

УДК 004.032.26

И.П. Плисс, С.В. Попов, Т.В. Рыбальченко

**ПРОГНОЗИРОВАНИЕ УЗЛОВЫХ НАГРУЗОК
ЭЛЕКТРОЭНЕРГЕТИЧЕСКОЙ СИСТЕМЫ НА ОСНОВЕ
НЕЙРОННОЙ СЕТИ ВСТРЕЧНОГО РАСПРОСТРАНЕНИЯ**

Введение и постановка задачи

Задача оперативного и краткосрочного прогнозирования электрических нагрузок последние тридцать лет является предметом интенсивных исследований, а ее рассмотрению посвящен практически необозримый объем публикаций во всем мире. Последние же годы особое внимание уделяется нейросетевому подходу [1, 2], который оказался особенно эффективен в условиях влияния неконтролируемых факторов, наличия нелинейностей и различного рода неопределенностей.

Подавляющее большинство публикаций при этом связано с анализом, моделированием и прогнозированием суммарной нагрузки рассматриваемой электроэнергетической системы, хотя не менее важной является задача прогнозирования нагрузок в узлах системы, которые определяются нагрузками множества потребителей, подключенных к этому узлу сети, и потерями мощности (включая «потери на корону») при передаче электроэнергии.

В принципе, при наличии достаточной ретроспективной информации о нагрузках в узлах, для прогнозирования можно использовать те же нейросетевые предикторы, что и для суммарной нагрузки. Здесь, однако, возникает проблема, состоящая в том, что вследствие влияния многочисленных возмущений и неопределенностей, прогноз нагрузки по энергосистеме в целом не совпадает с суммой прогнозных значений узловых нагрузок. Традиционно эта проблема «обходится» с помощью пропорционального распределения суммарной нагрузки и соответствующего ей прогноза между узлами. В этом случае, правда, приходится постоянно контролировать коэффициенты пропорциональности, а поскольку достаточно часто их рассчитывать весьма затруднительно, то точность прогнозирования существенно ухудшается.

Весьма изящно и эффективно эта задача была решена в [3] на основе инверсии многослойной нейронной сети прямого распространения. Суть данного подхода, вкратце, состоит в следующем: пусть имеются обучающие выборки по суммарной $y(1)$, $y(2)$, ..., $y(k)$, ... и узловым $y_q(1)$, $y_q(2)$, ..., $y_q(k)$, ..., $q = 1, 2, \dots, Q$ нагрузкам энергосистемы, где k имеет смысл текущего дискретного времени, Q – количество узлов в анализируемой системе. В качестве модели энергосистемы принимается трехслойный персептрон с Q входами и одним выходом, обучение которого производится на основе стандартного обратного распространения ошибки путем минимизации локальной целевой функции

$$E(k) = \frac{1}{2} e^2(k) = \frac{1}{2} (y(k) - F(W, y_1(k), y_2(k), \dots, y_Q(k)))^2, \quad (1)$$

где $F(\cdot)$ – нелинейный оператор, реализуемый нейромоделью, W – множество настраиваемых синаптических весов, подлежащих определению. В результате обучения по выборке из N наблюдений получаем нелинейную модель, связывающую узловые и суммарную нагрузки выражением

$$\hat{y}(k) = F(W, y_1(k), y_2(k), \dots, y_Q(k)), \quad (2)$$

где $\hat{y}(k)$ – оценка фактического сигнала $y(k)$, полученная с помощью нейромодели-эмулатора.

Полагается также, что для моментов времени $k > N$ данных по узловым нагрузкам нет, а прогноз суммарной нагрузки $\hat{y}(k | k > N)$ реализуется с помощью некоторого другого предиктора, не использующего информацию о состоянии узлов. Задача инверсии нейросети состоит в нахождении оценок входных сигналов $\hat{y}_1(k | k > N)$, $\hat{y}_2(k | k > N)$, ..., $\hat{y}_Q(k | k > N)$ по информации о прогнозе $\hat{y}(k | k > N)$.

Несмотря на достаточно высокое качество получаемых прогнозов, данному подходу присущи все недостатки систем, построенных на основе многослойных персепtronов. Это, прежде всего, низкая скорость обучения и необходимость использования многократного прохода по эпохам, численная громоздкость, необходимость наличия достаточно больших по объему обучающих выборок, возможность переобучения и паралича сети, в общем, все то, что привело к поиску

иных нейроархитектур и алгоритмов обучения, лишенных недостатков персепtronов, однако обладающих необходимыми аппроксимирующими свойствами.

Нейронная сеть встречного распространения

Наиболее приемлемой для решения рассматриваемой здесь задачи, на наш взгляд, является гетерогенная нейронная сеть встречного распространения, предложенная Р. Хехт-Нильсеном [4-6] в качестве альтернативы многослойным сетям с прямой передачей информации, обучаемым на основе обратного распространения ошибки. Эта сеть сокращает время обучения, как минимум, на порядок по сравнению с многослойным персепtronом [7, 8], хотя незначительно проигрывает ему по точности. Исходно нейросети встречного распространения были разработаны для аппроксимации по экспериментальным данным некоторого отображения «вход–выход», задаваемого оператором F , и нахождения обратного оператора F^{-1} , хотя более корректно было бы говорить о псевдообратном операторе F^+ [9]. В общем случае сеть встречного распространения представляет собой гибрид самоорганизующейся карты Т. Кохонена и звезд С. Гроссберга и соответственно сочетает в себе конкурентное самообучение с контролируемым обучением с учителем.

К настоящему времени известен ряд вариантов сетей встречного распространения, наиболее приемлемым из которых для обратного моделирования является двунаправленная (полная) сеть встречного распространения, архитектура которой для решаемой нами задачи приведена на рис 1.

Данная сеть имеет $Q+1$ входов и столько же выходов, которые могут быть разбиты на две секции (показаны пунктиром), и фактически представляет собой комбинацию двух односторонних сетей с общим слоем Кохонена. Уникальным же свойством двунаправленной сети встречного распространения является возможность восстановления не только $F: y_{NOD} = (y_1, y_2, \dots, y_Q)^T \rightarrow y$, но и псевдообратного отображения $F^+: y \rightarrow y_{NOD}$, что, собственно, и требуется в рассматриваемой нами задаче.

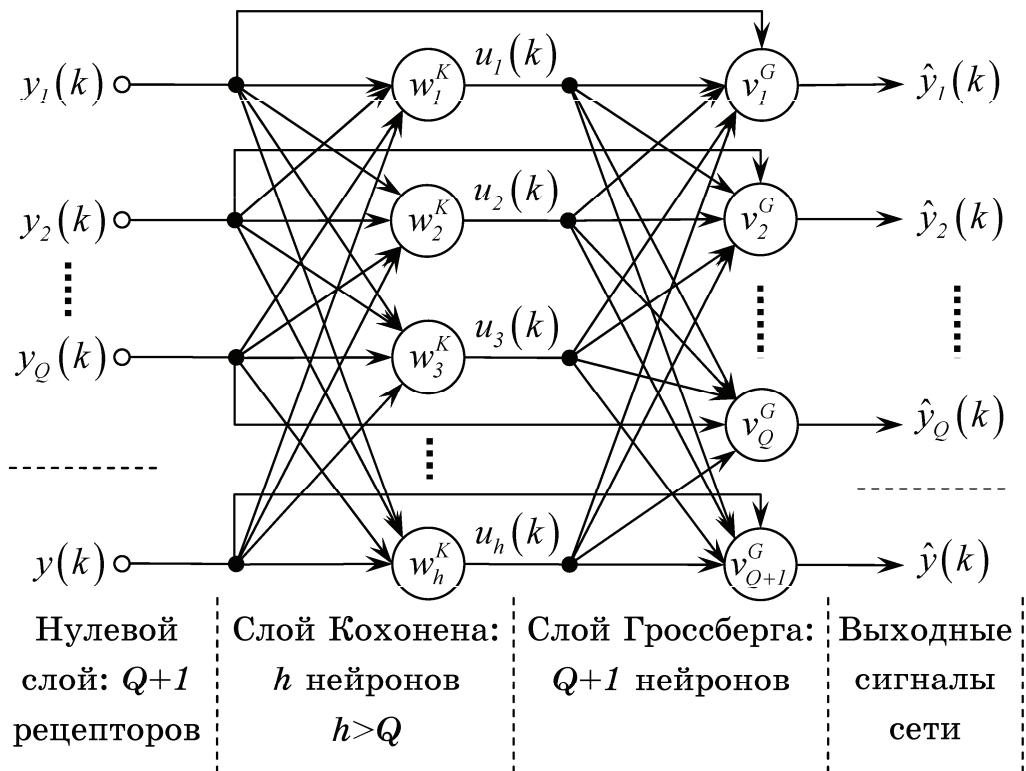


Рисунок 1 – Двунаправленная нейронная сеть встречного распространения в задаче прогнозирования узловых нагрузок

Обучение нейронной сети встречного распространения

Обучение нейронной сети встречного распространения происходит в два этапа. На первом этапе по данным выборки $y_{NOD}(1), y(1); y_{NOD}(2), y(2); \dots; y_{NOD}(N), y(N)$ в слое Кохонена происходит процесс самоорганизации, в результате которого входное пространство разбивается на h кластеров, при этом, как правило, реализуется стратегия самообучения типа «победитель получает все». На втором этапе по выборке данных в соответствии с правилом обучения выходной звезды [7] настраивается выходной слой, т.е. фактически происходит уточнение только тех весов, которые связывают нейрон Гроссберга с нейроном-победителем слоя Кохонена.

В результате, если на обученную сеть подать сигнал, не принадлежащий обучающей выборке, то сначала в слое Кохонена будет установлена его принадлежность определенному кластеру, после чего нейрон-победитель «возбудит» звезду Гроссберга так, что на выходе появится сигнал, соответствующий координатам прототипа (центроида) этого кластера.

Обученная двунаправленная сеть встречного распространения может работать в нескольких режимах одновременно: восстановление

прямого оператора $F : y_{NOD} \rightarrow y$, восстановление псевдообратного оператора $F^+ : y \rightarrow y_{NOD}$, а также как авто-, так и гетероассоциативные нейросетевые памяти.

Заключение

Решена задача прямого и обратного моделирования узловых и суммарной нагрузок электроэнергетической системы на основе нейросетевого подхода. В основу решения положено использование искусственной нейронной сети встречного распространения, являющейся комбинацией самоорганизующейся карты и выходных звезд. Численная простота и высокая скорость обучения при решении рассматриваемой задачи обеспечивают данному классу нейросетей преимущество перед традиционными многослойными персепtronами.

ЛИТЕРАТУРА

1. Hippert H.S., Pedreira C.E., Souza R.C. Neural networks for short-term load forecasting: a review and evaluation // IEEE Trans. Power Syst. – 2001. – 16. – N. 1. – P. 44–55.
2. Haque M.T., Kashtiban A.M. Application of neural networks in power systems; a review // Proc. World Academy of Science, Engineering and Technology. – 2005. – 6. – P. 53-57.
3. Шумилова Г.П., Готман Н.Э., Старцева Т.Б. Прогнозирование нагрузки узлов электроэнергетической системы с использованием инверсии искусственной нейронной сети // Электричество. – 2007. – N. 6. – С. 7-13.
4. Hecht-Nielsen R. Counterpropagation networks // Applied Optics. – 1987. – 26. – P. 4979-4984.
5. Hecht-Nielsen R. Counterpropagation networks // Proc. IEEE 1st Conf. on Neural Networks. – San Diego, CA, 1987. – 2. – P. 19-32.
6. Hecht-Nielsen R. Application of counterpropagation networks // Neural Networks. – 1988. – No. 1. – P. 131-139.
7. Haykin S. Neural Networks: A Comprehensive Foundation. – New Jersey: Prentice Hall, 1999. – 842 p.
8. Rojas R. Neural Networks. A Systematic Introduction. – Berlin: Springer-Verlag, 1996. – 502 p.
9. Алберт А. Регрессия, псевдоинверсия и рекуррентное оценивание. – М.: Наука, 1977. – 227 с.

Получено 11.03.2008 г.