

ПРОГНОЗИРОВАНИЕ ГОЛОЛЕДНОЙ НАГРУЗКИ НА ВОЗДУШНЫХ ЛИНИЯХ ЭЛЕКТРОПЕРЕДАЧИ НА ОСНОВЕ МЕТОДОВ ВЫЧИСЛИТЕЛЬНОГО ИНТЕЛЛЕКТА

ПОПОВ С.В., ЧЕРЕМИСИН Н.М.,
ПАРХОМЕНКО О.В., ШКУРО К.А.

Для предотвращения гололедных аварий на воздушных линиях электропередачи применяют системы мониторинга гололедной нагрузки. Предлагается новый метод прогнозирования гололедной нагрузки по данным таких систем, основанный на применении комплекса методов вычислительного интеллекта, что позволяет повысить точность прогнозирования.

1. Введение

Метеоусловия значительно влияют на работоспособность линий электропередачи (ЛЭП), целостность инфраструктуры и характеристики электросетей [1]. Погодные явления, которые могут привести к повреждению ЛЭП, включают экстремальные ветры, молнии и гололедо-изморозевые отложения на проводах и опорах ЛЭП. Исследование, проведенное Международным советом по большим электроэнергетическим системам (CIGRE), показало, что обледенение ЛЭП, ветер или сочетание того и другого стало причиной 87% от общего мирового аварийного ущерба за период с 1991 по 1995 год [2].

Прогнозирование гололедной нагрузки может помочь энергокомпаниям вовремя подготовиться к возможным аварийным ситуациям и принять соответствующие превентивные меры. Поэтому разработка и внедрение таких систем прогнозирования является одним из приоритетных направлений исследований в энергетике и смежных областях науки.

На сегодняшний день существует множество моделей динамики гололедной нагрузки [3], которые можно разделить на две большие группы: физические и имитационные модели. Первые описывают процесс гололедообразования в виде явной математической зависимости от множества влияющих факторов, которые необходимо непосредственно измерять, что может быть достаточно трудно. К таким параметрам, например, относится распределение размера капель жидких осадков [4]. Второй тип моделей основан на численном анализе экспериментальных данных, описывающих реальные периоды обледенения ЛЭП и сопутствовавшие этому погодные и другие условия [5, 6].

Среди имитационных моделей особо следует выделить методы, относящиеся к вычислительному интеллекту: нейронные сети, эволюционные алгоритмы и системы на основе нечеткой логики. Эти методы обладают высокой гибкостью, способностью обрабатывать нечеткую, недостоверную информацию, адап-

тироваться к изменяющимся условиям функционирования, способностью к обучению и самообучению. Все эти свойства оказываются чрезвычайно полезными при построении систем прогнозирования гололедной нагрузки, так как здесь приходится иметь дело с различного рода неопределенностью (ошибочные или потерянные показания датчиков, косвенный учет параметров, не поддающихся прямому измерению), нестационарностью (изменение во времени свойств моделируемых процессов) и другими сложностями, непосредственный учет которых может быть очень громоздким или вообще невозможным.

Основой для моделирования являются данные постов контроля гололедной нагрузки и метеофакторов, которые размещают на опорах ЛЭП в местах наиболее вероятного гололедообразования. В настоящей работе использованы данные, собранные на линиях 35 кВ «Старый Крым – Планерское» и «Подгорное – Орион», расположенных в АР Крым. Особенностью этих линий является их прохождение в прибрежной зоне, характеризующейся повышенной влажностью. Автоматические посты контроля гололедной нагрузки и метеофакторов располагаются на опорах ЛЭП в районах перевалов, где часто наблюдаются сильные ветры, что является дополнительным фактором, приводящим к гололедным авариям.

2. Постановка задачи

Главным контролируемым параметром является вес провода M , измеряемый с помощью тензодатчика в точке подвеса. Для удобства моделирования (так как для различных участков нормальный вес различен) этот параметр выражается в процентах от веса чистого провода. При образовании гололеда вес начинает расти и может достичь критического значения M_c , определенного конструктивными параметрами линии. Задача прогнозирования состоит в заблаговременном предупреждении дежурного персонала о вероятном превышении критического значения веса $M > M_c$. С учетом времени, необходимого для принятия решения и подготовки к выполнению плавки гололеда, интервал предупреждения h принят равным 2 ч.

Кроме веса провода, измеряется температура T и относительная влажность H воздуха, которые непосредственно влияют на процесс гололедообразования. Другие метеопараметры (сила и направление ветра, тип и интенсивность осадков) не измеряются, так как это вызывает определенные технические сложности и значительно увеличивает стоимость постов контроля. Съём информации с датчиков происходит непрерывно, затем выполняется усреднение полученных данных за прошедший час, и уже эти значения передаются по каналу связи на диспетчерский пункт. Исключение составляет параметр веса провода, для которого передается также максимально зафиксированное на протяжении часа значение M_{max} , по которому можно косвенно судить о наличии ветровой нагрузки на провод.

Итак, задача состоит в построении на основе имеющихся архивных данных наблюдений прогнозирующей математической модели вида

$$\begin{aligned} \hat{M}(k+h) &= F(M(k), \dots, M(k-d), \\ &M_{\max}(k), \dots, M_{\max}(k-d), T(k), \dots, \\ &T(k-d), H(k), \dots, H(k-d)), \end{aligned}$$

где k – номер часа; d – порядок модели, соответствующий глубине используемой предыстории; F – искомого, в общем случае нелинейное, преобразование.

3. Сеть на базе гибридных нейроподобных элементов

В силу того, что по имеющимся данным построение физической модели невозможно (недостаточно измеряемых параметров), обратимся к имитационным моделям на основе сети из гибридных нейроподобных элементов [7] (рис. 1).




Рис. 1. Архитектура сети на базе гибридных нейроподобных элементов (HNU)

Входными сигналами сети являются текущие значения прогнозируемой переменной $M(k)$ и остальных измеряемых величин $M_{\max}(k), T(k), H(k)$. Подавать на вход предысторию измерений нет необходимости, поскольку она формируется автоматически внутри гибридных нейроподобных элементов (HNU)[8], структура которых представлена на рис. 2.

Входные сигналы $x_i (i = 1, \dots, n)$ преобразуются с помощью синапсов различных типов S_i в сигналы $f_i(x_i)$, которые затем объединяются в сигнал внутренней активации $u = \sum_{i=1}^n f_i(x_i)$. Выходной сигнал нейроподобного элемента формируется с помощью нелинейной активационной функции

$$y = \psi(u) = \psi\left(\sum_{i=1}^n f_i(x_i)\right),$$

где в качестве $\psi(u)$ обычно используется сигмоидальная функция или гиперболический тангенс.




Рис. 2. Гибридный нейроподобный элемент

В гибридном нейроподобном элементе используются синапсы четырех типов: линейный синапс (рис. 3), синапс-фильтр с бесконечной импульсной характеристикой (рис. 4), синапс-фильтр с конечной импульсной характеристикой (рис. 5) и нелинейный синапс на основе нечеткой системы (рис. 6).




Рис. 3. Линейный синапс

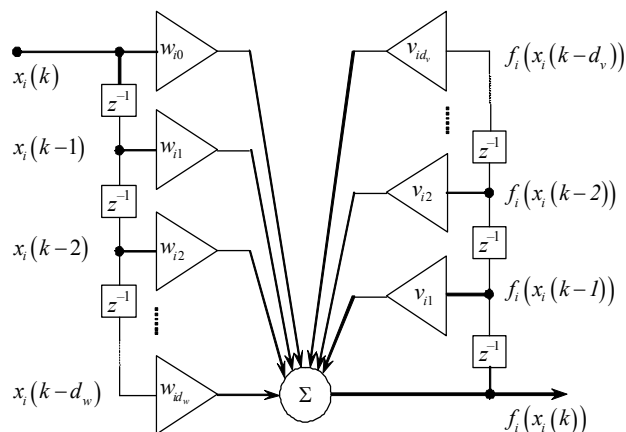


Рис. 4. Синапс-фильтр с бесконечной импульсной характеристикой




Рис. 5. Синапс-фильтр с конечной импульсной характеристикой

В приведенных схемах w_i, w_{ij}, v_{ij} – настраиваемые синаптические веса, μ_{ij} – функции принадлежности,

z^{-1} – элементы чистого запаздывания, d_w, d_v – максимальные порядки запаздываний.




Рис. 6. Нелинейный синапс на основе нечеткой системы

В соответствии с данными схемами выходные сигналы различных типов синапсов формируются следующим образом:

- для линейного синапса: $f_i(x_i) = w_i x_i$;
- для синапса-фильтра с бесконечной импульсной характеристикой:

$$f_i(x_i(k)) = \sum_{j=0}^{d_w} w_{ij} x_i(k-j) + \sum_{j=1}^{d_v} v_{ij} f_i(x_i(k-j));$$

- для синапса-фильтра с конечной импульсной характеристикой: $f_i(x_i(k)) = \sum_{j=0}^{d_w} w_{ij} x_i(k-j)$;

- для нелинейного синапса на основе нечеткой системы: $f_i(x_i) = \sum_{j=1}^{h_i} w_{ij} \mu_{ij}(x_i)$, где h_i – количество функций принадлежности для i -го входа.

В нелинейных синапсах на основе нечеткой системы обычно применяются треугольные функции принадлежности, значения которых определяются расстоянием между входом x_i и центрами c_{ij} :

$$\mu_{ij}(x_i) = \begin{cases} \frac{x_i - c_{i,j-1}}{c_{ij} - c_{i,j-1}}, & x_i \in [c_{i,j-1}, c_{ij}]; \\ \frac{c_{i,j+1} - x_i}{c_{i,j+1} - c_{ij}}, & x_i \in [c_{ij}, c_{i,j+1}]; \\ 0 & \text{в противном случае,} \end{cases}$$

при этом автоматически обеспечивается разбиение

$$\text{Руспини } \sum_{j=1}^{h_i} \mu_{ij}(x_i) = 1, \forall i.$$

Если активен нечеткий интервал p , выход нелинейного синапса можно выразить следующим образом [9]:

$$\begin{aligned} f_i(x_i) &= \sum_{j=1}^{h_i} w_{ij} \mu_{ij}(x_i) = w_{ip} \mu_{ip}(x_i) + w_{i,p+1} \mu_{i,p+1}(x_i) = \\ &= \frac{c_{i,p+1} - x_i}{c_{i,p+1} - c_{ip}} w_{ip} + \frac{x_i - c_{ip}}{c_{i,p+1} - c_{ip}} w_{i,p+1} = a_i x_i + b_i, \end{aligned}$$

$$\text{где } a_i = \frac{w_{i,p+1} - w_{ip}}{c_{i,p+1} - c_{ip}}, \quad b_i = \frac{c_{i,p+1} w_{ip} - c_{ip} w_{i,p+1}}{c_{i,p+1} - c_{ip}}.$$

Применение гибридных нейроподобных элементов позволяет строить нейронную сеть по стандартной многослойной архитектуре, специализация которой достигается за счет:

- выбора типа синапса для каждой связи сети, включая возможность разрыва связи (отсутствие синапса);
- выбора количества и порядка элементов задержек в синапсах-фильтрах с конечной и бесконечной импульсными характеристиками;
- выбора количества и параметров функций принадлежности в нелинейных синапсах.

Таким образом, построение сетей на базе гибридных нейроподобных элементов дает возможность гибкого выбора между универсальными (все синапсы одного типа, полностью связная архитектура) и специализированными (синапсы различных типов и/или неполностью связная архитектура) архитектурами. При этом возможна реализация нелинейных моделей авторегрессии (NAR), авторегрессии с внешними входами (NARX), авторегрессии – скользящего среднего (NARMA), авторегрессии – скользящего среднего с внешними входами (NARMAX).

Настройка параметров (синаптических весов) сети может осуществляться с помощью тех или иных известных в теории искусственных нейронных сетей алгоритмов, основанных на процедуре обратного распространения ошибки [10]. Что касается структурной оптимизации сети (выбора числа слоев, гибридных нейроподобных элементов в каждом из них, типа и структурных характеристик синапсов каждого элемента), то обычно это делается на основе априорной информации о прогнозируемом процессе. В условиях рассматриваемой задачи известные физические зависимости, описывающие процессы гололедообразования, не могут быть напрямую использованы, так как отсутствуют измерения по многим входящим в них параметрам. Следовательно, эти априорные знания не могут быть учтены при построении сети, что заставляет использовать для этой цели методы структурной оптимизации.

В нашем случае для синтеза сети воспользуемся генетическим алгоритмом [11, 12]. Это достаточно универсальный метод, не требующий дифференцируемости оптимизируемого функционала. Структура сети кодируется с помощью так называемых хромосом, несущих всю информацию о слоях, отдельных нейроподобных элементах и их синапсах, за исключением синаптических весов. Имитируя процесс естественной эволюции в природе, заключающийся в генерации поколений, естественном отборе и обмене генетической информацией, возможно находить оптимальные в заданном смысле или достаточно близкие к ним решения.

4. Прогнозирование гололедной нагрузки

Применим описанный подход к задаче прогнозирования гололедной нагрузки. Исходными данными для моделирования являются наблюдения с постов контроля, полученные в зимние периоды 2009/2010 и 2010/2011 гг. За это время произошло 21 событие, когда вес гололедо-изморозевых отложений длительно превышал 10% веса провода, из них 14 использованы для обучения моделей, 7 – для проверки. Для сравнения также применена линейная авторегрессионная модель с внешними входами (ARX) такого же порядка, как и полученная в результате структурной оптимизации нелинейная модель (NARX). В качестве базовой оценки использована модель наивного прогнозирования: будущее значение принимается равным текущему.

Так как прогнозируемая величина M выражается в процентном отношении, то мерой качества прогноза удобнее всего принять среднюю абсолютную ошибку в процентах (MAPE):

$$MAPE = \frac{1}{N} \sum_{k=1}^N |M(k) - \hat{M}(k)|,$$

где N – количество измерений.

На рис. 7 приведен пример графиков истинного веса провода и его прогноза, а также соответствующего графика температуры воздуха.




Рис. 7. Графики веса провода (сплошная линия), его прогноза (штриховая линия) и температуры воздуха (нижний график)

Анализ ошибок прогнозирования показывает: так как среди анализируемых ситуаций не было случаев с бурным нарастанием гололеда, то даже наивный прогноз оказывается достаточно точным. Тем не менее, линейная модель позволяет снизить ошибки на ~0,5%, а предлагаемая нелинейная модель на базе методов

вычислительного интеллекта улучшает этот показатель еще на ~1%.

5. Выводы

Применение сети на базе гибридных нейроразличных элементов в сочетании с генетическим алгоритмом для оптимизации ее структуры позволило с высокой точностью спрогнозировать динамику гололедной нагрузки на ЛЭП, что подтверждено экспериментальной проверкой на реальных данных. Повышение точности прогнозирования наиболее актуально для ситуаций с бурным нарастанием гололедо-изморозевых отложений на проводах и опорах ЛЭП, когда промедление в принятии контрмер может иметь значительные технические и материальные последствия. В этом отношении целесообразно повысить интервал упреждения для более раннего оповещения дежурного персонала о возможности возникновения аварийной ситуации.

Анализ графиков прогнозов также показывает, что максимальные ошибки прогнозирования возникают, когда происходит резкое изменение погодных условий. Поскольку при данной постановке задачи используются только текущие и прошлые измерения метеофакторов, то модель не может учесть будущие изменения в них. Кроме того, при наличии надежного внешнего источника метеопрогноза эту информацию целесообразно использовать при прогнозировании, что и будет сделано в наших дальнейших разработках.

Литература: 1. *Crocobette C.* The weather impact on the transmission of electricity in France // Proc. 8th European conference on Application of Meteorology. Madrid, Spain, 2007. Vol. 4. P. A-00670. 2. *Kiessling F., Neftzger P., Noslasco J., Kaintzyk U.* Overhead Power Lines: Planning, Design, Construction. Berlin: Springer, 2003. 759 p. 3. *Makkonen L., Lozowski E.* Fifty years of progress in modeling the accumulation of atmospheric ice on power network equipment // Proc. 11th International Workshop on Atmospheric Icing of Structures. Montreal, Canada, 2005. P. 55-62. 4. *McComber P., Druetz J., Lafontaine J., Paradis A., Laflamme J.N.* Estimation of transmission line icing at different sites using a neural network // Proc. 9th International Offshore and Polar Engineering Conference. Brest, France, 1999. Vol. II. P. 599-606. 5. *Jones K.F.* A simple model for freezing rain ice loads // Atmospheric Research. 1998. Vol 46. P. 87-97. 6. *Makkonen L.* Modeling power line icing in freezing precipitation // Atmospheric Research. 1998. Vol 43. P. 131-142. 7. *Понов С.В., Шкуро К.А.* Эволюционная нейро-фаззи сеть на базе гибридных нейроразличных элементов // 17 міжнародна конференція з автоматичного управління «Автоматика-2010». Тези доповідей. Том 2. Харків, 2010. С. 193-194. 8. *Понов С.В.* Специализированные архитектуры искусственных нейронных сетей на базе гибридных нейроразличных элементов // Збірник наукових праць Національного гірничого університету. 2009. Т. 2, № 33. С. 76-82. 9. *Bodyanskiy Ye., Popov S.* Neuro-fuzzy unit for real-time signal processing // Proc. IEEE East-West Design & Test Workshop (EWDWTW'06). Sochi, Russia, September 15-19, 2006. P. 403-406. 10. *Haykin S.* Neural Networks. A Comprehensive Foundation. Upper Saddle River: Prentice Hall, 1999. 842 p. 11. *Jain L.C., Martin N.M.* Fusion of Neural Networks, Fuzzy Systems and Genetic Algorithms: Industrial Applications. New York: CRC Press, 1998. 368 p. 12. *Schaffer*

J.D., Whitley D., Eshelman L.J. Combinations of Genetic Algorithms and Neural Networks: A Survey of the State of the Art // Proc. Int. Workshop Combinations of Genetic Algorithms and Neural Networks. Baltimore, June 6, 1992. P. 1-37.

Поступила в редколлегию 24.08.2011

Рецензент: д-р техн. наук, проф. Тевяшев А.Д.

Попов Сергей Витальевич, д-р техн. наук, с.н.с., главный научный сотрудник ПНИЛ АСУ ХНУРЭ. Научные интересы: интеллектуальная обработка данных с использованием технологий вычислительного интеллекта. Адрес: Украина, 61166, Харьков, пр. Ленина, 14, тел. 70-21-890.

Черемисин Николай Михайлович, канд. техн. наук, профессор кафедры электроснабжения и энергоменеджмента, Институт энергетики и компьютерных технологий, Харьковский национальный технический университет

сельского хозяйства имени Петра Василенко. Научные интересы: системы мониторинга распределительных электросетей. Адрес: Украина, 61000, Харьков, ул. Энгельса, 19, тел. 712-34-32.

Пархоменко Олег Викторович, аспирант кафедры электроснабжения и энергоменеджмента, Харьковский национальный технический университет сельского хозяйства имени Петра Василенко. Научные интересы: предотвращение гололедных аварий на воздушных линиях электропередачи. Адрес: Украина, 61000, Харьков, ул. Энгельса, 19, тел. 712-34-32.

Шкуро Кристина Александровна, аспирантка ПНИЛ АСУ ХНУРЭ. Научные интересы: методы обучения искусственных нейронных сетей. Адрес: 61166, Харьков, пр. Ленина, 14, тел. 70-21-890.