

МОДЕЛЬ ПРОГНОЗИРОВАНИЯ ПОТЕРЬ МОЩНОСТИ В ЭЛЕКТРИЧЕСКИХ СЕТЯХ ЭНЕРГОСИСТЕМЫ

В.З. Манусов, Ю.Б. Заиграева

Новосибирский государственный технический университет

E-mail: Zaigraeva@ngs.ru

Рассмотрены вопросы расчета, прогнозирования, нормирования потерь мощности в электрических сетях энергосистемы с применением искусственных нейронных сетей. Реализован алгоритм выбора оптимальных архитектуры искусственных нейронных сетей, функции активации, алгоритма обучения на примере магистральных электрических сетей Центра.

Федеральным законом «Об электроэнергетике» установлен переход к конкурентному оптовому рынку электроэнергии в России в 2008 г. Тема моделирования потерь мощности и электроэнергии имеет большую актуальность для электроэнергетических рынков.

Цикл управления энергетическим предприятием состоит из различных этапов, чаще всего этот процесс включает в себя: прогнозирование, планирование, текущее управление, учет, контроль, анализ и нормирование. В статье исследуются этапы — прогнозирование, планирование, учета одного из показателей эффективности функционирования энергетического предприятия — потерь мощности и электроэнергии в электрических сетях. Ставится задача учета технико-экономических показателей деятельности предприятия в целом. Прогнозирование требует определение объекта, целей функционирования и разработки математических моделей и методов с их учетом. Объектом в статье выступают электрические сети сетевого предприятия оптового рынка электроэнергии — магистральные электрические сети Центра. В связи с этим возникает вопрос достоверности и точности прогноза, от которого зависит достоверность планирования. В работе предлагается математическая модель и метод прогнозирования потерь мощности и электроэнергии для энергетического предприятия, основанный на базе современных алгоритмов искусственного интеллекта — нейротехнологиях.

Следует отметить, что, несмотря на многообразие методов прогнозирования технических потерь, в настоящее время существует ряд моментов, значительно затрудняющих решение этой задачи, например, недостаточная наблюдаемость электрических сетей [1], возникающая вследствие низкой обеспеченности электрических сетей средствами измерений и учета электроэнергии.

Как показывают исследования [2, 3], применение «интеллектуальных» методов и подходов позволяют эффективно «выйти» из «замкнутого круга новых рыночных требований», получив значительно лучшие решения, по сравнению с традиционными методиками.

Модели искусственных нейронных сетей (ИНС) обладают рядом достоинств, которые позволяют их широко использовать в задачах анализа и прогнозирования, а именно [2–4]:

- отсутствие необходимости построения математической модели анализируемого процесса;
- способность восстанавливать нелинейные функциональные зависимости между изучаемыми параметрами (характеристиками);
- эффективная работа в условиях неполноты исходной информации;
- возможность использования малых обучающих выборок;
- быстрый отклик обученной ИНС на поступление текущей информации;
- обеспечение практически полного режимного диапазона работы электрической сети;
- учет неограниченного количества влияющих факторов;
- нет необходимости эквивалентирования;
- высокая степень адекватности режимов сети;
- адаптивность модели обеспечивается путем самообучения.

Применение нейротехнологий для построения математической модели прогнозирования потерь мощности предполагает определение объекта моделирования, задач и целей его функционирования. Затем определяются свойства объекта, которые позволяют сформировать факторы для математической модели (рис. 1). Моделирование осуществляется на базе (ИНС).

Моделирование ИНС чаще осуществляется с помощью программ-нейроимитаторов, которые работают на персональных компьютерах. Такое моделирование предполагает последовательное выполнение следующих этапов [2]:

1. Формулирование задачи в нейросетевом базисе;
2. Формирование выборки обучения;
3. Выбор архитектуры ИНС (идентификация структуры модели);
4. Обучение ИНС (оценивание параметров модели);
5. Тестирование ИНС в целях установления адекватности модели.

Практическое применение ИНС реализовано на построении модели прогнозирования потерь мощности в межсистемных электрических сетях (МЭС) Центра.




Рис. 1. Структура формирования факторов модели, построенной на базе искусственных нейронных сетей

Основными предметами деятельности МЭС Центра являются: оказание услуг по передаче и распределению электрической энергии; оказание услуг по присоединению к электрическим сетям; оказание услуг по сбору, передаче и обработке технологической информации, включая данные измерений и учета. В зону ответственности МЭС Центра входят территории двадцати субъектов Российской Федерации общей площадью 947 тыс. км² с населением более 44 млн чел. Объем передачи электроэнергии за 2007 г. составил более 116 млрд. кВт·ч. Общая протяженность линий электропередачи МЭС Центра составляет 29377,690 км, в частности воздушные линии (ВЛ) 750 кВ – 2270,5 км; ВЛ 500 кВ – 8519,6 км; ВЛ 330 кВ – 1767,6 км. В эксплуатации МЭС Центра находятся 210 подстанций (ПС), напряжением 35 – 750 кВ: ПС 750 кВ – 6; ПС 550 кВ – 27; ПС 330 кВ – 14; ПС 220 кВ – 153; ПС 110 кВ – 9; ПС 35 кВ – 1 [5].

Метод, рассматриваемый в статье, использует вероятностную информацию, что позволяет оценить случайный характер изменения нагрузки. Этот факт обосновывается применением этих данных в исследовательских целях. Для каждого изменения мощности в узлах рассчитываются нагрузочные потери и потери в трансформаторах с помощью программы расчета установившегося режима. Изменение нагрузки подчиняется нормальному закону распределения.

В работе построение и обучение ИНС реализовано в программе-нейроимитаторе *Statistica Neural Networks*.

На первоначальном этапе вектор независимых переменных включает всевозможные факторы, на последующем этапе это количество сокращается вследствие применения алгоритмов понижения размерности [6]. Рассматриваемые математические модели характеризуют связи нагрузочных потерь с по-

требляемыми активной и реактивной мощностями по предприятию в целом и средними напряжениями сети; потерь в трансформаторах с аналогичными факторами. Задачи решены для МЭС Центра в целом и для каждого напряжения в отдельности (750, 500, 330 кВ). Входными данными являются: потребляемые активная и реактивная мощности, среднее напряжение по МЭС в целом. Выходные переменные – нагрузочные потери и потери в трансформаторах.

Применение генетического алгоритма и алгоритмов пошагового включения и исключения входных переменных (алгоритмы понижения размерности, реализованные в *Statistica Neural Networks*) дали следующие результаты (рис. 2):

- значимость входных переменных следует разместить в следующей последовательности: среднее напряжение 500 кВ, суммарная активная мощность, суммарная реактивная мощность, средние напряжения 750, 330 и 220 кВ;
- необходимо также отметить, что все переменные значимы.

Вывод о репрезентативности обучающей выборки устанавливается путем расчета следующих характеристик: полнота, равномерность, противоречивость и повторяемость обучающей выборки. Тестовая выборка используется для проверки адекватности построенной модели, поэтому сразу следует отвергнуть гипотезу о том, что объема тестовой выборки недостаточно для ее представительности. Для проверки гипотез о достаточности объема обучающей выборки и размера ИНС применяется теория «кривых обучения» [3, 7].

Объем выборки составил 5000 наблюдений, из них 3000 – обучающая выборка, 2000 – контрольная и тестовая. Применение теории «кривых обучения» показало, что в данном случае не имеет смысла уменьшать или увеличивать выборку.




Рис. 2. Значимость входных переменных

Рассмотрены следующие архитектуры ИНС – многослойный перцептрон и радиальная базисная функция. И с помощью теории «кривых обучения» определено оптимальное количество скрытых нейронов в скрытом слое. Кривые обучения и обобщения (прогноза) выходят на один асимптотический уровень при размере скрытого слоя в 10 и 12 скрытых нейронов для многослойного перцептрона и ≈ 50 скрытых нейронов для радиальной базисной функции. Результаты исследований приведены в таблице 1, в которой верхние значения соответствуют многослойному перцептрону, нижние – радиальной базисной функции.

Эффективность алгоритмов обучения проверяется на тестах [8], различные алгоритмы сравнива-

ются по значениям ошибки обучения и обобщения (прогноза), количеству циклов обучения необходимого для достижения фиксированного уровня погрешности (табл. 2). В статье рассмотрены алгоритмы обучения, которые реализованы в программно-нейроимитаторе *Statistica Neural Network*.

Исследования показали, что оптимальным алгоритмом обучения является квази-ньютоновский алгоритм. Также эффективными являются алгоритмы: сопряженных градиентов и Левенберга-Марквардта. Нерезультативными явились алгоритмы обратного и быстрого распространения.

В результате проведенных исследований были получены следующие результаты (рис. 3–4):

Таблица 1. Оптимальные структуры многослойных перцептронов и радиальных базисных функций и погрешности прогнозирования и обучения

Наименование задачи	Скрытые нейроны	Ошибка обучения, %		Ошибка прогноза, %	
		Среднее	Отклонение	Среднее	Отклонение
Нагрузочные потери в схеме	10	1,5E-04	1,7	0,1	2,0
	≈ 50	5,1E-10	1,9	0,1	2,0
Потери в трансформаторах	12	3,1E-04	0,6	0,1	1,0
	≈ 50	1,9E-09	2,0	0,1	2,1
Нагрузочные потери в сети 750 кВ	12	4,0E-08	1,0	0,8	2,3
	≈ 50	6,1E-12	2,0	0,2	2,1
Нагрузочные потери в сети 500 кВ	10	1,3E-04	1,4	0,1	2,1
	≈ 50	5,1E-14	2,1	0,1	1,8
Нагрузочные потери в сети 330 кВ	12	5,6E-06	1,4	0,03	2,0
	≈ 50	6,1E-12	2,0	0,2	2,1

Таблица 2. Результаты обучения ИНС

Алгоритм обучения	Ошибки обучения и прогноза %		Нагрузочные потери в схеме	Потери в трансформаторах	Нагрузочные потери в сети 750 кВ	Нагрузочные потери в сети 500 кВ	Нагрузочные потери в сети 330 кВ
Обратное распространение	Ошибка обучения	Средняя	5,3E-03	1,7E-02	3,17E-04	1,4E-03	7,2E-03
		Среднеквадратическая	2,7	2,3	1,1	1,4	1,5
	Ошибка прогноза	Средняя	0,4	4,0	0,8	5,7	12,3
		Среднеквадратическая	24,7	2,6	1,7	2,2	2,3
	Количество итераций		–	–	–	–	–
Сопряженных градиентов	Ошибка обучения	Средняя	2,8E-04	5,7E-04	2,7E-06	4,0E-06	5,6E-05
		Среднеквадратическая	2,4	1,8	0,8	1,3	1,3
	Ошибка прогноза	Средняя	0,2	0,3	0,4	1,3	0,3
		Среднеквадратическая	2,9	1,9	0,6	2,0	1,8
	Количество итераций		20	20	5	10	760
Квази-Ньютоновский	Ошибка обучения	Средняя	1,0E-04	2,6E-04	3,0E-05	1,0E-04	1,0E-05
		Среднеквадратическая	1,1	1,6	1,0	1,2	1,2
	Ошибка прогноза	Средняя	0,1	0,1	0,5	0,1	0,1
		Среднеквадратическая	1,9	1,9	2,0	1,9	1,9
	Количество итераций		28	18	25	500	15
Левенберга-Марквардта	Ошибка обучения	Средняя	2,2E-04	2,1E-04	1,1E-06	8,0E-07	9,4E-07
		Среднеквадратическая	0,8	1,7	0,6	1,3	1,2
	Ошибка прогноза	Средняя	0,1	0,3	0,3	1,2	0,2
		Среднеквадратическая	4,6	1,8	0,6	2,0	1,7
	Количество итераций		137	50	26	50	10
Быстрое распространение	Ошибка обучения	Средняя	1,1E-03	4,7E-05	5,8E-05	5,6E-06	1,8E-05
		Среднеквадратическая	2,2	2,0	1,1	1,3	1,4
	Ошибка прогноза	Средняя	0,3	0,6	0,3	1,2	0,2
		Среднеквадратическая	22,3	2,7	1,9	2,0	2,1
	Количество итераций		700	24	750	25	480

- погрешность моделей составила: средняя – $1,0E-05...2,6E-04$ %; среднеквадратическая – $1,0...1,6$ %.
- погрешность прогноза находится в пределах: средняя – $0,1...0,5$ %; среднеквадратическая – $1,9...2,0$ %.

В статье предлагается метод моделирования, основанный на базе нейротехнологий. Данный метод обладает следующими преимуществами:

1. отсутствие необходимости построения математической модели анализируемого процесса;




Рис. 3. Значения средних погрешностей ошибок обучения и прогноза




Рис. 4. Значения среднеквадратических погрешностей ошибок обучения и прогноза

2. эффективная работа в условиях неполноты исходной информации;
3. учет неограниченного количества влияющих факторов.

В статье рассматривается задача прогнозирования потерь мощности в электрических сетях сетевого предприятия. При построении модели прогнозирования на основе ИНС необходимо учесть, что:

- При выборе оптимального входного вектора на первоначальном этапе необходимо включить всевозможные факторы, в дальнейшем необходимо применить методы понижения размерности и отбора данных.
- Для нахождения оптимальной выборки ИНС и определения числа скрытых нейронов необходимо применять «теорию кривых». Проведенные

исследования показали, что достаточным является использование 10–12 скрытых нейронов в случае многослойного персептрона и 50 в случае применения радиальной базисной функции.

- Оптимальным алгоритмом обучения для рассмотренных моделей является квази-ньютоновский алгоритм. Также эффективными явились алгоритмы: сопряженных градиентов и Левенберга-Марквардта.

Модель прогнозирования потерь мощности для электрических сетей сетевого предприятия на основе ИНС имеет следующие погрешности: средняя погрешность модели – $1,0 \cdot 10^{-4}$ %; среднеквадратическая погрешность модели – 1,5 %; средняя погрешность прогноза – 0,5 %; среднеквадратическая погрешность прогноза – 2,0 %.

СПИСОК ЛИТЕРАТУРЫ

1. Гамм А.З. Наблюдаемость электроэнергетических систем. – М.: Наука, 1990. – 220 с.
2. Манов Н.А. и др. Новые информационные технологии в задачах оперативного управления электроэнергетическими системами. – Екатеринбург: Изд-во УрО РАН, 2002. – 205 с.
3. Заиграева Ю.Б., Манусов В.З. Прогнозирование потерь мощности и электроэнергии с учетом новых реалий в электроэнергетики // Энергетика: экология, надежность, безопасность: Матер. XIII Всеросс. научно-техн. конф. – Томск: Изд-во ТПУ, 2006. – С. 35–37.
4. Манова Н.А. Управление электроэнергетическими системами – новые технологии и рынок. – Сыктывкар: Коми научный центр УрО РАН, 2004. – 297 с.
5. Информация по магистральным электрическим сетям Центра // [Электронный ресурс]. – 2007. – Режим доступа: [http://center.fsk-ees.ru/ru].
6. Нейронные сети. STATISTICA Neural Networks // Пер. с англ. – М.: Горячая линия – Телеком, 2001. – 654 с.
7. Царегородцев В.Г. Оптимизация экспертов boosting-коллектива по их кривым обучения // Нейроинформатика и её приложения: Матер. XII Всеросс. семин. – Красноярск, 2004. – С. 152–157.
8. Осовский С. Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2004. – 344 с.

Поступила 06.12.2007 г.