

Прогнозирование хаотической динамики параметра потока отказов воздушных линий

ГАЛИАСКАРОВ И.М., МИСРИХАНОВ М.Ш., РЯБЧЕНКО В.Н., ШУНТОВ А.В.

Приведены результаты прогнозирования параметра потока отказов (частоты отказов) воздушных линий 500 кВ, представленного в виде временного ряда и обладающего признаками хаотичности. Прогнозные оценки получены с использованием методов регрессии (спектрального сингулярного анализа) и искусственного интеллекта (нейронных и нечетких нейронных сетей). В качестве объекта спектрального сингулярного анализа использована матрица задержек, формируемая на основе временного ряда параметра потока отказов. Прогноз осуществлен путем одношаговых преобразований исходных данных. Для прогнозирования с помощью нейронной сети применена сеть прямой передачи сигнала, обучаемая методом обратного распространения ошибок. С целью достижения минимальной средней квадратической ошибки обучающая выборка содержала максимально возможную предысторию. Для прогнозирования частоты отказов методом нечетких нейронных сетей была выбрана сеть Ванга-Менделя. Показано, что прогнозные оценки параметра потока отказов, полученные при достаточно большом количестве опытов на базе «высокоразвитой» нейронной сети, фактически приводят к выполнению условий центральной предельной теоремы. В итоге методы прогнозирования временных рядов параметра потока отказов, основанные на использовании регрессии и искусственного интеллекта, дали различные оценки. Это свидетельствует о том, что это лишь начало пути обоснования методологии прогнозирования аварийности в электрических сетях.

К л ю ч е в ы е с л о в а : воздушные линии, поток отказов, прогнозирование, спектральный сингулярный анализ, нейронные сети

Цикличность аварий воздушных линий (ВЛ) 500 кВ обширного региона на протяженном временном отрезке была исследована в [1]. Были выявлены существенные колебания значений их параметра потока устойчивых отказов ω (частоты от-

казов) под воздействием природных и социально-экономических факторов (рис. 1); предложено рассматривать указанный параметр как выходной сигнал динамической системы с множеством трудно формализуемых входов.




Рис. 1. Значения параметра потока отказов ВЛ 500 кВ за период 1974–2018 гг. с наложением циклов солнечной активности (…)

В [2] временной ряд на рис. 1 подвергнут анализу с использованием теории детерминированного (динамического) хаоса. Хаотичность поведения рассматриваемой динамической системы выявлена по признаку фрактальности этого ряда, а также положительности старшего показателя Ляпунова λ . Показано, что период прогнозирования в подобных задачах $T \approx 1/\lambda$. В данном случае $T \approx 1/0,2183 = 4,6$ лет, т.е. примерно пять лет.

В теории динамических систем присутствует многообразие методов анализа и прогнозирования временных рядов, в том числе хаотического характера. В [2] для этих целей был применен лишь один из них – метод спектрального сингулярного анализа (ССА).

Как известно, ССА относится к глобальным методам прогноза и используется для выделения периодических и квазипериодических составляющих из временного ряда. Его можно отнести к традиционным хорошо отработанным регрессионным методам. Среди альтернативных подходов к прогнозированию выделим методы, связанные с искусственным интеллектом, в частности, нейронные и нечеткие нейронные сети. Их применение для прогнозирования аварийности ВЛ 500 кВ и сравнение с методом ССА выявили некоторые закономерности, которые полезно принимать во внимание при обосновании достоверности оценок надежности основной сети энергосистем.

Спектральный сингулярный анализ. Большинство методов, связанных с анализом и прогнозированием временных рядов, основано на многомерном представлении в виде матрицы задержек – набора копий ряда, взятых с лагом, т.е. через определенный промежуток времени.

На первом шаге ССА исходный временной ряд длиной N (на рис. 1 $N=45$) переводится в последовательность многомерных векторов – векторов вложений размерностью L ; $1 < L < M$. Примем $L \approx N/2 = 45/2 \approx 22$ [3], а число столбцов матрицы задержек $K = N - L + 1 = 45 - 22 + 1 = 24$. Таким образом, матрица для временного ряда на рис. 1 имеет размерность 22×24 :

$$\Omega = \begin{bmatrix} \omega_{1974} & \omega_{1975} & \cdots & \omega_{1997} \\ \omega_{1975} & \omega_{1976} & \cdots & \omega_{1998} \\ \vdots & \vdots & \vdots & \vdots \\ \omega_{1995} & \omega_{1996} & \cdots & \omega_{2018} \end{bmatrix}$$

Здесь и далее подстрочные индексы параметра потока отказов соответствуют отчетному году.

На основе этой матрицы формируется симметрическая матрица

$$X = \frac{1}{L} \Omega^T \Omega,$$

сингулярное разложение которой приводит к виду

$$X = \Lambda V V^T,$$

где Λ – диагональная матрица упорядоченных по убыванию сингулярных (собственных) значений, определяющая главные компоненты; V – ортогональная матрица сингулярных векторов.

Матрица Ω имеет прямоугольный вид. Число ее столбцов (24) больше числа строк (22). Из-за этого часть ее столбцов является линейными комбинациями оставшихся столбцов. Последнее приводит к вырожденности матрицы X и, соответственно, равенству нулю ее определителя.

У вырожденных матриц обязательно нулевые собственные и сингулярные числа [4]. В рассматриваемом случае сингулярные числа присутствуют в диагональной матрице Λ . В результате не удастся построить полином так называемой линейной регрессионной формулы (ЛРФ), состоящей из линейных комбинаций произведений экспонент, полиномов и гармоник и управляющей поведением временного ряда. Причина кроется в том, что для получения коэффициентов полинома ЛРФ требуется деление на сингулярные числа, в нашем случае – на нуль [5].

Обратим внимание, что ССА похож на преобразование Фурье. Здесь исходный ряд также представляется в виде набора составляющих. Только в ССА они не являются в общем случае гармоническими.

Таким образом, при обработке временного ряда, представленного на рис. 1, пришлось задействовать одношаговые (а не многошаговые) прогнозирующие формулы и обновления матриц после каждого шага прогнозирования. Фактически речь идет об использовании идеи метода локальной аппроксимации. Его преимущество заключается в применении кусочно-линейного приближения, выражающегося в данном случае в одношаговом (рекуррентном) прогнозировании вместо глобальной линейной аппроксимации, что дает ЛРФ.

На основе сингулярного разложения (чаще употребляется SVD-разложение) симметрической матрицы X определено упорядоченное множество сингулярных чисел. Доминирующие сингулярные числа (их оказалось шесть) определили выбор соответствующего числа главных компонент для проведения сингулярного анализа. В результате матрица V в SVD-разложении X была редуцирована по столбцам до размера 24×6 и приняла вид

$$\mathbf{V}^* = \begin{bmatrix} \bar{\mathbf{V}} \\ v \end{bmatrix},$$

где v — последняя строка матрицы \mathbf{V}^* .

Вычисления прогнозных оценок параметра потока отказов с глубиной пять (см. выше) лет по формулам:

$$\omega_{2019} = \frac{v\mathbf{V}^T}{1-vv^T} \begin{bmatrix} \omega_{1995} \\ \omega_{1996} \\ \vdots \\ \omega_{2018} \end{bmatrix}; \quad \omega_{2020} = \frac{v\mathbf{V}^T}{1-vv^T} \begin{bmatrix} \omega_{1996} \\ \omega_{1997} \\ \vdots \\ \omega_{2019} \end{bmatrix}; \quad \dots;$$

$$\omega_{2023} = \frac{v\mathbf{V}^T}{1-vv^T} \begin{bmatrix} \omega_{1999} \\ \omega_{2002} \\ \vdots \\ \omega_{2022} \end{bmatrix},$$

с обновляющимися после каждого шага матрицами \mathbf{V} и \mathbf{V}^* дали следующие значения частоты отказов ВЛ 500 кВ на перспективу 2019–2023 гг.:

Год	2019	2020	2021	2022	2023
$\omega, 1/(\text{год} \times 100 \text{ км})$	0,12	0,14	0,11	0,25	0,27

Метод нейронных сетей. Известно, что одно из возможных применений нейронных сетей — предсказание поведения динамической системы, структура и параметры которой не известны, по ранее сгенерированному ею сигналу (в нашем случае — временному ряду на рис. 1, имеющему признаки хаотичности). Не вдаваясь в методологию нейронных сетей (она широко представлена в специализированной литературе), а также с учетом особенностей, описанных в [7], в данной статье задействованы нейросети, имеющие два и более слоев, с прямой передачей сигналов, т.е. без обратной связи.

Использована нейросеть, представленная программно в среде Matlab функцией *newff*. Последняя предназначена для создания в общем случае многослойных нейронных сетей с заданными функциями обучения и настройки, которые используют метод обратного распространения ошибки. Оптимизация параметров нейронной сети осуществлялась программно встроенным квази-ньютоновским методом Левенберга–Марквардта, объединяющим достоинства метода наискорейшего спуска и метода Гаусса–Ньютона [8, 9].

В качестве обучающего массива данных для нейронной сети также задействована матрица задержек. При ССА ее размеры формировались для достижения хорошей обусловленности (масштабированности) как прямоугольной матрицы, т.е. обеспечения как можно более близкого к единице

отношения максимального и минимального сингулярных чисел в SVD-разложении этой матрицы. Для нейронной сети, как показал вычислительный эксперимент, обучающая выборка требует учета максимально возможной предыстории для достижения минимальной средней квадратической ошибки. При этом число столбцов матрицы задержек априорно принималось равным горизонту прогнозирования (пять лет). Так, для прогноза на 2019 г. эта матрица имела размерность 40×5 :

$$\Omega = \begin{bmatrix} \omega_{1974} & \omega_{1975} & \omega_{1976} & \omega_{1977} & \omega_{1978} \\ \omega_{1975} & \omega_{1976} & \omega_{1977} & \omega_{1978} & \omega_{1979} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \omega_{2013} & \omega_{2014} & \omega_{2015} & \omega_{2016} & \omega_{2017} \\ \omega_{2014} & \omega_{2015} & \omega_{2016} & \omega_{2017} & \omega_{2018} \end{bmatrix}.$$

Первые 39 строк этой матрицы использовались для формирования обучающих входов нейросети, а последняя строка — «эталонных» выходов, т.е. после выполнения процедуры обучения выходной сигнал нейросети должен с исчезающе малой ошибкой совпадать с «эталоном». Для обучения нейросети использована функция *train* в среде Matlab. На каждый следующий прогнозный год к матрице задержек присоединялась строка, получаемая в результате добавления прогноза параметра потока отказов ВЛ на текущий год, а именно, 2020 г. — 41×5 , 2021 г. — 42×5 , ...

Прогнозирование частоты отказов ВЛ 500 кВ, как и в случае ССА, шло на один шаг (год) вперед. В качестве входного сигнала «обученной» нейросети, например на 2019 г., выступало значение частоты отказов в 2018 г.; выходным сигналом — прогноз на 2019 г., рассчитанный функцией *sim* в среде Matlab, а при прогнозировании, допустим, на 2020 г. — прогноз параметра потока отказов на 2019 г. и т.д.

В рамках одного прогнозного года нейросеть в цикле «обучение — прогноз» давала различные значения частоты отказов (рис. 2,а). Поэтому затронут аспект выбора числа испытаний нейронной сети. Во-первых, согласно методу Монте-Карло точность вычислений при обработке случайных величин пропорциональна отношению $\sqrt{D_\xi}/n$, где D_ξ — дисперсия случайной величины ξ ; n — число испытаний [10]. Как следует из данной формулы, указанная точность зависит от значения $\sqrt{n^{-1}}$. Выбор $n=10^4$, например, по сравнению с $n=10^3$ при одной и той же дисперсии увеличивает точность более чем в 3 раза, поскольку значение $\sqrt{n^{-1}}$ уменьшается с 0,0316 до 0,01. Во-вторых, установлено, что, начиная примерно с $n=10^4$, гистограммы распре-

лений частоты отказов становятся слабо зависимыми от их числа, т.е. приобретают свойство стационарности.

На рис. 2,б приведена гистограмма прогноза двухслойной нейросети на 2019 г. при 10^4 опытах и бине 0,05 1/(год×100 км). Как видно из этого рисунка, прогнозная оценка параметра потока может находиться в широком диапазоне. Наиболее вероятно (свыше 35% циклов «обучение–прогноз») она будет находиться в диапазоне от 0,1 до 0,15 1/(год×100 км).

На рис. 3 приведена гистограмма прогноза десятислойной нейросети на 2019 г. при 10^5 опытах. Как видно из рис. 3, чем более разнообразней и насыщенной становится структура нейросети, тем больше «степеней свободы» она себе позволяет, в частности, отрицательные значения частоты отказов. Общим итогом применения весьма развитой нейросети, обучаемой по временным рядам с при-

знаками хаотической динамики, является получение прогноза, описываемого (при нормализации гистограммы) нормальным гауссовским распределением случайных величин – сопоставлено с гистограммой, создаваемой генератором псевдослучайных чисел.

Обобщенные характеристики в виде математического ожидания M и среднего квадратического отклонения σ прогнозных значений параметра потока отказов ВЛ 500 кВ, вычисленные с помощью десятислойных нейронных сетей при $n=10^4$ испытаний, равны:

Год	M , 1/(год×100 км)	σ_y , 1/(год×100 км)
2019	0,189	0,057
2020	0,133	0,018
2021	0,134	0,018
2022	0,134	0,018
2023	0,159	0,027





Рис. 2. Прогноз на 2019 г. двухслойной нейронной сети (10^4 опытов): а – исходы опытов; б – гистограмма: Т: + — выход нейронной сети; - - - — линейный тренд




Рис. 3. Гистограмма прогноза на 2019 г. десятислойной нейронной сети (10^5 опытов)

Далее приведены прогнозные значения для двухслойной сети, соответствующие наибольшему числу исходов опытов (при $\omega=0,10\div 0,15$ 1/год \times 100 км):

Год	2019	2020	2021	2022	2023
Число исходов, %	37	75	80	85	46

Анализируя полученные прогнозные оценки, отметим, что метод нейросетей, связанный с искусственным интеллектом, действительно отразил психологию человека. Прогнозное значение может находиться в очень широком диапазоне с большей или меньшей вероятностью, а в чем-то «интеллект» превзошел человека, спрогнозировав отрицательные значения параметра потока отказов ВЛ.

Нечеткие нейронные сети. Эти сети, как известно, комбинируют методы нейронных сетей и систем нечеткой логики. Таким образом, свойства нейронной сети усиливаются достоинством нечеткой логики – возможностью использования экспертных знаний о структуре объекта в виде лингвистических выражений следующего вида: если «входы» такие-то, то «выходы» такие-то. Однако алгоритмы нечеткой логики сами по себе не содержат встроенных механизмов обучения и самоорганизации. Поэтому полученные с их помощью решения зависят от вида так называемых функций принадлежности, которыми формализуются нечеткие термы – качественные описания значений параметров, например, «мало», «много», «очень много» и др.

Для прогнозирования частоты отказов ВЛ 500 кВ была выбрана одна из наиболее простых нечетких нейронных сетей Ванга–Менделя (частный случай сети Сугено–Такаги–Канга) [11, 12 и др.]. Она реализована в среде Matlab с помощью программы ANFIS.

При решении задачи прогнозирования аварийности ВЛ с помощью программы ANFIS, как и прежде, использовалась обучающая выборка в виде матрицы задержек для нейронных сетей. При этом формирование функций принадлежности (брались трапециевидные) проводилось на основе экспертной информации, в качестве которой использовались результаты прогнозирования методами ССА и нейросетей. Так, указывались следующие диапазоны параметра потока отказов: «мало» – $0\div 0,075$ 1/(год \times 100 км); «средне» – $0,075\div 0,275$ 1/(год \times 100 км); «много» – $0,275\div 0,45$ 1/(год \times 100 км). Как видно, одним из управляющих факторов являлся запрет на отрицательные значения параметра потока отказов, а в качестве предпочтительного задавался диапазон $0,075\div 0,275$ 1/(год \times 100 км).

Как и ранее, ANFIS-прогнозирование велось на один шаг (год) вперед с выполнением 10^4 опытов для каждого шага пятилетнего горизонта прогнозирования. Получить распределения, близкие к гауссовским, не представилось возможным. Причина в том, что ни одна из функций принадлежности, фигурирующая в прогнозаторах, не допускала отрицательных значений частоты отказов линий. На рис. 4 в качестве примера приведена гистограмма прогноза параметра потока отказов ВЛ 500 кВ на 2019 г.

Далее приведены результаты прогнозирования на последующие годы:

Год	2019	2020	2021	2022	2023
ω , 1/(год \times 100 км)	$0,10\div 0,15$	$0,10\div 0,15$	$0,10\div 0,15$	$0,10\div 0,15$	$0,15\div 0,20$
Число исходов, %	41	41	38	37	42

По завершении 2019 г. оказалось возможным сравнить прогнозные и фактические данные за этот год. Обработка статистических данных выяви-

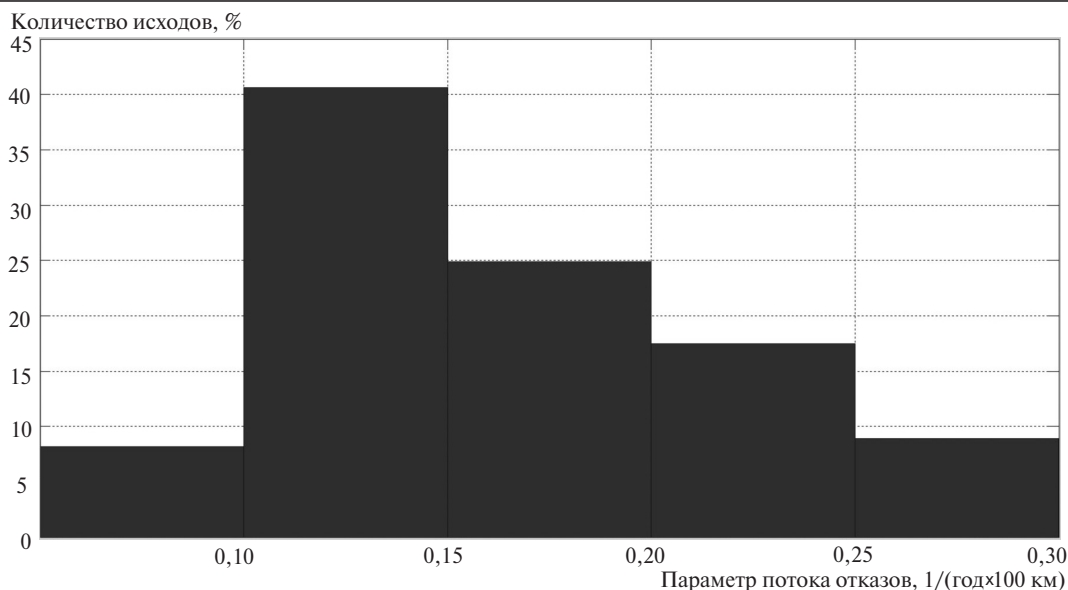


Рис. 4. Гистограмма прогноза на 2019 г. нечеткой нейронной сети

ла частоту отказов ВЛ 500 кВ рассматриваемого региона на уровне 0,1 1/(год×100 км) при прогнозе 0,12 1/(год×100 км) методом ССА и 0,10–0,15 1/(год×100 км) (наиболее вероятно) методами двухслойных нейронных и нечетких нейронных сетей, что является в определенной мере адекватной оценкой. Математическое ожидание частоты отказов ВЛ, выданное на 2019 г. десятислойной нейронной сетью, составило 0,189 1/(год×100 км) – по сути, ошибочный прогноз.

На перспективу пять лет метод ССА дает примерно трехкратный рост аварийности, следуя многолетним тенденциям, связанным отчасти с циклами солнечной активности (см. [1, 13]). Нейронные и нечеткие нейронные сети предлагают более благоприятные стабильные прогнозы частоты отказов ВЛ основной сети энергосистем.

Выводы. 1. Хаотическая динамика параметра потока отказов ВЛ 500 кВ делает проблематичным прогнозирование аварийности основных сетей энергосистем и снижает достоверность оценок их надежности.

2. Прогнозные оценки параметра потока отказов ВЛ 500 кВ, полученные при достаточно большом числе опытов на базе «высокоразвитой» нейронной сети, фактически привели к выполнению условий центральной предельной теоремы, согласно которой функции от большого числа слабо зависимых величин имеют распределения вероятностей, близкие к нормальному гауссовскому закону.

3. Нормальное гауссовское распределение частоты отказов ВЛ 500 кВ, надо полагать, является дополнительной характеристикой хаотичности рассматриваемого динамического процесса, поскольку нейронная сеть была обучена на численных характеристиках временного ряда параметра потока от-

казов, имеющего признаки хаотичности (фрактальность и положительность старшего показателя Ляпунова).

4. Методы прогнозирования временных рядов параметра потока отказов ВЛ 500 кВ, основанные на использовании регрессии (спектральный сингулярный анализ) и искусственного интеллекта (нейронных и нечетких нейронных сетей) дают различные оценки. Подтвердить или опровергнуть их можно будет по истечении предстоящего пятилетнего периода.

СПИСОК ЛИТЕРАТУРЫ

1. Галиаскаров И.М., Мисриханов М.Ш., Рябченко В.Н., Шунтов А.В. Еще раз о цикличности аварий в основных сетях энергосистем. – Электричество, 2019, № 11, с. 4–11.
2. Галиаскаров И.М., Мисриханов М.Ш., Рябченко В.Н., Шунтов А.В. О прогнозировании аварийности воздушных линий основной сети энергосистем. – Электричество, 2020, № 6, с. 6–11.
3. Леонтьева Л.Н. Многомерная гусеница, выбор длины и числа компонент. – Машинное обучение и анализ данных, 2011, № 1, с. 2–10.
4. Воеводин В.В., Кузнецов Ю.А. Матрицы и вычисления. М.: Наука. ФИЗМАТЛИТ, 1984, 320 с.
5. Голяндина Н.Э. Метод «Гусеница»–SSA: прогноз временных рядов. СПб., 2004, 52 с.
6. Лоскутов А.Ю., Михайлов А.С. Основы теории сложных систем. М.; Ижевск: Институт компьютерных исследований, 2007, 620 с.
7. Шабунин А.В. Нейронная сеть как предсказатель динамики дискретного отображения. – Известия вузов. Проблемы нелинейной динамики, 2014, т. 22, № 5, с. 58–72.
8. Аксенов С.В., Новосельцев В.Б. Организация и использование нейронных сетей (методы и технологии) / Под общ. ред. В.Б. Новосельцева. Томск: Изд-во НТЛ, 2006, 128 с.
9. Kriesel D. A Brief Introduction to Neural Networks [Электрон. ресурс] http://dkriesel.com/en/science/neural_networks (дата обращения 13.03.2020).
10. Соболев И.М. Метод Монте-Карло. М.: Наука, 1968, 64 с.

11. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение. М.: ДМК Пресс, 2018, 652 с.
12. Круглов В.В., Дли М.И., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. М.: ФИЗМАТЛИТ, 2001, 198 с.
13. Скопинцев В.А. Качество электроэнергетических систем: надёжность, безопасность, экономичность, живучесть. М.: Энергоатомиздат, 2009, 332 с.

[23.03.2020]

Авторы: **Галиаскаров Ирек Миньрахманович** — главный инженер филиала АО «Центр инжиниринга и управления строительством Единой энергетической системы» — Центр инжиниринга и управления строительством Центра.

Мисриханов Мисрихан Шапиевич — доктор техн. наук, ведущий научный сотрудник кафедры электроэнергетических систем Национального исследовательского университета «Московский энергетический институт» («НИУ «МЭИ»), диссертацию защитил в 2010 г.

Рябченко Владимир Николаевич — доктор техн. наук, главный технолог АО «Научно-технический центр ФСК ЕЭС», диссертацию защитил в 2002 г.

Шунтов Андрей Вячеславович — доктор техн. наук, главный научный сотрудник кафедры электроэнергетических систем «НИУ «МЭИ», диссертацию защитил в 2002 г.

Electrichestvo, 2020, No. 9, pp. 4–10

DOI:10.24160/0013-5380-2020-9-4-10

Prediction of Chaotic Dynamics Parameter for the Flow of Overhead Line Failures

GALIASKAROV Irek M. (Branch of Center for Engineering and Construction Management JSC – CECM Center) — Chief engineer

MISRIKHANOV Misrikhan Sh. (National Research University «Moscow Power Engineering Institute» — NRU «MPEI», Moscow, Russia) — Leading researcher of the Research Laboratory «Automation of Electrical Distribution Networks», Dr. Sci. (Eng.)

RYABCHENKO Vladimir N. (R&D Center FGS UES, Moscow, Russia) — Chief technologist, Dr. Sci. (Eng.)

SHUNTOV Andrei V. (NRU «MPEI», Moscow, Russia) — Chief researcher of Electric Power Systems Dept., Dr. Sci. (Eng.)

The results from predicting the failure rate of 500 kV overhead power lines represented as a time series and having signs of its being chaotic in nature are presented. The predictive estimates were obtained using the regression (spectral singular analysis) method and artificial intelligence (neural and fuzzy neural networks) method. The matrix of delays formed proceeding from the failure rate time series was used as the object of spectral singular analysis. The prediction was made by carrying out single-step transformations of input data. For carrying out prediction by means of a neural network, a direct signal transmission network trained using the back propagation method was used. For achieving the minimal root-mean-square error, the training sample contained the maximum possible prehistory. For predicting the failure rate using the fuzzy neural network method, the Wang—Mendel neural network was chosen. It is shown that the predictive estimates of the failure rate obtained with a sufficiently large number of experiments on the basis of a «highly developed» neural network lead in fact to fulfilling the conditions of the central limit theorem. As a result, the failure rate time series prediction methods based on using regression and artificial intelligence yielded different estimates. This outcome testifies that this is only the beginning of work on substantiating the methodology for predicting failure rates in electric networks.

Key words: overhead power lines, failure flow, prediction, spectral singular analysis, neural networks

REFERENCES

1. Galiaskarov I.M., Misrikhanov M.Sh., Ryabchenko V.N., Shuntov A.V. *Electrichestvo* — in Russ. (*Electricity*), 2019, No. 11, pp. 4–11.
2. Galiaskarov I.M., Misrikhanov M.Sh. *Elektrichestvo* — in Russ. (*Electricity*), 2020, No. 6, pp. 6–11.
3. Leont'yeva L.N. *Mashinnoye obucheniye i analiz dannykh* — in Russ. (*Machine Learning and Data Analysis*), 2011, No. 1, pp. 2–10.
4. Voyevodin V.V., Kuznetsov Yu.A. *Matritsy i vychisleniya* (Matrices and calculations). M.: Nauka. FIZMATLIT, 1984, 320 p.
5. Golyandina N.E. *Metod «Gusenitsa»-SSA: prognoz vremennykh ryadov* (Caterpillar-SSA: Time Series Forecast). SPb., 2004, 52 p.
6. Loskutov A.Yu., Mikhaylov A.S. *Osnovy teorii slozhnykh sistem* (Foundations of the theory of complex systems). M.: Izhevsk: Institut komp'yuternykh issledovaniy, 2007, 620 p.
7. Shabunin A.V. *Isv. vuzov. Problemy nelineynoy dinamiki* — in Russ. (*News of universities. Problems of nonlinear dynamics*), 2014, vol. 22, No. 5, pp. 58–72.
8. Aksenov S.V., Novosel'tsev V.B. *Organizatsiya i ispol'zovaniye neyronnykh setey (metody i tekhnologii)/Pod obshch. red. V.B. Novosel'tseva* (Organization and use of neural networks (methods and technologies)/Ed. V.B. Novosel'tsev). Tomsk: Izd-vo NTL, 2006, 128 p.
9. Kriesel D. Brief Introduction to Neural Networks [Elektron. Resourse] http://dkriesel.com/en/science/neural_networks (Data of appeal 13.03.2020).
10. Sobol' I.M. *Metod Monte-Karlo* (Monte Carlo method). M.: Nauka, 1968, 64 p.
11. Gudfellou Ya., Bendzhio I., Kurvill' A. *Glubokoye obucheniye* (Deep learning). M.: ДМК Пресс, 2018, 652 p.
12. Kруглов В.В., Дли М.И., Голунов Р.Ю. *Nechetkaya logika i iskussvennyye neyronnyye seti* (Fuzzy logic and artificial neural networks). M.: ФИЗМАТЛИТ, 2001, 198 p.
13. Skopintsev V.A. *Kachestvo elektroenergeticheskikh sistem: nadozhnost', bezopasnost', ekonomichnost', zhivuchest'* (The quality of power systems: reliability, safety, efficiency, survivability). M.: Energoatomizdat, 2009, 332 p.

[23.03.2020]