

А.Н. Мороз, Н.М. Черемисин, В.В. Черкашина, А.В. Холод

НЕЙРО-СЕТЕВОЕ МОДЕЛИРОВАНИЕ В ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ РЕЖИМОВ РАБОТЫ ЭЛЕКТРИЧЕСКИХ СЕТЕЙ

У статті сформована нейро-фаззі мережа з урахуванням температурного моніторингу повітряної лінії. Відмінною особливістю, запропонованої мережі, є можливість обробки інформації, яку задано в різних шкалах вимірювання, і висока швидкодія для прогнозування режимів роботи електричної мережі. Бібл. 10, рис. 1.

Ключові слова: електрична мережа, нейромережа, нейро-фаззі мережа, температурний моніторинг повітряної лінії, прогнозування режимів роботи електричної мережі.

В статье сформирована нейро-фаззи сеть с учетом температурного мониторинга воздушной линии. Отличительной особенностью, предложенной сети, являются возможность обработки информации, заданной в разных шкалах измерения, и высокое быстродействие для прогнозирования режимов работы электрической сети. Библ. 10, рис. 1.

Ключевые слова: электрическая сеть, нейросеть, нейро-фаззи сеть, температурный мониторинг воздушной линии, прогнозирование режимов работы электрической сети.

Введение. Важным фактором, влияющим на режим работы электрических сетей (ЭС), является возрастание нагрузки и старение электросетевого оборудования, что характерно и для большинства промышленно развитых стран мира. Пропускная способность ЭС с течением времени снижается за счёт разветвлённости и усложнения конфигурации сети. Данный факт приводит к увеличению нагрузки воздушных линий (ВЛ), как магистральных, так и распределительных. Отсутствие информации о реальных параметрах ВЛ заставляет использовать приближенные к реальности расчеты допустимых режимов работы сети. В большинстве случаев они не соответствуют действительному состоянию режимов работы сетей, что ведет к значительному уменьшению транзитных потоков мощности и перегрузке элементов ЭС.

Для устранения недопустимой перегрузки элементов ЭС предусмотрены средства противоаварийной автоматики. Устройства автоматического ограничения перегрузки ВЛ предназначены для противоаварийного управления, включающего в себя: изменение конфигурации ЭС, отключение части потребителей электрической энергии, категория надёжности которых допускает перерыв электроснабжения, отключение ВЛ.

Основное требование к таким устройствам – селективность действия, т.е. автоматика должна действовать только в недопустимых режимах работы, не ограничивая пропускную способность ЭС. Спрогнозировать пропускную способность ЭС возможно на основе реальной и накопленной информации о ее параметрах.

Анализ последних публикаций. Как показал анализ научных информационных источников, задачи прогнозирования потребления электроэнергии решаются практически всеми организациями, связанными с производством и её распределением. Для решения этих задач используются как традиционные методы прогнозирования (регрессионный, корреляционный, спектральный анализы, подход Бокса-Дженкинса, экспоненциальное сглаживание, адаптивные предикторы и т.п.), так и более «продвинутые» подходы, основанные на интеллектуальном анализе данных – Data Mining [1].

Преимущество традиционных подходов состоит в простоте применения прогнозирующих моделей и

наличии доступного программного обеспечения. Однако, в силу того, что связи между потреблением электроэнергии и влияющими на него факторами зачастую носят сложный нелинейный характер, в рамках указанных подходов получить приемлемые по точности прогнозы удается далеко не всегда [2].

Существенные трудности при использовании систем вычислительного интеллекта возникают в случае, когда часть обрабатываемой информации задана не в количественной, а в порядковой или номинальной шкалах. Ставшие уже традиционными нейро- и нейро-фаззи сети плохо приспособлены к обработке информации вида «плохая, нормальная, хорошая погода», «сильный или слабый ветер», «облачно – туманно – морозно» и т.п. [3].

В связи с этим предлагается синтез прогнозирующей нейро-фаззи сети, способной к восприятию данных в разных шкалах и алгоритма ее обучения, обладающего высокой скоростью сходимости и способностью к обработке информации по мере ее поступления в реальном времени [4].

Эффективной альтернативой может служить подход, основанный на применении методов вычислительного интеллекта и, прежде всего, искусственных нейронных сетей и систем нечеткого вывода. Эффективность этих систем связана с их универсальными аппроксимирующими возможностями и способностью к обучению непосредственно в процессе прогнозирования.

На сегодня эти методы подтвердили свою эффективность при решении широкого круга задач, связанных с прогнозированием в электроэнергетике [5-7].

Методы прогнозирования электрической нагрузки ЭС, архитектура которых основанная на базе гибридных нейроподобных элементов с блоком оценивания точности, в значительной мере позволяет получить результаты максимально приближенные к реальным данным. Но учитывая значительное влияние условий окружающей среды (скорость и направление ветра, температура среды и т.д.) на пропускную способность ВЛ, существует необходимость в насыщении количественными и порядковыми переменными скрытого слоя, для более достоверного прогноза допустимого режима ЭС [7-9].

© А.Н. Мороз, Н.М. Черемисин, В.В. Черкашина, А.В. Холод

Система мониторинга параметров ВЛ станет инструментом измерения температуры провода, что позволит на основе ретроспективного анализа накопленной информации о параметрах ВЛ прогнозировать термическую стойкость линии и в результате проводить расчет допустимой нагрузки в реальном времени.

Цель статьи – сформировать нейро-фаззи сеть с учетом температурного мониторинга воздушной линии для прогнозирования режимов работы электрической сети.

Основные материалы исследования. Для прогнозирования допустимой нагрузки ВЛ предлагается применение архитектуры нейро-фаззи сети с учетом температурного мониторинга ВЛ.

Предлагаемая нейро-фаззи сеть имеет четырехслойную архитектуру с прямой передачей информации. Для создания полносвязной архитектуры сети на базе гибридных нейроподобных элементов с блоком оценивания точности выполнены два этапа процедур:

- первым этапом генерируется основная сеть (без блока оценивания точности);
- на втором этапе фиксируется архитектура и параметры сети, полученные в ходе выполнения первого этапа, и к ней добавляется блок оценивания точности, входными сигналами которого становятся все входные, внутренние и выходные сигналы основной сети, а также дополнительные входные сигналы (при необходимости).

С нулевого слоя информация поступает на первый скрытый слой задержек и фаззификации входных сигналов. В этом слое формируется предыстория прогнозируемого сигнала, а также функции принадлежности факторов, которые заданы в различных шкалах измерений. С выхода этого слоя информация в числовой форме поступает на второй и третий скрытые слои, которые сформированы из однотипных элементарных нейронов Розенблатта. Выходной слой образован единственным нейроном с нелинейной функцией активации, на выходе которого и формируется прогнозируемый сигнал [9, 10].

Добавление блока оценивания точности значительно расширяет эксплуатационные возможности сети за счет добавления к точечным аппроксимациям оценок их ожидаемой точности, что снижает уровень неопределенности в процессе дальнейшего принятия решений.

На вход первого скрытого слоя подается информация:

- количественные переменные:
 - текущее значение прогнозируемого сигнала $y(k)$ (здесь $k = 0, 1, 2, \dots, N$ имеет смысл текущего дискретного времени, N – длина выборки);
 - температура воздуха;
- порядковые переменные:
 - относительная влажность в форме «низкая – средняя – высокая»;
 - скорость ветра в форме «штиль – слабый – сильный – ураганный»;
 - облачность в форме «ясно – переменная – плотная»;
 - номер часа в сутках: 0, 1, 2, ..., 23;
 - день недели в форме «понедельник – вторник – ... – воскресенье»;

- номинальные переменные:

- тип дня в форме «рабочий – выходной – праздничный – региональный праздник – перенесенный выходной – перенесенный рабочий»;

- тип погоды в форме «без осадков – туман – дождь – снег».

Переменные предварительно кодируются в интервал $[0, 1]$ следующим образом:

$$\tilde{x}_l = \frac{\hat{x}_l - \hat{x}_{l\min}}{\hat{x}_{l\max} - \hat{x}_{l\min}}, \quad (1)$$

$$\hat{x}_l = \hat{x}_{l\max}\tilde{x}_l - \hat{x}_{l\min}(\tilde{x}_l - 1), \quad (2)$$

где \hat{x}_l – значение l -й входной переменной в исходной шкале измерений: МВт·ч, °С; \tilde{x}_l – кодированное значение l -й входной переменной; $\hat{x}_{l\min}$, $\hat{x}_{l\max}$ – минимальное и максимальное значение l -й входной переменной в исходной шкале.

Далее, в первом скрытом слое с помощью элементов задержки z^{-1} формируется предыстория прогнозируемого сигнала вида $y(k-1)$, $y(k-2)$, $y(k-24)$, $y(k-48)$, $y(k-168)$, $y(k-336)$, которая подается на второй скрытый слой в виде набора $x_1(k)$, $x_2(k)$, $x_3(k)$, $x_4(k)$, $x_5(k)$, $x_6(k)$, при этом в зависимости от горизонта упреждения могут использоваться и другие значения задержек, отличные от указанных выше [8-10].

Далее в этом же слое производится фаззификация сигналов температуры воздуха, номера часа в сутках, относительной влажности, скорости ветра, облачности и дня недели с помощью треугольных функций принадлежности, равномерно распределенных в интервале $[0, 1]$ и которые имеют вид:

$$\mu_{l1} = \frac{c_{l2} - \tilde{x}_l}{c_{l2}}, \quad \tilde{x}_l \in [0, c_{l2}], \quad (3)$$

$$\mu_{li} = \begin{cases} \frac{\tilde{x}_l - c_{l,i-1}}{c_{li} - c_{l,i-1}}, & \tilde{x}_l \in [c_{l,i-1}, c_{li}] \\ \frac{c_{l,i+1} - \tilde{x}_l}{c_{l,i+1} - c_{li}}, & \tilde{x}_l \in [c_{li}, c_{l,i+1}] \\ i = 2, \dots, p_l - 1, \end{cases} \quad (4)$$

$$\mu_{p_l i} = \frac{\tilde{x}_l - c_{l,p_l-1}}{1 - c_{l,p_l-1}}, \quad \tilde{x}_l \in [c_{l,p_l-1}, 1], \quad (5)$$

где c_{li} – расположение центра i -й функции принадлежности l -й переменной, p_l – количество функций принадлежности l -й переменной.

Архитектура прогнозирующей нейро-фаззи сети с учетом параметров провода ВЛ показана на рис. 1.

В результате обработки исходных данных в первом скрытом слое формируется набор выходных сигналов $o_1^{[1]}$, $o_2^{[1]}$, ..., $o_n^{[1]}$, которые далее подаются на второй скрытый слой в форме $(n+1) \times 1$ -вектора

$$x^{[2]} = (1, o_1^{[1]}, o_2^{[1]}, \dots, o_n^{[1]})^T, \quad (6)$$

где единичная компонента необходима для оценки смещения каждого из нейронов последующих слоев.




Рис. 1. Архитектура прогнозирующей многослойной нейро-фаззи сети

Второй скрытый слой предлагаемой нейро-фаззи сети содержит n однотипных нейронов с нелинейными сигмоидальными функциями активации $\psi_j^{[2]}$, $j = 1, 2, \dots, n$ и содержит $(n+1)$ настраиваемых синаптических весов $w_{ji}^{[2]}$. Выходной сигнал j -го нейрона второго скрытого слоя имеет вид

$$o_j^{[2]} = \psi_j^{[2]}(u_j^{[2]}) = \psi_j^{[2]} \left(\sum_{i=0}^n w_{ji}^{[2]} x_i^{[2]} \right), \quad (7)$$

где $w_{j0}^{[2]} \equiv \theta_j^{[2]}$ – уровень смещения j -го нейрона, а выходной сигнал слоя:

$$o^{[2]} = \Psi^{[2]}(W^{[2]} x^{[2]}), \quad (8)$$

где $o^{[2]} - (n \times 1)$ – векторный сигнал, передаваемый на третий скрытый слой в виде $x^{[3]} = (1, o^{[2]T})^T$, $\Psi^{[2]} = \text{diag}\{\psi_j^{[2]}\}$ – $(n \times n)$ – матричная активационная функция, $W^{[2]} - n \times (n+1)$ – матрица настраиваемых синаптических весов.

Третий скрытый слой содержит $2n+1$ нейронов и формирует сигналы вида

$$o_j^{[3]} = \psi_j^{[3]}(u_j^{[3]}) = \psi_j^{[3]} \left(\sum_{i=0}^n w_{ji}^{[3]} x_i^{[3]} \right), \quad (9)$$

$$o^{[3]} = \Psi^{[3]}(W^{[3]} x^{[3]}), \quad (10)$$

где $\Psi^{[3]} = \text{diag}\{\psi_j^{[3]}\}$ – $((2n+1) \times (2n+1))$ – матричная активационная функция, $W^{[3]} - ((2n+1) \times (n+1))$ – матрица настраиваемых синаптических весов, $o^{[3]} - ((2n+1) \times 1)$ – векторный сигнал, передаваемый на выходной слой в виде

$$x^{[4]} = (1, o^{[3]T})^T.$$

Выходной слой сети образован единственным нейроном, формирующим скалярный сигнал прогноза

$$\hat{y} = \psi^{[4]}(u^{[4]}) = \psi^{[4]} \left(\sum_{i=0}^{2n+1} w_i^{[4]} x_i^{[4]} \right) = \psi^{[4]}(w^{[4]T} x^{[4]}), \quad (11)$$

где $w^{[4]} - ((2n+2) \times 1)$ – вектор настраиваемых синаптических весов.

Объединяя выражения (9-11), передаточная функция сети в целом имеет вид:

$$\hat{y} = \psi^{[4]}(w^{[4]T} \Psi^{[3]}(W^{[3]} \Psi^{[2]}(W^{[2]} x^{[2]}))). \quad (12)$$

Предлагаемый в статье подход обеспечивает высокую точность прогнозирования в условиях изменчивости и стохастичности исходных данных для прогнозирования набора взаимосвязанных временных рядов, описывающих потребление электрической энергии в пределах нескольких областей одной территории, входящих в единую энергосистему.

Выводы. Сформирована нейро-фаззи сеть с учетом температурного мониторинга воздушной линии. Отличительной особенностью, предложенной сети, являются возможность обработки информации, заданной в разных шкалах измерения, и высокое быстродействие для прогнозирования режимов работы электрической сети.

СПИСОК ЛИТЕРАТУРЫ

1. Наумов А.Н., Вендров А.М., Иванов В.К. Системы управления базами данных и знаний. – М.: Финансы и статистика, 1991. – 352 с.
2. Kenneth C. Sevcik. Priority scheduling disciplines in queuing network models of computer systems. In Proceedings of IFIP Congress'77. August 8-12, 1977, Toronto, Canada, pp. 565-570.
3. V. Mainkar, K.S. Trivedi. Approximate analysis of priority scheduling systems using stochastic reward nets. In Proceedings of the 13th International Conference on Distributed Computing Systems ICDCS'93. May 1993, Pittsburgh, PA, USA, pp. 466-473. doi: 10.1109/icdcs.1993.287678.

4. Leonard Kleinrock. *Queueing Systems. Volume 8: Computer Applications*. John Wiley and Sons, New York, NY, USA, 1976.
5. Попов С.В., Черемисин М.М., Пархоменко О.В., Шкуро К.А. Нейромрежевий метод прогнозування аварійних ситуацій внаслідок утворення ожеледі на повітряних лініях електропередачі // Вісник Вінницького політехнічного інституту. – 2012. – №1. – С. 161-163.
6. Попов С.В., Шкуро К.А., Черемисин Н.М., Пархоменко О.В. Гибридный метод прогнозирования гололедной нагрузки на ВЛ // Энергетика та електрифікація. – 2013. – №5. – С. 33-38.
7. Круглов В.В. Методы прогнозирования многомерных временных рядов // Приборы и системы. Управление, контроль, диагностика. – 2005. – №2. – С. 62-66.
8. Попов С.В., Шкуро К.А. Эволюционная нейро-фаззи сеть на базе гибридных нейроподобных элементов // 17 міжн. конф. з автоматичного управління «Автоматика-2010». Тези доповідей. Т. 2. – Харків, 2010. – С. 193-194.
9. Попов С.В. Специализированные архитектуры искусственных нейронных сетей на базе гибридных нейроподобных элементов // Збірник наукових праць Національного гірничого університету. – 2009. – Т.2. – №33. – С. 76-82.
10. Титов Н.Н. Повышение надежности и качества функционирования автоматизированных систем диспетчерского управления электроэнергетическими системами. – Харьков: Факт, 2013. – 200 с.

REFERENCES

1. Naumov A.N., Vendrov A.M., Ivanov V.K. *Sistemy upravleniia bazami dannyykh i znaniy* [Database management systems and knowledge]. Moscow, Finansy i statistika Publ., 1991. 352 p. (Rus).
2. Kenneth C. Sevcik. Priority scheduling disciplines in queueing network models of computer systems. *In Proceedings of IFIP Congress'77*. August 8-12, 1977, Toronto, Canada, pp. 565-570.
3. V. Mainkar, K.S. Trivedi. Approximate analysis of priority scheduling systems using stochastic reward nets. *In Proceedings of the 13th International Conference on Distributed Computing Systems ICDCS'93*. May 1993, Pittsburgh, PA, USA, pp. 466-473. doi: 10.1109/icdcs.1993.287678.
4. Leonard Kleinrock. *Queueing Systems. Volume 8: Computer Applications*. John Wiley and Sons, New York, USA, 1976.
5. Popov S.V., Cheremisin M.M., Parkhomenko O.V., Shkuro K.A. Neural network method for predicting accidents due to formation of ice on power lines overhead. *Visnyk Vinnytskoho politekhnichnoho instytutu – Visnyk of Vinnytsia Politechnical Institute*, 2012, no.1, pp.161-163. (Ukr).
6. Popov S.V., Shkuro K.A., Cheremisin N.M., Parkhomenko O.V. A hybrid method of predicting ice load on power lines overhead. *Enerhetyka ta elektryfikatsiia – Energetic and electrification*, 2013, no.5, pp. 33-38. (Rus).
7. Kруглов В.В. Methods of forecasting multivariate time series. *Pribery i sistemy. Upravlenie, kontrol', diagnostika – Devices and systems. Management, monitoring, diagnostics*, 2005, no.2, pp. 62-66. (Rus).
8. Popov S.V., Shkuro K.A. Evolutionary neuro-fuzzy network based on hybrid neural elements. *17 mizhn. konf. z avtomatychnoho upravlinnia «Avtomatyka-2010»*. Tezy dopovidei [Proceedings of 17th Int. Conf. of Automatic Control «Automation 2010»]. Kharkiv (Ukraine), 2010, vol.2, pp. 193-194. (Rus).
9. Popov S.V. Specialized architecture of artificial neural networks based on hybrid neural elements. *Zbirnyk naukovykh prats Natsionalnoho hirnychoho universytetu – The collection of scientific works of National Mining University*, 2009, vol.2, no.33, pp. 76-82.

10. Titov N.N. *Povyshenie nadezhnosti i kachestva funktsionirovaniia avtomatizirovannykh sistem dispetcherskogo upravleniia elektroenergeticheskimi sistemami* [Improving the reliability and quality of the functioning of the automated systems of dispatching management of power systems]. Kharkov, Fakt Publ., 2013. 200 p. (Rus).

Поступила (received) 20.10.2015

Мороз Александр Николаевич¹, д.т.н., проф.,
Черемисин Николай Михайлович¹, к.т.н., проф.,
Черкашина Вероника Викторовна², к.т.н., доц.,
Холод Андрей Владимирович³, инженер,
¹ Харьковский национальный технический университет
сельского хозяйства им. П. Василенко,
61052, Харьков, ул. Энгельса, 19,
e-mail: moroz-fekt@inbox.ru, cheremisin.energy@rambler.ru
² Национальный технический университет
«Харьковский политехнический институт»,
61002, Харьков, ул. Фрунзе, 21,
e-mail: cherk34@rambler.ru
³ ЧАО «ЭЛАКС»,
61085, Харьков, ул. Ак. Проскуры, 1, корпус 12,
e-mail: underholod@mail.ru

A.N. Moroz¹, N.M. Cheremisin¹, V.V. Cherkashina², A.V. Kholod³
¹ Kharkiv Petro Vasylenko National Technical University of
Agriculture,
19, Engelsa Str., Kharkiv, 61052, Ukraine.
² National Technical University «Kharkiv Polytechnic Institute»,
21, Frunze Str., Kharkiv, 61002, Ukraine.
³ Company «ELAKS»,
1, build. 12, Ac. Proskura Str., Kharkiv, 61085, Ukraine.

Neural network modeling in problems of prediction modes of electrical grids.

Purpose. Form a neuro-fuzzy network based on temperature monitoring of overhead transmission line for the prediction modes of the electrical network. **Methodology.** To predict the load capacity of the overhead line architecture provides the use of neuro-fuzzy network based on temperature monitoring of overhead line. The proposed neuro-fuzzy network has a four-layer architecture with direct transmission of information. To create a full mesh network architecture based on hybrid neural elements with power estimation accuracy of the following two stages of the procedure: - in the first stage a core network (without power estimation accuracy) is generated; - in the second stage architecture and network parameters are fixed obtained during the first stage, and it is added to the block estimation accuracy, the input signals which are all input, internal and output signals of the core network, as well as additional input signals. **Results.** Formed neuro-fuzzy network based on temperature monitoring of overhead line. **Originality.** A distinctive feature of the proposed network is the ability to process information specified in the different scales of measurement, and high performance for prediction modes mains. **Practical value.** The monitoring system will become a tool parameter is measuring the temperature of the wire, which will, based on a retrospective analysis of the accumulated information on the parameters to predict the thermal resistance of the HV line and as a result carry out the calculation of load capacity in real time. References 10, figures 1.

Key words: electric grid, neural grid, neuro-fuzzy grid, temperature monitoring of air electric line, prediction modes of electric grid.