

# МЕТОД И АЛГОРИТМ МОДЕЛИРОВАНИЯ ДИАГНОСТИ ДЛЯ СИЛОВОГО ТРАНСФОРМАТОРА НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ

## METHOD AND ALGORITHM OF DIAGNOSTICS MODELING FOR A POWER TRANSFORMER BASED ON MACHINE LEARNING

**A. Shaikhullin  
M. Nizamiev**

*Summary.* The emerging technology of forecasting and condition management (PUS) has recently attracted a lot of attention from scientists and industries. The need to increase the availability of equipment and reduce maintenance costs is the driving force behind the development and integration of forecasting and condition management systems. PUS models depend on smart sensors and data generated by sensors. In this article, machine learning-based methods for the development of PUS models based on sensor data for performing fault diagnostics of transformer systems in an intelligent network are proposed. In particular, an algorithm is used to optimize the neural network of back propagation (BP) in order to build high-performance models of fault diagnosis. The models were developed using sensor data called dissolved gas data in the oil of a power transformer. The results obtained demonstrate that the developed algorithm for optimizing the parameters of the neural network is effective and useful; and models based on machine learning have significantly improved the performance and accuracy of diagnostics /fault detection for the power transformer PUS.

*Keywords:* machine learning; neural network; predicting and controlling the state of a power transformer; fault diagnosis.

**Шайхуллин Артур Зуфарович**

Аспирант Казанский Государственный  
Энергетический Университет  
Казань

a6968271@gmail.com

**Низамиев Марат Фирденатович**

Доцент, к.т.н. Казанский Государственный  
Энергетический Университет  
Казань

*Аннотация.* Появляющаяся технология прогнозирования и управления состоянием (ПУС) в последнее время привлекла большое внимание ученых и отраслей промышленности. Необходимость повышения доступности оборудования и снижения затрат на техническое обслуживание является движущей силой разработки и интеграции систем прогнозирования и управления состоянием. Модели ПУС зависят от интеллектуальных датчиков и данных, генерируемых датчиками. В этой статье предложены основанные на машинном обучении методы разработки моделей ПУС на основе данных датчиков для выполнения диагностики неисправностей трансформаторных систем в интеллектуальной сети. В частности, применяется алгоритм для оптимизации нейронной сети обратного распространения (ОП) с целью построения высокопроизводительных моделей диагностики неисправностей. Модели были разработаны с использованием данных датчиков, называемых данными о растворенном газе в масле силового трансформатора. Полученные результаты демонстрируют, что разработанный алгоритм оптимизации параметров нейронной сети является эффективным и полезным; а модели, основанные на машинном обучении, значительно улучшили производительность и точность диагностики/обнаружения неисправностей для силового трансформатора ПУС.

*Ключевые слова:* машинное обучение; нейронная сеть; прогнозирования и управления состоянием силового трансформатора; диагностика неисправностей.

## Введение

Система прогнозирования и управления работоспособностью системы (ПУС) обычно предоставляет такие возможности, как обнаружение неисправностей, прогнозирование отказов и отслеживание срока службы компонентов для оценки надежности продукта. Технологии ПУС включают в себя зондирова-

ние, обнаружение аномалий, диагностику, прогнозирование и поддержку принятия решений для интеллектуального технического обслуживания оборудования и дальнейшей эксплуатации. Используя преимущества достижений в области современных технологий, ПУС обеспечивает активную стратегию предотвращения неисправностей путем постоянного мониторинга работоспособности сложных систем. Силовой трансформа-

тор — это часть оборудования, которая имеет большое значение для электронной системы. Таким образом, его производительность может оказать большое влияние на электросеть [1–3]. Старение силовых трансформаторов является важным фактором, приводящим к выходу из строя электросети, что также может вызвать три основных типа неисправностей в трансформаторах: электрические, механические и тепловые. Среди них механическая неисправность занимает первое место [4,5]. Поэтому крайне важно повысить точность диагностики неисправностей силовых трансформаторов [6,7].

Некоторые традиционные методы диагностики неисправностей трансформаторов, такие как анализ растворенных газов (ХАГР) [8–10], реактивное сопротивление короткого замыкания (РКЗ) [11] и анализ частотной характеристики (ЧР) [12], широко используются в промышленности. Тем не менее, эти методы были ограничены низкой точностью диагностики неисправностей, когда компонент растворенного газа является сложным. Многомерные данные о неисправностях силовых трансформаторов могут привести к нелинейности всей системы, и ЧР и РКЗ в этом состоянии не могут найти реальные места неисправностей, а также не могут предоставить информацию о типах трансформаторов [11].

Методы диагностики неисправностей силовых трансформаторов [13] включают в себя, в основном, метод четырех коэффициентов Международной электротехнической комиссии (МЭК) и метод трех коэффициентов, метод характеристического газа и так далее. Однако эти методы приводят к большим ошибкам при диагностике силовых трансформаторов. Точность будет значительно снижена, если выборочные данные будут слишком малы или в выборках будут какие-то отклонения. Поэтому желательно использовать технологию искусственного интеллекта с отличной производительностью для диагностики неисправностей трансформаторов. Интеллектуальные алгоритмы, основанные на данных ХАГР, являются широко используемыми методами диагностики неисправностей трансформаторов, особенно нейронная сеть обратного распространения (ОР) [14,15]. Нейронная сеть ОР может быть использована для определения весов соединений и смещения для реализации точных диагностических методов или моделей для ХАГР. Обновленные параметры нейронной сети ОР следуют правилу убывания градиента, чтобы избежать принятия параметров за оптимальные параметры.

В настоящее время многие интеллектуальные алгоритмы оптимизации и алгоритмы машинного обучения применяются в различных областях, таких как силовые трансформаторы, поскольку эти методы обладают высокой производительностью диагностики неисправ-

ностей. Существует множество диагностик неисправностей силовых трансформаторов и других передовых исследований. При диагностике неисправностей силовых трансформаторов для определения состояния трансформаторов используются различные интеллектуальные методы и методы машинного обучения.

Что касается диагностики неисправностей силового трансформатора, разработан метод классификации неисправностей силового трансформатора на основе машины опорных векторов (МОВ), используя данные каретки для построения многослойного классификатора МОВ. Этот классификатор обладает превосходной производительностью при определении типов неисправностей трансформатора. [17] Интеллектуальный метод диагностики неисправностей силового трансформатора на основе выбранного соотношения газов и МОВ. Этот метод был применен для диагностики растворенного масла в трансформаторе. Разработан новый метод диагностики неисправностей трансформатора, основанный на вероятностной нейронной сети (PNN) и анализе растворенных газов. Для оптимизации параметров PNN используется гибридный эволюционный алгоритм, основанный на оптимизации роя частиц (PSO) и ОР. Чтобы решить проблему аварий силовых трансформаторов разработана интеллектуальная система управления инженерными активами. Модели, основанные на данных, используются для обнаружения потенциальных неисправностей в трансформаторах.

## Метод

Нейронная сеть с обратным распространением (ОР) представляет собой многослойную нейронную сеть с прямой связью, которая относится к неопределенной нелинейной математической модели [32–34]. Сеть BP состоит из входного уровня, скрытого уровня и выходного уровня. Два процесса прямого распространения и обратного распространения имеют большое значение для нейронной сети BP [35,36]. Сеть ОР может иметь лучшие показатели в классификации и прогнозировании благодаря сочетанию этих двух процессов. При прямом распространении данные передаются через входной слой и объединяются с весами и пороговыми значениями скрытого слоя для вычисления слой за слоем и, наконец, достигают выходного слоя для получения результата классификации. При обратном распространении, когда выходные данные в выходном слое не соответствуют ожиданиям, сигнал ошибки будет распространяться обратно. Он использует алгоритм градиентного спуска ошибок для уменьшения среднеквадратичной ошибки между выходным значением сети и фактическим выходным значением, и сеть регулирует веса и пороговые значения слой за слоем

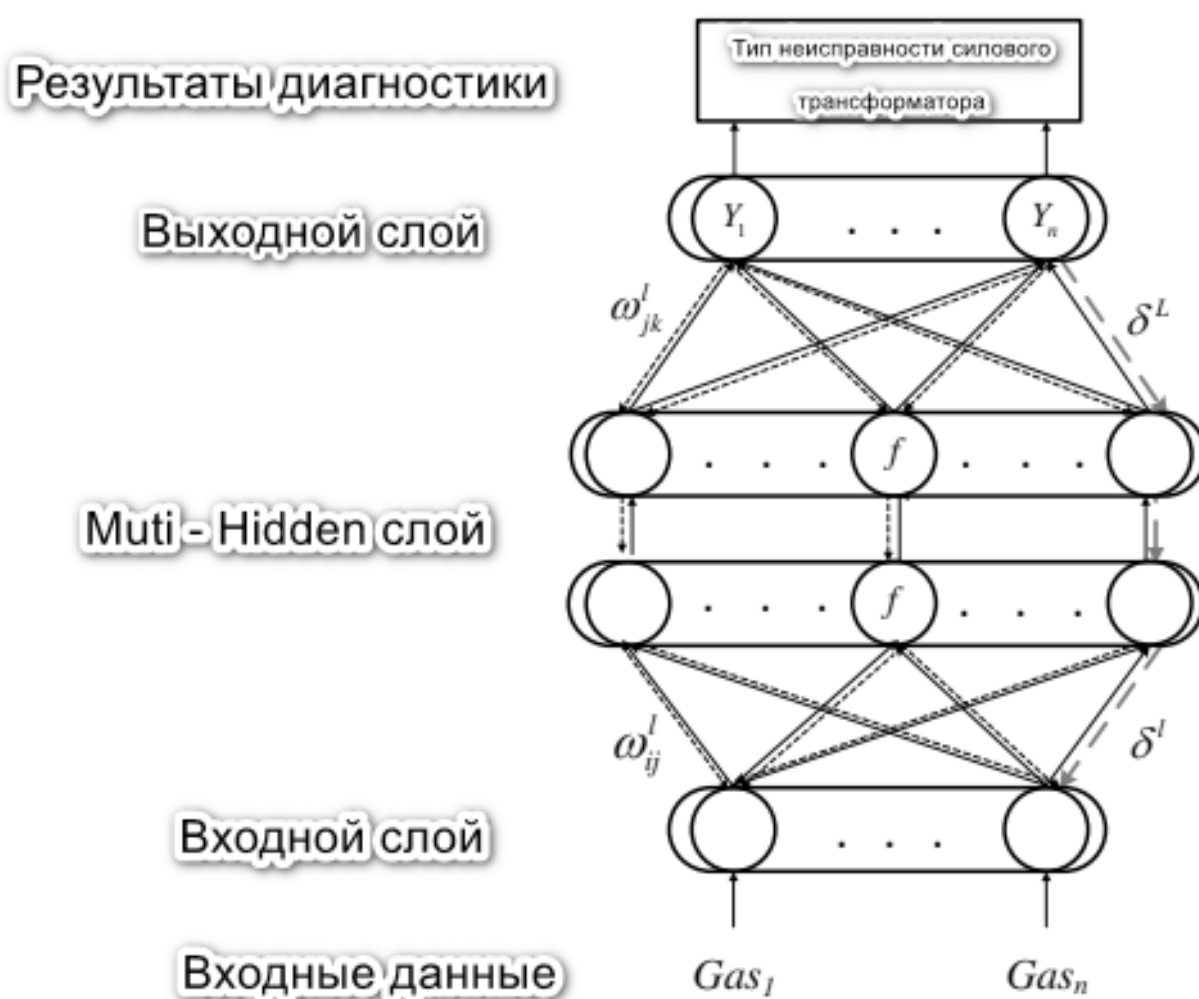


Рис. 1. Структура модели нейронной сети ОР.

от выходного слоя ко всем скрытым слоям. Наконец, исправленный результат выводится на выходной слой.

**Прямая трансляция**

После записи вектора входного значения  $x$  активация  $a^l$  во входном слое  $l$  может быть вычислена в простой и компактной векторизованной форме:

$$a^l = f(w^l a^{l-1} + b^l) \quad (l = 2, 3, \dots, L), \quad (1)$$

где  $w^l$  и  $b^l_j$  — вес и смещение между  $(l - 1)$ -м и  $l$  слоями.

Чтобы установить соответствующую активацию, в этой статье используется самая популярная сигмоидальная функция:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

Квадратичная функция критерия ошибки выборки  $n$  равна  $C$ :

$$C = \frac{1}{2n \sum_x |y(x) - a^L(x)|^2} \quad (3)$$

**Обратное распространение**

При достижении уровня  $L$  выходная ошибка  $\delta^L$  может быть вычислена с помощью:

$$\delta^L = \nabla_a C \odot \sigma'(z^L) \quad (4)$$

$\nabla_a C$  содержит скорость изменения  $C$ .  $\odot$  обозначает входное произведение двух векторов.

Впоследствии ошибка в следующем слое будет:

$$\delta^l = ((w^{l+1})^T \delta^{l+1}) \odot \sigma'(z^l) \quad (5)$$

Где  $(\omega^{l+1})^T$  — это транспонирование для  $(l + 1)$  слоя  
 $\odot \sigma'(z^l)$  — произведение Адамара

в интервале:

$$\frac{\partial C}{\partial b_j^l} = \delta_j^l \tag{6}$$

Любой вес в сети — это:

$$\frac{\partial C}{\partial \omega_{jk}^l} = a_k^{l-1} \delta_j^l \tag{7}$$

При объединении слоя (11) со слоем (12) ошибка передается в обратном направлении через функцию активации в слое  $l$ .

Структуру модели нейронной сети ОР можно увидеть на рисунке 1

Диагностика неисправностей силового трансформатора на основе оптимизированного алгоритма нейронной сети ОР может быть использована в качестве комплексной платформы диагностики, которая объединяет данные о газе в масле с системой обнаружения, а затем получит хорошие результаты с помощью контролируемых методов обучения.

Как показано на рис. 2, алгоритм оптимизирует блок-схему нейронной сети ОР. Ниже приведены основные шаги:

Шаг 1: Сначала используем метод трех коэффициентов ИЕС для обработки характеристик данных ХАГР силового трансформатора.

Шаг 2: Случайным образом выбираем различные типы неисправностей силовых трансформаторов в нейронной сети.

Шаг 3: Инициализируем параметры нейронной сети ОР.

Шаг 4: Инициализируем измененный размер поиска алгоритма  $x_i$  ( $i = 1, 2, \dots, N$ ), размер популяции  $N$ , вероятность переключения  $P_c$ , вероятность мутации  $P_m$  и значение размера шага  $\alpha_0$ , максимальное значение размера шага  $\alpha_{max}$ , минимальное значение размера шага  $\alpha_{min}$ , максимальное значение вероятности обнаружения  $P_{amax}$ , минимальное значение вероятности обнаружения  $P_{amin}$ , нелинейные коэффициенты  $m$  и  $n$ , масштабный коэффициент  $F$  и функция пригодности  $f(x)$ . Функция пригодности, которую мы использовали в этой статье, представляет собой среднеквадратичную ошибку алгоритма следующим образом:

$$f(x) = \frac{1}{2n \sum_{i=1}^n (\gamma_i - o_i)^2} \tag{8}$$

где  $\gamma_i$  — значение измерения, а  $\gamma_i$  — прогнозируемый результат.

Шаг 5: Вычислим значение пригодности исходного с помощью функции пригодности, а затем выберем текущее оптимальное решение в пространстве решений.

Шаг 6: Сгенерируем случайное число  $K1$  и сравним с  $Pc$ . Сравним  $K1$  и  $Pc$ , если  $x_i^{t+1}$  по уравнению

$$x_i^{t+1} = x_i^t + \alpha L(s, \lambda), \tag{9}$$

в противном случае по уравнению

$$x_i^{t+1} = x_i^t + t_1(x_{q1}^t - x_i^t) + T(x_{q2}^t - x_{q3}^t). \tag{10}$$

Шаг 7: Сгенерируем случайное число  $K2$  и сравните с  $Pm$  алгоритма. Если  $K2 < Pm$ , выполним мутацию по уравнению

$$x_{ik}^{t+1} = x_{ik}^t + t_2(x_{ik}^t - x_{ik}^t); \tag{11}$$

в противном случае она остается неизменной.

Шаг 8: Вычислим значение пригодности обновленного решения и обновите вероятность обнаружения  $P_a$  и размер шага  $\alpha$  с помощью уравнения

$$P_a = P_{amin} + (P_{amax} - P_{amin}) \cdot IR^m \tag{12}$$

и уравнения

$$\alpha = \alpha_{min} + (\alpha_{max} - \alpha_{min}) IR^m \tag{13}$$

Шаг 9: Сгенерируем случайное число  $K3$  и сравним с  $P_a$ . Если  $K3 > P_a$ , обновим значения  $x_i^{t+1}$  с помощью уравнения

$$x_i^{t+1} = x_i^t + r_1(x_{q1}^t - x_{q2}^t) + r_2(x_{best}^t - x_{q3}^t) \tag{14}$$

или не меняем его. Сравним последние показатели пригодности с новыми значениями, сохраним оптимальное значение в качестве последнего  $x_b$ .

Шаг 10: Если он может достичь максимального условия итерации, перейдем к следующему шагу или возвращаемся к шагу 6.

Шаг 11: Заменяем оптимизированные веса и смещение нейронной сети обратного распространения (ОР).

Шаг 12: Введем тестовый набор в обученную нейронную сеть ОР, чтобы получить выходные данные классификации.




Рис. 2. Алгоритм диагностики неисправностей силовых трансформаторов

Таблица 1. Диагностика с использованием метода трех соотношений

Тип неисправности	C2H2/C2H4	CH4/H2	C2H4/C2H6
PD	<0.1	<0.1	<0.2
D1	>1	0.1–0.5	>1
D2	0.6–2.5	0.1–1	>2
T1	NS	>1/NS	<1
T2	<0.1	>1	1–4
T3	<0.2	>1	>4

Таблица 2. Тип неисправности, используемый при анализе

№ .	Тип неисправности	Код типа неисправности
Ошибка 1	Тепловые неисправности $T > 700\text{ }^{\circ}\text{C}$	T3
Ошибка 2	Тепловые неисправности $T < 300\text{ }^{\circ}\text{C}$	T1
Ошибка 3	Высокоэнергетический разряд	D2
Ошибка 4	Низкий энергетический разряд	D1
Ошибка 5	ЧР	PD




Рис. 3. Структура процесса диагностики неисправностей силового трансформатора.

Таблица 3. Статистические данные частичных выборок.

C2H4	H2	C2H6	Тип неисправности
0.019	0.0899	2.157	T1
0.029	0.231	2.654	T1
0.0246	0.9655	8.2797	T3
0.0541	1.2551	8.9697	T3
1.38	0.211	5.396	D2
0.12	0.438	5.664	D2
8.097	2.694	1.752	D1
8.382	2.708	1.768	D1
0	0.041	0.149	PD
0.088	0.052	0.099	PD

Таблица 4. Выведите целевое кодирование различных неисправностей.

	T3	T1	D2	D1	PD
	1	0	0	0	0
	0	1	0	0	0
Формат кодирования	0	0	1	0	0
	0	0	0	1	0
	0	0	0	0	1

### Блок-схема алгоритма

В этой статье диагностика неисправностей силового трансформатора в основном разделена на четыре части: сбор и предварительная обработка данных, сегментация набора данных, обучение модели нейронной сети и сравнение выходных данных тестового набора с выходными данными обучающего набора, как показано на рисунке 3.

На рисунке 3 сначала данные ХАГР силового трансформатора будут обработаны при выборе функции с помощью метода трех коэффициентов ИЕС. Этот процесс можно увидеть в таблице 1. Затем 70% данных могут быть использованы в обучающей модели, которая была отсортирована случайным образом, чтобы гарантировать, что обучающий набор и тестовый набор содержат все типы ошибок. Остальные 30% данных используются для тестирования оптимизированной модели. В этом исследовании мы тестируем пять типов неисправностей силовых трансформаторов, а именно тепловые неисправности  $T > 700\text{ }^\circ\text{C}$ , тепловые неисправности  $T < 300\text{ }^\circ\text{C}$ , разряд высокой энергии, разряд низкой энергии и частичный разряд. Это можно увидеть в виде таблицы 2, и каждая группа данных сбалансирована. Существует 109 наборов данных.

С помощью этой оптимизационной модели можно прогнозировать и классифицировать потенциальные неисправности силовых трансформаторов.

### Экспериментальные данные

Чтобы оценить эффективность предлагаемого метода диагностики неисправностей силовых трансформаторов, мы получаем реальные данные для проведения экспериментов. Путем обработки Индекса технического состояния в трех соотношениях 109 наборов данных ХАГР получены наборы данных, отфильтрованные по признакам, некоторые из которых показаны в таблице 3. В данной работе в качестве базового классификатора используется нейронная сеть, поэтому метод заполнения данных показан в таблице 4.

Мой метод сравнивается с другими превосходными прогностическими классификаторами ОР, оптимизатором мультиверса — многослойным перцептроном (MVO-MLP), PSO-BP, GA-BP, PNN и SVM соответственно. Во-первых, сравнивается точность и частота ошибок моего алгоритма с ОР, и доказываются превосходство алгоритма в оптимизации нейронной сети. Во-вторых, путем сравнения моего алгоритма с другими алгоритмами машинного обучения и алгоритмами оптимизации доказано, что алгоритм обладает высокой надежностью и производительностью классификации.

### Результаты

Алгоритм устанавливает вероятность обнаружения  $P_a$  равной 0,25,  $A$  равной 1, а размер шага  $a$  равен 0,4. Точность классификации приведена в таблице 5. Для

Таблица 5. Сравнение основных методов (\* означает наилучший результат в таблице).

Тип неисправности	Коэффициент точности (%)		
	ОР	ИТС	Новый алгоритм
T3	100.00	100.00	100.00
T1	100.00	85.71	100.00
D2	85.71	85.71	85.71
D1	100.00	100.00	100.00
PD	0.00	100.00	100.00
Total	77.14	94.29	97.14 *

Таблица 6. Сравнение выборочных ошибок.

Модель	Тренировочный дата-сет	Тестовый дата-сет
ОР	0.0330	0.1571
ИТС	0.0053	0.0220
Новый алгоритм	0.0058	0.0204




Рис. 4. Результаты классификации модели алгоритма. (а) представляет результаты тренировочной выборки. (б) представляет собой результаты классификации тестовых образцов для метода, соответственно.

пяти типов выходных сигналов неисправностей имеет высокую скорость распознавания 97,14% с помощью выборки, а скорость распознавания классификации различных типов неисправностей выше или равна алгоритмам ОР. Как показано в таблице 6, обучающий набор и тестовый набор являются наименьшими. По сравнению с другими алгоритмами производительность моего алгоритма лучше, чем у обычного ОР и стандартного индекса технического состояния.

Чтобы дополнительно оценить производительность нового алгоритма, наносим на график выходные результаты алгоритма, такие как Рисунок 4а, для выходных данных обучающего набора и компоновки прогнозируемых результатов классификации, и рисунок 4б, для выходных данных классификации тестовых наборов. Его эффект классификации тестового набора не идеален; однако новый алгоритм (а), (б) показывает хорошую скорость распознавания и (б) показывает.



Из рисунка 4 мы знаем, что разработанный метод лучше других алгоритмов в отношении стабильности, поскольку результаты тестовых данных могут отражать, что наша модель не столкнется с проблемой чрезмерной подгонки, и как обучающая выборка, так и тестовые выборки имеют отличные результаты классификации. Это указывает на то, что эта модель полезна для диагностики неисправностей силового трансформатора, поскольку она может дать подходящее решение, для которого содержится тип неисправности силового трансформатора.

### Заключение

В этой статье предлагаю метод, основанный на машинном обучении, оптимизированную модель нейрон-

ной сети обратного распространения для диагностики неисправностей силового трансформатора. Этот алгоритм может адаптивно корректировать шаг поиска пространства решений, чтобы найти лучшее глобальное оптимальное решение, а значение пригодности каждого решения используется для построения вероятности аналитики, чтобы избежать локальной сходимости функций. Кроме того, алгоритм повышает эксплуатационную способность и скорость конвергенции. Проведенные эксперименты для проверки разработанных моделей, используя 109 наборов реальных данных, собранных с силовых трансформаторов. По сравнению с другими алгоритмами экспериментальные результаты показывают, что разработанный метод превосходит другие методы и может сходиться к оптимальному решению для большинства тестовых случаев.

### ЛИТЕРАТУРА

1. Wang, T.; He, Y.; Li, B.; Shi, T. Transformer Fault Diagnosis Using Self-powered RFID Sensor and Deep Learning Approach. *IEEE Sens. J.* 2018.
2. Tang, S.; Hale, C.; Thaker, H. Reliability modeling of power transformers with maintenance outage. *Syst. Sci. Control Eng. Open Access J.* 2014, 2, 316–324.
3. Zeng, W.; Yang, Y.; Gan, C.; Li, H.; Liu, G. Study on Intelligent Development of Power Transformer On-Line Monitoring Based on the Data of DGA. In *Proceedings of the Power and Energy Engineering Conference (ACTPEEC)*, Wuhan, China, 25–28 March 2011; стр. 1–4.
4. Abu-Elanien, A.E.B.; Salama, M.M.A.; Ibrahim, M. Calculation of a Health Index for Oil-Immersed Transformers Rated Under 69 kV Using Fuzzy Logic. *IEEE Trans. Power Deliv.* 2012, 27, 2029–2036.
5. Mauntz, M.; Peuser, J. Continuous condition monitoring of high voltage transformers by direct sensor monitoring of oil aging for a stable power network. In *Proceedings of the IEEE Conference on Diagnostics in Electrical Engineering (Diagnostika)*, Pilsen, Czech Republic, 6–8 September 2016; стр. 1–4.
6. Bakshi, A.; Kulkarni, S. V. Eigenvalue Analysis for Investigation of Tilting of Transformer Winding Conductors Under Axial Short-Circuit Forces. *IEEE Trans. Power Deliv.* 2011, 26, 2505–2512.
7. Rybel, T.D.; Singh, A.; Vandermaar, J.A.; Wang, M.; Marti, J.R.; Srivastava, K. D. Apparatus for Online Power Transformer Winding Monitoring Using Bushing Tap Injection. *IEEE Trans. Power Deliv.* 2009, 24, 996–1003.
8. Khan, S.A.; Equbal, M.D.; Islam, T. A comprehensive comparative study of DGA based transformer fault diagnosis using fuzzy logic and ANFIS models. *IEEE Trans. Dielectr. Electr. Insul.* 2015, 22, 590–596.
9. Zhou, Q.; Wang, S.; An, W.; Sun, C.; Xie, H.; Rao, J. Power transformer fault diagnosis based on DGA combined with cloud model. In *Proceedings of the 2014 International Conference on High Voltage Engineering and Application (ICHVE)*, Poznan, Poland, 8–11 September 2014; 1–4 стр.
10. Sarma, D.S.; Kalyani, G. ANN approach for condition monitoring of power transformers using DGA. In *Proceedings of the 2004 IEEE Region 10 Conference (TENCON2004)*, Chiang Mai, Thailand, 21–24 November 2004; Volume 100, стр. 444–447.
11. Palani, A.; Santhi, S.; Gopalakrishna, S.; Jayashankar, V. Real-time techniques to measure winding displacement in transformers during short-circuit tests. *IEEE Trans. Power Deliv.* 2008, 23, 726–732.
12. Биргер И. А. Техническая диагностика / И. А. Биргер — М.: Машиностроение, 1978. — 240 с.
13. Ключев В. В. Неразрушающий контроль и диагностика:
14. Справочник / В. В. Ключев, Ф. Р. Соснин, В. Н. Филинов и др. — М.: Машиностроение, 2003. — 657 с. Сви П. М. Методы и средства диагностики оборудования высокого напряжения / П. М. Сви. — М.: Энергоатомиздат, 1992. — 240 с.
15. Концепция диагностики электротехнического оборудования подстанций и линий электропередачи электрических сетей ОАО «ФСК ЕЭС». М., 2004. — 188 с.
16. Объем и нормы испытаний электрооборудования: РД 34.45–51.300–97: утв. Департаментом науки и техники РАО «ЕЭС России» 08.05.97. — М.: ЭНАС, 2004. — 153 с
17. Валуйский А.О., Мордкович А. Г., Цфасман Г. М. Система управления, мониторинга и диагностики трансформаторного оборудования // *Электро*. — 2004. — № 6. — С. 35–37.
18. Руссов В.А., Софьин Н. Н. Мониторинг технического состояния трансформаторов при помощи системы «ТДМ»: Сб. тез. докл. VIII симпозиума «Электротехника 2010». — М.: ВЭИ, 2005.
19. Монастырский А.Е., Пильщиков В. Е. Система непрерывного мониторинга изоляции силовых трансформаторов СКИТ: Сб. докл. «Методы и средства оценки состояния энергетического оборудования». Вып. 20. — СПб.: ПЭИПК, 2002.

22. Рассальский А.Н., Козик Н. Н., Левкоаский А. И. Система мониторинга и управления для силовых трансформаторов // Новое в российской электроэнергетике. — 2004. — № 6.
23. Аракелян В. Г. Оперативная диагностика состояния элегазового оборудования по физико-химическим показателям // Электротехника. — 2002-№ 3.- С. 56–65.
24. Ванин Б.Н., Львов Ю. Н., Неклепаев Б. Н. и др. О повреждениях силовых трансформаторов напряжением 110–500 кВ в эксплуатации // Электрические станции. 2001. — № 9. — С. 53–58.
25. ГОСТ 11677 85. Трансформаторы силовые. Общие технические условия. Издательство стандартов, 1986.
26. Алексеев Б. А. Система непрерывного контроля состояния крупных силовых трансформаторов // Электрические станции. 2000. -№ 8. — С. 62–71.
27. Виноградова Л.В., Игнатьев Е. Б. и др. Модели развивающихся дефектов силовых трансформаторов для компьютерной диагностики // Известия ВУЗов. Электромеханика. 1997- № 1–2 — С. 3–5.
28. Засыпкин А.С., Саїбуіс Е. И. Выявление места вероятного повреждения и управление системой охлаждения силовых трансформаторов на основе тепловой модели // Известия ВУЗов. Электромеханика. 1997. — № 1–2- С 64–65.

---

© Шайхуллин Артур Зуфарович ( a6968271@gmail.com ), Низамиев Марат Фирденатович.

Журнал «Современная наука: актуальные проблемы теории и практики»



г. Казань