

СИСТЕМНЫЙ АНАЛИЗ И УПРАВЛЕНИЕ

УДК 621.311

ПРОГНОЗИРОВАНИЕ РАЗВИТИЯ РЕГИОНАЛЬНОЙ ЭНЕРГЕТИЧЕСКОЙ СИСТЕМЫ

FORECASTING OF REGIONAL ENERGY SYSTEM DEVELOPMENT

Д.В. Куделина
D.V. Kudelina

Юго-Западный государственный университет, Россия, 305040, Курск, ул. 50 лет Октября, 94

South-West State University, 94 50 let Oktyabrya St, Kursk, 305040, Russia

e-mail: mary_joy@mail.ru

Аннотация. В статье рассмотрены проблемы прогнозирования развития региональной энергетики. Несмотря на большое количество разработанных и применяемых методов прогнозирования развития сложных систем, их точное моделирование затруднено из-за нелинейных и сложных отношений между элементами данных систем. Показано, что применение метода, основанного на совместном использовании математического аппарата нечеткой логики и нейронных сетей, использующего при своей работе основные положительные свойства данных способов обработки информации, позволяет проводить прогнозирование потребления энергетических ресурсов с большей достоверностью по сравнению с традиционными методами прогнозирования. Это объясняется тем, что такие сети могут использовать опыт экспертов и специалистов, и процесс их обучения имеет меньшую длительность по сравнению с классическими нейронными сетями. Рассмотрен процесс создания нечеткой нейронной сети для прогнозирования потребления электроэнергии в машиностроении.

Resume. The article deals with the problem of regional energy sector development forecasting. Despite the large number of developed and applied methods of complex systems development forecasting, their exact simulation is difficult because of non-linear and complex relations between the elements of these systems. It is shown that the use of a method based on the joint use of the mathematical apparatus of fuzzy logic and neural networks, which use the main positive characteristics of information processing methods, allows to predict the consumption of energy resources with greater reliability compared to the traditional methods of forecasting. This is explained by the fact that such networks can use the experience of experts and specialists, and the process of their training has a shorter duration in comparison with classical neural networks. The process of creating a fuzzy neural network for energy consumption predicting in mechanical engineering is considered.

Ключевые слова: региональная энергетическая система, прогнозирование, топливно-энергетические ресурсы, нечеткая логика, математическая модель, нейронные сети

Keywords: regional energy system, forecasting, fuel and energy resources, fuzzy logic, mathematical model, neural networks

Введение

В условиях рыночной экономики, для которой характерны различные формы собственности как промышленных предприятий, так и хозяйствующих субъектов, объектов регионального топливно-энергетического комплекса, моделирование и прогнозирование развития энергосистемы, включая прогнозы изменения потребления электроэнергии и других энергоресурсов, является сложной и в то же время актуальной задачей.

Системный подход в наибольшей степени отвечает требованиям научного подхода к решению подобных задач высокого уровня сложности в современной их постановке. Использование системного подхода позволяет осуществлять всестороннее комплексное рассмотрение решаемой проблемы, максимально использовать эффективные методы для решения подобных задач в условиях неопределенности, многоцелевой и многокритериальной оптимизации.



Системный подход при разработке долгосрочного прогнозирования потребности в энергетических ресурсах предполагает рассмотрение экономики хозяйства региона, с одной стороны, как большой экономической системы, с другой, – как энергопотребляющей системы, которые как элементы экономики хозяйства страны, в свою очередь, представляют иерархически организованные многоуровневые и многофункциональные системы, состоящие из подсистем. Каждая такая подсистема, развиваясь самостоятельно и имея характерные для нее внутренние свойства, посредством объективно существующих внешних причинно-следственных связей взаимодействует с другими подсистемами согласованно с магистралью развития целостной системы с присущими ей целостными свойствами.

Состояние и развитие топливно-энергетического комплекса региона оказывает большое влияние на возможность выполнения различных долгосрочных региональных программ и стратегий. Эффективность принимаемых решений по дальнейшему развитию инфраструктуры и одновременно повышению энергетической безопасности региона во многом зависит от объективности и обоснованности информации, полученной по результатам прогнозирования.

Прогнозирование развития региональной энергетики представляет собой сложный процесс, учитывающий широкие связи развития основных элементов энергетической инфраструктуры с общим социально-экономическим уровнем и развитием региональных образований. Прогнозирование и планирование развития регионального топливно-энергетического комплекса невозможно без долгосрочного и в достаточной мере достоверного прогнозирования развития экономической и социальной сферы страны, регионов и муниципальных образований.

Объекты и методы исследования

Значительные сложности решения проблемы прогнозирования развития региональной энергетики возникают в условиях существования всеобщей экономической и политической нестабильности, а также продолжающегося реформирования структуры как отраслей, так и предприятий. Динамика развития и структурные изменения в хозяйствующих комплексах регионов определяются существующими общими стратегическими тенденциями развития экономики России и территориальными особенностями рассматриваемых при прогнозировании регионов.

Более или менее достоверное прогнозирование развития региональной энергосистемы может выполняться только в общих рамках региональных социально-экономических систем, которые являются по своей природе сложными, нелинейными и в значительной мере неопределенными.

Для этих целей наиболее часто используются регрессионные модели, позволяющие определять участие тех или иных факторов в формировании получаемого прогноза. Но используемые при этом зависимости, создаваемые с помощью регрессионных методов, в большинстве случаев представляют собой линейные выражения. В реальных условиях большинство рассматриваемых элементов региональной энергосистемы и потребители энергоресурсов характеризуются нелинейностью большинства зависимостей, например, величиной потребления тепловой и электрической энергии от факторов промышленного или сельскохозяйственного производства, погодных и климатических условий и т.д.

Но несмотря на большое количество разработанных и применяемых методов прогнозирования развития сложных систем, их точное моделирование затруднено из-за нелинейных и сложных отношений между элементами данных систем. Кроме того, некоторые методы выполнения прогнозов представляют динамические показатели работы изучаемых систем изменения на аппарате временных рядов. Такие модели некорректно учитывают информацию, связанную с погодно-климатическими условиями, а также имеют и другие недостатки [Бэнн Д.В., 1987].

Рассмотренные недостатки применяемых ранее методов обеспечивают достаточно широкое применение в настоящее время относительно нового метода, основанного на совместном использовании математического аппарата нечеткой логики и нейронных сетей. Другими словами, такой метод прогнозирования является гибридом нечеткой логики и нейронных сетей, использующим при своей работе основные положительные свойства данных способов обработки информации.

Искусственные нейронные сети представляют собой современные вычислительные устройства, основанные на выполнении обработки информации наподобие процессов, протекающих в мозгу человека [Рутковская Д., 2004]. Нейронные сети обладают некоторыми свойствами искусственного интеллекта. Для них характерно наличие способности к обучению и обобщению накопленных при работе сети знаний. Преимущество нейронных сетей перед традиционными моделями прогнозирования обуславливается тем, что при их работе не требуется построения достаточно полной математической модели объекта, также не теряется работоспособность созданной сети при неполноте входной информации.

Но нейронные сети также имеют свои недостатки. Для них в процессе работы характерно автоматическое приобретение и накопление знаний о моделируемом объекте [Круглов В.В., 2002]. Применение этих сетей эффективно для решения многих задач, в том числе прогнозирования и идентификации, но при этом лицо, принимающее решение (ЛПР), не может провести анализ работы уже обученной нейронной сети. Для пользователя такая обученная сеть является «черным ящиком». Многие из подобных затруднений могут быть разрешены с применением систем, использующих нечеткую логику.

Основным достоинством нечеткой логики служит возможность применения знаний и опыта экспертов о работе и поведении объекта моделирования в виде лингвистических высказываний [Серебровский В.В., 2014]. Но системы с нечеткой логикой не содержат механизмов предварительного обучения. Поэтому на полученные результаты будут сильно влиять типы функций принадлежности, которые используются для обработки нечетких данных. Кроме того, эксперту необходимо заранее определить все правила из базы знаний. Такой алгоритм обработки информации во многом статичен. При необходимости его изменения нужно выполнять довольно трудоемкую процедуру новой работы с экспертами.

Объединение аппарата нечеткой логики с нейронными сетями предоставляет принципиально новые возможности для обработки информации. Создаваемая таким образом нечеткая нейронная сеть обладает двумя важными интеллектуальными свойствами:

- а) лингвистичностью, или предоставлением знаний и опыта экспертов на естественном языке;
- б) обучаемостью созданной сети в реальном масштабе времени.

Можно сказать, что системы с нечеткой логикой являются удобными и полезными для объяснения получаемых с их помощью результатов, они обеспечивают более высокую устойчивость к воздействию мешающих факторов. Однако такие системы не могут автоматически обучаться и приобретать новые знания.

В итоге, искусственные нейронные сети и системы с нечеткой логикой эквивалентны друг другу, но, тем не менее, у них, имеются собственные достоинства и недостатки.

Основная идея, положенная в основу нечетких нейронных сетей заключается в том, что используется существующая выборка данных для определения параметров функций принадлежности, которые лучше всего соответствуют некоторой системе логического вывода, то есть выводы делаются на основе аппарата нечеткой логики. А для нахождения параметров функций принадлежности используются алгоритмы обучения нейронных сетей. Такие системы могут использовать заранее известную информацию, обучаться, приобретать новые знания, прогнозировать временные ряды, выполнять классификацию образов, также они являются вполне наглядными для пользователя.

Результаты и их обсуждение

Для использования в прогнозировании развития энергопотребления выделяем следующие основные группы потребителей: промышленные потребители, сельскохозяйственные потребители, строительного комплекса, потребители транспортной инфраструктуры, потребители коммунальной сферы.

Коммунально-бытовое хозяйство городов и поселков описано абсолютными и удельными (на 1 человека) показателями потребления тепловой и электрической энергии, коэффициентом урбанизации, удельной обеспеченностью жилой площади, возрастными характеристиками жилищного фонда и т. д.

Исходная информация формируется из разных источников, в том числе и из форм отчетности учреждений статистики, и включает, например, отчетные данные за последний базовый год:

- среднегодовая численность городского и сельского населения по области и районам в целом;
- численность промышленно-производственного персонала по основным отраслям промышленности и хозяйствам региона;
- величина дохода и валовая продукция по отраслям промышленности и сельскому хозяйству региона;
- значения стоимости основных производственных фондов по отраслям промышленности и другим отраслям хозяйства региона;
- материалоемкость и трудоемкость продукции в основных отраслях промышленности;
- капитальные вложения и ввод в эксплуатацию основных фондов в целом в промышленности, сельском хозяйстве и других отраслях региональной экономики;
- показатели развития и функционирования транспортного комплекса региона;
- посевные площади по основным культурам сельскохозяйственных угодий региона;
- основные составляющие структуры электропотребления по отраслям промышленности региона;



- производство валовой продукции на душу населения, производительность труда в промышленности и ее отраслях, сельском хозяйстве;
- производство электроэнергии и тепловой энергии на региональных генерирующих мощностях, удельные расходы топлива на производство электроэнергии и тепловой энергии на ТЭС;
- расход топливно-энергетических ресурсов в отраслях промышленности и других отраслях региональной экономики.

Для примера рассмотрим создание нечеткой нейронной сети для прогнозирования потребления электроэнергии в машиностроении. Выбираем следующий комплекс показателей, включающий данные по нескольким календарным годам, для работы создаваемой сети, одновременно присваивая им обозначения соответствующих переменных:

- выпуск продукции в натуральном выражении (x_1);
- материалоемкость производимой продукции (x_2);
- первоначальная стоимость основных производственных фондов предприятий (x_3);
- остаточная стоимость основных производственных фондов предприятий (x_4);
- производственные мощности предприятий (x_5);
- рентабельность предприятий (x_6);
- прибыль предприятий (x_7);
- сумма издержек предприятий (x_8);
- общехозяйственные расходы (x_9);
- сырье и основные материалы (x_{10});
- вспомогательные материалы (x_{11});
- расход электроэнергии (x_{11}).

После выбора используемых показателей формируем гибридную (нечеткую) нейронную сеть. Такая сеть представляет собой сеть, имеющую в своем составе четкие сигналы и веса, но при этом эти сигналы и веса объединяются между собой с применением T -нормы, T -конормы, или же некоторых других непрерывных операций [Дьяконов В.П., 2006]. Применяемые значения входов, выходов и весов разрабатываемой нечеткой нейронной сети представляют собой вещественные числа, принадлежащие интервалу $[0,1]$.

Нечеткие нейронные сети позволяют использовать нечеткие правила вывода для получения выходного результата. В отличие от обычных систем нечеткого вывода в таких сетях вместо расчета уровня активации разработанных правил вывода производится адаптивный подбор параметров. Для дальнейшей работы выбираем нечеткую нейронную сеть типа TSK [Осовский С., 2002.], так как в этой сети функция заключения определяется нечетким, но точечным способом. Это позволяет не применять дефаззификацию на выходе такой системы, что упрощает построение модели вывода.

Для такой сети любое правило базы знаний в общем случае имеет следующий вид:

$$\text{если } x_1 \text{ есть } A_1 \text{ И } x_2 \text{ есть } A_2 \text{ И } \dots \text{ И } x_n \text{ есть } A_n, \text{ то } y = f(x_1, x_2 \dots x_n),$$

где $f(x) = f(x_1, x_2 \dots x_n)$ – четкая функция от входных переменных.

Классическое представление используемой четкой функции $f(x)$, наиболее часто используемое в практических разработках, является полином первого порядка в следующем виде:

$$y = p_0 + \sum_{i=1}^N p_i x_i, \quad (1)$$

где p_0, p_1, \dots, p_N – цифровые веса, значения которых находятся в процессе обучения рассматриваемой сети.

Данная функция будет линейной относительно всех используемых входных переменных рассматриваемой модели.

$$\text{если } (x_1 \text{ есть } A_1^{(1)}) \text{ И } (x_2 \text{ есть } A_2^{(1)}) \text{ И } \dots \text{ И } (x_n \text{ есть } A_n^{(1)}) \text{ то } y_1 = p_{j0} + \sum_{j=1}^N p_{1j} x_j, \quad (2)$$

$$\text{если } (x_1 \text{ есть } A_1^{(M)}) \text{ И } (x_2 \text{ есть } A_2^{(M)}) \text{ И } \dots \text{ И } (x_n \text{ есть } A_n^{(M)}) \text{ то } y_M = p_{M0} + \sum_{j=1}^N p_{Mj} x_j. \quad (3)$$

Для входных переменных используем фаззификацию с применением обобщенной функции Гаусса отдельно для каждой входной переменной x_i :

$$\mu_A(x_i) = \frac{1}{1 + \left(\frac{x_i - c_i}{\sigma_i} \right)^{2b_i}}, \quad (4)$$

где $\mu_A(x_i)$ – представляет оператор A_i из выражений (2–3); b_i, c_i, σ_i – коэффициенты функции принадлежности.

Для этой сети характерна многослойная структура, состоящая из пяти слоев, выполняющих следующие функции [Осовский С., 2002.].

Первый слой обеспечивает выполнение фаззификации для каждой переменной x_i ($i = 1, 2, \dots, N$). В результате выполнения данной операции определяется для каждого k -го правила вывода значение

коэффициента принадлежности $\mu^{(k)}_A(x)$ в соответствии с применяемой для этого функцией фаззификации. Этот слой содержит параметры $b^{(k)}_j$, $c^{(k)}_i$, $\sigma^{(k)}_i$, значения которых должны адаптироваться в процессе обучения разрабатываемой нейронной сети.

Второй слой выполняет агрегирование отдельных входных переменных x_i , в результате которого получается значение коэффициента принадлежности $w_k = \mu^{(k)}_A(x)$.

Третий слой представляет собой генератор функции TSK, рассчитывающий значения по следующей формуле:

$$y_k(x) = p_{k0} + \sum_{j=1}^N p_{kj} x_j, \quad (5)$$

В этом слое производится умножение сигналов $y_k(x)$ на значения w_k , сформированные в предыдущем слое. Этот слой является параметрическим, в котором адаптируются получаемые линейные веса p_{kj} для $k=1,2,\dots,M$ и $j=1,2,\dots,N$, определяющие функцию следствия модели TSK.

Четвертый слой состоит из двух нейронов-сумматоров, один из которых рассчитывает взвешенную сумму сигналов $y_k(x)$, а второй определяет сумму весов $\sum_{k=1}^M w_k$. Это непараметрический слой.

Последний, пятый слой, состоящий из единственного выходного нейрона, обеспечивает нормализацию весов и формирование выходного сигнала. Этот слой так же, как и предыдущий, является непараметрическим.

Из приведенного описания следует, что нечеткая сеть TSK содержит только два параметрических слоя, параметры которых уточняются в процессе обучения. Параметры первого слоя являются нелинейными, поскольку они относятся к нелинейной функции (4), а параметры третьего слоя – линейными весами так как они относятся к параметрам p_{kj} линейной функции TSK.

При использовании гибридного алгоритма обучения нейронной сети все подлежащие адаптации параметры разделяются на две группы. Первая из них состоит из линейных параметров p_{kj} третьего слоя, а вторая группа – из параметров нелинейной функции принадлежности первого слоя. Уточнение параметров проводится в два этапа.

На первом этапе при фиксации определенных значений параметров функции принадлежности (в первом цикле – это значения, полученные в результате инициализации) путем решения системы линейных уравнений рассчитываются линейные параметры полинома TSK.

На втором этапе после фиксации значений линейных параметров рассчитываются фактические выходные сигналы сети, для чего используется линейная зависимость и далее – вектор ошибки. Сигналы ошибок направляются через подключенную сеть по направлению ко входу сети (обратное распространение) вплоть до первого слоя, где могут быть рассчитаны компоненты градиента целевой функции относительно конкретных параметров. После формирования вектора градиента параметры уточняются с использованием одного из градиентных методов обучения.

После уточнения нелинейных параметров вновь запускается процесс адаптации линейных параметров функции TSK (первый этап) и нелинейных параметров (второй этап). Этот цикл повторяется вплоть до стабилизации всех параметров процесса.

Заключение

Такой гибридный алгоритм является одним из наиболее эффективных способов обучения нечетких сетей. Его основной особенностью является разделение процесса обучения на два обособленных во времени этапа. На каждом этапе производится уточнение только части параметров сети. Если принять во внимание, что вычислительная сложность каждого алгоритма оптимизации пропорциональна в нелинейной зависимости количеству параметров, то уменьшение размерности задачи оптимизации существенным образом сокращает количество математических операций и увеличивает скорость выполнения применяемого алгоритма.

Благодаря этому подобный гибридный алгоритм значительно более эффективен, чем обычный градиентный алгоритм фронтального типа, согласно которому уточнение всех параметров сети производится параллельно и одновременно.

Предлагаемая нечеткая нейронная сеть позволяет проводить прогнозирование потребления энергетических ресурсов с большей достоверностью по сравнению с традиционными методами прогнозирования. Это объясняется тем, что такие сети могут использовать опыт экспертов и специалистов, и процесс их обучения имеет меньшую длительность по сравнению с классическими нейронными сетями.



Список литературы References

- Бэнн Д.В., Фармер Е.Д. 1987. Сравнительные модели прогнозирования электрической нагрузки. Пер. с англ. М., Энергоатомиздат, 200. (Bunn D.W., Farmer E.D. 1985. Comparative Models for Electrical Load Forecasting. New York, John Wiley and Sons, 232.).
- Benn D.V., Farmer E.D. 1987. Sravnitel'nye modeli prognozirovaniya elektricheskoy nagruzki [Comparative Models for Electrical Load Forecasting]. Moscow, Energoatomizdat, 200. (Bunn D.W., Farmer E.D. 1985. Comparative Models for Electrical Load Forecasting. New York, John Wiley and Sons, 232.).
- Дьяконов В.П., В.В.Круглов. 2006. MATLAB 6.5 SP1/7/7 SP1/7 SP2 + Simulink 5/6. Инструменты искусственного интеллекта и биоинформатики. М., СОЛОН-ПРЕСС, 456.
- D'yakonov V.P., V.V.Kruglov. 2006. MATLAB 6.5 SP1/7/7 SP1/7 SP2 + Simulink 5/6. Instrumenty iskusstvennogo intellekta i bioinformatiki [MATLAB 6.5 SP1 / 7/7 SP1 / 7 SP2 + Simulink 5/6. Tools of Artificial Intelligence and Bioinformatics]. Moscow, SOLON-PRESS, 456.
- Круглов В.В., Борисов В.В. 2002. Искусственные нейронные сети. Теория и практика. М., Горячая линия-Телеком, 382.
- Kruglov V.V., Borisov V.V. 2002. Iskusstvennye neyronnye seti. Teoriya i praktika [Artificial neural networks. Theory and practice]. Moscow, Goryachaya liniya-Telekom, 382. (in Russian)
- Осовский С. 2002. Нейронные сети для обработки информации. Пер. с польского. М., Финансы и статистика, 344. (Osowski S. 2000. Sieci neuronowe do przetwarzania informacji, Warszawa, Oficyna Wydawnicza PW).
- Osovskiy S. 2002. Neyronnye seti dlya obrabotki informatsii [Neural networks for information processing]. Moscow, Finansy i statistika, 344. (Osowski S. 2000. Sieci neuronowe do przetwarzania informacji, Warszawa, Oficyna Wydawnicza PW).
- Рутковская Д., Пилиньский М., Рутковский Л. 2004. Нейронные сети, генетические алгоритмы и нечеткие системы. Пер. с польского. М., Горячая линия-Телеком, 452. (Rutkowska D., Piliński M., Rutkowski L. 1997. Sieci neuronowe, algorytmy genetyczne i systemy rozmyte, Warszawa, PWN, 411.).
- Rutkovskaya D., Piliński M., Rutkovskiy L. 2004. Neyronnye seti, genetycheskie algoritmy i nechetkie sistemy [Neural networks, genetic algorithms and fuzzy systems], Moscow, Goryachaya liniya-Telekom, 452. (Rutkowska D., Piliński M., Rutkowski L. 1997. Sieci neuronowe, algorytmy genetyczne i systemy rozmyte, Warszawa, PWN, 411.).
- Серебровский В.В., Филлист С.А., Шаталова О.В., Черепанов А.А. 2014. Информационная система детектирования ишемических кардиоциклов с использованием нечеткой логики. Научные ведомости Белгородского государственного университета. Серия История, Политология, Экономика, Информатика, 8 (179): 71–75.
- Serebrovskiy V.V., Filist S.A., Shatalova O.V., Cherepanov A.A. 2014. Informatsionnaya sistema detektirovaniya ishemicheskikh kardiotsiklov s ispol'zovaniem nechetkoy logiki. Nauchnye vedomosti Belgorodskogo gosudarstvennogo universiteta. Seriya Istoriya, Politologiya, Ekonomika, Informatika [Belgorod State University Scientific bulletin. History, Political Science, Economics, Informatics serie], 8 (179):71–75. (in Russian)