

Применение методов машинного обучения для классификации дефектов маслонаполненных трансформаторов

В.А. Шеломенцев, Р.Н. Хамитов, С.В. Сидоров, И.С. Сухачев

Тюменский индустриальный университет, Тюмень

Аннотация: В работе рассматривается задача классификации разрядных и тепловых дефектов силовых трансформаторов по данным хроматографического анализа растворенных газов, для чего сформировано расширенное признаковое пространство на основе концентраций ключевых газов и диагностических отношений согласно стандарту международной электротехнической комиссии МЭК 60599. Проведено сравнение различных методов машинного обучения, среди которых наилучшие результаты показал алгоритм случайный лес, обеспечивший максимальную точность и устойчивость классификации. Разработанный классификатор дополняет существующую систему поддержки принятия решений, обеспечивая автоматическую идентификацию природы дефектов на основе хроматографического анализа растворенных газов. Результаты исследования демонстрируют эффективность методов искусственного интеллекта в повышении надежности диагностики трансформаторного оборудования.

Ключевые слова: силовой трансформатор, хроматографический анализ растворенных газов, диагностика дефектов, частичный разряд, автоматизированное машинное обучение, ансамблевые методы, случайный лес, экстремум-деревья.

Введение

Надежная работа силовых трансформаторов требует своевременной диагностики зарождающихся дефектов [1, 2]. Дегградация трансформаторного масла и ненормальные режимы эксплуатации являются одними из основных причин отказов оборудования. Состав масла выступает индикатором технического состояния трансформатора, позволяя судить о состоянии изоляционных материалов и внутренних узлов [1]. Ранее авторами разработана система поддержки принятия решений (СППР) [3] для комплексной оценки состояния трансформаторов на основе совокупности диагностических параметров, включая результаты хроматографического анализа растворенных газов (ХАРГ), что повысило объективность мониторинга и точность прогноза остаточного ресурса оборудования. Однако интегральный индекс технического состояния, используемый в СППР, не раскрывает причины газообразования и природу развивающихся повреждений.

Существующие методики интерпретации ХАРГ [4 – 6], включая стандарт международной электротехнической комиссии МЭК 60599 и диаграммы Дюваля, широко применяются, но нередко дают разночтения при анализе одной и той же пробы масла. В ряде исследований [7 – 9] отмечены случаи расхождения диагнозов при использовании различных правил и схем интерпретации. Это ограничивает достоверность традиционных подходов и подчеркивает необходимость более углубленного анализа газовых данных. Современные методы искусственного интеллекта демонстрируют преимущество по точности интерпретации результатов ХАРГ по сравнению с жесткими правилами стандартов. Среди них используются нейро-нечеткие алгоритмы, а также модели глубокого обучения и ансамблевые методы, что подтверждает перспективность применения машинного обучения для повышения надежности диагностирования дефектов [10, 11].

Целью работы является разработка модели интеллектуальной диагностики типа дефекта на основе ХАРГ, которая дополняет СППР, расширяя ее функциональность за счет распознавания характера повреждений трансформатора.

Задачи исследования включают формирование комплексного признакового пространства для анализа данных ХАРГ; проведение сравнительного анализа алгоритмов машинного обучения для многоклассовой классификации шести основных типов дефектов трансформатора; верификацию разработанной модели с применением фреймворка эволюционного поиска оптимальных деревьев и других моделей (Framework for Evolutionary Discovery of Optimal Trees and other models – *FEDOT*).

Сравнительный анализ алгоритмов машинного обучения для классификации дефектов трансформатора

Для анализа использованы данные ХАРГ, включающие концентрации водорода H_2 , метана CH_4 , этана C_2H_6 , этилена C_2H_4 , ацетилена C_2H_2 , а также суммарное содержание углеводородов ΣHC . Эти компоненты служат основными индикаторами дефектов маслонаполненного оборудования согласно [7 – 9]. Для нормализации масштабов применено логарифмирование концентраций, а также рассчитаны диагностические отношения R_1 , R_2 , R_3 в соответствии со стандартом МЭК 60599 [4], учитывающие пропорции ключевых газов. В результате сформировано признаковое пространство, включающее как исходные, так и инженерные параметры. На рис. 1 приведен пример комбинированной визуализации распределения концентрации одного из базовых диагностических газов – водорода H_2 в логарифмическом масштабе. Аналогичные графики построены для всех остальных признаков, включенных в анализ.




Рис. 1. – Графическая визуализация распределения концентрации водорода:
а) гистограмма; б) диаграмма размаха; в) оценка плотности распределения

Перед обучением моделей выполнена очистка выборки: удалены выбросы, дубликаты и заполнены пропуски. Все числовые признаки стандартизированы. Получено 796 наблюдений с метками классов дефектов, сформированных по международной классификации [6].

Целевая переменная представляет собой тип дефекта, определенный на основе экспертного анализа ХАРГ и сопутствующих данных. Как показано в таблице № 1, всего выделено шесть категорий повреждений, отражающих различные физико-химические процессы в трансформаторе.

Таблица № 1

Классификация основных типов дефектов трансформатора по данным ХАРГ

| Класс | Тип повреждения |
|-----------|-------------------------------------|
| <i>PD</i> | Частичный разряд в газовой среде |
| <i>D1</i> | Низкоэнергетический разряд |
| <i>D2</i> | Высокоэнергетический разряд |
| <i>T1</i> | Низкотемпературный тепловой дефект |
| <i>T2</i> | Среднетемпературный тепловой дефект |
| <i>T3</i> | Высокотемпературный тепловой дефект |

Распределение классов в выборке близко к сбалансированному (от 88 до 191 наблюдений на каждый класс), что позволило обучать модели без использования специальных методов балансировки.

Для задачи многоклассовой классификации дефектов трансформаторов протестированы следующие алгоритмы машинного обучения: ансамбли на основе решающих деревьев (*случайный лес*, *экстра-деревья*), *CatBoost*, основанный на методе градиентного повышения, *метод опорных векторов*, *логистическая регрессия*, а также базовые методы – *k-ближайших соседей* и *наивный байесовский классификатор* [12 – 14]. Обучение проводилось на расширенном наборе признаков, включающем исходные концентрации, логарифмы и диагностические отношения газов. Для обеспечения корректности результатов использовались стратифицированное разбиение выборки (80/20) и *k*-блочная перекрестная проверка.

Все перечисленные модели были реализованы на основе фреймворков *scikit-learn* и *CatBoost*. Их качество оценивалось по стандартным метрикам классификации: общей точности (*Accuracy*) и макроусредненной *F*₁-мере [15,

16]. Наилучшие результаты показали ансамблевые методы, эффективность которых для задач диагностики трансформаторного оборудования подчеркивается в исследовании [17], в частности *случайный лес*, превосходящий другие алгоритмы по совокупности метрик, приведенных в таблице № 2.

Таблица № 2

Сводные итоги сравнения работы алгоритмов для задачи классификации

| Наименование алгоритма | Общая точность классификации, % | Макроусредненная F_1 -мера |
|--------------------------------|---------------------------------|------------------------------|
| <i>случайный лес</i> | 84 | 0,82 |
| <i>экстра-деревья</i> | 82 | 0,80 |
| <i>CatBoost</i> | 80 | 0,78 |
| <i>метод опорных векторов</i> | 73 | 0,70 |
| <i>логистическая регрессия</i> | 68 | 0,65 |

Несмотря на высокие значения интегральных метрик, приведенных в таблице №2, ключевым аспектом оценки качества диагностических моделей является анализ того, как именно распределяются ошибки между классами. В технической диагностике отдельных видов дефектов маслонаполненных трансформаторов характер ошибок критически важен, поскольку неверная классификация может приводить к некорректной оценке риска, пропуску опасных состояний или необоснованным диагностическим мероприятиям.

Для оценки надежности определения моделью дефектов построена матрица ошибок, приведенная на рис. 2. Матрица ошибок показала относительно сбалансированное распознавание классов PD , $D2$, $T2$ – $T3$. Наихудшие показатели отмечены для класса $D1$: значительная доля экземпляров $D1$ ошибочно классифицирована как PD или $T1$. Такой результат хорошо согласуется с выводами работ, указывающих на низкую газообразующую активность низкоэнергетических разрядов и трудности их отделения от частичных разрядов и слабых тепловых дефектов [17 – 19].




Рис. 2. – Матрица ошибок алгоритма *случайный лес* при классификации внутренних дефектов силовых трансформаторов по данным ХАРГ

Таким образом, алгоритм *случайный лес* показал наилучшие результаты классификации, обеспечив высокую точность и полноту распознавания дефектов. Наибольшую сложность для всех моделей представлял класс D1 (низкоэнергетические разряды), для которого макроусредненная F_1 -мера составила 0,66-0,68, в то время как для остальных классов F_1 превышала 0,8. Это объясняется слабой выраженностью газового состава при D1 по сравнению с более характерными профилями разрядных и тепловых повреждений.

Сравнительный анализ традиционного и автоматизированного подходов при построении модели диагностики

На следующем этапе применен фреймворк автоматизированного машинного обучения (Automated Machine Learning – *AutoML*) *FEDOT* [20] для автоматизированного построения модели диагностики по данным ХАРГ. Для автоматического подбора гиперпараметров (режим «*best_quality*») задана оптимизация по макроусредненной F_1 -мере. В процессе эволюционного

поиска перебирались различные классификаторы, ансамбли и каскадные структуры [21 – 23]. Итоговым оптимальным решением, найденным в процессе автоматического поиска, стал алгоритм *случайный лес*. Его параметры и производительность совпали с моделью, отобранной экспертом вручную. Эффективность выбранного решения подтверждается метриками: Accuracy $\approx 84\%$, макроусредненная F_1 -мера $\approx 0,82$. Таким образом, *AutoML* воспроизвел выбор эксперта, показав, что более сложные композиции не обеспечивают прироста качества для данной задачи. Полученная модель может быть использована в прикладных диагностических системах без доработки.

Сравнение традиционного подхода к построению модели с подходом на основе *AutoML* подтвердило, что алгоритм *случайный лес* демонстрирует наибольшую эффективность при интерпретации данных ХАРГ для диагностики дефектов силовых трансформаторов [24 – 26]. Алгоритм показал высокую точность, устойчивость к вариациям данных и воспроизводимость результатов. Его способность учитывать нелинейные зависимости и взаимодействия признаков обеспечивает надежное распознавание как разрядных, так и тепловых дефектов. Встроенные механизмы регуляризации и усреднения повышают устойчивость модели к шуму и выбросам. Превосходство алгоритма *случайный лес* над линейными методами и сложными ансамблевыми алгоритмами делает его оптимальным выбором для практического применения в системах диагностики.

Заключение

В результате проведенного исследования получены следующие результаты:

1. Сформировано комплексное признаковое пространство для анализа данных ХАРГ, включающее, наряду с концентрацией ключевых газов (H_2 , CH_4 , C_2H_6 , C_2H_4 , C_2H_2 , $\sum H_2C$), логарифмированные значения концентраций и

диагностические отношения R_1 , R_2 , R_3 , рассчитанные по стандарту МЭК 60599. Это обеспечило учет как абсолютных значений, так и пропорциональных связей между концентрациями газов, что критически важно для идентификации различных физико-химических процессов в трансформаторе.

2. Проведен сравнительный анализ алгоритмов машинного обучения для многоклассовой классификации шести основных типов дефектов трансформатора (PD , $D1$, $D2$, $T1$, $T2$, $T3$). Установлено, что алгоритм *случайный лес* имеет высокую эффективность, достигая значений метрик $Accuracy \approx 84\%$ и макроусредненной F_1 -меры ≈ 0.82 , что достаточно для учета сложных нелинейных зависимостей в данных и обеспечения устойчивого распознавания как разрядных, так и тепловых дефектов трансформаторов.

3. В результате верификации разработанной модели с применением *FEDOT* установлено: алгоритм *случайный лес* объективно является оптимальным решением для данной задачи; более сложные композиционные модели, генерируемые *AutoML*, не обеспечивают прироста качества, что указывает на достаточность и эффективность выбранного подхода.

Таким образом, разработанная модель интеллектуальной диагностики типа дефекта на основе ХАРГ дополняет существующую СППР, расширяя ее функциональность за счет точного распознавания характера повреждений на основе алгоритма *случайный лес* и успешно решает задачу классификации дефектов, превосходя по точности традиционные методики.

Практический эффект заключается в повышении объективности диагностики и снижении влияния человеческого фактора при интерпретации газовых показателей. Разработанный классификатор может быть интегрирован в существующие системы мониторинга как модуль вычислительной диагностики, поддерживающий переход к риск-

ориентированному обслуживанию и уменьшение вероятности аварийных отказов.

Статья подготовлена в рамках реализации гранта ФГБОУ ВО «Тюменский индустриальный университет» (проект «Программный комплекс поддержки принятия решений по обеспечению надежности и устойчивости функционирования электротехнической системы нефтяного промысла»).

Литература

1. Михеев Г.М. Трансформаторное масло. Чебоксары: ЧГУ, 2003. 197 с.
2. Михеев Г.М. Электростанции и электрические сети. Диагностика и контроль электрооборудования. Саратов: Профобразование, 2017. 297 с.
3. Шеломенцев В.А., Сухачев И.С., Сидоров С.В., Сушков В.В., Хамитов Р.Н., Чепур П.В. Разработка системы поддержки принятия решений для оценки технического состояния силовых трансформаторов // Известия Томского политехнического университета. Инжиниринг георесурсов, 2025. Т. 336. №6. С. 120-135.
4. IEC 60599:2022. Mineral oil-filled electrical equipment in service. Guide for the interpretation of the analysis of gases in transformers. Geneva: International Electrotechnical Commission, 2022. 80 p.
5. Duval M., Northrop R.B. Interpretation of gas-in-oil analyses using new IEC codes // IEEE Transactions on Power Delivery, 1990. Vol. 5. №3. pp. 1335-1343.
6. IEEE Std C57.104-2019. IEEE guide for the interpretation of gases generated in oil-immersed transformers. New York: IEEE, 2019. 72 p.
7. Saha T.K. Review of modern diagnostic techniques for assessing insulation condition in aged transformers // IEEE Transactions on Dielectrics and Electrical Insulation, 2003. Vol. 10. №5. pp. 903-917.

8. IEC 60599:2022. Mineral oil-filled electrical equipment in service. Guide to the interpretation of dissolved and free gases analysis. Geneva: International Electrotechnical Commission, 2022. 88 p.

9. Dladla V.M.N., Thango B.A. Fault Classification in Power Transformers via Dissolved Gas Analysis and Machine Learning Algorithms: A Systematic Literature Review // Applied Sciences, 2025. Vol. 15, №5. P. 2395.

10. Хохлов Д.А. Инновационные методы диагностики и мониторинга состояния трансформаторов // Вестник науки, 2024. Т. 2. №7. С. 548-551.

11. Nanfak A., Eke S., Kom C.H., Fofana I. A dissolved gases analysis method for power transformer faults diagnosis based on the observation of subsets of labelled fault data // Journal of Electrical Engineering & Technology, 2025. Vol. 20. pp. 2019-2028.

12. Методические указания по подготовке и проведению хроматографического анализа газов, растворенных в масле силовых трансформаторов: РД 34.46.303-98. Москва: Госэнергоатом, 1998. 35 с.

13. Методические указания по диагностике развивающихся дефектов трансформаторного оборудования по результатам хроматографического анализа газов, растворенных в масле: РД 153-34.0-46.302-00, 2000. 26 с.

14. Диагностика дефектов трансформаторного оборудования по результатам анализа растворенных газов: СТО 34.01-23-003-2019, 2019. 63 с.

15. Григорьева С.В., Бородянский И.А. Современные средства, используемые при формировании интеллектуальных систем управления // Инженерный вестник Дона, 2025. №1. URL: ivdon.ru/ru/magazine/archive/n1y2025/9788.

16. Скворцов, А.А., Анурьева М.С., Солодовников А.Н. Применение алгоритмов машинного обучения для прогнозирования отказов и адаптивного управления производственными системами // Инженерный вестник Дона, 2025. №5. URL: ivdon.ru/ru/magazine/archive/n5y2025/10059.

17. Ru F., Zhang L., Yang X., Zou H., Lu Y., Xu X. Transformer fault diagnosis based on dissolved gas analysis in oil and ensemble learning // 2022 IEEE 5th International Electrical and Energy Conference (CIEEC), 2022.

18. Liu C., Yang W. Transformer fault diagnosis using machine learning: a method combining SHAP feature selection and intelligent optimization of LGBM // Energy Informatics, 2025. Vol. 8. P. 52.

19. Olowolafe F., Adari D., Fuzzy, Olatunde A.B. logic and decision tree models for dissolved gas analysis of power transformers // AJERD (Abuad Journal of Engineering Research and Development), 2024. Vol. 16, №1. URL: [mail.journals.abuad.edu.ng/index.php/ajer/article/view/329/247](mailto:journals.abuad.edu.ng/index.php/ajer/article/view/329/247) (дата обращения: 24.11.2025).

20. Nikitin N.O., Vychuzhanin P., Sarafanov M., Polonskaia I.S., Revin I., Barabanova I.V., Maximov G., Kalyuzhnaya A.V., Boukhanovsky A. Automated evolutionary approach for the design of composite machine learning pipelines // Future Generation Computer Systems, 2022. Vol. 127. pp. 109-125.

21. Suwarno, Sutikno H., Prasajo R.A., Abu-Siada A. Machine learning based multi-method interpretation to enhance dissolved gas analysis for power transformer fault diagnosis // Heliyon, 2024. Vol. 10, №4. P. e25975.

22. Белякова А.Ю., Беляков Ю.Д. Разработка программного продукта для анализа и прогнозирования концентрации газов в трансформаторном масле // Инженерный вестник Дона, 2021. №4. URL: ivdon.ru/ru/magazine/archive/n4y2021/6940.

23. Гимадиев Р.А., Ившин И.В., Денисова Н.В., Билалов Ф.Ф., Валиуллин Р.Р., Бикчурин Р.Р. Программный комплекс для контроля технического состояния силовых трансформаторов по анализу масла // Вестник Казанского технологического университета, 2016. №20. URL: cyberleninka.ru/article/n/programmnyy-kompleks-dlya-kontrolya-tehnicheskogo-

sostoyaniya-silovyh-transformatorov-po-analizu-masla (дата обращения: 24.11.2025).

24. Chanchotisation P., Vong C. Feature engineering and feature selection for fault type classification from dissolved gas values in transformer oil // ICSEC 2021 – 25th International Computer Science and Engineering Conference, 2021. pp. 75-80.

25. Sutikno H., Suwarno N.A., Prasajo R.A., Abu-Siada A. Machine learning based multi-method interpretation to enhance dissolved gas analysis for power transformer fault diagnosis // Heliyon, 2024. Vol. 10, №4. P. e25975.

26. Al-Sakini S. R., Bilal G.A., Sadik A.T., Al-Maliki W. Dissolved Gas Analysis for Fault Prediction in Power Transformers Using Machine Learning Techniques // Applied Sciences, 2024. Vol. 15, №1. P. 118.

References

1. Mikheev G. M. Transformatornoe maslo [Transformer oil]. Cheboksary: CSU, 2003. 197 p.

2. Mikheev, G. M. Elektrostantsii i elektricheskie seti. Diagnostika i kontrol' elektrooborudovaniya [Power plants and electrical grids. Diagnostics and monitoring of electrical equipment]. Saratov: Profobrazovanie, 2017. 297 p.

3. Shelomentsev V.A., Sukhachev I.S, Sidorov S.V., Sushkov V.V., Khamitov R.N., Chepur P.V. Izvestiya Tomskogo politekhnicheskogo universiteta. Inzhiniring georesursov, 2025. Vol. 336. №6. pp. 120-135.

4. IEC 60599:2022. Mineral oil-filled electrical equipment in service. Guide for the interpretation of the analysis of gases in transformers. Geneva: International Electrotechnical Commission, 2022. 80 p.

5. Duval M., Northrop R.B. IEEE Transactions on Power Delivery, 1990. Vol. 5. №3. pp. 1335-1343.

6. IEEE Std C57.104-2019. IEEE guide for the interpretation of gases generated in oil-immersed transformers. New York : IEEE, 2019. 72 p.

7. Saha T. K. IEEE Transactions on Dielectrics and Electrical Insulation, 2003. Vol. 10. №5. pp. 903-917.

8. IEC 60599:2022. Mineral oil-filled electrical equipment in service. Guide to the interpretation of dissolved and free gases analysis. Geneva: International Electrotechnical Commission, 2022. 88 p.

9. Dladla V.M.N., Thango B.A. Applied Sciences, 2025. Vol. 15, №5. P. 2395

10. Khokhlov, D. A. Vestnik nauki, 2024. Vol. 2. № 7. pp. 548-551.

11. Nanfak A., Eke S., Kom C.H., Fofana I. Journal of Electrical Engineering & Technology, 2025. Vol. 20. pp. 2019-2028.

12. Metodicheskie ukazaniya po podgotovke i provedeniyu khromatograficheskogo analiza gazov, rastvorenykh v masle silovykh transformatorov: RD 34.46.303-98 [Guidelines for the preparation and performance of chromatographic analysis of gases dissolved in oil of power transformers: RD 34.46.303-98]. Moskva: Gosenergoatom, 1998. 35 p.

13. Metodicheskie ukazaniya po diagnostike razvivayushchikhsya defektov transformatornogo oborudovaniya po rezul'tatam khromatograficheskogo analiza gazov, rastvorenykh v masle: RD 153-34.0-46.302-00 [Guidelines for the diagnosis of developing defects in transformer equipment based on the results of chromatographic analysis of gases dissolved in oil: RD 153-34.0-46.302-00], 2000. 26 p.

14. Diagnostika defektov transformatornogo oborudovaniya po rezul'tatam analiza rastvorenykh gazov: STO 34.01-23-003-2019 [Diagnostics of defects in transformer equipment based on dissolved gas analysis results: STO 34.01-23-003-2019], 2019. 63 p.

15. Grigoryeva S.V., Borodyansky I.A. Inzhenernyi vestnik Dona, 2025. №1. URL: ivdon.ru/ru/magazine/archive/n1y2025/9788.

16. Skvortsov, A.A., Anuryeva M.S., Solodovnikov A.N. Inzhenernyi vestnik Dona, 2025. №5. URL: ivdon.ru/ru/magazine/archive/n5y2025/10059.

17. Ru F., Zhang L., Yang X., Zou H., Lu Y., Xu X. 2022 IEEE 5th International Electrical and Energy Conference (CIEEC), 2022.
18. Liu C., Yang W. Energy Informatics, 2025. Vol. 8. P. 52.
19. Olowolafe F., Adari D., Fuzzy, Olatunde A.B. AJERD (Abuad Journal of Engineering Research and Development), 2024. Vol. 16, №1. URL: [mail.journals.abuad.edu.ng/index.php/ajer/article/view/329/247](mailto:journals.abuad.edu.ng/index.php/ajer/article/view/329/247) (date of the application 24.11.2025).
20. Nikitin N.O., Vychuzhanin P., Sarafanov M., Polonskaia I.S., Revin I., Barabanova I.V., Maximov G., Kalyuzhnaya A.V., Boukhanovsky A. Future Generation Computer Systems, 2022. Vol. 127. pp. 109-125.
21. Suwarno, Sutikno H., Prasjo R.A., Abu-Siada A. Heliyon, 2024. Vol. 10, №4. P. e25975.
22. Belyakova A.Yu., Belyakov Yu.D. Inzhenernyi vestnik Dona, 2021. №4. URL: ivdon.ru/ru/magazine/archive/n4y2021/6940.
23. Gimadiev R.A., Ivshin I.V., Denisova N.V., Bilalov F.F., Valiullin R.R., Bikchurin R.R. Vestnik Kazanskogo tekhnologicheskogo universiteta, 2016. №20. URL: cyberleninka.ru/article/n/programmnyy-kompleks-dlya-kontrolya-tehnicheskogo-sostoyaniya-silovyh-transformatorov-po-analizu-masla (date accessed: 24.11.2025).
24. Chanchotisation P., Vong C. ICSEC 2021 – 25th International Computer Science and Engineering Conference, 2021. pp. 75-80.
25. Sutikno H., Suwarno N.A., Prasjo R.A., Abu-Siada A. Heliyon, 2024. Vol. 10, №4. P. e25975.
26. Al-Sakini S. R., Bilal G.A., Sadik A.T., Al-Maliki W. Applied Sciences, 2024. Vol. 15, №1. P. 118.

Авторы согласны на обработку и хранение персональных данных.

Дата поступления: 4.11.2025

Дата публикации: 23.12.2025