

## Assessment of Power Transformer Technical State Using Explainable Artificial Intelligence

Khalyasmaa A.I., Matrenin P.V., Eroshenko S.A.

Ural Federal University, Ekaterinburg, Russian Federation

**Abstract.** The functioning of deeply integrated technological systems in the power industry depends on the quality of power supply systems. Reliable power supply requires minimizing emergencies at power plants and substations. Reducing the accident rate is possible by switching to the maintenance and repair of high-voltage equipment based on its actual technical state. Machine learning methods make it possible to assess the actual technical state of various equipment types based on an aggregated analysis of many parameters, in contrast to methods based on comparing parameters with boundary values without considering their mutual influence. Therefore, machine learning can be an effective tool for decision support systems for equipment diagnostics. The opacity of the models and the lack of interpretability of their recommendations significantly complicate industry implementation. The purpose of the study is to develop a method for increasing the interpretability of machine learning models for assessing the technical state of equipment. A power transformers' oil dataset, decision tree ensembles and the Shapley additive explanations were used. The novelty of this study is the modification of the additive Shapley additive explanations, aimed at increasing the information content of the visualization of machine learning model output interpretation. The most significant results are the substantiation of the applicability of explainable artificial intelligence for the assessment of the technical state of high-voltage equipment. In addition, for the first time in this problem, a Light gradient boosting method was applied. The proposed method allows for increasing the validity of the technical state assessment of high-voltage equipment using machine learning.

**Keywords:** technical state, diagnostics, power transformers, explainable artificial intelligence, Shapley additive explanations.

**DOI:** <https://doi.org/10.52254/1857-0070.2024.4-64.01>

**UDC:** 621.311

### Evaluarea stării tehnice a transformatoarelor de putere care utilizează metode explicabile de inteligență artificială

Halyasmaa A.I., Matrenin P.V., Eroshenko S.A.

Universitatea Federală din Ural, Ekaterinburg, Federația Rusă

**Rezumat.** Funcționarea sistemelor tehnologice profund integrate în industria energetică depinde de calitatea sistemelor de alimentare cu energie. Alimentarea fiabilă cu energie necesită reducerea la minimum a situațiilor de urgență la centralele și substațiile electrice. Reducerea ratei accidentelor este posibilă prin trecerea la întreținerea și repararea echipamentelor de înaltă tensiune pe baza stării sale tehnice reale. Metodele de învățare automată fac posibilă evaluarea stării tehnice reale a diferitelor tipuri de echipamente pe baza unei analize agregate a mai multor parametri, spre deosebire de metodele bazate pe compararea parametrilor cu valorile limită fără a lua în considerare influența lor reciprocă. Prin urmare, învățarea automată poate fi un instrument eficient pentru sistemele de sprijinire a deciziilor pentru diagnosticarea echipamentelor. Capacitatea modelelor și lipsa de interpretabilitate a recomandărilor acestora complică semnificativ implementarea în industrie. Scopul studiului este de a dezvolta o metodă de creștere a interpretabilității modelelor de învățare automată pentru evaluarea stării tehnice a echipamentelor. Au fost utilizate un set de date privind uleiul transformatoarelor de putere, ansambluri de arbore de decizie și explicațiile aditivilor Shapley. Noutatea acestui studiu este modificarea explicațiilor aditive Shapley, care vizează creșterea conținutului informațional al vizualizării interpretării rezultatelor modelului de învățare automată. Cele mai semnificative rezultate sunt fundamentarea aplicabilității inteligenței artificiale explicabile pentru evaluarea stării tehnice a echipamentelor de înaltă tensiune. În plus, pentru prima dată în această problemă, a fost aplicată o metodă de creștere a gradientului de lumină. Metoda propusă face posibilă creșterea transparenței modelelor de învățare automată în diagnosticarea echipamentelor automate.

**Cuvinte-cheie:** stare tehnică, diagnosticare, transformatoare de putere, inteligență artificială explicabilă, explicație aditivă Shepley.

**Оценка технического состояния силовых трансформаторов с использованием методов объяснимого искусственного интеллекта  
Хальясмаа А.И., Матренин П.В., Ерошенко С.А.**

Уральский федеральный университет, Екатеринбург, Российская Федерация

**Аннотация.** Функционирование глубоко интегрированных технологических систем в электроэнергетике зависит от качества их электроснабжения. Надежное электроснабжение требует минимизации аварий на электрических станциях и подстанциях. Снижение аварийности возможно при переходе к техническому обслуживанию и ремонту высоковольтного оборудования по его фактическому техническому состоянию. Методы машинного обучения позволяют выполнять оценку фактического технического состояния различных видов оборудования на основе агрегированного анализа множества параметров, в отличие от методов, основанных на сопоставлении параметров с граничными значениями без учета их взаимовлияния. Поэтому машинное обучение может быть эффективным инструментом для создания систем поддержки принятия решений при диагностике оборудования. В то же время непрозрачность таких моделей и отсутствие интерпретируемости формируемых ими рекомендаций существенно затрудняют их отраслевое внедрение. Целью исследования является разработка метода повышения интерпретируемости моделей машинного обучения в задаче оценки технического состояния оборудования на примере силовых трансформаторов с помощью предложенного модифицированного метода аддитивного объяснения Шепли. Для достижения цели были построены ансамблевые модели деревьев решений на выборке, содержащей результаты отбора проб трансформаторного масла и применен метод аддитивного объяснения Шепли. Отличием работы является модификация аддитивного объяснения Шепли, направленная на повышение информативности визуализации интерпретаций результатов моделей машинного обучения. Наиболее существенными результатами являются обоснование применимости методов объяснимого искусственного интеллекта в задаче оценки технического состояния высоковольтного оборудования; кроме того, впервые в данной задаче применен такой метод построения ансамблей как быстрый градиентный бустинг (LightGBM), показавший высокую точность. Значимость полученных результатов заключается в том, что предложенный метод позволяет повысить обоснованность принимаемых решений при определении фактического технического состояния высоковольтного оборудования с использованием моделей машинного обучения.

**Ключевые слова:** техническое состояние, диагностика, силовые трансформаторы, объяснимый искусственный интеллект, аддитивное объяснение Шепли.

## ВВЕДЕНИЕ

В настоящее время большинство электроэнергетических предприятий реализуют программу технического обслуживания и ремонта (ТОиР) высоковольтного оборудования на основе планово-предупредительной стратегии, которая не учитывает фактическое техническое состояние каждой единицы оборудования. Это приводит к необоснованному увеличению трудоемкости ТОиР или, наоборот, к авариям из-за несвоевременного обнаружения дефектов [1], что делает задачу оценки технического состояния оборудования актуальной.

К основным методам диагностики трансформаторов относятся испытания масла (коэффициент рассеяния, напряжение пробоя и т. д.), хроматографический анализ растворенного газа в масле (ХАРГ) [2-4], спектроскопия [5], обнаружение частичных разрядов [6], тепловизионный контроль [7] и другие методы испытаний [8].

Для сбора диагностических данных рассматриваются, в основном, традиционные для электроэнергетики технологии мониторинга (датчики, стационарные камеры, SCADA-системы) [9, 10].

В статье [11] представлен обзор исследований по данной теме для оценки технического состояния различных видов высоковольтного оборудования. Сложность и разнообразие физических процессов в силовом трансформаторе приводят к тому, что оценка его технического состояния представляет собой сложную задачу нелинейного отображения, поскольку входные и выходные данные являются переменными, не имеющими линейной зависимости [12].

Автоматизация процедур сбора данных с электрооборудования при использовании различных методов измерений позволяет накапливать их в больших объемах, что открывает возможности для применения методов машинного обучения. Достоинствами машинного обучения является возможность учета множества факторов (признаков) различной физической природы.

Относительно новым направлением является применение беспилотных робототехнических комплексов в составе интеллектуальных автоматизированных систем для диагностики высоковольтного оборудования электрических станций и подстанций методами искусственного интеллекта, научно-методическая

база которого сформирована в диссертации Хальясмаа А.И. «Синтез моделей и методов автоматизированной диагностики высоковольтного оборудования электрических станций и подстанций». Робототехнические комплексы могут быть как воздушного [13, 14], так и наземного типов [15].

Также в указанной диссертации обоснована эффективность ансамблевых моделей на основе деревьев решений для оценки технического состояния высоковольтного оборудования.

В статьях [15, 16, 17] описано применение нейросетевых моделей для анализа данных о концентрациях растворенных в масле газов. Также используются и другие методы машинного обучения, например, метод опорных векторов [17] и нечеткая логика [18].

Следует отметить, что методы диагностики силовых трансформаторов развиваются не только за счет применения новых математических моделей, но и за счет совершенствования методов и средств измерений [19, 20]. Однако, повышение точности и информативности входных данных также положительно влияет и на результаты, полученные с помощью машинного обучения, применение которого можно рассматривать как инструмент для автоматизации и повышения эффективности деятельности специалиста по диагностике. Но для этого модель машинного обучения должна предоставлять некоторые пояснения к своим выводам.

Поэтому в настоящее время одним из наиболее важных ограничений машинного обучения является тот факт, что они применяются как модели вида «черный ящик», поэтому полученные результаты оказываются не интерпретируемыми, что приводит к низкому уровню доверия к ним.

В задаче технической диагностики система поддержки принятия решений должна предоставлять специалистам объяснения, почему сформирована та или иная рекомендация. В области искусственного интеллекта существует отдельное направление – объяснимый искусственный интеллект (Explainable Artificial Intelligence, XAI), которое занимается вопросами повышения интерпретируемости моделей на основе искусственного интеллекта и их результатов [21, 22].

В известных работах не рассмотрена проблема интерпретации рекомендаций, которые формируются моделями машинного обучения для каждого конкретного результата анализа

технического состояния единицы оборудования. Обзор применения методов объяснимого искусственного интеллекта в промышленности [23] не содержит ни одной статьи, посвященной диагностике электрооборудования, кроме вращающихся электрических машин.

Для интерпретации моделей машинного обучения используют апостериорные методы, которые можно разделить на локальные и глобальные.

Локальные методы направлены на интерпретацию отдельных выходных результатов, а глобальные – на интерпретацию всей модели в целом, но на таком уровне, который позволяет интерпретировать затем каждый отдельный результат. Для рассматриваемой задачи достаточно использовать локальные методы такие как аддитивное объяснение Шепли (SHAP) [24, 25].

Применение SHAP в промышленности продемонстрировано для диагностики авиадвигателей [25], турбин [26], подшипников [27].

В данной работе метод SHAP применен для интерпретации результатов, формируемых моделью оценки технического состояния силовых трансформаторов по результатам анализа трансформаторного масла, а также, предложена модификация метода для более информативного визуального представления результатов.

Цель исследования – разработка метода интерпретации оценок технического состояния высоковольтного оборудования по результатам анализа масла на основе методов машинного обучения и объяснимого искусственного интеллекта.

## I. МЕТОДЫ ИССЛЕДОВАНИЯ

Для создания системы поддержки принятия решений по определению текущего технического состояния высоковольтного оборудования необходимо решить следующие задачи:

- 1) извлечение значимых признаков;
- 2) создание модели машинного обучения;
- 3) реализация интерпретации результатов.

### A. Оценка технического состояния

Для построения модели оценки технического состояния трансформатора в данной работе использованы ансамблевые модели деревьев решений:

- адаптивный бустинг деревьев решений (AdaBoost, AB) [28];
- случайный лес (Random Forest, RF) [28];

- градиентный бустинг деревьев решений (XGBoost, XGB) [29];
  - быстрый бустинг (LightGBM, LGBM) [30].
- Дерево решений (Decision Tree, DT) можно представить в виде:

$$y_i = t(X) \quad (1)$$

где  $y$  – выходное значение целевой переменной,  $X$  – вектор входных признаков,  $t$  – дерево как иерархия правил вида «ЕСЛИ  $X_j > T$ , ТО  $y = A$ , ИНАЧЕ  $y = B$ » и «ЕСЛИ  $X_j > T$ , ТО *переход к правилу K*, ИНАЧЕ *переход к правилу L*», где  $T$  – пороговое значение, индивидуальное для каждого правила,  $A$  и  $B$  – выходные значения.

Случайный лес – это ансамбль деревьев решений, каждое из которых строится на случайно выбранном подмножестве экземпляров из обучающей части датасета.

Адаптивный бустинг и экстремальный градиентный бустинг – ансамбли, которые создаются итерационно, каждая следующая модель ансамбле зависит от результатов предыдущих, стремясь минимизировать ошибку ансамбля.

В основе быстрого бустинга лежат две эвристики [31]. Первая – выбор подмножества экземпляров обучающей выборки с наибольшим значением градиента функции потерь. Вторая – объединение взаимоисключающих признаков, которые редко принимают ненулевые значения одновременно. Также были применены более простые методы: линейная регрессия с регуляризацией (Ridge); дерево решений, метод опорных векторов (SVM);  $k$ -ближайших соседей (kNN).

### В. Интерпретация решений модели

Для интерпретации решений модели использован метод аддитивного объяснения Шепли [24]. Метод основан на определении вклада каждого из признаков в выходной результат модели. При этом выполняется анализ всех возможных комбинаций признаков, чтобы учесть их взаимовлияние.

Значимость  $j$ -го признака для модели  $f(X)$  при анализе набора входных признаков  $X_i$  вычисляется как:

$$\phi_j(f, X_i) = \sum_{S \subseteq P \setminus \{j\}} \frac{|S|!(|P| - |S| - 1)!}{|P|!} \Delta f_{S,i,j} \quad (2)$$

$$\Delta f_{S,i,j} = f_{S \cup \{j\}}(X_{i,S \cup \{j\}}) - f_S(X_{i,S}) \quad (3)$$

где  $P$  – множество всех признаков. Если признак не используется, то его значение заменяется математическим ожиданием. В результате происходит оценка важности  $j$ -го признака путем анализа его влияния на результаты модели с ним и без него при всевозможных комбинациях признаков

При этом в существующих работах визуализация результатов строится, как правило, путем построения каскадной диаграммы по значениям  $\phi_j$ . В данной работе предложено вводить порог значимости и признаки с вкладом ниже него не включать в объяснение, а для остальных показывать не  $\phi_j$ , а его нормализованное значение  $\Psi_j$ :

$$\Psi_j = \phi_j / \sum_{l=1}^m \phi_l \quad (4)$$

## II. РЕЗУЛЬТАТЫ

В работе использован открытый набор данных (Open Dataset) с результатами отбора проб трансформаторного масла силовых трансформаторов [32], содержащий 470 записей, из которого были взяты:

- концентрации растворенных в масле газов:
  - водорода (H<sub>2</sub>);
  - кислорода (O<sub>2</sub>);
  - азота (N<sub>2</sub>);
  - метана (CH<sub>4</sub>);
  - оксида углерода (CO);
  - углекислого газа (CO<sub>2</sub>);
  - этилена (C<sub>2</sub>H<sub>4</sub>);
  - этана (C<sub>2</sub>H<sub>6</sub>);
  - ацетилена (C<sub>2</sub>H<sub>2</sub>);
- концентрация дибензилсульфида (DBDS);
- пробивное напряжение (BV);
- влагосодержание (WC);
- техническое состояние (Health index, HI).

Последний столбец использован как целевая переменная для задачи регрессии. В используемом наборе данных параметр Health index тем выше, чем хуже техническое состояние (0 – идеальное состояние, 100 – наихудшее возможное состояние), он не связан с понятием «Индекс технического состояния», используемого Министерством энергетики России. Кроме того, были добавлены соотношения следующих пар газов:

- C<sub>2</sub>H<sub>2</sub>/C<sub>2</sub>H<sub>4</sub>,
- CH<sub>4</sub>/H<sub>2</sub>,
- C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub>,
- CO/CO<sub>2</sub>.

Выборка данных была разделена на обучающую и тестовую в отношении 80 на 20 %. Настройка гиперпараметров выполнена с помощью случайного поиска в режиме кросс-валидации с разделением на 5 наборов. Таким образом, обучающая выборка каждый раз снова делилась в том же отношении 80 на 20 % на обучающую и валидационную.

В Таблице 1 приведены наиболее значимые гиперпараметры используемых моделей ( $d$  – максимальная глубина,  $n$  – число деревьев).

Таблица 1  
Гиперпараметры моделей  
Table 1  
Hyperparameters of the models

Модель Model	Гиперпараметр Hyperparameter	Значение Value
Ridge	$\alpha$	1
DT	$d$	5
RF	$d$	5
	$n$	27
AB	$d$	8
	$n$	22
XGB	$d$	2
	$n$	41
LGBM	$d$	3
	$n$	50
kNN	$k$	11
SVM	$\gamma$	0.05
	ядро kernel	RBF

В Таблице 2 приведены результаты тестирования моделей. Использованы следующие показатели:

- коэффициент детерминации ( $R^2$ ):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y_i^*)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (5)$$

- средняя по модулю ошибка (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i^* - y_i|, \quad (6)$$

- среднеквадратическая ошибка (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i^* - y_i)^2}, \quad (7)$$

где  $y$  – истинное значение технического состояния из выборки данных,  $y^*$  – значение, определенное моделью,  $n$  – количество экземпляров в тестовой выборке.

Таблица 2  
Результаты тестирования моделей

Table 2  
Results of models' testing

Модель Model	MAE	RMSE	$R^2$
Ridge	9.82	13.32	0.48
DT	6.76	10.22	0.69
RF	6.24	9.19	0.75
AB	8.84	11.19	0.63
XGB	5.68	8.20	0.80
LGBM	6.07	8.85	0.77
kNN	8.52	12.36	0.55
SVM	8.96	13.19	0.49

На Рисунке 1 показан вклад признаков для отдельного экземпляра выборки данных при использовании распространенного каскадного способа визуализации результатов SHAP, полученных по выражениям (2) и (3).

На Рисунке 2 для этого же экземпляра показана визуализация при использовании авторского способа на основе выражения (4) и отсеки признаков, вклад которых менее 3 %. На Рисунках 3–5 приведены результаты визуализации для других экземпляров.

### III. ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Создание моделей машинного обучения показало, что задача не может быть с высокой точностью решена путем введения ограничений по каждому из признаков или построения их взвешенной суммы. Это подтверждается тем, что результаты дерева решений, линейной регрессии, kNN и SVM оказались относительно слабыми (Таблица 2).

Применение ансамблевых моделей для оценки технического состояния высоковольтного оборудования уже было описано в научных работах. Но следует отметить необходимость применения различных моделей, поскольку априори определить, какая именно модель окажется эффективнее – невозможно. Об этом свидетельствует различие в полученных метриках точности между примененными ансамблевыми моделями. Для наилучшей модели – экстремального градиентного бустинга коэффициент детерминации составил 0.80, тогда как для адаптивного бустинга – 0.63 (Таблица 2).

Впервые для задачи диагностики силовых трансформаторов был применен алгоритм LightGBM, показавший высокую точность ( $R^2 = 0.77$ ).

Средняя ошибка по модулю для экстремального градиентного бустинга составила 5.68, для быстрого градиентного бустинга 6.07, что с учетом шкалы искомой величины  $HI$  от 0 до 100, можно трактовать как среднюю точность 94 %.

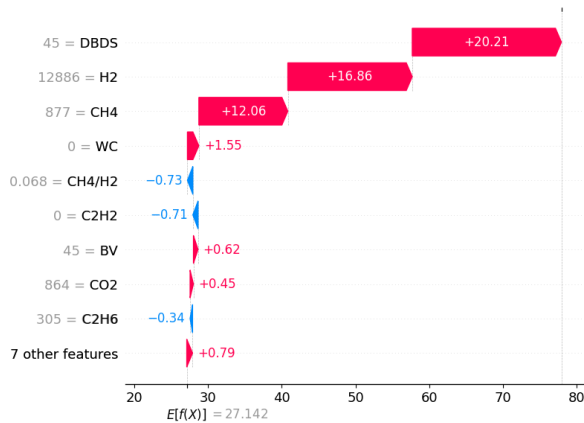


Рис. 1. Визуализация вклада признаков  
Fig. 1. Visualization of the features contribution.

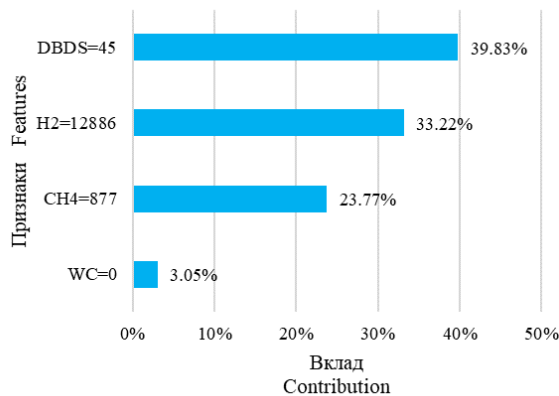


Рис. 2. Визуализация вклада признаков с использованием предложенной модификации (оценка технического состояния = 77.9).  
Fig. 2. Visualization of the features contribution with the modification proposed (estimated health index = 77.9).

Сравнение рисунков 1 и 2 позволяет сделать вывод о том, что предложенная модификация метода аддитивного объяснения Шепли приводит к более лаконичной и при этом информативной визуализации. Используются нормализованные значения вкладов, что делает более простым определение их долей в принятии решений. Вместо ограничения по числу отображаемых признаков предложено

использовать ограничения по их вкладу. Если он ниже 3 %, признак не отображается.

На Рисунках 2–4 приведены примеры интерпретации для трансформаторов в плохом техническом состоянии (77.9, 71.1, 61.5, соответственно).

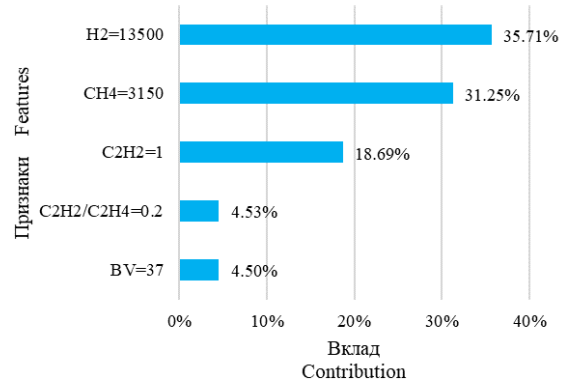


Рис. 3. Визуализация вклада признаков при оценке технического состояния 71.1  
Fig. 3. Visualization of the features contribution with the estimated health index 77.9.

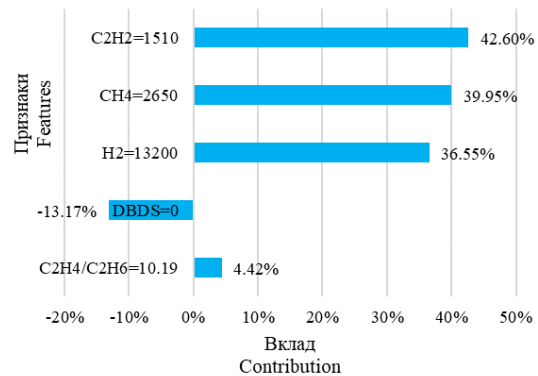


Рис. 4. Визуализация вклада признаков при оценке технического состояния 61.5  
Fig. 4. Visualization of the features contribution with the estimated health index = 61.5.

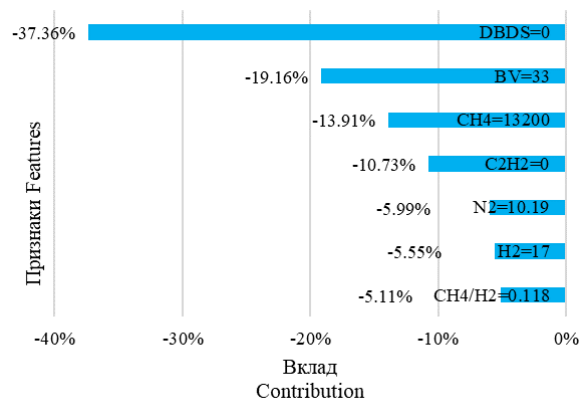


Рис. 5. Визуализация вклада признаков при оценке технического состояния 13.6  
Fig. 5. Visualization of the features contribution with the estimated health index = 13.6).

Пользователь системы поддержки принятия решений с такой визуализацией будет видеть, какие признаки повлияли на решение модели в каждом конкретном случае. На Рисунке 2 показано, что модель приняла решение о плохом техническом состоянии из-за высоких концентраций дибензилсульфида, метана и водорода. Из Рисунка 3 видно, что на результат модели повлияли концентрации водорода, метана и ацетилена.

Если значение какого-либо признака соответствует хорошему техническому состоянию, то это может скорректировать решение модели, пример показан на Рисунке 4. Отсутствие дибензилсульфида несколько поменяло оценку в лучшую сторону.

Пример результата для трансформатора с хорошим техническим состоянием приведен на Рисунке 5 (13.6 по оценке модели, при среднем значении 27.1 по выборке). Видно, что такая оценка получена из-за низких концентраций различных веществ в масле. При этом число признаков, вклад которых выше 3 % оказалось наибольшим среди рассмотренных примеров, что также логично. Принятие решения о плохом состоянии возможно даже по 1–2 основным признакам, в то время как при хорошем состоянии большинство признаков должны иметь значения в рамках нормы.

### ЗАКЛЮЧЕНИЕ

Проведено исследование метода аддитивного объяснения Шепли для повышения интерпретируемости моделей машинного обучения в задаче оценки технического состояния силовых трансформаторов на выборке данных с результатами измерений параметров трансформаторного масла. Приведены примеры объяснений результатов диагностики для модели экстремального градиентного бустинга.

Показано, что ансамблевые модели экстремального и быстрого градиентного бустинга позволяют достичь средней точности оценки технического состояния силовых трансформаторов 94 % или 0.8 по критерию  $R^2$ .

Предложенная модификация метода аддитивного объяснения Шепли позволяет сделать визуализацию его результатов более наглядной. В каждом случае распределение значимости признаков оказывается уникальным, так что выделить несколько наиболее важных для всей выборки в целом нельзя. Это подтверждает необходимость интерпретации результатов модели для каждого отдельного случая.

Предложенный подход способен ускорить внедрение методов искусственного интеллекта в задачах автоматизированной диагностики оборудования за счет повышения интерпретируемости моделей машинного обучения.

В то же время следует отметить существующие ограничения полученных результатов.

1. Используемая выборка данных не включает ряд важных параметров трансформаторного масла, она была выбрана благодаря тому, что размещена в открытом доступе. При использовании большего количества параметров появляется возможность применять метод аддитивного объяснения Шепли также для выбора наиболее значимых из них.

2. Из-за относительно небольшого объема данных в исследовании не рассмотрено применение метода для интерпретации моделей глубокого обучения.

3. Визуализация вклада признаков для каждого конкретного рассматриваемого случая все еще далека от формирования полноценного объяснения на языке эксперта.

Поэтому в качестве направлений дальнейшей работы рассматривается расширение количества параметров и возможность создания языковой модели, формирующей словесное объяснение в дополнение к визуализации.

### ACKNOWLEDGEMENTS

Работа выполнена в рамках государственного задания при финансовой поддержке Министерства науки и высшего образования Российской Федерации (тема № FEUZ-2022-0030 Разработка интеллектуальной мультиагентной системы для моделирования глубоко интегрированных технологических систем в электроэнергетике).

### Литература (References)

- [1] Li S., Li J. Condition monitoring and diagnosis of power equipment: Review and prospective. *High Voltage*, 2017, vol. 2(2), pp. 82–91. doi: 10.1049/hve.2017.0026
- [2] Duval M. The Duval triangle for load tap changers, non-mineral oils and low temperature faults in transformers. *IEEE Electrical Insulation Magazine*, 2018, vol. 24, pp. 22–29. doi: 10.1109/MEI.2008.4665347
- [3] Nanfak A, Eke S., Meghnefi F., Fofana I., Ngaleu G.M., Kom C.H. Hybrid DGA Method for Power Transformer Faults Diagnosis Based on Evolutionary k-Means Clustering and Dissolved Gas Subsets Analysis. *IEEE Transactions on Dielectrics and Electrical Insulation*, 2023, vol. 30(5), pp. 2421–2428. doi: 10.1109/TDEI.2023.3275119

- [4] Jin L., Kim D., Chan K.Y., Abu-Siada A. Deep Machine Learning-Based Asset Management Approach for Oil- Immersed Power Transformers Using Dissolved Gas Analysis. *IEEE Access*, 2024, vol. 12, pp. 27794–27809. doi: 10.1109/ACCESS.2024.3366905
- [5] Chavda A., Patel J., Bhatt H., Pandya V. Dielectric Frequency Response of Transformers-Field Experience. *Proc. 2021 IEEE Electrical Insulation Conference (EIC)*, Denver, USA, 2021, pp. 606–609. doi: 10.1109/EIC49891.2021.9612286
- [6] Gorgan B., Koltunowicz W., Zander P. Temporary Monitoring of Stator Winding Insulation Using an Advanced PD System. *Proc. 2020 International Conference on Diagnostics in Electrical Engineering (Diagnostika)*, Pilsen, Czech Republic, 2020, 4 p. doi: 10.1109/Diagnostika49114.2020.9214718
- [7] Fanchiang K.-H., Huang Y.-C., Kuo C.-C. Power Electric Transformer Fault Diagnosis Based on Infrared Thermal Images Using Wasserstein Generative Adversarial Networks and Deep Learning Classifier. *Electronics*, 2021, vol. 10, art. id. 1161. doi: 10.3390/electronics10101161
- [8] Li S., Li X., Cui Y., Li H. Review of Transformer Health Index from the Perspective of Survivability and Condition Assessment. *Electronics*, 2023, vol. 12, art. id. 2407. doi: 10.3390/electronics12112407
- [9] Sacerdotianu D., et al. Contributions to monitoring the condition of substations. *Proc. 2019 8th International Conference on Modern Power Systems (MPS)*, Cluj-Napoca, Cluj, Romania, 2019, 6 p. doi: 10.1109/MPS.2019.8759689
- [10] Ou Y., Yan Z., Xie T., Xi N., Hu X. Power Intelligent Operation and Maintenance System. *Proc. 2023 International Conference on Internet of Things, Robotics and Distributed Computing (ICIRDC)*, Rio De Janeiro, Brazil, 2023, pp. 23–27. doi: 10.1109/ICIRDC62824.2023.00010
- [11] Mantach S., Lutfi A., Moradi Tavasani H., Ashraf A., El-Hag, A., Kordi, B. Deep Learning in High Voltage Engineering: A Literature Review. *Energies*, 2022, vol. 15, art. id. 5005. doi: 10.3390/en15145005
- [12] Rokani V., Kaminaris S.D., Karaisas P., Kaminaris D. Power Transformer Fault Diagnosis Using Neural Network Optimization Techniques, *Mathematics*, 2023, vol. 11, art. id. 4693. doi: 10.3390/math11224693
- [13] Shen H., Zhang X., Alhassan A.B., Guo J., Xu H. Research on the Coupling Model for Inspection Robot to Depart from High-Voltage Transmission Line. *Proc. 2018 International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC)*, Xian, China, 2018, pp. 801–805. doi: 10.1109/SDPC.2018.8664988
- [14] Li H., et al. Study on the insulation level of the gap between UAV and typical high voltage equipment in 110 kV substation. *Proc 2022 IEEE International Conference on High Voltage Engineering and Applications (ICHVE)*, Chongqing, China, 2022, 4 p. doi: 10.1109/ICHVE53725.2022.9961657
- [15] Waikat J., et. al. First Measurement Campaign by a Multi-Sensor Robot for the Lifecycle Monitoring of Transformers. *Energies*, 2024, vol. 17, art. id. 1152. doi: 10.3390/en17051152
- [16] Barkas D.A., Kaminaris S.D., Kalkanis K.K., Ioannidis G.C., Psomopoulos C.S. Condition Assessment of Power Transformers through DGA Measurements Evaluation Using Adaptive Algorithms and Deep Learning, *Energies*, 2023, vol. 16, art. id. 54. doi: 10.3390/en16010054
- [17] Dhini A., Faqih A., Kusumoputro B., Surjandari I., Kusiak A. Data-driven Fault Diagnosis of Power Transformers using Dissolved Gas Analysis (DGA). *International Journal of Technology*, 2020, vol. 11(2), pp. 388–399. doi: /10.14716/ijtech.v11i2.3625
- [18] Ma H., Ekanayake C. Saha T.K. Power transformer fault diagnosis under measurement originated uncertainties. *IEEE Transactions on Dielectrics and Electrical Insulation*, 2012, vol. 19(6), pp. 1982–1990. doi: 10.1109/TDEI.2012.6396956
- [19] Kozlov V.K., Kurakina O.E. Moisture Content and Aromatic Compounds Determination in Transformer Oil Using Spectral Method. *Problems of the Regional energetics*, 2022, vol. 2(54), pp. 1-12. (in Russian). doi: 10.52254/1857-0070.2022.2-54.01
- [20] Kozlov V.K., Kurakina O.E., Sabitov A.H., Nigmatullina G. F., Salyakhutdinov R. A. Spectral Methods for Monitoring Transformer Equipment State of Paper Insulation. *Problems of the Regional energetics*, 2022, vol. 4(56), pp. 26-38. (in Russian). doi: 10.52254/1857-0070.2022.4-56.03
- [21] Clement T., Kemmerzell N., Abdelaal M., Amberg M. XAIR: A Systematic Metareview of Explainable AI (XAI) Aligned to the Software Development Process. *Machine Learning and Knowledge Extraction*, 2023, vol. 5, pp. 78–108. doi: 10.3390/make5010006
- [22] Kim M.Y., et al. A Multi-Component Framework for the Analysis and Design of Explainable Artificial Intelligence. *Machine Learning and Knowledge Extraction*, 2021, vol. 3, pp. 900–921. doi: 10.3390/make3040045
- [23] Alexander Z., Chau D.H., Saldana C. An Interrogative Survey of Explainable AI in Manufacturing *IEEE Transactions on Industrial Informatics*, 2024, vol. 20(5), pp. 7069–7081. doi: 10.1109/TII.2024.3361489
- [24] Lundberg S., Lee S. A Unified Approach to Interpreting Model Predictions. Available at: <https://arxiv.org/abs/1705.07874> (accessed 28.05.2024). doi: 10.48550/arXiv.1705.07874



- [25] Bourokba A., El Hamdi R., Njah M. A. A Shapley based XAI approach for a turbofan RUL estimation. *Proc. 21st International Multi-Conference on Systems, Signals & Devices (SSD)*, Erbil, Iraq, 2024, pp. 832–837. doi: 10.3390/aerospace10050474
- [26] Ghadekar P., Manakshe A., Madhikar S., Patil S., Mukadam M., Gambhir T. Predictive Maintenance for Industrial Equipment: Using XGBoost and Local Outlier Factor with Explainable AI for analysis. *Proc. 14th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, Noida, India, 2024, pp. 25–30. doi: 10.1109/Confluence60223.2024.10463280
- [27] Brusa E., Cibrario L., Delprete C., Di Maggio, L.G. Explainable AI for Machine Fault Diagnosis: Understanding Features' Contribution in Machine Learning Models for Industrial Condition Monitoring. *Applied Science*, 2023, vol. 13, art. id. 2038. doi: 10.3390/app13042038
- [28] Raschka S., Mirjalili V. Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2. *Packt Publishing Ltd.*, 2019, 770 p.
- [29] Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System. *Proc. 22nd SIGKDD Conference on Knowledge Discovery and Data Mining*, New York, USA, 2016. doi: 10.48550/arXiv.1603.02754
- [30] LightGBM 4.0. Available at: <https://lightgbm.readthedocs.io/en/stable/> (accessed 11.06.2024).
- [31] Ke G., et al. LightGBM: A Highly Efficient Gradient Boosting Decision Tree. *Advances in Neural Information Processing Systems 30 (NIPS 2017)*, 2017.
- [32] Velasquez A.M.R., Lara J.V.M. Data for: Root cause analysis improved with machine learning for failure analysis in power transformers. *Engineering Failure Analysis*, 2020, vol. 115, art. id. 104684. doi: 10.1016/j.engfailanal.2020.104684.

#### Сведения об авторах.



**Хальясмаа Александра Ильмаровна**, к.т.н., доцент, ведущий научной лабораторией цифровых двойников в электроэнергетике Уральского энергетического института Уральского федерального университета им. первого Президента России Б.Н. Ельцина (УралЭНИН УрФУ).  
Область научных интересов: диагностика состояния оборудования, возобновляемые источники энергии, искусственный интеллект в энергетике, методы обработки и анализа данных, робототехнические комплексы.  
E-mail: [a.i.khaliasmaa@urfu.ru](mailto:a.i.khaliasmaa@urfu.ru)



**Матренин Павел Викторович**, к.т.н., ведущий научный сотрудник научной лаборатории цифровых двойников УралЭНИН УрФУ  
Область научных интересов: системный анализ, искусственный интеллект в энергетике, методы обработки и анализа данных, прогнозирование временных рядов, объяснимый искусственный интеллект.  
E-mail: [p.v.matrenin@urfu.ru](mailto:p.v.matrenin@urfu.ru)



**Ерошенко Станислав Андреевич**, к.т.н., доцент кафедры электротехники УралЭНИН УрФУ.  
Область научных интересов: диагностика состояния оборудования, возобновляемые источники энергии, искусственный интеллект в энергетике, режимы работы электроэнергетических систем, робототехнические комплексы.  
E-mail: [s.a.eroshenko@urfu.ru](mailto:s.a.eroshenko@urfu.ru)