

ИДЕНТИФИКАЦИЯ И ПРОГНОЗИРОВАНИЕ НАГРУЗОК ЭЛЕКТРОПРИВОДА С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ WAVELET- АНАЛИЗА

Прогнозирование нагрузки необходимо для решения широкого спектра задач энергоэффективного управления электроприводами. В число факторов, осложняющих прогнозирование, входит отсутствие непосредственного доступа к данным о качественных изменениях в оцениваемой функции.

Наиболее перспективным является разработка интеллектуальных моделей прогнозирования. Основу таких моделей составляют искусственные нейронные сети (ИНС) благодаря их способности аппроксимировать с любой заданной точностью произвольную непрерывную последовательность.

У большинства реальных объектов можно выделить их основные составляющие:

1. детерминированная составляющая, которая в принципе подлежит точному предсказанию;
2. вероятностная составляющая, которую можно предсказать с заданной степенью вероятности;
3. случайная составляющая, которую невозможно ни учесть, ни предусмотреть.

Поэтому при оценке объекта исследования нужно выбирать такие признаки, для которых возможно уменьшение случайной составляющей, оценивание вероятностной составляющей и максимальное увеличение детерминированной части. Предлагаемый далее подход позволяет разрешить проблему путем введения в модель прогнозирования предварительной фильтрации данных с целью выделения аддитивных составляющих в динамике временного ряда и прогнозирования каждой такой составляющей в отдельности.

Для построения модели динамики нагрузки часто используют вейвлет-преобразование. Одна из основополагающих идей вейвлет-преобразования сигналов заключается в разложении сигнала на две составляющие – грубую (аппроксимирующую cA) и уточняющую (детализирующую cD) – с

последующим их дроблением с целью изменения уровня декомпозиции сигнала. В результате вейвлет-фильтрации получаются некоторые временные последовательности, в сумме дающие исходный временной ряд.

Результаты разложения удобно изображать графически в виде дерева, изображенного на рис. 1.

$$\begin{array}{ccccccc}
 s & \rightarrow & cA_1 & \rightarrow & cA_2 & \rightarrow & \dots & \rightarrow & cA_N \\
 \downarrow & & \downarrow & & \downarrow & & & & \downarrow \\
 cD_1 & & cD_2 & & \dots & & & & cD_N
 \end{array}$$

Рис. 1. Дерево разложения

Полученные при разложении аппроксимирующие коэффициенты представляют сглаженный сигнал, а детализирующие коэффициенты описывают колебания. Следовательно, шумовая компонента больше отражается в детализирующих коэффициентах. Поэтому при удалении шума обрабатывают обычно детализирующие коэффициенты. Удаление шума реализуется с помощью метода пороговой обработки коэффициентов (трешолдинг) и заключается в обнулении значений коэффициентов, меньших некоторого порогового значения.

Обучение ИНС и прогнозирование осуществляется для каждого уровня разложения в отдельности. Задача прогнозирования в общем случае сводится к получению оценки будущих значений упорядоченных во времени данных на основе анализа уже имеющихся. Прогнозируемой величиной являются значения временного ряда на интервале $[T(n+1), T(n+f)]$, где $T(n)$ – текущий момент времени, а f – интервал прогнозирования.

Моделирующий комплекс состоит из программных файлов, выполненных в системе MATLAB. Для решения задачи использовались два пакета расширения системы. Первый из них Wavelet Toolbox. Было выбрано пакетное вейвлет-преобразование, которое является обобщением вейвлет-преобразования и предлагает более широкий спектр функций анализа сигналов и позволяет выбрать оптимальное разложение за счет свойства адаптивности к особенностям сигнала.

Второй пакет расширения – это Neural Network Toolbox, который помогает пользователю проектировать сети любой конфигурации и расширять область их использования.

Рассмотрим некоторый график нагрузки (рис. 2). Видно, что кривая момента имеет трендовую, циклическую и случайную составляющие.




Рис. 2. График исследуемой нагрузки

Пусть данная кривая имеет следующее аналитическое описание:

$$y = a_1 \cdot t^2 + 1 + a_2 \cdot \sin\left(\frac{3 \cdot t}{\pi}\right) + a_3 \cdot \sin\left(\frac{9 \cdot t}{\pi}\right) + \\ + a_4 \cdot \sin\left(15 \cdot \frac{t}{\pi}\right) + a_5 \cdot \sin\left(30 \cdot \frac{t}{\pi}\right),$$

где первые два члена выражения соответствуют трендовой составляющей, а остальные формируют циклическую составляющую. К данной кривой был добавлен белый шум, который относится к случайной составляющей.

Для выделения тренда принимается глубина разложения $M = 6$, а тип вейвлета – Добеши 6. После разложения производится очистка от шума, путем вычисления шума на каждом уровне и вычисления его глобального порога. Очистка шума обнуляет высокочастотные составляющие. Далее для выделения циклической составляющей из очищенного восстановленного сигнала вычисляется полученная трендовая составляющая. Для улучшения однородности формы циклической кривой производится ее разложение при $M = 3$, используя биортогональный вейвлет порядка 5.5, после чего производится обнуление детализирующих коэффициентов. Тот же результат можно получить, используя функции выбора вейвлет-коэффициентов сигнала.

На рисунке 3 изображены трендовая и циклическая составляющие исходного сигнала, полученные при разложении.




Рис. 3. Разложение исходного сигнала на составляющие:
1 – трендовая, 2 – циклическая

Далее составляющие очищенного сигнала используются для прогнозирования с помощью соответствующим им ИНС. В качестве ИНС была выбрана частично-рекуррентная сеть Эльмана, которая обладает обратной связью из скрытого слоя к входному. Количество нейронов в скрытом слое равно 5. Этот тип сетей успешно используется для предсказания временных рядов, поскольку именно рекуррентная сеть выучивает закономерности в последовательности величин. Прогнозирование осуществляется по 10 предшествующим значениям на один шаг вперед. В качестве критерия качества обучения была выбрана среднеквадратичная ошибка, равная 10^{-11} . Для проверки качества обучения данные были поделены на 3 множества: обучающее, проверочное и тестовое.

На рисунке 4, 5 приведены результаты прогнозирования на тестовом множестве на один шаг вперед по каждой составляющей, которые в свою очередь сравниваются с исходными составляющими, построенными по аналитическому описанию и составляющими, полученными после вейвлет-разложения. На рисунке 6 показаны графики сумм составляющих и общей исходной кривой.

Средняя абсолютная ошибка прогнозирования по отношению к исходной трендовой составляющей составила 0,44%, по отношению к исходной циклической составляющей – 1,68 % и к зашумленному исходному сигналу – 1,77 %. Дальнейшее качество прогноза вероятно возможно улучшить с

помощью более детального разложения сигнала, подбора оптимальной архитектуры ИНС и увеличения количества данных в ее входном векторе.




Рис. 4. 1 – исходная трендовая составляющая , 2—трендовая составляющая, полученная путем разложения, 3 – спрогнозированная трендовая составляющая на один шаг вперед




Рис. 5. 1 – исходная циклическая составляющая , 2—циклическая составляющая, полученная путем разложения, 3 – спрогнозированная циклическая составляющая на один шаг вперед




Рис. 6. 1 – исходная кривая с шумом , 2 – кривая, полученная восстановлением после разложения и очистки от шума, 3 – спрогнозированная кривая на данных кривой, полученной после восстановления

Выводы

Проведенные исследования предполагают возможность использования предложенного метода относительно реальных кривых нагрузок электропривода, в частности, где предполагается возникновение разнообразия условий ее формирования, например в электроприводе штанговой глубинно-насосной установки. Следующей задачей исследования является расчет оптимального шага прогнозирования и решение задачи многошагового прогнозирования с горизонтом предсказания равным периоду циклической составляющей.

Литература

1. *Круг П.Г.* Нейронные сети и нейрокомпьютеры: Учебное пособие по курсу «Микропроцессоры». – М.: Издательство МЭИ, 2002. – 176 с.
2. *Медведев В.С., Потемкин В.Г.* Нейронные сети. MATLAB 6/ Под общ.ред. к.т.н. В.Г. Потемкина. – М.: Диалог-МИФИ, 2002.- 496 с. – (Пакеты прикладных программ; Кн.4).
3. *Павел Панфилов.* Нейросетевые прогнозы в техническом анализе. Журнал «Современный трейдинг», №3, 2001.
4. *Зюзов А.М., Нестеров К.Е.* Исследование энергетических показателей электроприводов штанговых глубинно-насосных установок методами математического моделирования. Электротехника №9, 2004.