

формацию, необходимую для корректной интерпретации результатов. В тех случаях, когда определение исследуемой величины проводят независимо различными методами, следует внести в таблицу информацию об альтернативных методиках [6].

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Израэль Ю.А.* Экология и контроль состояния природной среды. – М.: Гидрометеиздат, 1984. – 560 с.
2. *Бурдин К.С.* Основы биологического мониторинга. – М.: МГУ, 1985. – 158 с.
3. *Израэль Ю.А.* Концепция мониторинга состояния биосферы // Мониторинг состояния окружающей природной среды. Т.1 советско-английского симпозиума. – Л.: Гидрометеиздат, 1977. – С. 10-25.
4. *Федоров В.Д.* Устойчивость экологических систем и ее измерение // Изв. АН СССР. Сер. биол. 1974. – № 3. – С. 402-415.
5. *Николаевский В.С.* иомониторинг, его значение и роль в системе экологического мониторинга и охране окружающей среды // Методологические и философские проблемы биологии. – Новосибирск. Наука, 1981. – С. 341-354.
6. Сборник методик и инструктивных материалов по определению вредных веществ для контроля источников загрязнения окружающей среды: Ч. 1 / Под редакцией Ярмака Л.П. – Краснодар: Северный Кавказ, 1993. – 224 с.

УДК 621.31

Е.А. Шестова

РАЗРАБОТКА МЕТОДОВ ТЕСТИРОВАНИЯ ПОТРЕБИТЕЛЕЙ ЭЛЕКТРОЭНЕРГИИ

Энергетическая инфраструктура в настоящее время является устойчивым импортером электрической энергии. Ограничения в работе электроэнергетического комплекса в значительной степени определяются состоянием оборудования, а также дефицитом топлива (природного газа). Проблема энергосбережения напрямую связана с эффективным использованием энергоресурсов. Эффективное управление энергоресурсами невозможно осуществлять без использования максимально более точного прогнозирования потребления электроэнергии. Чем точнее совпадение прогнозного значения с реальным потреблением, тем дешевле электроэнергия.

Проблема прогноза потребления электроэнергии представляет собой сложную многопараметрическую задачу. Потребление электроэнергии зависит от типа дня (рабочий день, суббота, выходной день, праздничный день, предпраздничный день), времени года, погодных условий (температура воздуха, облачность, осадки, туман и т.п.), времени суток и других параметров. Зависимость потребления электроэнергии от каждого из этих параметров довольно сложна и не имеет однозначного формального описания.

Часто для решения задач прогнозирования применяется статистический аппарат корреляционного анализа [1], который строится на предыдущих значениях одномерного случайного процесса. Рассматривается модель вида

$$y = X\theta + \varepsilon, \quad (1)$$

где $y = (y_1, \dots, y_n)^T$ – вектор значений объясняемой переменной в n наблюдениях, $X = (n \times p)$ матрица значений объясняющих переменных в n наблюдениях, $\theta = (\theta_1, \theta_2, \dots, \theta_p)^T$ – вектор коэффициентов, $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n)^T$ – вектор случайных ошибок (возмущений) в n наблюдениях.

Данный метод не позволяет устанавливать причинно-следственные связи параметров прогнозируемой системы в целом. Очевидно, для повышения качества прогноза необходимо проводить одновременный анализ сразу нескольких доступных показателей. Следовательно, задача прогнозирования должна быть сведена к прогнозированию многомерного временного ряда, каждый элемент которого будет являться одним из связанных параметров системы.

Традиционно для прогноза потребления электроэнергии используется метод авторегрессии: линейный алгоритм, основанный на предсказании будущего по ближайшему прошлому. Обычно обнаруживается, что значения отклика в некоторой точке временного ряда сильно коррелированы с несколькими предшествующими и/или последующими значениями. Действительно, для многих явлений их современное состояние функционально определяется предшествующими состояниями системы, в большей степени недавними, в гораздо меньшей – далеко отстоящими от заданного по временному ряду.

Авторегрессия первого порядка характеризует тесноту связи между соседними значениями временного ряда, авторегрессия второго порядка – между отстоящими друг от друга на два периода и так далее. Авторегрессия n -го порядка относится к степени связанности откликов, разнесенных на n периодов. Предполагая, что возникшая связь между значениями сохранится некоторое время в будущем, мы получаем механизм прогнозирования, основанный на построении регрессии точек ряда на самих себя, то есть – авторегрессии.

Авторегрессионные модели разных порядков – первого (2), второго (3), в общем случае n -го (4) – можно описать уравнениями следующего вида:

$$y_t = \beta_0 + \beta_1 y_{t-1} + \varepsilon_t; \quad (2)$$

$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \varepsilon_t; \quad (3)$$

$$1 \ y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_n y_{t-n} + \varepsilon_t, \quad (4)$$

где β_0 – константа (свободный член) авторегрессионного уравнения, $\beta_1, \beta_2, \dots, \beta_n$ – коэффициенты авторегрессии, y_t – величина отклика в некоторый момент времени, $y_{t-1}, y_{t-2}, \dots, y_{t-n}$ – соответственно отклики одним, двумя, ..., n периодами ранее заданного, ε_t – некоррелированная случайная компонента, присутствующая в отклике и связанная с ошибками наблюдения и погрешностями модели.

Было показано [2], что для решения таких задач наиболее перспективными с точки зрения эффективности прогноза являются модели векторной авторегрессии (VAR) и нейронной сети. Базовая модель VAR основана на статистическом подходе к прогнозированию и является обобщением метода авторегрессии для многомерного случая. В работе [3] имеется математическое описание данной модели.

Пусть имеется m процессов y_{it} , $i = 1, \dots, m$ и $t = 1, \dots, N$ (число временных отсчетов). Тогда в матричной форме модель векторной авторегрессии имеет вид

$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_p y_{t-p} + \varepsilon_t \quad (5)$$

Базовой предпосылкой для модели (5) являются предположение, что вектор остатков ε_t представляет собой вектор белого шума, то есть:

$$M(\varepsilon_t) = 0, R(\varepsilon_t, \varepsilon_s) = \begin{cases} \sum \varepsilon, & t = s \\ 0, & t \neq s \end{cases}.$$

Кроме того, матричные коэффициенты должны удовлетворять условиям стационарности VAR-модели:

$$|I - \beta_1 z - \dots - \beta_p z^p| = 0. \quad (6)$$

Корни уравнения (6) должны лежать за пределами единичной окружности для стационарной модели. Для нахождения коэффициентов модели используют метод наименьших квадратов.

Эта модель достаточно широко применяется в многомерных прогнозах макроэкономики как достаточно мощный и надежный инструмент. Сильной стороной VAR-модели является возможность отражения глубоких динамических свойств многомерных временных рядов. Исследования подтверждают, что существуют ограничения использования данного вида модели, которое заключается в требовании стационарности процесса y_t . Кроме того, VAR-модель плохо моделирует нелинейные структуры.

Исследуемый ряд проверяется на стационарность. Стационарность регрессоров является очень важным условием при оценивании регрессионных моделей. Если модель неверно специфицирована, и некоторые из переменных включены в нее неправильно, то полученные оценки будут очень плохими. Они не будут обладать свойством состоятельности, то есть не будут сходиться по вероятности к истинным значениям параметров по мере увеличения размеров выборки. Привычные показатели, такие как коэффициент детерминации R^2 , t -статистики, F -статистики будут указывать на наличие связи там, где на самом деле ее нет. Такой эффект называют ложной регрессией.

Возможно построение отдельных авторегрессионных моделей для различных типов дней. При этом все остальные факторы, влияющие на потребление электроэнергии, используются опосредованно, то есть через их влияние на прошлые значения потребления электроэнергии. Этот метод позволяет получать хорошие результаты прогноза в стабильных ситуациях (нет резких изменений погоды). Однако при неожиданном резком изменении внешних параметров применение такого подхода не позволяет правильно спрогнозировать ситуацию. Например, при резком сильном похолодании, даже в случае если известен примерно правильный прогноз погоды, метод не предусматривает возможности его использовать.

Кроме авторегрессионного метода, в последнее время все большее внимание со стороны специалистов, занимающихся прогнозом временных рядов, и в частности, рядов по потреблению электроэнергии, привлекает использование относительно нового метода, основанного на нечеткой логике и искусственных нейронных сетях (ИНС). Иными словами, этот метод является гибридом нечеткой

логики и нейронных сетей, который вобрал в себя основные свойства присущие этим направлениям [4].

Основная привлекательность применения ИНС для задач прогноза потребления электроэнергии состоит в возможности использования большого количества разнообразных входных параметров – исторические данные по потреблению электроэнергии и соответствующие исторические погодные условия, прогноз погоды, время суток, время года, тип дня и т.д. При этом функция влияния входного параметра на выходной результат может быть какой угодно сложной (нелинейной, нестационарной) и неизвестной формы. Кроме того, часть входных параметров модели является численными (исторические значения потребления электроэнергии, температура воздуха, время суток и т.п.), а часть – категориальными (время года, тип дня, тип облачности и другие). Возможно также неявное использование входных параметров. Через построение системы ИНС, каждый элемент которой (отдельная ИНС) обучен на определенный случай, например, для определенного типа дня или времени года. Общий вход системы ИНС (ворота) служит для направления данных на вход конкретной ИНС, предназначенной для соответствующей прогнозируемому случаю ситуации. При этом выбор ИНС определяется по специальному, неявно задаваемому параметру (или набору параметров) – например, тип дня [5].

ИНС являются аналитическими системами, в которых поставленные задачи не достаточно четко сформулированы. Недостаточная точность формулировки восполняется способностью ИНС к самообучению, умению находить в данных скрытые и неясные образы. Важным свойством ИНС является способность к изменению своего поведения и знания в зависимости от изменений внешней среды.

ИНС представляет собой структуру, соединенных между собой нейронов. Связи между нейронами обладают весовыми коэффициентами. Структура связей задается заранее и определяет топологию ИНС.

Топология может быть различной (только вперед от одного слоя к другому, каждый нейрон с каждым и другие).

Каждый нейрон скрытого слоя вычисляет сумму от поступивших на его вход значений (при этом до поступления на вход выходные значения нейронов предыдущего слоя умножаются на вес связи, по которой оно передается). Над полученной суммой выполняется нелинейная операция. Результат нейрон выдает на свой выход. Нейроны входного и выходного слоев отличаются тем, что просто передают соответственно входные значения или результат.

До того как использовать ИНС ее необходимо обучить на данных, имеющих те же свойства, что и те, которые будут в дальнейшем подаваться на вход. Для обучения используются исторические данные, то есть для которых уже известны ответы (реальное потребление электроэнергии). Процесс обучения ИНС состоит в настройке весовых коэффициентов связей между нейронами так, чтобы получился лучший ответ на входной пример. Качество ответа определяется по разнице между реакцией ИНС и реальным известным значением. Одним из важнейших аспектов работы с ИНС является выявление правильного момента окончания обучения, то есть предотвращение переобучения сети. Переобученная сеть очень хорошо воспроизводит данные, на которых она училась, но плохо работает на других, так как ее внимание излишне заострилось на деталях, отраженных в примерах для обучения и отсутствующих в любых других. Одним из приемов для предотвращения переобучения является метод раннего останова.

Хорошо обученная ИНС может функционировать и в стабильных, и в переменных условиях, так как выход зависит не только от близких предшествующих данных, а от аналогичных имевших место когда-либо.

Нейронные сети – это устройства параллельной обработки информации всеми звеньями. Они обладают способностью к обучению и обобщению накопленных знаний. Натренированная на ограниченном множестве данных сеть способна обобщать полученную информацию и показывать хорошие результаты на данных, не использовавшихся в процессе обучения. Однако нейронные сети все же обладают недостатками. Несмотря на то, что они являются очень удобными для задач распознавания, классификации образов, прогнозирования и идентификации, лицо принимающее решение не может получить ответа на вопрос как осуществляются эти процессы. Многие из недостатков могут быть разрешены с помощью систем с нечеткой логикой, которые используют основные понятия теории нечетких множеств.

Нечеткое множество – это такое множество, которое содержит совокупность элементов произвольной природы. Причем относительно этих элементов нельзя с полной определенностью сказать – принадлежит или не принадлежит тот или иной элемент рассматриваемой совокупности данному множеству.

Нечеткая логика выделяется из теории нечетких множеств и представляет собой разновидность непрерывной логики, в которой логические формулы могут принимать истинностные значения между 1 и 0. Следует отметить, что результат, полученный в системах с нечеткой логикой, также представляется неточно, нечетко. Для того чтобы получить какое-либо конкретное значение, которое может быть использовано в управляющих системах, применяются системы нечеткого вывода. Процесс нечеткого вывода представляет собой некоторую процедуру или алгоритм получения нечетких заключений на основе нечетких предпосылок или условий.

Системы нечеткого вывода позволяют решать задачи принятия решений, распознавания образов, классификации данных и многие другие [6].

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 и кроме этого они являются вполне наглядными для пользователя. В свою очередь, так же как и при классификации образов, предсказание электрической нагрузки базируется на учете свойств прогнозируемого процесса. Главная особенность нагрузок энергетической системы – это определенная повторяемость характеризующих их выборок в зависимости от дня недели и месяца.

Приведенный пример показывает перспективность использования адаптивных научных методов для прогноза потребления электроэнергии. Развитие и тестирования на различных примерах предложенной методики использования нечеткой логики и искусственных нейронных сетей может привести к очень эффективному и удобному методу прогноза потребления электроэнергии. Данная задача является крайне важной для определения стратегии поведения в электроэнергетике. Внедрение методов и технологий компьютерного тестирования позволяет организовать эффективный контроль и оценку уровня качества оказания услуг.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Магнус Я.Р., Катышев П.К., Пересецкий А.А.* Эконометрика. Начальный курс: Учебник. – 7-е изд., испр. – М.: Дело, 2005. – 504 с.
2. *Кругов В.В.* Методы прогнозирования многомерных временных рядов / В.В.Круглов // Приборы и системы. Управление, контроль, диагностика. – 2005. – № 2. – С. 62-66.
3. *Швайко П.* Эконометрические модели анализа и прогнозирования емкости первичного рынка ГКО / П.Швайко // Эковест. – 2002. – № 2. – С. 111 – 153.
4. *Бирюков Е.В., Корнев М.С.* Практическая реализация нечеткой нейронной сети при краткосрочном прогнозировании электрической нагрузки.
5. *Савельева Е.А., М Каневский.Ф., Кравецкий А.С., Огарь В.П., Большой Л.А.* Пример прогноза потребления электроэнергии при экстремальных погодных условиях//ЭСКО – Электронный журнал энергосервисной компании “Экологические системы”. 2004. – №2.
6. *Леоненков А.В.* Нечеткое моделирование в среде MATLAB и fuzzy TECH. – СПб.: БХВ-Петербург, 2003. – 736 с.

УДК 620.9.001.12/.18

В.И. Финаев, В. Ю. Евтушенко

МЕТОДОЛОГИЯ НЕЧЕТКОГО УПРАВЛЕНИЯ АВТОНОМНОЙ ЭНЕРГЕТИЧЕСКОЙ СИСТЕМОЙ

При управлении сложными техническими системами, как правило, приходится сталкиваться с различной степенью неопределенности исходных данных, параметров системы, нечеткостью целей и задач управления.

Выбор методов формализации исходной информации зависит главным образом от типа неопределенности, к которому относится данная задача.

В современной научной литературе обращается внимание на необходимость разработки и применения новых методов раскрытия неопределенности при управлении в условиях неполной (нечеткой) информации [5, 6, 9].

Методы управления, основанные на теории нечетких множеств, разработанной американским математиком Л. А. Заде, являются наиболее перспективными для решения данного класса задач.

Качественный процесс решения задачи, свойственный человеку, называют *нечетким алгоритмом*. Для более содержательного определения нечеткого алгоритма введем понятие *нечеткого оператора* – это любой оператор, содержащий в своей формулировке, по крайней мере, одну нечеткую или лингвистическую переменную, нечеткую функцию или нечеткое отношение. Тогда *нечеткий алгоритм* – это последовательность выполняемых в соответствии с их семантикой