев

ПРИМЕНЕНИЕ АДАПТИВНЫХ РЕГУЛЯТОРОВ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ В ЭНЕРГЕТИКЕ

Необходимость применения адаптивных систем управления электроэнергетическими объектами на современном этапе развития энергетики возрастает из-за изменения условий их функционирования. Структурная перестройка и вне-

дрение энергетического рынка сопровождается не только увеличением числа решаемых технологических задач управления, но и динамичностью ситуаций и взаимосвязью технологических задач разных групп.

Для обеспечения надлежащего уровня надежности функционирования электроэнергетических объектов существует настоятельная необходимость совершенствования систем управления, особенно диспетчерского, путем разработки новых подходов, в том числе, основанных на методах искусственного интеллекта и принципах адаптивного управления.

Нейросетевые вычислительные модели дают большие надежды для улучшения различных аспектов операций на электростанциях. Они включают предсказание нагрузки, управление безопасностью, оптимизацию обратного давления турбин и моделирование процессов.

Здесь способность нейронных сетей обучаться сложному отображению обучающих данных используется для построения оценок или предсказания различных интересующих свойств.

Появляются разработки в этой области крупных зарубежных фирм [2]. Предварительный анализ последних исследований показал, что в настоящее время повышение быстродействия адаптивных систем управления систем обеспечивается за счет:

- построения и использования многопроцессорных систем параллельной архитектуры;
- разработки и реализации алгоритмов параллельных вычислений на соответствующем аппаратном обеспечении (нейрочипах);
- комбинированного использования генетических алгоритмов и методов минимизации, для которых характерна сверхлинейная скорость сходимости. При этом используются упрощенные математические модели (в первую очередь линейаризованные), а решение задач выполняется, как правило, в режиме on-line;
- обеспечения хорошей обусловленности задачи различными методами;
- использования робастных методов, устойчивых к наличию погрешностей в исходной информации [3];
- обучения нейронной сети вне реального времени, но при обеспечении учета сложной поверхности функции качества и адаптации к изменениям топологии электрической сети и изменению режима;
- использования рекуррентных нейронных сетей типа Хопфилда–Лагранжа, в которых точные измерения учитываются в виде ограничений типа равенств и многослойных рекуррентных нейронных сетей, в которых реализуется распараллеливание вычислительного процесса и используется преимущественно аналоговая или аналогово-цифровая элементная база с высоким быстродействием.

Основные задачи, решаемые адаптивными регуляторами на основе нейронных сетей в современных энергетических системах:

- предсказание нагрузки;
- прогнозирование температуры окружающей среды с целью прогнозирования нагрузки;
- управление потоками электроэнергии в сетях;
- обеспечение максимальной мощности;
- регулирование напряжения;
- диагностика энергосистем с целью определения неисправностей;
- оптимизация размещения датчиков для контроля безопасности энергосистем;

- мониторинг безопасности энергосистем;
- обеспечение защиты трансформаторов;
- обеспечение устойчивости, оценка динамического состояния и диагностика генераторов;
- управление турбогенераторами;
- управление сетью генераторов;
- управление мощными переключательными системами.

Перечень задач применения адаптивных регуляторов на основе нейронных сетей в системах управления энергетическими системами постоянно растет.

Как следует из значительного числа работ, наибольшее распространение в энергетике получили три вида ИНС: многослойные сети прямого распространения, сети Кохонена, рекуррентные сети Хопфильда. Особенности нейросетевого моделирования инициировали множество исследований его применения при решении различных задач оперативного управления ЭЭС. Важным этапом в создании ИНС является ее обучение, которое заключается в настройке параметров ИНС. Вид ИНС определяет особенности обучения. Обучение многослойных ИНС. В сетях оптимальные выходные значения нейронов всех слоев, кроме последнего, как правило, не известны. В таких условиях обучить многослойный перцептрон невозможно руководствуясь только величинами ошибок на выходах ИНС. Обучение многослойных сетей супервизерное, требующее в обучающей выборке наличия не только множества входных векторов, но и множества соответствующих откликов [2].

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. Суммирование ведется по всем нейронам выходного слоя и по всем обрабатываемым сетью образам.

Алгоритм обратного распространения ошибки определяет стратегию подбора весов многослойной сети с применением градиентных методов оптимизации. "Изобретенный заново" несколько раз, он в настоящее время считается одним из наиболее эффективных алгоритмов обучения многослойной сети. Его основу составляет целевая функция, формулируемая, как правило, в виде квадратичной суммы разностей между фактическими и ожидаемыми значениями выходных сигналов [4].

Обучение многослойной сети с применением градиентных методов требует определения вектора градиента относительно весов всех слоев сети, что необходимо для правильного выбора направления $p(w)$. Эта задача имеет очевидное решение только для весов выходного слоя. Для других слоев создана специальная стратегия, которая в теории искусственных нейронных сетей называется *алгоритмом обратного распространения ошибки* (англ.: *error backpropagation*), отождествляемым, как правило, с процедурой обучения сети. В соответствии с этим алгоритмом в каждом цикле обучения выделяются следующие этапы.

1. Анализ нейронной сети в прямом направлении передачи информации при генерации входных сигналов, составляющих очередной вектор x . В результате такого анализа рассчитываются значения выходных сигналов нейронов скрытых слоев и выходного слоя, а также соответствующие производные

$\frac{df(u_i^{(1)})}{du_i^{(2)}}, \frac{df(u_i^{(2)})}{du_i^{(2)}}, \dots, \frac{df(u_i^{(m)})}{du_i^{(m)}}$ функции активации каждого слоя (m – количество слоев сети).

2. Создание сети обратного распространения ошибок путем изменения направлений передачи сигналов, замена функций активации их производными и подача на бывший выход (а в настоящий момент – вход) сети возбуждения в виде разности между фактическим и ожидаемым значением. Для определенной таким образом сети необходимо рассчитать значения требуемых обратных разностей.

3. Уточнение весов (обучение сети) производится по предложенным выше формулам на основе результатов, полученных в п. 1 и 2, для оригинальной сети и для сети обратного распространения ошибки.

4. Описанный в п. 1, 2 и 3 процесс следует повторить для всех обучающих выборок, продолжая его вплоть до выполнения условия остановки алгоритма. Действие алгоритма завершается в момент, когда норма градиента упадет ниже априори заданного значения ε , характеризующего точность процесса обучения [1].

Базовые формулы и их модификации для конкретных типов нейронных сетей считаются классическими для теории нейронных сетей. По этой причине мы рассмотрим только условия, относящиеся к сети с одним скрытым слоем.

Количество входных узлов N , количество нейронов в скрытом слое K , а количество нейронов в выходном слое M . Основу алгоритма составляет расчет значения целевой функции как квадратичной суммы разностей между фактическими и ожидаемыми значениями выходных сигналов сети. В случае единичной обучающей выборки (x, d) целевая функция задается формулой

$$E(w) = \frac{1}{2} \sum_{k=1}^M (y_k - d_k)^2, \quad (1)$$

а для множества обучающих выборок j ($j = 1, 2, \dots, p$) – формулой

$$E(w) = \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^M (y_k^{(j)} - d_k^{(j)})^2 \quad (2)$$

Для упрощения используем целевую функцию вида (1) которая позволяет уточнять веса после предъявления каждой обучающей выборки.

$$E = \frac{1}{2} \sum_{k=1}^M \left[f \left(\sum_{i=0}^K w_{ki}^{(2)} v_i \right) - d_k \right]^2 = \frac{1}{2} \sum_{k=1}^M \left[f \left(\sum_{i=0}^K w_{ki}^{(2)} f \left(\sum_{j=0}^N w_{ij}^{(1)} x_j \right) \right) - d_k \right]^2 \quad (3)$$

Конкретные компоненты градиента рассчитываются дифференцированием зависимости (3). В первую очередь подбираются веса нейронов выходного слоя. Для выходных весов получаем

$$\frac{\partial E}{\partial w_{ij}^{(2)}} = (y_i - d_i) \frac{df(u_i^{(2)})}{du_i^{(2)}} v_j, \quad (4)$$

где $u_i^{(2)} = \sum_{j=0}^K w_{ij}^{(2)} v_j$. Если ввести обозначение $\delta_i^{(2)} = (y_i - d_i) \frac{df(u_i^{(2)})}{du_i^{(2)}}$, то

соответствующий компонент градиента относительно весов нейронов выходного слоя можно представить в виде

$$\frac{\partial E}{\partial w_{ij}^{(2)}} = \delta_i^{(2)} v_j. \quad (5)$$

Компоненты градиента относительно нейронов скрытого слоя определяются по тому же принципу, однако они описываются другой, более сложной зависимостью, следующей из существования функции, заданной в виде

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = \sum_{k=1}^M (y_k - d_k) \frac{dy_k}{dv_i} \frac{dv_i}{dw_{ij}^{(1)}}. \quad (6)$$

После конкретизации отдельных составляющих этого выражения получаем

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = \sum_{k=1}^M (y_k - d_k) \frac{df(u_k^{(2)})}{du_k^{(2)}} w_{ki}^{(2)} \frac{df(u_k^{(1)})}{du_i^{(1)}} x_j. \quad (7)$$

Если ввести обозначение

$$\delta_i^{(1)} = \sum_{k=1}^M (y_k - d_k) \frac{df(u_k^{(2)})}{du_k^{(2)}} w_{ki}^{(2)} \frac{df(u_k^{(1)})}{du_i^{(1)}}, \quad (8)$$

то получим выражение, определяющее компоненты градиента относительно весов нейронов скрытого слоя в виде

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = \delta_i^{(1)} x_j. \quad (9)$$

В обоих случаях описание градиента имеет аналогичную структуру и представляется произведением двух сигналов: первый соответствует начальному узлу данной взвешенной связи, а второй - величине погрешности, перенесенной на узел, с которым эта связь установлена. Определение вектора градиента очень важно для последующего процесса уточнения весов. В классическом алгоритме обратного распространения ошибки фактор $p(w)$, учитываемый в выражении $w(k+1) = w(k) + \Delta w$, задает направление отрицательного градиента, поэтому

$$\Delta w = -\eta \nabla E(w). \quad (10)$$

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. При использовании линейаризованных моделей технологических задач упрощается поверхность функции качества, что влияет на адекватность модели знаний. При ориентации на существующие аппаратные средства управления с учетом их эволюционной модификации перспективным направлением в построении адекватной модели знаний для ИНС

является вынос этапа обучения из процедуры управления в реальном времени [5].

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Оссовский С.* Нейронные сети для обработки информации. / Пер. с польского *И.Д. Рудинского*. – М.: Финансы и статистика, 2002. – 344 с.
2. *Чукреев Ю.Я., Хохлов М.В., Алла Э.А.* Оперативное управление режимами региональной энергосистемы с использованием технологии искусственных нейронных сетей // *Электричество*. 2000. – №4. – С. 2-10.
3. *Горбань А.Н.* Обучение нейронных сетей – М.: СП Параграф, 1990. – 160с.
4. *Брикман М.С., Кристинков Д.С.* Аналитическая идентификация управляемых систем. – Рига: Зинатне, 1999.
5. *Комашинский В.И.* Введение в нейро-информационные технологии – Спб.: Тема, 1999. – С 36-40.

УДК 007.51; 681.32

Е.Ю. Косенко, А.Я. Номерчук

ИССЛЕДОВАНИЕ ПРОБЛЕМ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ С ПОМОЩЬЮ КОГНИТИВНЫХ МОДЕЛЕЙ НА ОСНОВЕ ЭКСПЕРТНЫХ ОЦЕНОК

Известно, что Россия обладает огромными запасами органических топлив: 45% мировых запасов природного газа, 23% угля и 13% нефти находится в ее недрах. Таким образом, на будущие десятилетия, а может быть и столетия проблема недостатка запасов органических топлив для России не существует (табл. 1). Но страна не может уповать только на органические топлива и проводить обычную политику. Формулируя энергетическую стратегию на перспективу, необходимо учитывать многие факторы: экономические, социальные, экологические

Таблица 1

Запасы органического топлива в России

	Доказанные запасы начало 90-х гг	Ожидаемый прирост запасов		
		0,942	0,950	0,992
Нефть+конденсат, млрд т	75	0,942	0,950	0,992
Природный газ, трлн м3	50	1,550	1,640	1,750
Уголь, млрд т	202	0,470	0,480	0,500

Сегодня энергетика России испытывает ряд трудностей, начиная с 1990 года, происходил существенный спад во всех основных секторах экономики. Однако, несмотря на то, что падение чрезвычайно было велико, в последние годы наметилась тенденция к увеличению производства и подъема экономики. Падение добычи органических топлив и преобразующих видов энергии относительно меньше, чем в основном секторе экономики.