

УДК 621.316.1.017 + 004.8 + 004.032.26

МОДЕЛЬ ЭЛЕМЕНТА ИСКУССТВЕННОГО ИНТЕЛЛЕКТА С УЧЕТОМ МЕТЕОФАКТОРОВ И АЛГОРИТМОВ ЕЕ ОБУЧЕНИЯ ДЛЯ РАСШИРЕНИЯ ЗАДАЧИ УПРАВЛЕНИЯ РЕЖИМАМИ СИСТЕМ ЭЛЕКТРОСНАБЖЕНИЯ

В.С. Павлюков, С.В. Павлюков, С.П. Сусанин

Приводятся результаты разработки и исследования модели элемента искусственного интеллекта с целью прогнозирования функций времени, влияющими на перспективный режим функционирования технических систем.

Ключевые слова: элемент искусственного интеллекта, нейронная сеть, алгоритм обучения, функции времени.

Разработка систем управления для различных электротехнических объектов в современных условиях является важной научной задачей, которая требует развития и применения новых методологий. До настоящего времени имеется еще много задач, которые ждут своего решения. Так например, узловые нагрузки, которые являются важным режимным параметром, могут моделироваться детерминированными данными [1], разложением графиков нагрузок рядом гармонических функций [2], с использованием факторного анализа [3], применением разложения Карунена-Лоэва [4], рассматривающего исходные данные на уровне случайных процессов, нестационарными вероятностно-статистическими способами [5] и др. Указанные подходы громоздки, требуют большую предварительную информацию, связанную с регулярными, объемными замерами режимных параметров и их сложной численной обработкой. Первостепенное значение при разработке новых технологий будет иметь повышение требований к точности моделирования текущих и перспективных процессов управления техническими коммуникациями и объектами электроэнергетики. К таким новым технологиям можно отнести использование элементов искусственного интеллекта. Указанное выше является актуальным и определяет направление исследований в области управления техническими системами.

В работе предлагается развитие математического моделирования функций времени или графиков мощностей нагрузок, позволяющее решать задачу оперативных расчетов режимов в разрезе суток, а также краткосрочного планирования режимов, повышая качество управления работой электротехнических систем. Перспективным направлением исследований для указанной задачи является применение аппарата элементов искусственного интеллекта.

Наиболее объемную режимную узловую информацию высоковольтной или питающей системы можно представить в виде вектора-функции графиков полных мощностей за некоторый дискретный интервал времени [6].

$$\mathbf{s}(t) = [s_i(t)] = [p_i(t) + jq_i(t)], \quad (1)$$

или с использованием режимной информации в виде узловых токов:

$$\mathbf{j}(t) = j'_i(t) + j''_i(t) . \quad (2)$$

Зависимости компонент узловых нагрузок рассматриваются в виде произведений $p_i(t) = p_i f_i^p(t)$, $q_i(t) = q_i f_i^q(t)$, $j'_i(t) = j'_i f_i^{j'}(t)$, $j''_i(t) = j''_i f_i^{j''}(t)$ средних значений активных p_i , реактивных q_i мощностей, действительной j'_i и мнимой j''_i составляющих узловых токов и соответствующих функций $f_i^p(t)$, $f_i^q(t)$, $f_i^{j'}(t)$, $f_i^{j''}(t)$, ($i = \overline{1, n}$, n – число независимых узлов электрической системы) математические ожидания, каждой из которых за период времени T равны единице.

Технические системы, в том числе электроэнергетическая, работают по определенному ритму, в котором внешнее и внутреннее ее состояние во многом повторяется через определенные промежутки времени. Используя наблюдение работы системы в момент времени t , можно предсказать ее работу в момент времени $t+d$, то есть ожидаемое в перспективе состояние. Подобные задачи можно решать с использованием элементов искусственного интеллекта, таких как Multiple layer perceptron–MLP[7] или многослойных нейронных сетей. Разработка нейронной сети зависит от типа задачи и ее сложности. Под конкретную задачу (например, прогноз среднего) разрабатывают необходимую архитектуру нейронной сети со всеми ее атрибутами. Нейронная сеть представляет собой математическую модель особой конструкции, под которой понимается ее определенная многослойная архитектура и способы ее обучения для решения задач.

Прежде чем использовать сеть для получения результатов, допустим прогнозирования функций времени, необходимо ее обучить. Для этого подготавливают определенные данные, с помощью которых необходимо обучить нейронную сеть, разделяя их на две группы: обучающую и тестирующую. Для целей прогнозирования берутся выборки данных ретроспективного характера и некоторых внешних эффектов. Рассматривались несколько вариаций данных. Например, данные почасовых мощностей графиков текущих суток, данные почасовых графиков текущих суток и предыдущих, данные почасовых графиков текущих суток и двух предыдущих суток. Все исходные данные были нормированы с учетом выбора функции активации. Входы сети синапсами соединяются с первым скрытым слоем, первый скрытый слой своими аксонами соединяется с синапсами следующего скрытого слоя, и т.д., последний скрытый слой с выходом сети. Все связи инициализировались весовыми коэффициентами случайным образом в интервале $\pm 1,0$, или используя генератор случайных чисел, распределенных в некоторой окрестности чисел, например, $[\pm 1,0]$ или $[+1,-1]$. Процесс обучения представляет итерационный характер. Каждая итерация на-

зывается эпохой, состоящей, в данной разработке, из двух этапов. Первый этап предназначен для развития вычислительного процесса от входа к выходу сети (эта часть алгоритма называется прямым функционированием сети) с выполнением соответствующих операций.

Входные сигналы скрытого слоя обрабатывались активационной сигмоидной функцией [7]:

$$\varphi(f_v^{sk}) = \frac{1}{1 + \exp(-f_v^{sk})}, \quad (1)$$

где sk – номер слоя нейронов; v – номер нейрона в соответствующем слое. После обработки сигналы предыдущего слоя передавались как входные сигналы для следующего слоя сети. Важным свойством функции (1) является ее дифференцируемость, производная которой имеет следующий вид:

$$\begin{aligned} f'(y_v^{sk}) &= \frac{\exp(-y_v^{sk})}{(1 + \exp(-y_v^{sk}))} = \frac{1}{1 + \exp(-y_v^{sk})} \cdot \left[1 - \frac{1}{1 + \exp(-y_v^{sk})} \right] = \\ &= f(y_v^{sk}) \cdot [1 - f(y_v^{sk})]. \end{aligned} \quad (2)$$

На выходе сети проверяется правильность работы сети. Если ошибка будет больше заданной при обучении сети на обучающей выборке данных, то для решаемой задачи применялся алгоритм Backpropagation algorithm (процедура этой части алгоритма называется обратным функционированием). При втором запуске сети для того же примера привело к ошибке равной:

$$err == 0,034. \quad (3)$$

Вторая итерация обучения сети дала снижение ошибки на 0,004. На сотой итерации ошибка составляла $1,763 \cdot 10^{-3}$, на тысячной $-1,333 \cdot 10^{-4}$, на десяти тысячной $-1,072 \cdot 10^{-5}$, на стотысячной $-9,028 \cdot 10^{-7}$.

Тестирующий пример входных данных показал адекватность модели нейронной сети получением максимально близкого желаемого результата. Также были исследованы результаты работы сети с другими активационными функциями в режиме обучения. Результаты получены следующие: для функции $f(x) = th(x)$: на первой итерации ошибка составляла 0,037, на второй – 0,034, на сотой – $1,677 \cdot 10^{-3}$, на тысячной $-1,301 \cdot 10^{-4}$, на десяти тысячной $-1,065 \cdot 10^{-5}$, на стотысячной $-9,061 \cdot 10^{-7}$; для функции $f(x) = e^x / (1 + e^x)$: на первой итерации ошибка составляла 0,038, на второй – 0,034, на сотой – $1,763 \cdot 10^{-3}$, на тысячной $-1,333 \cdot 10^{-4}$, на десяти тысячной $-1,072 \cdot 10^{-5}$, на стотысячной $-9,028 \cdot 10^{-7}$; для функции $f(x) = 1 / (1 + x^2)$: на

первой итерации ошибка составляла 0,034, на второй – 0,033, на сотой – $3,152 \cdot 10^{-3}$, на тысячной – $1,608 \cdot 10^{-4}$, на десятитысячной – $1,075 \cdot 10^{-7}$, на стотысячной – $8,31 \cdot 10^{-7}$; для функции $f(x) = e^{-x^2}$: на первой итерации ошибка составляла 0,036, на второй – 0,035, на сотой – $3,137 \cdot 10^{-3}$, на тысячной – $1,588 \cdot 10^{-4}$, на десятитысячной – $1,065 \cdot 10^{-7}$, на стотысячной – $8,243 \cdot 10^{-7}$.

Пример, проиллюстрированный выше, далее развит для прогноза временных функций, с использованием режимных данных за прошедшие с G по G-3 годы для конкретных узлов региональной электрической сети. Анализ погрешностей результатов среднего суточного прогноза для рабочих суток в разрезе недели по данным указанных лет, варьировался от 3,9 до 2,8 % и, примерно, от 0,4 % до 0,6 % больше для нерабочих дней. При прогнозировании среднесуточной нагрузки узлов погрешность не превышала 1,63 % с использованием алгоритма обратного распространения для минимизации ошибки совместно с коэффициентом обучения сети. Проход осуществляется в противоположную сторону до первого скрытого слоя с выполнением корректирующих действий. Так как нейронная сеть обрабатывает только числовые данные, то исходные данные предварительно подвергались преобработке, для того, чтобы каждый элемент входного вектора принадлежал отрезку [0; 1] или [-1;1] в зависимости от используемой функции активации. Нейроны скрытого слоя, связанного с входом, получают комбинированные сигналы, которые моделируются следующим уравнением, записанным в общем виде:

$$ner_j^k = \sum_{j=1}^n w_{ji}^k pow_i, \quad (4)$$

где w_{ji}^k – весовые коэффициенты связей нейронов с ячейками входных сигналов сети; $k = \overline{1, sl}$, sl – количество скрытых слоев сети; $j = \overline{1, m}$, m – число нейронов в скрытом слое; $pow(i)$ – сигналы входа, $i = \overline{1, n}$ – количество ячеек ввода сети. К этим сигналам добавляются сигналы $ec^k(cm)$ источников смещения: $nc^k(cm) = wc^k(cm) \cdot ec^k(cm)$, $cm = \overline{1, kc}$, kc – количество связей с k слоем сети. Комбинированные сигналы слоя активируются с помощью специальных функций, например, $f(x) = 1/(1 + e^{(-x)})$. После прямого прохода сигналов по сети проверяется ее реакция на ошибку. Ошибка работы сети проверяется согласно методу наименьших квадратов по выражению $err = 0,5(out_{ut} - out_1)^2$. Правильная реакция сети задается параметром o_{ut} . Реальное состояние выхода сети – out_1 . Если результат не удовлетворяет поставленной задаче, то для уточнения или дальнейшего

обучения нейронной сети применяют специальные приемы, например, алгоритм Backpropagation algorithm – обратного распространения ошибки. Функции данного алгоритма будут представлять обратный ход текущей эпохи [7].

Для разработанной нейронной сети (подробности не приводятся) был запущен пример для прогнозирования среднего некоторой функции времени за период T . Реальное значение выходного сигнала рассчитанного сетью – $out_1 = 0,725$. Правильная реакция нейронной сети на входной сигнал задана $o_{ut} = 1$. Ошибка сети составила $err = 0,038$. Параметры сети требуют корректировки, что и осуществляет разработанный алгоритм.

Достоинство предложенного подхода заключается в том, что при моделировании функций времени громоздкие методы указанные выше, заменены моделями, использующими элементы искусственного интеллекта, свободных от трудоемких вычислений, и теория о которых последнее время активно развивается.

Погрешность в расчетах прогноза потокораспределения электроэнергии, потерь мощности и энергии, а также и в других задачах, например, определения мест повреждений на линиях электропередач при ликвидации аварийных ситуаций вносят и параметры схем замещения воздушных линий электрических передач:

- погонные активное и реактивное сопротивления, Ом/км;
- погонные активная и реактивная проводимости (для линий длиной более 300 км), $1/(\text{Ом} \cdot \text{км})$. Градиент изменения указанных параметров зависит от сложных вариаций метеорологических условий (например, температуры окружающей среды, объемов осадков, механических напряженностей от скорости ветра и др.), типа дня недели и характера потребления нагрузки. Поэтому традиционный подход для расчета параметров схем замещения на основе погонных характеристик с использованием справочников для поставленной задачи сопровождается существенной погрешностью [8] при определении потерь мощности и энергии. Более точный учет параметров схем замещения решается с привлечением аппарата искусственных нейронных сетей [7]. Вопрос уточнения параметров и уменьшения погрешности решался на базе многослойной сети. В качестве активационной функции использовалась (2).

Обучение сети проводилось с помощью алгоритма обратного распространения ошибок. Выполнение алгоритма производилось, начиная со случайной генерации весов многослойной сети. Во время продвижения по сети от входа к выходу вперед рассчитываются комбинированные весовые суммы входных сигналов для текущего скрытого слоя нейронов и перевод данных сигналов к следующему слою с помощью обработки их функцией активации указанной выше. Для элементов выхода рассчитывается совокупный вводный и выводной сигналы. Начиная с выхода, выполняется об-

ратное движение через нейроны скрытых слоев, предварительно вычислив значение ошибки, сравнением реальных и целевых величин исследуемых переменных на выходе. Для коррекции весов в сети на обратном ходе используется значение среднеквадратичной ошибки для указанных переменных. Процесс обучения носит циклический характер в виде эпох, в ходе которых минимизируется ошибка для заданной переменной. После завершения обучения весовые коэффициенты фиксируются и проверяется работа сети на тестовых данных. Если требуется учет короны, то можно обратиться к [9]. Охлаждение проводов воздушных линий и изолированных жил кабелей имеет разную физическую природу и для обеспечения устойчивой и надежной работы питающих и распределительных сетей, регламентируемой «Правилами устройств электроустановок», для кабельных линий следует вводить дополнительные признаки, связанные с конструкцией, определяющих условия прокладки и свойства грунта, значения температуры поверхности земли (или перепада температур между жилой кабеля и поверхностью земли) при монтаже кабелей в траншеях. В процессе обучения учитывается разнохарактерность режимов отдельных нагрузок введением коэффициента относительного времени продолжительности включения параметром ПВ.

Проведенные исследования влияния климатических условий на режимные параметры показали, что наибольшее влияние на точность прогноза оказывает температурный фактор данной местности. Особенно при аномальных явлениях. Стабилизация факторов может иметь продолжительность до нескольких суток (чаще всего двое-трое суток по метеоданным для рассматриваемого материкового региона). Нейронная многослойная сеть, алгоритм работы которой был проиллюстрирован выше, имела входы, на которых не инициировался сигнал. При исследовании влияния метеофактора был инициирован сигнал, приведенный к выше описанным условиям. На первой эпохе работы алгоритма ошибка была $err = 0,864$, на тысячной итерации $err = 1,784 \cdot 10^{-4}$. Результаты превышают точность коррекции прогноза, так называемым интуитивным способом, на порядки. Исследуются влияния и других метеофакторов. Надо отметить, что при исключении из узловых режимных параметров составляющих, график нагрузки которых за сутки изменялся незначительно (например, непрерывный характер работы предприятия), адаптивность моделирования на первой итерации по погрешности была близка к выше приведенной.

В работе предложен подход на базе применения элементов искусственного интеллекта для краткосрочного прогнозирования режимных и схемных параметров, не требующий разработки сложных математических моделей и достаточно эффективный как для задач проектирования так и для анализа электроэнергетических процессов.

Библиографический список

1. Герасименко, А.А. Передача и распределение электрической энергии: Учебное пособие / А.А. Герасименко, В.Т. Федин. – Ростов-н/Д.: Феникс; Красноярск: Издательские проекты, 2006. – 720 с.
2. Гамм, А.З. Статистические методы оценивания состояния электроэнергетических систем / А.З. Гамм. – М.: Наука, 1967. – 220 с.
3. Иберла, К. Факторный анализ / К. Иберла. – М.: Статистика, 1980. – 398 с.
4. Лоэв, М. Теория вероятностей / М. Лоэв. – М.: Ил. 1962.
5. Фокин, Ю.А. Экспериментальное исследование вероятностно-статистических характеристик нагрузок в энергосберегающей системе / Ю.А. Фокин, И.С. Пономоренко, В.С. Павликов // Электричество. – 1983. – № 9. – С. 9–15.
6. Фомин, Н.И. Метод определения потерь электроэнергии в питающей сети для задачи комплексной оптимизации схем распределительных электрических сетей / Н.И. Фомин, В.С. Павлюков // Электробезопасность. – 1999. – № 3–4. – С. 3–7.
7. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. – М.: ИД Вильямс, 2006. – 1104 с.
8. Потери электроэнергии в электрических сетях энергосистем / В.Э. Воротницкий, Ю.С. Железко, В.Н. Казанцев и др.; под ред. В.Н. Казанцева. – М.: Энергоатомиздат, 1983. – 368 с.
9. Справочник по проектированию электрических сетей / И.Г. Карапетян, Д.Л. Файбисович, И.М. Шапиро; под ред. Д.Л. Файбисовича. – М.: ЭНАС, 2005. – 313 с.

[К содержанию](#)