

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**ANDRÉ LUÍS BARBOSA FRANÇA ALVES**

**AUGUSTO FRIZON NOBRE**

**MATHEUS VINÍCIUS DE OLIVEIRA PRESTES**

**INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO PREDITIVA DE  
FALHAS EM TRANSFORMADORES ELÉTRICOS DE POTÊNCIA**

**CURITIBA**

**2026**

**ANDRÉ LUÍS BARBOSA FRANÇA ALVES  
AUGUSTO FRIZON NOBRE  
MATHEUS VINÍCIUS DE OLIVEIRA PRESTES**

**INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO PREDITIVA DE  
FALHAS EM TRANSFORMADORES ELÉTRICOS DE POTÊNCIA**

**ARTIFICIAL INTELLIGENCE IN PREDICTIVE FAULT DETECTION  
IN POWER TRANSFORMERS**

Trabalho de Conclusão de Curso de Graduação apresentado como requisito para obtenção do título de Bacharel em Engenharia de Controle e Automação do curso de Engenharia de Controle e Automação da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador: Prof. Dr. Narco Afonso Ravazolli Maciejewski

**CURITIBA**

**2026**



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

**ANDRÉ LUÍS BARBOSA FRANÇA ALVES  
AUGUSTO FRIZON NOBRE  
MATHEUS VINÍCIUS DE OLIVEIRA PRESTES**

**INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO PREDITIVA DE  
FALHAS EM TRANSFORMADORES ELÉTRICOS DE POTÊNCIA**

Trabalho de Conclusão de Curso de Graduação apresentado como requisito para obtenção do título de Bacharel em Engenharia de Controle e Automação do curso de Engenharia de Controle e Automação da Universidade Tecnológica Federal do Paraná (UTFPR).

Data de aprovação: 19 / Junho / 2026

---

Narco Afonso Ravazolli Maciejewski  
Doutorado  
Universidade Tecnológica Federal do Paraná

---

Mariana Antonia Aguiar Furucho  
Doutorado  
Universidade Tecnológica Federal do Paraná

---

Roberto Zanetti Freire  
Doutorado  
Universidade Tecnológica Federal do Paraná

**CURITIBA  
2026**

## **AGRADECIMENTOS**

Primeiramente, agradecemos a Deus por nos conceder sabedoria, força e perseverança ao longo desta jornada. Sua presença foi essencial para superar os desafios e alcançar esta conquista.

À nossas famílias, expressamos nossa profunda gratidão pelo apoio incondicional, paciência e compreensão durante todo o curso. Vocês foram o pilar que sustentou nossa trajetória, oferecendo suporte nos momentos de dificuldade e celebrando conosco cada vitória. Sem o amor e o incentivo de vocês, esta conquista não teria o mesmo significado.

Aos amigos e colegas de curso, nosso sincero obrigado por tornarem esta jornada mais leve e prazerosa. O companheirismo, as trocas de conhecimento e os momentos compartilhados fizeram toda a diferença. Juntos, transformamos desafios em aprendizado e construímos memórias que levaremos para toda a vida.

À Universidade Tecnológica Federal do Paraná (UTFPR) e a todos os professores que contribuíram para nossa formação acadêmica e profissional, nosso reconhecimento e gratidão.

“A missão da IA não é substituir os humanos,  
mas entender e empoderar a mente humana.”  
(Li, 2025).

## RESUMO

Este trabalho tem como objetivo desenvolver uma plataforma de diagnóstico preditivo para transformadores de potência, baseada em Inteligência Artificial (IA). A solução emprega algoritmos de *Machine Learning* (ML) para analisar dados de *Dissolved Gas Analysis* (DGA), com o propósito de evitar manutenções corretivas, prevenir danos aos equipamentos e obter acurácia superior à dos métodos convencionais como Método dos Gases Chave e Triângulo de Duval. Para o embasamento teórico, o estudo revisa a literatura sobre o funcionamento de transformadores, os tipos de falhas elétricas recorrentes, as normas e os fundamentos da DGA, além de apresentar uma análise comparativa dos métodos de IA aplicáveis. A metodologia proposta estrutura-se em três etapas fundamentais. A primeira consiste na aquisição e no tratamento de dados de DGA, aplicando técnicas de pré-processamento para normalização dos valores e remoção de *outliers*, visando garantir a qualidade da base de treinamento. Na segunda etapa, realiza-se o treinamento supervisionado dos algoritmos *Artificial Neural Networks* (ANN), *k-Nearest Neighbor* (k-NN) e *Support Vector Machine* (SVM). Para assegurar a robustez dos modelos, adota-se o método de validação cruzada, mitigando os riscos de sobreajuste do modelo (*overfitting*). A avaliação de desempenho foi conduzida com base em métricas estatísticas, comparando os resultados obtidos aos diagnósticos fornecidos por métodos clássicos, como o Triângulo de Duval e as razões de gases. Os resultados demonstraram que os classificadores de aprendizado de máquina alcançaram acurácias expressivamente superiores aos métodos tradicionais, que se mostraram estruturalmente limitados e incapazes de identificar transformadores em condição normal de operação. Adicionalmente, foi desenvolvida uma interface interativa de visualização que permite a inserção de concentrações gasosas e retorna o diagnóstico preditivo com o respectivo nível de confiança, consolidando assim o uso de técnicas de ML como suporte efetivo à tomada de decisão em sistemas de potência.

Palavras-chave: análise de gases dissolvidos; aprendizado de máquina; inteligência artificial; manutenção preditiva; transformadores de potência.

## ABSTRACT

This work aimed to develop a predictive diagnostic platform for power transformers, based on Artificial Intelligence (AI). The solution employs Machine Learning (ML) algorithms to analyze Dissolved Gas Analysis (DGA) data, with the purpose of avoiding corrective maintenance, preventing equipment damage, and achieving accuracy superior to that of conventional methods such as the Key Gas Method and Duval's Triangle. For the theoretical foundation, the study reviews the literature on transformer operation, the types of recurrent electrical faults, the standards and fundamentals of DGA, and presents a comparative analysis of applicable AI methods. The proposed methodology is structured in three fundamental stages. The first consists of the acquisition and treatment of DGA data, applying preprocessing techniques for value normalization and outlier removal, aiming to ensure the quality of the training dataset. In the second stage, supervised training of the Artificial Neural Networks (ANN), k-Nearest Neighbor (k-NN), and Support Vector Machine (SVM) algorithms is carried out. To ensure the robustness of the models, the cross-validation method is adopted, mitigating the risks of overfitting. The performance evaluation was conducted based on statistical metrics, comparing the results obtained with the diagnoses provided by classical methods, such as the Duval Triangle and gas ratios. The results demonstrated that the machine learning classifiers achieved accuracies significantly superior to the traditional methods, which proved to be structurally limited and unable to identify transformers under normal operating conditions. Additionally, an interactive visualization interface was developed that allows the input of gas concentrations and returns the predictive diagnosis with the respective confidence level, thus consolidating the use of ML techniques as effective support for decision-making in power systems.

**Keywords:** artificial intelligence; dissolved gas analysis; machine learning; power transformers; predictive maintenance.

## LISTA DE ILUSTRAÇÕES

<b>Figura 1</b>	<b>– Fluxo mútuo e disperso de um transformador .....</b>	<b>16</b>
<b>Figura 2</b>	<b>– Circuito equivalente do transformador .....</b>	<b>17</b>
<b>Figura 3</b>	<b>– Sistema de isolamento básico .....</b>	<b>19</b>
<b>Figura 4</b>	<b>– Transformador a seco WEG .....</b>	<b>20</b>
<b>Figura 5</b>	<b>– Óleo de isolamento no transformador de potência .....</b>	<b>21</b>
<b>Figura 6</b>	<b>– Cromatógrafo .....</b>	<b>25</b>
<b>Figura 7</b>	<b>– Representação tridimensional das razões de Rogers .....</b>	<b>28</b>
<b>Figura 8</b>	<b>– Triângulo de Duval para DGA .....</b>	<b>29</b>
<b>Figura 9</b>	<b>– Pentágono de Duval 1 .....</b>	<b>29</b>
<b>Figura 10</b>	<b>– Taxonomia do aprendizado indutivo .....</b>	<b>32</b>
<b>Figura 11</b>	<b>– Fluxo do processo de aprendizado supervisionado .....</b>	<b>32</b>
<b>Figura 12</b>	<b>– Comparação entre neurônio biológico e neurônio artificial .....</b>	<b>34</b>
<b>Figura 13</b>	<b>– Arquitetura de ANN do tipo Perceptron Multicamada (MLP) .....</b>	<b>35</b>
<b>Figura 14</b>	<b>– Hiperplano linear .....</b>	<b>36</b>
<b>Figura 15</b>	<b>– Hiperplano não linear .....</b>	<b>37</b>
<b>Figura 16</b>	<b>– Representação da distância euclidiana entre pontos no espaço de características .....</b>	<b>38</b>
<b>Figura 17</b>	<b>– Exemplo ilustrativo do método k-NN para classificação de um novo ponto .....</b>	<b>39</b>
<b>Figura 18</b>	<b>– Tela de inclusão de amostra do PEDITRAFO .....</b>	<b>43</b>
<b>Figura 19</b>	<b>– Correlação .....</b>	<b>49</b>
<b>Figura 20</b>	<b>– Boxplot H2 .....</b>	<b>50</b>
<b>Figura 21</b>	<b>– Boxplot CH4 .....</b>	<b>51</b>
<b>Figura 22</b>	<b>– Boxplot C2H6 .....</b>	<b>51</b>
<b>Figura 23</b>	<b>– Boxplot C2H4 .....</b>	<b>52</b>
<b>Figura 24</b>	<b>– Boxplot C2H2 .....</b>	<b>52</b>
<b>Figura 25</b>	<b>– Distribuição original .....</b>	<b>54</b>
<b>Figura 26</b>	<b>– Distribuição balanceada .....</b>	<b>55</b>
<b>Figura 27</b>	<b>– Divisão treino teste .....</b>	<b>56</b>
<b>Figura 28</b>	<b>– Dashboard .....</b>	<b>57</b>
<b>Figura 29</b>	<b>– Visualização .....</b>	<b>58</b>
<b>Figura 30</b>	<b>– Matriz de confusão do modelo K-NN .....</b>	<b>65</b>
<b>Figura 31</b>	<b>– Matriz de confusão do modelo SVM .....</b>	<b>66</b>
<b>Figura 32</b>	<b>– Matriz de confusão do modelo ANN .....</b>	<b>69</b>
<b>Figura 33</b>	<b>– Análise realizada por Triângulo de Duval .....</b>	<b>72</b>
<b>Figura 34</b>	<b>– Análise realizada por Pentágono de Duval .....</b>	<b>73</b>
<b>Figura 35</b>	<b>– Sistema de visualização de dados para o Exemplo 1 .....</b>	<b>74</b>
<b>Figura 36</b>	<b>– Sistema de visualização de dados para o Exemplo 2 .....</b>	<b>75</b>
<b>Figura 37</b>	<b>– Sistema de visualização de dados para o Exemplo 3 .....</b>	<b>76</b>

## LISTA DE TABELAS

Tabela 1 – Comparação das características físico-químicas dos isolantes óleo mineral e silicone .....	21
Tabela 2 – Distribuição de falhas em componentes de um transformador regulador.	23
Tabela 3 – Classificação de falhas em transformadores de potência segundo a norma IEC 60599 .....	26
Tabela 4 – Gases-chave e tipos de falhas associados conforme NBR 7274 .....	27
Tabela 5 – Critérios de diagnóstico baseados nas razões de Rogers conforme IEC 60599 .....	27
Tabela 6 – Distribuição das classes de falha no <i>dataset</i> original.....	47
Tabela 7 – Bibliotecas <i>Python</i> utilizadas.....	48
Tabela 8 – Resumo da classificação pelo método das razões de gases IEC 60599.....	59
Tabela 9 – Relatório de classificação do método IEC 60599 (amostras efetivamente classificadas) .....	60
Tabela 10 – Distribuição das predições pelo Triângulo de Duval 1 .....	61
Tabela 11 – Relatório de classificação do Triângulo de Duval 1 .....	62
Tabela 12 – Distribuição das classes do <i>dataset</i> após pré-processamento. ....	63
Tabela 13 – Relatório de classificação do modelo K-NN ( $K = 4$ ).....	64
Tabela 14 – Métricas de desempenho do classificador SVM por classe de falha. ....	66
Tabela 15 – Espaço de busca de hiperparâmetros da ANN.....	67
Tabela 16 – Métricas globais da ANN no conjunto de teste. ....	68
Tabela 17 – Relatório de classificação da ANN no conjunto de teste. ....	68
Tabela 18 – Desempenho global dos modelos .....	70
Tabela 19 – F1-score por classe de falha .....	70
Tabela 20 – Falsos positivos (FP) e falsos negativos (FN) por classe e por algoritmo...	71
Tabela 21 – Total de erros e percentual em relação ao banco de teste .....	71

## LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ANN	<i>Artificial Neural Networks</i> (Redes Neurais Artificiais)
CELPE	Companhia Energética de Pernambuco
DGA	<i>Dissolved Gas Analysis</i> (Análise de Gases Dissolvidos)
DL	<i>Deep Learning</i> (Aprendizado Profundo)
FN	<i>False Negatives</i> (Falsos Negativos)
FP	<i>False Positives</i> (Falsos Positivos)
IA	<i>Inteligência Artificial</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
IEC	<i>International Electrotechnical Commission</i> (Comissão Eletrotécnica Internacional)
IEEE	<i>Institute of Electrical and Electronics Engineers</i> (Instituto de Engenheiros Elétricos e Eletrônicos)
k-NN	<i>k-Nearest Neighbor</i> (K vizinhos mais próximos)
ML	<i>Machine Learning</i> (Aprendizado de Máquina)
MLP	<i>Multi Layer Perceptron</i> (Multi Layer Perceptron)
NBR	Normas Brasileiras
NF	<i>Normal Functioning</i> (Funcionamento Normal)
O&M	Operação e Manutenção
P&D	Pesquisa e Desenvolvimento
ppm	partes por milhão
SMOTE	<i>Synthetic Minority Over-sampling Technique</i> (Técnica de Sobreamostragem Sintética da Classe Minoritária)
SVM	<i>Support Vector Machine</i> (Máquina de vetores de suporte)
TN	<i>True Negatives</i> (Verdadeiros Negativos)
TP	<i>True Positives</i> (Verdadeiros Positivos)

UFPE Universidade Federal de Pernambuco

UTFPR Universidade Tecnológica Federal do Paraná

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>13</b>
<b>1.1</b>	<b>Objetivos</b> .....	<b>14</b>
1.1.1	Objetivo geral .....	14
1.1.2	Objetivos específicos .....	14
<b>1.2</b>	<b>Estrutura do trabalho</b> .....	<b>14</b>
<b>2</b>	<b>TRANSFORMADORES DE POTÊNCIA</b> .....	<b>16</b>
<b>2.1</b>	<b>Características construtivas</b> .....	<b>17</b>
<b>2.2</b>	<b>Materiais isolantes</b> .....	<b>18</b>
2.2.1	Transformadores a seco .....	18
2.2.2	Líquido isolante .....	20
<b>2.3</b>	<b>Falhas nos transformadores de potência</b> .....	<b>22</b>
<b>2.4</b>	<b>Fundamentos da análise de gases dissolvidos</b> .....	<b>23</b>
2.4.1	Análise cromatográfica .....	24
2.4.2	Normas aplicáveis .....	25
2.4.3	Tipos de falhas identificadas .....	25
2.4.4	Métodos de interpretação .....	27
2.4.5	Método DGA na manutenção preditiva .....	30
<b>3</b>	<b>APRENDIZADO DE MÁQUINAS APLICADO À DETECÇÃO DE FA-</b> <b>LHAS</b> .....	<b>31</b>
<b>3.1</b>	<b>Tipos de aprendizado de máquina</b> .....	<b>31</b>
<b>3.2</b>	<b>Conjuntos de dados em ML</b> .....	<b>33</b>
<b>3.3</b>	<b>Classificadores supervisionados</b> .....	<b>34</b>
3.3.1	<i>Artificial Neural Network</i> .....	34
3.3.2	<i>Support Vector Machine</i> .....	36
3.3.3	<i>K-Nearest Neighbors</i> .....	37
<b>3.4</b>	<b>Aplicação de classificadores na análise de gases dissolvidos</b> .....	<b>39</b>
3.4.1	Limitações dos métodos convencionais de DGA .....	39
3.4.2	Classificadores inteligentes aplicados a DGA .....	40
<b>3.5</b>	<b>Métricas para avaliação de desempenho de classificadores</b> .....	<b>40</b>
<b>4</b>	<b>TRABALHOS RELACIONADOS</b> .....	<b>42</b>
<b>4.1</b>	<b>Sistema inteligente de manutenção preditiva de transformadores: PRE-</b> <b>DITRAFO</b> .....	<b>42</b>
<b>4.2</b>	<b>Diagnóstico inteligente de falhas em transformadores utilizando DGA</b> ....	<b>43</b>
<b>4.3</b>	<b>Monitoramento e diagnóstico de um transformador de potência: análise</b> <b>de gases dissolvidos no óleo e análise térmica</b> .....	<b>44</b>
<b>4.4</b>	<b>Posicionamento da pesquisa atual</b> .....	<b>45</b>
<b>5</b>	<b>METODOLOGIA</b> .....	<b>47</b>
<b>5.1</b>	<b>Base de dados</b> .....	<b>47</b>
<b>5.2</b>	<b>Ambiente computacional</b> .....	<b>48</b>
<b>5.3</b>	<b>Pré-processamento dos dados</b> .....	<b>48</b>
5.3.1	Remoção de <i>outliers</i> .....	49
5.3.2	Cálculo das razões dos gases .....	53
5.3.3	Balanceamento das classes .....	53
5.3.4	Divisão do conjunto de dados .....	55
<b>5.4</b>	<b>Otimização de hiperparâmetros</b> .....	<b>56</b>
<b>5.5</b>	<b>Sistema de visualização de dados</b> .....	<b>57</b>

<b>6</b>	<b>RESULTADOS E DISCUSSÕES .....</b>	<b>59</b>
<b>6.1</b>	<b>Métodos tradicionais de diagnóstico.....</b>	<b>59</b>
6.1.1	Razões de gases.....	59
6.1.2	Método de Duval .....	61
<b>6.2</b>	<b>Métodos de <i>Machine Learning</i> aplicados .....</b>	<b>63</b>
6.2.1	<i>K-NN</i> aplicado em DGA .....	63
6.2.2	<i>SVM</i> aplicado em DGA.....	65
6.2.3	<i>ANN</i> aplicado em DGA .....	67
<b>6.3</b>	<b>Análise comparativa dos modelos.....</b>	<b>69</b>
<b>6.4</b>	<b>Sistema de visualização de dados .....</b>	<b>73</b>
<b>7</b>	<b>CONCLUSÃO .....</b>	<b>77</b>
<b>7.1</b>	<b>Trabalhos Futuros .....</b>	<b>78</b>
	<b>REFERÊNCIAS.....</b>	<b>79</b>

## 1 INTRODUÇÃO

Com os avanços da Indústria 4.0 e a crescente digitalização dos sistemas produtivos e energéticos, a confiabilidade operacional dos equipamentos tornou-se essencial para garantir a eficiência e continuidade dos processos. A manutenção preditiva consolida-se como uma abordagem estratégica ao antecipar falhas por meio do monitoramento contínuo das condições operacionais. A coleta e a análise sistemáticas de dados permitem identificar anomalias e programar intervenções oportunas, evitando paradas não planejadas, reduzindo custos e prolongando a vida útil dos ativos (Mendonça *et al.*, 2015).

Nesse cenário, os transformadores de potência destacam-se como ativos críticos no sistema elétrico, e a gestão da vida útil desses ativos nas concessionárias de energia é uma atividade complexa. A confiabilidade do sistema depende diretamente da condição desses equipamentos, e a ineficiência no monitoramento pode levar a falhas catastróficas, com consequências severas, como interrupções de serviço e riscos operacionais (Aquino *et al.*, 2011a).

A *Dissolved Gas Analysis* (DGA) é um dos principais métodos de monitoramento desses equipamentos, pois identifica gases como hidrogênio ( $H_2$ ), metano ( $CH_4$ ), acetileno ( $C_2H_2$ ), etileno ( $C_2H_4$ ) e monóxido de carbono ( $CO$ ) no óleo isolante. Cada padrão de concentração está associado a tipos específicos de falha, como descargas parciais, arco elétrico ou sobreaquecimento. Contudo, métodos tradicionais de interpretação, como os descritos nas normas IEC 60599 IEC (2022) e NBR 7274 ABNT (2026), apresentam limitações quando os dados não se enquadram nas faixas estabelecidas (Dhiman *et al.*, 2024).

Diante dessas limitações, algoritmos de Inteligência Artificial (IA), como *Artificial Neural Networks* (ANN), lógica *fuzzy*, *Deep Learning* (DL), *Support Vector Machine* (SVM), *K-Nearest Neighbors* (K-NN) e sistemas híbridos, têm demonstrado potencial para complementar as abordagens convencionais. Essas técnicas contribuem para a redução de diagnósticos incorretos e para o aumento da robustez dos modelos preditivos, mesmo em cenários em que as normas tradicionais falham (Dhiman *et al.*, 2024; Aquino *et al.*, 2011a). Dessa forma, a IA apresenta-se como uma ferramenta promissora, capaz de identificar padrões complexos, extrair características relevantes e prever falhas com precisão considerável (Zhang *et al.*, 2022).

O desafio central reside na dificuldade de diagnosticar falhas em estágios iniciais, especialmente quando os dados não se encaixam nas classificações tradicionais. Embora existam métodos normativos estabelecidos, essas abordagens têm limitações conhecidas que podem dificultar a tomada de decisão preditiva, resultando em manutenções corretivas dispendiosas e em queda na disponibilidade do sistema.

Nesse contexto, investigar a aplicação de técnicas de IA na manutenção preditiva de transformadores de potência mostra-se relevante. A utilização desses modelos como instrumentos de apoio pode contribuir para uma gestão mais assertiva e baseada em dados concretos, o que se reflete na alocação racional de recursos e na mitigação de despesas operacionais (Barbosa, 2023). Diante disso, a exploração do potencial da IA nesse domínio configura-se como uma linha de investigação estratégica e necessária.

## 1.1 Objetivos

Para o desenvolvimento deste trabalho, realizou-se uma pesquisa descritiva sobre a implementação de algoritmos de *Machine Learning* (ML) na identificação de falhas em transformadores de potência, com a finalidade de desenvolver um classificador de padrões baseado em IA para o diagnóstico preditivo de falhas. Nesse contexto, foram delineados o objetivo geral e os objetivos específicos desta pesquisa.

### 1.1.1 Objetivo geral

Analisar o desempenho de algoritmos de *Machine Learning* para diagnóstico preditivo de falhas em transformadores elétricos de potência, com base em dados de análise de gases dissolvidos.

### 1.1.2 Objetivos específicos

- Estudar técnicas de ML que melhor se adaptem ao problema de classificação de falhas em transformadores.
- Coletar bases de dados públicas de DGA.
- Construir um sistema inteligente baseado em ML para a extração de conhecimento na manutenção preditiva de transformadores de potência.
- Avaliar os resultados do sistema inteligente em comparação com as abordagens da literatura pertinente.
- Comparar a implementação de sistemas inteligentes com os métodos tradicionais de classificação de falhas.
- Propor um sistema de visualização de dados para auxiliar as equipes de manutenção na interpretação dos diagnósticos e na tomada de decisão.

## 1.2 Estrutura do trabalho

No Capítulo 1, realizou-se uma breve introdução e o enquadramento do tema, bem como a apresentação dos objetivos propostos e a descrição dos trabalhos correlatos já desenvolvidos.

No Capítulo 2, abordou-se a revisão teórica sobre transformadores de potência, demonstrando suas características construtivas, materiais isolantes, falhas comuns e os fundamentos da DGA.

No Capítulo 3, apresentou-se a revisão bibliográfica sobre ML aplicado à detecção de falhas em transformadores. Foram detalhadas as diferenças entre os tipos de aprendizado, os

modelos de classificação supervisionada, a aplicação desses modelos na análise de gases e a comparação de seus desempenhos.

No Capítulo 4, foram elencados os trabalhos relacionados que fundamentaram a pesquisa e as contribuições nesta temática.

No Capítulo 5, definiu-se a metodologia adotada, incluindo as etapas de preparação dos dados e de implementação de técnicas de normalização, balanceamento e otimização de hiperparâmetros.

No Capítulo 6, apresentaram-se a análise e discussão dos resultados obtidos após implementação dos modelos de ML, e também, comparam-se os métodos propostos.

O Capítulo 7 realizam-se as considerações finais do presente trabalho e futuros pontos a serem desenvolvidos em monografias futuras.

## 2 TRANSFORMADORES DE POTÊNCIA


Segundo o Operador Nacional do Sistema Elétrico (ONS) (2025), o Brasil conta com uma capacidade instalada de 248.098 MW no Sistema Interligado Nacional (SIN), responsável por integrar a geração de energia elétrica em todo o território nacional. Essa energia é distribuída por meio de uma rede básica de transmissão de aproximadamente 176.169 km. Juntas, essas estruturas formam a base do sistema brasileiro de produção e transmissão de energia elétrica. Para facilitar a transmissão, os transformadores desempenham um papel fundamental nos principais sistemas de conversão de energia, pois possibilitam a geração elétrica e sua transmissão em uma tensão mais econômica, além de sua utilização em níveis de tensão mais adequados (Umans, 2014).

Segundo Umans (2014), um transformador consiste em dois ou mais enrolamentos acoplados por meio de um fluxo magnético comum, em que um enrolamento primário é conectado a uma fonte de tensão alternada, que produz um fluxo alternado cuja amplitude dependerá da tensão do primário, da frequência da tensão aplicada e do número de espiras. Uma porção desse fluxo, denominada fluxo mútuo, concatenada a um enrolamento secundário, induz nele uma tensão cujo valor depende do número de espiras do secundário, bem como da magnitude do fluxo comum e da frequência. Ao se estabelecer uma proporção adequada entre os números de espiras do primário e do secundário, praticamente qualquer relação de tensões pode ser obtida.

Já Kulkani e Khaparde (2012) apresenta uma definição que simplifica o entendimento, afirmando que o transformador é um equipamento estático que transforma e transfere energia elétrica de um circuito para outro, por meio do fenômeno da indução eletromagnética, e é capaz de conectar tensões diferentes sem alterar a frequência.

Na Figura 1, pode-se analisar como o fluxo mútuo interage com os enrolamentos primário e secundário de um transformador de núcleo envolvido, no qual se observam os sentidos das correntes nas duas bobinas.

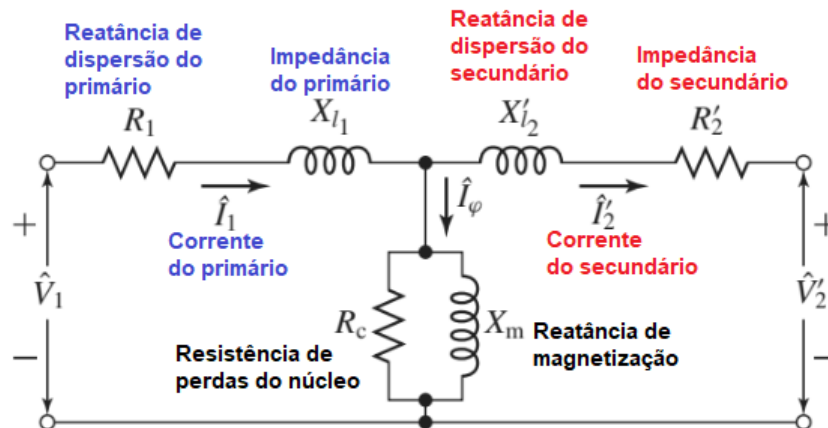
**Figura 1 – Fluxo mútuo e disperso de um transformador. Os sinais 'x' e '•' indicam, respectivamente, a entrada e a saída da corrente nas bobinas.**



**Fonte: Umans (2014).**

Para uma compreensão mais simples, é possível analisar na Figura 2 o circuito equivalente desse mesmo transformador, onde os fluxos dispersos do primário e secundário da Figura 1 são representados pelas respectivas reatâncias de dispersão. Além disso, percebe-se que o fluxo mútuo é representado pelo ramo de magnetização ( $R_c$  e  $X_m$ ) e que a resultante do mesmo concatena ambos os enrolamentos.

**Figura 2 – Circuito equivalente do transformador**



Fonte: Adaptado de Umans (2014).

## 2.1 Características construtivas

De acordo com Filho (2013), uma forma de classificar os transformadores de distribuição e de força é pelo número de fases. Primeiramente, existem os transformadores monofásicos, que têm apenas uma bucha no primário e outra no secundário, com baixa potência nominal (não superior a 15 kVA na classe de tensão de 15 kV), operando com o terminal primário ligado à fase e o secundário ligado à terra. Sua importância se deve ao amplo uso em sistemas de potência elevados (maiores ou iguais a 500 kV), que geralmente são formados por três transformadores monofásicos (um por fase).

Essa prática é vantajosa, pois, em caso de falha em uma fase, apenas um transformador monofásico é substituído, reduzindo o custo e facilitando o transporte do equipamento por rodovias e vias urbanas. Em seguida, vêm os transformadores bifásicos, construídos para operar individualmente em redes de distribuição rural ou na formação de bancos de transformação, em postes ou em cabines. Quando utilizados sozinhos, antedem cargas monofásicas e, quando em bancos, alimentam cargas monofásicas e trifásicas (Filho, 2013).

Por fim, os transformadores trifásicos são os mais utilizados nos sistemas de distribuição e transmissão de energia elétrica das concessionárias brasileiras, tendo em vista que operam nas mais diversas classes de tensão. São constituídos por um núcleo de lâminas de aço envolvidas por bobinas, geralmente de fio de cobre, que formam os enrolamentos primário e secundário.

Esse conjunto é mergulhado em um líquido isolante dentro de um tanque, e o acesso aos terminais das bobinas é realizada através de buchas de tensões adequadas às características do transformador, tanto para o primário, quanto para o secundário. Também são construídos sistemas de radiadores térmicos para a refrigeração desse líquido isolante (Filho, 2013).

Para este trabalho, a característica mais importante é o isolamento óleo-papel, que, conforme descrito por Van (2010), consiste na combinação dos óleos isolantes usados para resfriamento dos enrolamentos ativos e do núcleo, com um papel de celulose que evita a ruptura elétrica entre os enrolamentos e o núcleo e também serve como suporte mecânico para os enrolamentos.

Segundo Myers, Kelly e Parrish (1981), as fibras de papel foram rapidamente aceitas pela indústria, tendo em vista seu baixo custo, sua facilidade de aplicação e sua resistência mecânica, em comparação com seu peso. Porém, sua efetividade real decorre da impregnação dessa fibra com óleo, que resulta em maior estabilidade dielétrica e química, dificultando a absorção de umidade pelo material e preenchendo quaisquer vazios existentes, evitando a formação de bolsas de ar que podem levar à ruptura do dielétrico, além de evitar a oxidação.

Na Figura 3 é possível analisar um sistema básico de isolamento de um transformador de potência tipo núcleo envolvido (onde os enrolamentos envolvem o núcleo), onde (A) representa o isolamento de papel dos fios, (B) representa o isolamento de papel do aterramento, (C) representa o isolamento entre o enrolamento primário e o enrolamento secundário e (D) representa o isolamento entre as fases.

Myers, Kelly e Parrish (1981) também destacam que o óleo isolante precisa apresentar quatro funções básicas: fornecer uma força dielétrica suficiente para garantir a isolação, ser eficiente no resfriamento e na troca de calor, preservar o conjunto núcleo/bobina e minimizar a quantidade de oxigênio em contato com a celulose e outros materiais suscetíveis à oxidação. Quando qualquer uma dessas funções apresenta avarias, tanto a eficiência quanto a vida útil do transformador são afetadas.


## **2.2 Materiais isolantes**

Os materiais isolantes desempenham papel essencial na operação adequada dos transformadores, presentes no interior do tanque e cumprindo funções como a dissipação do calor gerado durante a operação e a prevenção de curtos-circuitos por meio do isolamento elétrico (Filho, 2013). A classificação dos transformadores quanto ao tipo de isolamento é feita de acordo com o material dielétrico, podendo ser a seco ou com líquido isolante. Cada tipo apresenta características, aplicações e vantagens específicas que serão detalhadas nas subseções a seguir.

### **2.2.1 Transformadores a seco**

Os transformadores a seco são amplamente empregados em instalações com elevado risco de incêndio. Sua construção difere dos transformadores imersos em líquido isolante, nos

**Figura 3 – Sistema de isolamento básico de um transformador trifásico**




**Fonte: Adaptado de Myers, Kelly e Parrish (1981).**

quais o enrolamento primário é composto por fitas de alumínio ou cobre inseridas em moldes metálicos e encapsuladas sob vácuo em resina, enquanto o enrolamento secundário utiliza folhas de alumínio isoladas com materiais inorgânicos à base de resina (Filho, 2013).

Embora apresentem vantagens quanto à segurança contra incêndios e menor necessidade de manutenção, os transformadores a seco têm limitações técnicas, como a baixa condutividade térmica da resina, o que reduz a capacidade de dissipação de calor. Para superar essa limitação térmica, utiliza-se papel Nomex, material com elevada resistência a altas temperaturas (aproximadamente 220 °C). Contudo, o custo inicial desse tipo de transformador pode ser de 60 a 70% superior ao de transformadores refrigerados a óleo, o que restringe sua aplicação a situações em que a segurança contra incêndios justifica o alto investimento (Kulkani; Khaparde, 2012).

Segundo a fabricante WEG (2025), sua função principal é a mesma dos transformadores imersos em líquido isolante, ou seja, adequar os níveis de tensão primária aos de utilização em indústrias, residências e empreendimentos em geral. Suas aplicações mais comuns incluem shoppings, hospitais, data centers, aeroportos, navios e plataformas *offshore*. Na Figura 4 é apresentado um exemplo do encapsulamento do transformador a seco. Nessa figura, pode-se observar que os enrolamentos ficam extremamente vedados, mantendo a isolamento a vácuo.

**Figura 4 – Transformador a seco WEG**

**Fonte: Adaptado da WEG (2025).**


### 2.2.2 Líquido isolante

Os transformadores com líquido isolante são os mais empregados em sistemas elétricos de potência, nos quais se pode utilizar óleo mineral, silicone ou ascarel, sendo o último proibido em território nacional há anos (Filho, 2013).

Filho (2013) define os líquidos isolantes como líquidos de baixa viscosidade destinados à refrigeração do transformador, transferindo o calor gerado pelo efeito Joule nos enrolamentos, pelo efeito Joule e pela corrente parasita, e pela corrente de histérese no núcleo para as paredes do tanque. Além disso, possuem alta rigidez dielétrica.

É importante ressaltar a necessidade de um conservador de líquido isolante, que consiste em um reservatório fixado na parte superior da carcaça do transformador, destinado a receber o óleo do tanque quando se expande devido ao aquecimento, servindo para compensar e permitir a expansão do líquido isolante (Filho, 2013). Na Figura 5, detalha-se o local de permanência do óleo isolante em um transformador trifásico, onde observam-se as partes submersas no óleo, além do reservatório superior, denominado tanque de expansão.

**Figura 5 – Óleo de isolamento no transformador de potência**



**Fonte: Adaptado de Frontin (2013).**

Atualmente, o fluido mais utilizado em transformadores é o óleo mineral, tendo em vista seu baixo custo, facilidade de manuseio e descarte e, principalmente, suas boas características elétricas e térmicas. Como desvantagem, apresenta baixo ponto de combustão, o que representa um risco em transformadores urbanos e em áreas de risco de explosão.

Em alguns casos, utiliza-se o óleo de silicone, um polímero sintético à base principalmente de silício, que, embora possua um custo mais elevado em relação ao óleo mineral, apresenta uma boa estabilidade térmica, suportando temperaturas de ponto de chama de aproximadamente 300°C, assim, mitigando a ocorrência de incêndios. Por isso, esse tipo de isolamento é indicado por algumas concessionárias para ser utilizado em áreas residenciais e comerciais (Filho, 2013). Na Tabela 1, pode-se comparar algumas características do óleo mineral e do óleo de silicone, de acordo com a *American Society for Testing and Materials* (ASTM).

**Tabela 1 – Comparação das características físico-químicas dos isolantes óleo mineral e silicone**

<b>Teste ASTM</b>	<b>Óleo Mineral</b>	<b>Óleo Silicone</b>
Rigidez Dielétrica a 25 °C, kv	45	40
Viscosidade (cSt) 40 °C	9,2	39
Viscosidade (cSt) 100 °C	2,3	17
Ponto de Combustão (°C)	165	343
Ponto de Fulgor (°C)	140	305
Calor Específico (cal/gr°C)	0,39	0,36
Ponto de Fluidez (°C)	-50	-55
Gravidade Específica	0,87	0,96
Demanda Bioquímica de Oxigênio	6	0

**Fonte: (Campos, 2017).**

Ao analisar a Tabela 1, observa-se que algumas características físico-químicas dos óleos são semelhantes, especialmente a rigidez dielétrica, que apresenta valores praticamente iguais. No entanto, destaca-se que o óleo de silicone possui ponto de combustão e ponto de fulgor mais elevados, o que reforça sua aplicação em ambientes que exigem maior proteção contra incêndio.

Para este trabalho, é importante ressaltar os fatores de degradação do óleo em transformadores, tendo em vista que o objeto de estudo são os gases dissolvidos no óleo de isolamento do transformador. Com o passar do tempo, o envelhecimento do óleo forma ácidos que prejudicam o material isolante do tanque do transformador e, juntamente com a perda das características isolantes, tornam o óleo inviável para o uso, sendo necessária sua substituição. Segundo o manual da fabricante de equipamentos elétricos ABB (1999), o envelhecimento precoce de transformadores pode ser acelerado quando ocorre deterioração do sistema de isolamento, seja por alterações térmicas, elétricas ou mecânicas, seja por reações químicas que comprometem a isolamento.

### 2.3 Falhas nos transformadores de potência

Inicialmente, é importante ressaltar a diferença entre os conceitos de falha, defeito, falta e pane. Segundo a NBR 5462 ABNT (1994), que possui como objetivo definir os termos relacionados com a confiabilidade e a manutenibilidade, têm-se os seguintes conceitos:

- **Falha:** Término da capacidade de um item de desempenhar sua função. Também se caracteriza como um evento;
- **Defeito:** Qualquer desvio de uma característica de um item em relação aos seus requisitos. Porém, um defeito não necessariamente afeta a capacidade de um item de desempenhar sua função;
- **Falta:** Embora a norma não especifique diretamente o conceito de falta, é possível interpretar como sendo um estado de incapacidade de um item devido a razões externas;
- **Pane:** Estado em que um item se encontra incapaz de desempenhar sua função, exceto quando a incapacidade ocorre durante a manutenção preventiva ou outras ações planejadas.

Conforme aponta a ABB (1999), análises indicam que a probabilidade de um transformador apresentar alguma falha num período de 30 anos situa-se entre 20% e 53%, reforçando a necessidade de métodos que assegurem a confiabilidade na operação dos transformadores. Na Tabela 2 observam-se as percentagens de falhas que ocorrem em um transformador regulador, de acordo com dados de ensaios realizados pela fabricante ABB.

**Tabela 2 – Distribuição de falhas em componentes de um transformador regulador**

<b>Causa</b>	<b>Porcentagem</b>
Comutador sob carga	41%
Enrolamentos	19%
Tanque+Óleo	13%
Saídas e buchas	12%
Acessórios	12%
Núcleo	3%

**Fonte: Adaptado de ABB (1999).**

Outro conceito importante refere-se às falhas internas e externas. As falhas internas são todas aquelas que ocorrem entre as buchas de tensão superior e as de tensão inferior, ou dentro da zona de proteção diferencial do transformador. De modo geral, podem ser associadas à temperatura (geralmente relacionada com falha no sistema de resfriamento ou falha de conexão interna), à pressão (devido à formação de gases que se acumulam no interior do tanque do transformador causados pelas queimaduras na isolação), a curtos-circuitos ou a avarias no equipamento (Filho, 2024).

Como a pesquisa atual está relacionada à deterioração do óleo isolante, será dada maior ênfase às falhas internas do transformador, principalmente às causadas pelos gases dissolvidos no óleo. Para melhor entendimento sobre o assunto, é necessário diferenciar óleo contaminado e deteriorado, que segundo Milasch (1984):

- **Óleo contaminado:** Contém substâncias estranhas que não resultam de sua decomposição.
- **Óleo deteriorado:** Contém substâncias resultantes da sua oxidação. Esse processo se inicia no instante em que o tanque do transformador é preenchido.

Já as falhas externas têm origem no sistema elétrico e ocorrem fora da zona de proteção diferencial do transformador; logo, necessitam ser eliminadas pelos relés de sobrecorrente. Estão relacionados com curtos-circuitos, que, quando ocorrem na jusante do transformador, devem ser eliminados para evitar danos, com sobrecargas ou subfrequência, que reduzem a vida útil do equipamento devido ao aquecimento causado pelo aumento da corrente de magnetização, e com sobretensão, que afeta os enrolamentos e provoca perdas no ferro (Filho, 2024).

## **2.4 Fundamentos da análise de gases dissolvidos**

A Análise de Gases Dissolvidos (em inglês, *Dissolved Gas Analysis*, DGA) é uma das técnicas mais utilizadas no monitoramento da condição dos transformadores de potência. O princípio da DGA baseia-se no fato de que falhas internas, como descargas elétricas ou sobreaquecimento, provocam a decomposição do óleo mineral e do papel celulósico, liberando gases característicos que permanecem dissolvidos no óleo. A norma IEC C57.104 IEC (2022) reconhece esse método como a principal ferramenta de diagnóstico para equipamentos imersos em

óleo, justamente porque permite identificar anomalias antes que se tornem críticas, funcionando como um verdadeiro "exame preventivo" do transformador.

Os principais gases formados durante a operação ou em falhas são:  $H_2$ ,  $CH_4$ ,  $C_2H_6$ ,  $C_2H_4$ ,  $C_2H_2$ ,  $CO$  e  $CO_2$ . Cada gás está associado a fenômenos distintos. De acordo com a IEC (2022), concentrações elevadas de  $H_2$  geralmente indicam descargas parciais, enquanto altos níveis de  $C_2H_4$  estão associados ao aquecimento do óleo. O monóxido e o dióxido de carbono, por sua vez, são gerados principalmente pela degradação do papel isolante.  $CH_4$  e  $C_2H_4$  serão formados caso a falha envolva uma estrutura impregnada de óleo. Outro exemplo de fácil percepção é a maior presença de  $C_2H_2$  quando ocorre um arco elétrico, considerado um dos defeitos mais graves, o que indica uma forte correlação entre ambos.

A norma reforça essa classificação, destacando que a identificação correta dos gases é essencial para correlacionar o fenômeno físico à falha em questão.

Embora a análise das concentrações individuais de cada gás forneça uma indicação preliminar do estado do equipamento, é a relação entre os diferentes gases que permite identificar efetivamente o tipo e a gravidade da falha. Conforme estabelece a NBR 7274 ABNT (2026), cada classe de defeito conduz a um padrão característico de composição de hidrocarbonetos gasosos, que pode ser traduzido em tabelas de interpretação baseadas nas razões entre os gases. Essa abordagem constitui o eixo central da metodologia diagnóstica da DGA, pois supera as limitações da análise individual ao considerar as proporções relativas entre os gases, o que confere maior especificidade e confiabilidade ao diagnóstico.

A DGA ainda possui a vantagem de ser uma técnica não intrusiva, uma vez que a coleta de amostras de óleo pode ser realizada com o transformador em plena operação. Quando realizada periodicamente, essa prática gera um histórico de medições que possibilita não apenas a identificação de falhas ativas, mas também o acompanhamento das tendências de evolução dos gases ao longo do tempo. Abdullaev *et al.* (2025) verifica que grande parte das falhas em transformadores analisados estava relacionada ao isolamento e às sobretensões, reforçando que a degradação do óleo e do papel isolante — justamente os fenômenos monitorados pela DGA — constitui o principal fator de falha nesses equipamentos, o que justifica a ampla adoção dessa técnica.


#### 2.4.1 Análise cromatográfica

A cromatografia é uma técnica analítica utilizada para a separação, identificação e quantificação de misturas de gases ou líquidos voláteis. No contexto de transformadores de potência, a cromatografia gasosa é o princípio básico da DGA, sendo frequentemente comparada a um "exame de sangue" do equipamento (Peixinho, 2024), pois permite diagnosticar a saúde interna do equipamento a partir de amostras de óleo.

Nesse contexto, os gases precisam ser separados do óleo para a análise das propriedades físico-químicas da DGA e, para essa separação, utiliza-se um equipamento de precisão chamado cromatógrafo (Figura 6), que é composto por várias colunas com diferentes tipos de detectores

(Filho, 2012). As amostras de gases para transformadores de potência são coletadas conforme os procedimentos descritos na NBR 7070 ABNT (2006).

**Figura 6 – Cromatógrafo**



**Fonte: DCTech (2018).**

#### 2.4.2 Normas aplicáveis

A interpretação dos resultados da DGA segue normas técnicas que definem critérios, limites e métodos padronizados para avaliar o estado dos transformadores. No Brasil, a principal referência é a ABNT (2026) — *Interpretação da análise dos gases de transformadores em serviço* —, que descreve como a concentração de gases livres ou dissolvidos pode ser usada para diagnosticar as condições dos equipamentos elétricos em operação e indicar ações futuras. Essa norma se aplica a equipamentos preenchidos com óleo mineral isolante e isolados com papel ou papelão celulósicos, o que abrange a grande maioria dos transformadores de potência do sistema elétrico brasileiro.

No cenário internacional, a IEC (2022) — *Mineral Oil-Filled Electrical Equipment in Service – Guidance on the Interpretation of Dissolved and Free Gases Analysis* — é outra referência importante, com foco na análise da tendência de crescimento dos gases ao longo do tempo e na correlação entre si. A IEEE (2019) — *IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers* — complementa esse conjunto ao trabalhar com critérios baseados nas concentrações absolutas dos gases e propor quatro níveis de condição, que vão da operação normal a estados severos que exigem intervenção imediata. Na prática, o uso combinado dessas normas é recomendado para obter diagnósticos mais completos.

#### 2.4.3 Tipos de falhas identificadas

Os transformadores de potência estão sujeitos a diversos tipos de falhas, sendo as mais comuns as térmicas, as elétricas e as relacionadas ao isolamento. A DGA é particularmente eficaz na identificação das duas primeiras. As falhas térmicas decorrem do superaquecimento do

óleo ou do papel isolante. Segundo a IEC (2022), podem ser classificadas conforme apresentado na Tabela 3:

**Tabela 3 – Classificação de falhas em transformadores de potência segundo a norma IEC 60599**

<b>Tipo</b>	<b>Falha</b>
PD	Descargas parciais
D1	Descargas de baixa energia
D2	Descargas de alta energia
T1	Falha térmica ( $t < 300^{\circ}\text{C}$ )
T2	Falha térmica ( $300^{\circ}\text{C} < t < 700^{\circ}\text{C}$ )
T3	Falha térmica ( $t > 700^{\circ}\text{C}$ )

**Fonte: Adaptado de IEC (2022).**

Abaixo, é descrito em detalhes cada tipo de falha abordado na Tabela 3:

- Descargas parciais (PD) do tipo plasma frio (ou corona), que podem resultar em possível deposição de partículas sólidas de carbono e polímeros de hidrocarbonetos sobre o isolamento de papel;
- Descargas de baixa energia (D1), no óleo e/ou no papel, evidenciadas por maiores perfurações carbonizadas através do papel, carbonização da superfície do papel ou presença de partículas de carbono no óleo;
- Descargas de alta energia (D2), no óleo e/ou no papel, com corrente de seguimento, caracterizadas por destruição e carbonização extensiva do papel, fusão metálica nas extremidades de descarga, carbonização intensa do óleo e, em alguns casos, desligamento do equipamento, confirmando a alta corrente de falha;
- Falhas térmicas, no óleo e/ou no papel, abaixo de  $300^{\circ}\text{C}$  se o papel estiver amarronzado (T1) e acima de  $300^{\circ}\text{C}$  se estiver carbonizado (T2);
- Falhas térmicas com temperaturas acima de  $700^{\circ}\text{C}$  (T3) quando há fortes evidências de carbonização do óleo, coloração metálica ( $800^{\circ}\text{C}$ ) ou fusão do metal ( $> 1\ 000^{\circ}\text{C}$ ).

As falhas elétricas incluem descargas parciais e arcos elétricos de alta energia. As descargas parciais produzem principalmente hidrogênio, enquanto os arcos liberam quantidades significativas de acetileno. Em estudo com base em falhas reais, Bechara (2010) verificou que 46,5% das falhas em transformadores estavam relacionadas ao isolamento e a sobretensões. Esse dado reforça a importância da DGA no monitoramento do sistema isolante.

As falhas mecânicas, embora menos diretamente identificadas pela DGA, podem causar deformação dos enrolamentos e facilitar o surgimento de falhas térmicas e elétricas secundárias (Abdullaev *et al.*, 2025). Portanto, a DGA permite não apenas identificar o tipo de falha, mas também avaliar sua gravidade e evolução, fornecendo subsídios técnicos essenciais para a tomada de decisões de manutenção.

#### 2.4.4 Métodos de interpretação

A interpretação correta dos resultados da DGA é a etapa que determina a utilidade prática de todo o processo de análise. Segundo a pesquisa de Sun, Huang e Huang (2012), diversos métodos foram desenvolvidos para esse fim, entre os quais se destacam o Método dos Gases-Chave, as Razões de Rogers, o Triângulo de Duval e, mais recentemente, o Pentágono de Duval (ABNT, 2026).

O Método dos Gases-Chave identifica falhas com base no gás predominante. Se houver alta concentração de acetileno, por exemplo, é provável que haja um arco elétrico interno. Esse método, apesar de simples, pode falhar em casos de coexistência de diferentes defeitos, conforme a Tabela 4, que apresenta um resumo da interpretação realizada pelo Método dos Gases-Chave.

**Tabela 4 – Gases-chave e tipos de falhas associados conforme NBR 7274**

<b>Gás-chave</b>	<b>Tipo de falha</b>	<b>Proporções típicas</b>
Etileno (C <sub>2</sub> H <sub>4</sub> )	Falha térmica no óleo	Predominância de etileno com traços de etano, metano, hidrogênio e acetileno.
Monóxido de carbono (CO)	Falha térmica no óleo e na celulose	Predominância de CO com menores concentrações de etileno, etano e metano.
Hidrogênio (H <sub>2</sub> )	Descargas parciais (DP)	Predominância de hidrogênio com traços de metano, etileno e etano.
H <sub>2</sub> e C <sub>2</sub> H <sub>2</sub>	Descargas de alta energia (arco elétrico)	Predominância de hidrogênio e acetileno; CO presente se houver celulose.

**Fonte: Adaptado de ABNT (2026).**

Os métodos baseados em razões de gases são mais robustos, pois consideram a proporção relativa entre os gases formados. Com isso, surgiu o método das razões de gases, como o de Rogers, que utiliza três razões principais ( $CH_4/H_2$ ,  $C_2H_2/C_2H_4$  e  $C_2H_4/C_2H_6$ ) para classificar as falhas (Sun; Huang; Huang, 2012). Os critérios de diagnóstico para essa técnica são apresentados na Tabela 5.


**Tabela 5 – Critérios de diagnóstico baseados nas razões de Rogers conforme IEC 60599**

<b>Caso</b>	<b>Falha característica</b>	$\frac{C_2H_2}{C_2H_4}$	$\frac{CH_4}{H_2}$	$\frac{C_2H_4}{C_2H_6}$
PD	Descargas parciais	Não significativo	<0,1	<0,2
D1	Descargas de baixa energia	>1	0,1 – 0,5	>1
D2	Descargas de alta energia	0,6 – 2,5	0,1 – 1	>2
T1	Falha térmica $t < 300\text{ }^\circ\text{C}$	Não significativo	>1 mas não signif.	<1
T2	Falha térmica $300\text{ }^\circ\text{C} < t < 700\text{ }^\circ\text{C}$	<0,1	>1	1 – 4
T3	Falha térmica $t > 700\text{ }^\circ\text{C}$	<0,2 <sup>b</sup>	>1	>4

**Fonte: IEC (2022).**

Com base nos dados da Tabela 5, pode-se representar graficamente as falhas nas proporções básicas de gases, como mostrado na Figura 7.

**Figura 7 – Representação tridimensional das razões de Rogers para diagnóstico de falhas em transformadores de potência**




Fonte: IEC (2022).

O Triângulo de Duval é considerado um dos métodos gráficos mais confiáveis para interpretação da DGA, especialmente na detecção de falhas incipientes. Desenvolvido por Michael Duval e publicado pela primeira vez em 1974, esse método utiliza três gases hidrocarbonetos como parâmetros de avaliação: ( $CH_4$ ), ( $C_2H_4$ ) e ( $C_2H_2$ ) (Dhiman *et al.*, 2024). Campos (2017) destaca que o desempenho do método foi eficaz na identificação de falhas previamente verificadas em transformadores, o que o tornou amplamente aceito na indústria elétrica.

Conforme ilustrado na Figura 8, o Triângulo de Duval apresenta uma superfície triangular dividida em zonas distintas que correspondem a diferentes tipos de falhas. Cada vértice do triângulo representa a concentração percentual de um dos três gases, e a posição resultante no gráfico indica a natureza do defeito (Dallamuta; Holzmann, 2021). A região identificada como DT representa a combinação de arco elétrico e falta térmica, indicando situações em que múltiplos mecanismos de degradação ocorrem simultaneamente no equipamento.

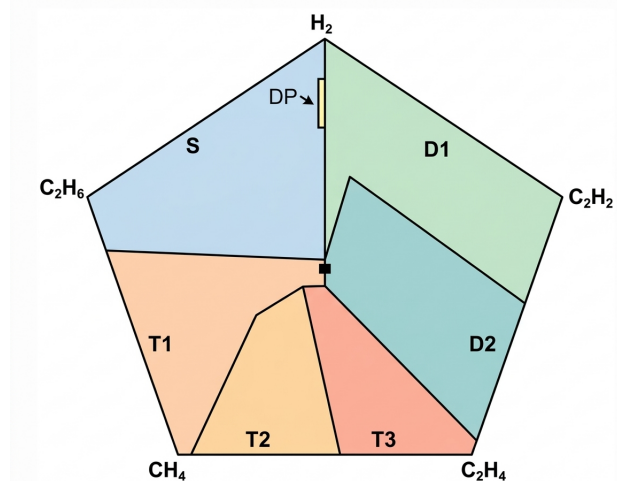
**Figura 8 – Triângulo de Duval para DGA**



Fonte: Adaptado de Barbosa *et al.* (2016).

O Pentágono de Duval 1 constitui uma ferramenta complementar ao Triângulo de Duval, desenvolvida para o diagnóstico de falhas em transformadores de potência, utilizando os cinco gases de hidrocarbonetos:  $\text{H}_2$ ,  $\text{C}_2\text{H}_6$ ,  $\text{CH}_4$ ,  $\text{C}_2\text{H}_4$  e  $\text{C}_2\text{H}_2$  (ABNT, 2026). A ordem desses gases nas cinco arestas do pentágono corresponde ao aumento progressivo da energia ou da temperatura das falhas que os produzem, permitindo que o ponto de operação do transformador seja plotado graficamente dentro de uma das zonas de falha delimitadas (IEC, 2022). O método permite identificar os seis tipos básicos de falhas, como ilustrados na Figura 9.

**Figura 9 – Pentágono de Duval 1 para identificação de falhas em transformadores de potência**



Fonte: ABNT (2026).

#### 2.4.5 Método DGA na manutenção preditiva

Outros conceitos de interesse para esse trabalho são referentes aos diferentes tipos de manutenção, que, segundo Milasch (1984), distinguem-se da seguinte forma:

- **Manutenção preventiva:** Serviço programado em equipamentos instalados ou em obras e instalações executadas, com o intuito de mantê-los em condições adequadas de operação, prevenindo quaisquer problemas e, conseqüentemente, sua indisponibilidade. Inicia-se a realização de testes para verificar as condições de funcionamento dos componentes, com periodicidade anual.
- **Manutenção preditiva:** Caso os testes de manutenção preventiva indiquem necessidade de repetições mais frequentes, por estarem próximos dos limites admissíveis, a manutenção preventiva é substituída pela manutenção preditiva, na qual os testes são realizados com maior frequência.
- **Manutenção corretiva:** Serviço realizado para corrigir problemas decorrentes de falha, defeito, falta ou pane, que acarretam a indisponibilidade, em condições quase sempre não programadas.

Este trabalho se enquadra na manutenção preditiva, pois visa identificar e antecipar falhas, garantindo a confiabilidade e reduzindo custos. Nesse contexto, a DGA é considerada uma das técnicas mais eficientes, pois permite acompanhar a evolução das concentrações de gases ao longo do tempo e detectar o início e a progressão de defeitos. De acordo com Sun, Huang e Huang (2012), a detecção de certos gases dissolvidos em transformadores em operação é frequentemente a primeira indicação de um mau funcionamento que, se não corrigido, pode eventualmente causar uma falha catastrófica.

Em transformadores monitorados continuamente, a taxa de crescimento dos gases é ainda mais importante do que a concentração absoluta. Quando o aumento for acelerado, o equipamento deve ser retirado de serviço preventivamente. Segundo Abdullaev *et al.* (2025), a integração da DGA em programas de manutenção preditiva reduziu o número de falhas catastróficas em até 30% nas usinas analisadas.

Outro aspecto relevante é o uso da Inteligência Artificial (IA) para apoiar a manutenção preditiva. Em estudos recentes (que terão maior destaque no Capítulo 4), algoritmos de aprendizado de máquina alcançaram resultados mais consistentes do que os métodos tradicionais, garantindo maior confiabilidade na tomada de decisão (Dhiman *et al.*, 2024). Dessa forma, a DGA é uma ferramenta que pode auxiliar na manutenção, sendo importante para a extensão da vida útil dos transformadores e na redução de custos operacionais.

### 3 APRENDIZADO DE MÁQUINAS APLICADO À DETECÇÃO DE FALHAS

A IA pode ser definida como o ramo da ciência da computação que se ocupa da automação do comportamento inteligente, com foco no desenvolvimento de sistemas que exibem características como compreensão da linguagem, raciocínio e resolução de problemas (Barbosa, 2023). Como destaca Géron (2019), o *Machine Learning* (ML) representa o campo de estudo que confere aos computadores a habilidade de aprender sem serem explicitamente programados, permitindo que sistemas melhorem seu desempenho através da experiência acumulada.

A distinção entre IA, ML e *Deep Learning* (DL) é fundamental para compreender o escopo e as aplicações de cada conceito. A IA representa o conceito mais amplo, englobando todos os aspectos da aprendizagem ou qualquer característica da inteligência que possa ser descrita com precisão de modo que uma máquina possa realizá-la (Faceli, 2011). O ML, por sua vez, pode ser considerado uma vertente da IA, definido como o conjunto de métodos capazes de detectar padrões automaticamente em conjuntos de dados e usá-los para fazer previsões sobre dados futuros ou tomar decisões em ambientes de incerteza (Barbosa, 2023). O DL, finalmente, constitui um ramo do ML que procura produzir representações hierárquicas de alto nível dos dados de entrada por meio de camadas de processamento sequencial em redes neurais artificiais (Faceli, 2011).

O potencial do ML reside especialmente em sua capacidade de resolver problemas complexos para os quais as abordagens tradicionais não encontraram soluções determinísticas ou que exigem ajustes de parâmetros. Segundo Géron (2019), o ML é particularmente adequado para problemas onde as soluções existentes exigem muita configuração manual ou longas listas de regras, para problemas complexos sem boa solução tradicional, e para ambientes flutuantes onde o sistema precisa se adaptar continuamente a novos dados.

No contexto da manutenção preditiva, o ML permite integrar informações e aproveitar o potencial da grande quantidade de dados que, tipicamente, são armazenados em sistemas industriais (Barbosa, 2023). Os modelos preditivos desenvolvidos têm a capacidade de aprender padrões a partir de dados históricos e, assim, prever resultados futuros com uma determinada incerteza associada, sendo que a precisão preditiva desses modelos depende diretamente da relevância, quantidade e qualidade dos dados disponíveis (Faceli, 2011).

#### 3.1 Tipos de aprendizado de máquina

As técnicas de aprendizado de máquina empregam um princípio de inferência denominado indução, no qual se obtêm conclusões genéricas a partir de um conjunto particular de exemplos (Lorena; Carvalho, 2007). O aprendizado indutivo divide-se em dois tipos principais: supervisionado e não supervisionado, conforme apresentado na Figura 10. Esta classificação é fundamental para aplicações de manutenção preditiva, nas quais a disponibilidade de dados rotulados orienta a seleção do método mais apropriado para cada contexto (Faceli, 2011).

**Figura 10 – Taxonomia do aprendizado indutivo**

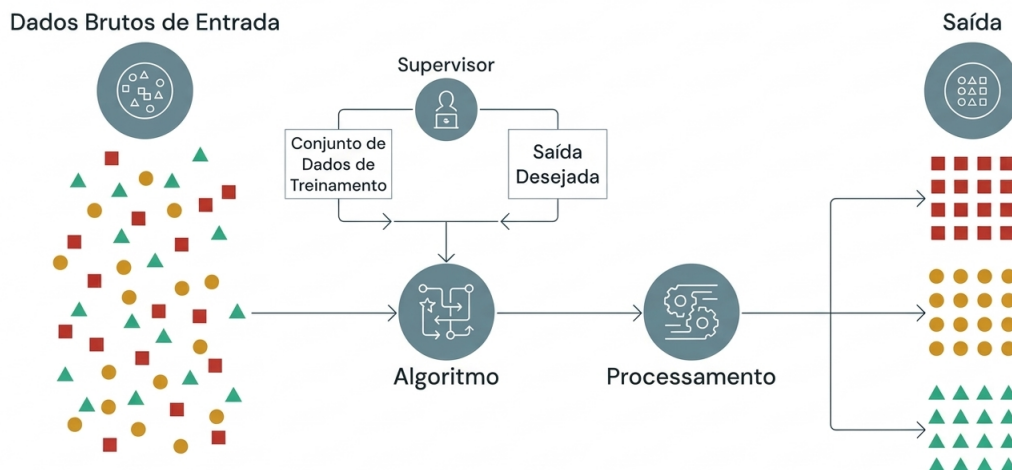


**Fonte: Adaptado de Lorena e Carvalho (2007).**

O aprendizado supervisionado é o paradigma mais utilizado em aplicações de diagnóstico e de classificação. Neste modo, os dados de treino incluem a solução desejada, denominada rótulo, permitindo que o algoritmo aprenda a relação entre as variáveis de entrada e de saída (Barbosa, 2023). O sistema é treinado com exemplos rotulados na forma de entrada-saída desejada, em que um supervisor externo fornece o conhecimento do ambiente por meio de pares de dados que orientam o processo de aprendizagem (Lorena; Carvalho, 2007).

O objetivo deste paradigma é que o modelo gerado seja capaz de produzir saídas corretas para novas entradas não vistas durante o treinamento (Faceli, 2011). Conforme ilustrado na Figura 11, o processo inicia-se com dados brutos associados a rótulos conhecidos, que são processados por um algoritmo sob orientação do supervisor. Após o treinamento, o modelo torna-se capaz de classificar novos dados nas categorias aprendidas, generalizando o conhecimento adquirido para situações inéditas (Géron, 2019).

**Figura 11 – Fluxo do processo de aprendizado supervisionado**



**Fonte: Elaborado pelo autor.**

Os problemas de aprendizado supervisionado dividem-se em classificação, em que o modelo categoriza dados em classes discretas predefinidas, e regressão, em que se preveem valores contínuos (Faceli, 2011). Os algoritmos mais utilizados incluem *K-Nearest Neighbors (k-NN)*, *Support Vector Machine (SVM)*, Árvores de Decisão e *Artificial Neural Networks (ANN)* (Géron, 2019).

O aprendizado não supervisionado, por sua vez, trabalha com dados não rotulados, identificando padrões e estruturas ocultas de forma autônoma. As principais tarefas incluem agrupamento (*clustering*), redução de dimensionalidade e classificação (Faceli, 2011). Embora relevante em cenários em que a rotulação é custosa, o presente trabalho concentra-se no aprendizado supervisionado devido à sua adequação ao diagnóstico de falhas em transformadores, em que os dados de análise de gases dissolvidos podem ser associados a tipos específicos de falhas, caracterizando um problema típico de classificação (Khan, 2025).

### 3.2 Conjuntos de dados em ML

Os dados de treinamento, validação e teste consistem em conjuntos distintos de informações que desempenham funções essenciais ao longo das diferentes fases de desenvolvimento de um modelo de ML. A finalidade dessa divisão é assegurar que o sistema aprenda, seja devidamente otimizado e desenvolva a capacidade de generalizar o conhecimento de maneira eficaz (Russell; Norvig, 2021).

Os dados de treinamento representam a base fundamental do algoritmo, sendo aplicados na fase inicial do processo para instruir o modelo na identificação de padrões e relações. O sistema processa esse conjunto repetidas vezes, calibrando seus parâmetros internos com o intuito de minimizar erros e aprimorar a classificação de entradas e saídas.

Os dados de validação correspondem a um grupo de dados separado, empregado paralelamente ao processo de treinamento. Sua função é avaliar o desempenho do modelo diante de informações até então desconhecidas, viabilizando sua otimização. Essa etapa possibilita aos cientistas de dados o ajuste fino de hiperparâmetros e atua como um ponto de verificação. O propósito essencial da validação é prevenir problemas como o *overfitting* que ocorre quando o modelo memoriza os dados de treinamento e o *underfitting* quando a simplicidade do modelo compromete a precisão das previsões.

Os dados de teste são um conjunto utilizado exclusivamente após a conclusão do treinamento e da otimização do modelo. O objetivo é prover uma medição imparcial sobre a precisão e a eficácia do sistema em um cenário análogo ao mundo real. Os dados fornecidos não apresentam rótulos, simulando condições práticas nas quais o sistema não dispõe previamente da resposta correta.


### 3.3 Classificadores supervisionados

Os classificadores supervisionados são técnicas de aprendizado de máquina que utilizam conjuntos de dados rotulados para treinar modelos capazes de identificar padrões e fazer previsões sobre novos dados. No contexto do diagnóstico de falhas em transformadores de potência, estes algoritmos têm demonstrado superior capacidade de reconhecimento de padrões complexos em comparação com métodos tradicionais baseados em regras fixas (Khan, 2025). Entre os classificadores mais utilizados para DGA, destacam-se as ANN, SVM e o algoritmo k-NN, cada um com características específicas que os tornam adequados a diferentes aspectos do problema de diagnóstico (Kherif *et al.*, 2021).

#### 3.3.1 Artificial Neural Network

As redes neurais artificiais, ou *artificial neural networks* (ANN), são modelos computacionais inspirados no funcionamento do cérebro humano, compostos por neurônios artificiais organizados em camadas interconectadas. Segundo Mendonça *et al.* (2015), as ANNs são dotadas de capacidade de aprendizado por meio do treinamento e proporcionam eficiência mesmo em processos em que não há conhecimento explícito sobre como identificar uma solução factível, além de serem modelos robustos ao ruído nos dados. A Figura 12 apresenta a analogia entre o neurônio biológico e o neurônio artificial, em que os dendritos correspondem às entradas ponderadas, o corpo celular à função de agregação e ativação, e o axônio à saída do neurônio (Lima, 2016).

**Figura 12 – Comparação entre neurônio biológico e neurônio artificial**



**Fonte: Adaptado de Enriquez (2020).**

Matematicamente, o neurônio artificial realiza uma combinação linear das entradas ponderadas pelos pesos sinápticos, seguida da aplicação de uma função de ativação não-linear. A

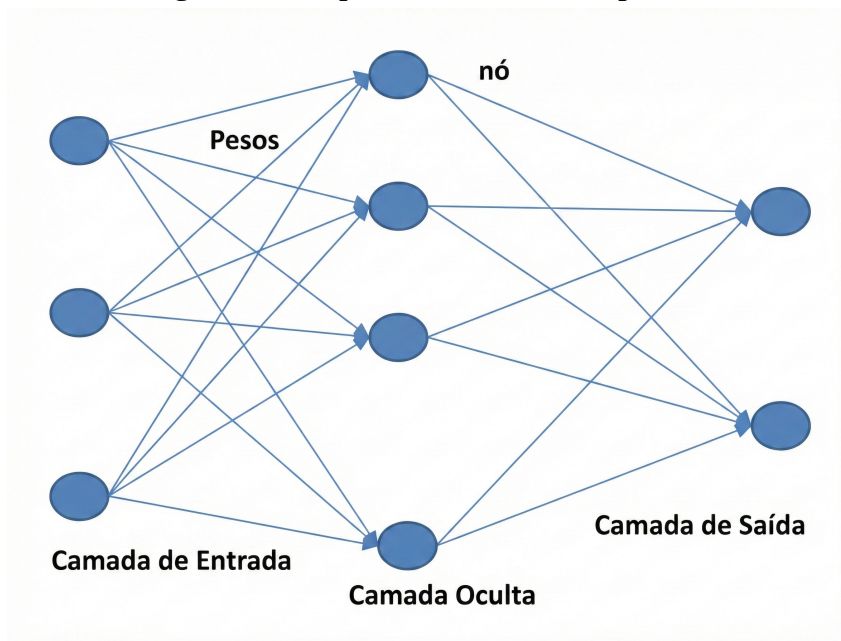
saída  $y$  de um conjunto de neurônios pode ser expressa pela Equação 1, em que  $u_i$  representa as entradas,  $w_i$  os pesos sinápticos,  $b$  o bias e  $\varphi$  a função de ativação (Enriquez, 2020).

$$y = \varphi \left( \sum_{i=1}^n w_i \cdot u_i + b \right). \quad (1)$$

A capacidade de aprendizado das ANNs reside no ajuste iterativo dos pesos sinápticos durante o treinamento, o que lhes permite captar padrões complexos nos dados. Este ajuste é realizado por meio de algoritmos de otimização que minimizam o erro entre a saída produzida pela rede e a desejada, sendo o *backpropagation* o método mais utilizado em redes multicamadas (Lima, 2016).

O Perceptron Multicamada (*Multi Layer Perceptron - MLP*) é a arquitetura de ANN mais utilizada em tarefas de classificação, devido à sua capacidade de aproximar funções não-lineares complexas (Enriquez, 2020). Conforme ilustrado na Figura 13, a rede MLP é organizada em três tipos de camadas: de entrada, uma ou mais camadas ocultas e de saída. O número de neurônios na camada de entrada corresponde às variáveis do problema, enquanto a camada de saída é dimensionada de acordo com as classes de classificação desejadas.

**Figura 13 – Arquitetura de ANN do tipo MLP**




**Fonte: Adaptado de (Enriquez, 2020).**

A determinação do número de neurônios nas camadas ocultas é realizada experimentalmente ou por meio de técnicas de otimização. Camadas com poucos neurônios podem resultar em *underfitting*, em que o modelo não captura adequadamente a complexidade dos dados, enquanto camadas excessivamente grandes podem levar a *overfitting*, caracterizado pela memorização dos dados de treinamento sem capacidade de generalização para novos exemplos (Enriquez, 2020).

### 3.3.2 Support Vector Machine

O SVM é um modelo de aprendizado supervisionado amplamente empregado em tarefas de classificação e regressão. O objetivo fundamental do SVM é determinar um hiperplano ótimo que separe as diferentes classes de dados no espaço de características. Este hiperplano é construído de modo a maximizar a margem, que corresponde à distância entre o próprio hiperplano e os pontos de dados mais próximos de cada classe. Tais pontos, que definem a fronteira de decisão, são denominados vetores de suporte, e uma das principais vantagens do modelo é que sua complexidade depende do número destes vetores, e não da dimensionalidade do espaço, o que favorece a generalização (Russell; Norvig, 2021). A representação bidimensional desse hiperplano é ilustrada na Figura 14. Nesta representação, os eixos x e y correspondem a duas características distintas extraídas do conjunto de dados, e os pontos espalhados pelo plano representam as amostras analisadas.

**Figura 14 – Hiperplano linear**



Fonte: Russell e Norvig (2021).

Matematicamente, a fronteira de decisão resulta da otimização de uma função quadrática, sendo expressa pela Equação 2:


$$f(x) = \sum_i \alpha_i z_i K(x, x_i) + b. \quad (2)$$

Onde  $\alpha$  são os dados do conjunto de treinamento,  $b$  o parâmetro *bias* (viés) encontrado durante o treinamento,  $x$  representa o vetor de suporte,  $x_i$  representam os vetores característicos,  $z_i$  os rótulos da classe e  $K$  a função *kernel*.

Para lidar com dados não linearmente separáveis, o SVM utiliza a técnica conhecida como *kernel trick* (truque do *kernel*). Essa abordagem mapeia os dados para um espaço de características de dimensão superior, no qual é possível encontrar um hiperplano de separação linear, conforme ilustrado na representação tridimensional da Figura 15. Nesse novo espaço

mapeado, os eixos da base representam as características originais dos dados, enquanto o eixo vertical ilustra a nova dimensão gerada pela função matemática. É essa dimensão adicional que permite que um plano reto atue como fronteira de separação entre as classes. Essa característica confere ao modelo grande flexibilidade e eficácia, tornando-o robusto em domínios de alta dimensionalidade ou quando o conhecimento prévio sobre a distribuição dos dados é limitado (Russell; Norvig, 2021).

**Figura 15 – Hiperplano não linear**



Fonte: Russell e Norvig (2021).

Dentre as funções de *kernel*, a *Radial Basis Function* (RBF) destaca-se pela ampla utilização, mapeando os dados para um espaço de alta dimensionalidade, sendo definida pela Equação 3:

$$K(x, x_i) = e^{-\gamma \|x - x_i\|^2}. \quad (3)$$

Em que,  $\gamma$  é o parâmetro que controla a largura da função *kernel*, determinando o alcance de influência de cada vetor de suporte e  $\|x - x_i\|^2$  a distância Euclidiana ao quadrado entre os vetores.

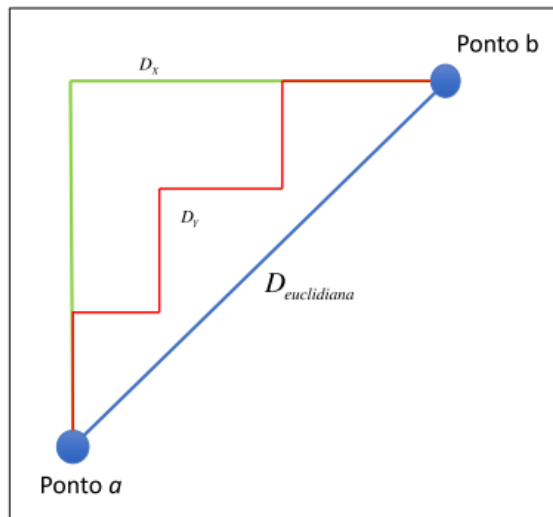
### 3.3.3 K-Nearest Neighbors

O k-NN é um algoritmo de classificação não paramétrico baseado em aprendizagem supervisionada, proposto por Fukunaga e Narendra em 1975, caracterizado por sua simplicidade conceitual e eficácia em diversas aplicações práticas (Enriquez, 2020). Conforme descrito por Guo *et al.* (2003), para classificar um novo registro de dados, o algoritmo recupera seus  $k$  vizinhos mais próximos no espaço de características, formando uma vizinhança local. A classe atribuída ao novo dado é determinada por votação majoritária entre os registros desta vizinhança, podendo incorporar ponderação por distância para aumentar a influência dos vizinhos mais próximos.

O funcionamento do k-NN fundamenta-se em critérios de similaridade, em que a proximidade entre pontos no espaço  $d$ -dimensional determina a classificação. A distância euclidiana é a métrica mais utilizada para este cálculo, definida entre dois pontos  $a$  e  $b$  pela Equação 4, que representa a menor distância geométrica entre esses pontos no espaço de características (Enriquez, 2020). A Figura 16 ilustra este conceito, demonstrando como a distância entre um novo ponto e os exemplos de treinamento é calculada para identificar os vizinhos mais próximos.

$$D(a,b) = \sqrt{\sum_{i=1}^d (a_i - b_i)^2}. \quad (4)$$


**Figura 16 – Representação da distância euclidiana entre pontos no espaço de características**



**Fonte: Adaptado de (Enriquez, 2020).**

O processo de classificação do k-NN é ilustrado na Figura 17, na qual um novo ponto (destacado) é classificado com base nos seus vizinhos mais próximos. O valor de  $k$  constitui um hiperparâmetro crítico do algoritmo, pois valores pequenos tornam o classificador sensível ao ruído nos dados, enquanto valores grandes podem suavizar excessivamente as fronteiras de decisão entre classes (Guo *et al.*, 2003). A seleção adequada de  $k$  geralmente é realizada por meio de validação cruzada, buscando o equilíbrio entre sensibilidade e capacidade de generalização do modelo.

**Figura 17 – Exemplo ilustrativo do método k-NN para classificação de um novo ponto**



**Fonte: Adaptado de (Enriquez, 2020).**

Uma característica importante do k-NN é sua classificação como método de aprendizado preguiçoso (*lazy learning*), pois não constrói um modelo explícito durante a fase de treinamento e armazena todos os exemplos para comparação na fase de classificação (Guo *et al.*, 2003). Esta abordagem apresenta vantagens como simplicidade de implementação e adaptabilidade a novos dados, porém, pode representar uma limitação em aplicações que exigem respostas rápidas, devido ao custo computacional de comparar cada nova instância com todo o conjunto de treinamento. Segundo Kherif *et al.* (2021), aprimoramentos no algoritmo, por meio da otimização do número de vizinhos e do tipo de distância, podem elevar significativamente a acurácia diagnóstica em aplicações de detecção de falhas.

### 3.4 Aplicação de classificadores na análise de gases dissolvidos

#### 3.4.1 Limitações dos métodos convencionais de DGA

Os métodos tradicionais de interpretação da DGA apresentam limitações significativas que comprometem a confiabilidade do diagnóstico de falhas em transformadores. Conforme destacam Zhang *et al.* (2022). O problema central associado aos métodos convencionais é que a decisão final sempre fica nas mãos de um especialista, o que gera dependência humana na tomada de decisões. Além disso, estes métodos têm dificuldade em lidar com casos ambíguos em que múltiplas falhas podem estar presentes simultaneamente, dependem de valores de limiar rígidos que nem sempre são eficazes para diagnosticar falhas em estágio inicial, e não consideram tendências históricas na evolução dos gases, o que reduz sua capacidade preditiva (Mendonça *et al.*, 2015). Segundo Zhang *et al.* (2022), o método de gás-chave, por exemplo, requer a presença de uma grande quantidade de gás na amostra de óleo, o que, em alguns casos, não permite chegar a uma conclusão definitiva.

### 3.4.2 Classificadores inteligentes aplicados a DGA

A DGA constitui o método mais amplamente utilizado para detecção de falhas incipientes em transformadores de potência, baseando-se na identificação e quantificação de gases produzidos pela decomposição do óleo isolante e da celulose. Os gases gerados no óleo isolante dos transformadores incluem  $H_2$ ,  $CH_4$ ,  $C_2H_6$ ,  $C_2H_4$ ,  $C_2H_2$ ,  $CO$  e  $CO_2$ , associados a diferentes tipos de falhas, como arco elétrico, aquecimento por sobrecarga, efeito corona e degradação da celulose (Mendonça *et al.*, 2015). A aplicação de técnicas de inteligência computacional na interpretação destes dados gasosos tem permitido superar limitações significativas dos métodos tradicionais, proporcionando diagnósticos mais precisos e confiáveis (Khan, 2025).

O problema associado aos métodos de DGA convencionais é que a decisão final sempre fica nas mãos de um especialista, existindo, portanto, dependência nas tomadas de decisão, além da dificuldade em lidar com casos ambíguos em que múltiplas falhas podem estar presentes simultaneamente. A aplicação de classificadores inteligentes na análise de gases dissolvidos tem demonstrado superioridade em relação aos métodos tradicionais em diversos aspectos. Autores como Dhiman *et al.* (2024), Khan (2025) e Zhang *et al.* (2022) demonstram que classificadores inteligentes, como ANN, SVM, k-NN e Árvores de Decisão, conseguem identificar padrões complexos em bases de dados de gases dissolvidos, alcançando taxas de acerto superiores a 95%.

Assim, o uso desses modelos treinados com base nos métodos tradicionais representa um avanço significativo na manutenção preditiva, contribuindo diretamente para a redução de falhas e o aumento da confiabilidade e assertividade no diagnóstico de falhas, mesmo em situações onde os transformadores apresentam diferentes características quanto à produção de gases devido a fatores como fabricante, nível de tensão, potência, estrutura e histórico de manutenção.

### 3.5 Métricas para avaliação de desempenho de classificadores

A avaliação de desempenho dos classificadores empregados no diagnóstico de falhas em transformadores de potência constitui uma etapa fundamental para determinar a eficácia das metodologias baseadas em IA. Os indicadores mais utilizados incluem acurácia, precisão, *recall* e F1-score, sendo este último particularmente relevante para conjuntos de dados desbalanceados, pois combina precisão e sensibilidade em uma única métrica harmônica (Zhang *et al.*, 2022). Estes parâmetros permitem uma análise comparativa abrangente entre diferentes abordagens e auxiliam na seleção da técnica mais adequada para aplicações práticas.

A acurácia representa a proporção de classificações corretas em relação ao total de amostras, conforme definida pela Equação 5:

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

Em que:

- *TP (True Positives)*: Verdadeiros positivos, amostras corretamente classificadas como pertencentes à classe positiva.
- *TN (True Negatives)*: Verdadeiros negativos, amostras corretamente classificadas como pertencentes à classe negativa.
- *FP (False Positives)*: Falsos positivos, amostras incorretamente classificadas como pertencentes à classe positiva.
- *FN (False Negatives)*: Falsos negativos, amostras incorretamente classificadas como pertencentes à classe negativa.

A precisão indica a proporção de verdadeiros positivos entre todas as predições positivas, sendo expressa pela Equação 6:

$$Precisão = \frac{TP}{TP + FP}. \quad (6)$$

Em que *TP* representa os verdadeiros positivos e *FP* os falsos positivos. Esta métrica é particularmente importante quando o custo de falsos positivos é elevado, pois quantifica a confiabilidade das predições positivas do classificador.

O *recall* (sensibilidade ou revocação) mede a capacidade do modelo de identificar corretamente os casos positivos, conforme apresentado na Equação 7:

$$Recall = \frac{TP}{TP + FN}. \quad (7)$$

Em que *TP* denota os verdadeiros positivos e *FN* os falsos negativos. Esta métrica avalia a proporção de casos positivos reais corretamente identificados pelo classificador, sendo crítica em aplicações em que a não detecção de falhas pode acarretar consequências severas para a operação do transformador.

O F1-score é a média harmônica entre precisão e *recall*, sendo especialmente útil quando há desbalanceamento entre classes, conforme definido pela Equação 8:

$$F1 = 2 \times \frac{Precisão \times Recall}{Precisão + Recall}. \quad (8)$$

Em que os termos *Precisão* e *Recall* são obtidos pelas Equações 6 e 7, respectivamente. O F1-score equilibra a capacidade do modelo de evitar falsos positivos (*precisão*) e de detectar todos os casos positivos (*recall*), sendo particularmente valioso quando ambas as métricas são igualmente importantes para a aplicação.

## 4 TRABALHOS RELACIONADOS

Este capítulo apresenta uma revisão dos principais trabalhos que abordam temas semelhantes aos desta pesquisa. Foram selecionados estudos sobre manutenção preditiva em transformadores de potência, utilizando IA e DGA. A revisão contempla trabalhos com diversas abordagens, como sistemas de inferência fuzzy e redes neurais convolucionais, o que evidencia a evolução das técnicas convencionais.

### 4.1 Sistema inteligente de manutenção preditiva de transformadores: PREDITRAFO

Através de um projeto de pesquisa e desenvolvimento (P&D) a Companhia Energética de Pernambuco (CELPE) e a Universidade Federal de Pernambuco (UFPE) desenvolveram um software denominado PREDITRAFO (Aquino *et al.*, 2011b), desenvolvido com o objetivo de auxiliar os especialistas de manutenção na tomada de decisão quanto à realização de manutenção preditiva em transformadores de potência, por meio da análise cromatográfica do óleo isolante.

Antes do software, a CELPE utilizava um sistema manual e descentralizado de armazenamento de laudos, no qual os relatórios eram mantidos em pastas físicas identificadas pelo número de série do transformador. Essa prática dificultava o acesso ao histórico de análises e a identificação de tendências evolutivas dos gases dissolvidos ao longo da vida útil do equipamento.

A principal motivação era substituir essa abordagem ultrapassada por um sistema computacional integrado, capaz de armazenar dados de forma estruturada, aplicar técnicas de IA para o diagnóstico de falhas e possibilitar o acompanhamento histórico dos transformadores.

O PREDITRAFO foi implementado em MATLAB, utilizando um sistema de inferência fuzzy baseado nas normas IEC e Rogers como máquina de inferência. O sistema funciona por meio da fuzzificação das relações entre gases ( $C_2H_2/C_2H_4$ ,  $CH_4/H_2$ ,  $C_2H_4/C_2H_6$ ), atribuindo valores de pertinência a cada razão gasosa. Cada função de pertinência é parametrizada heurísticamente para aproximar os limites estabelecidos pelas normas, resultando em diagnósticos probabilísticos.

Os resultados de validação do PREDITRAFO foram notáveis, tendo em vista que, quando avaliado pelas normas IEC e Rogers, o sistema de inferência fuzzy alcançou altas taxas de acertos em todos os casos tabelados e estimou diagnósticos nos casos não tabelados pelas normas. Este caso demonstra a importância crítica de sistemas capazes de fornecer diagnósticos, mesmo quando os métodos tradicionais não resultam em conclusões definidas.

Contudo, o trabalho apresenta limitações, como, por exemplo, na Figura 18, pode-se observar a tabela de inclusão de amostras do software, e percebe-se que os volumes dos gases de cada transformador são inseridos manualmente pelo usuário. Segundo os autores, as funções de pertinência que realizam a fuzzificação da relação dos gases foram realizadas de forma heurística, isto é, pela avaliação empírica dos resultados. Além disso, o software não contempla a

adaptação automática do sistema a novos padrões de falha, limitando-se a métodos baseados em regras fuzzy.

**Figura 18 – Tela de inclusão de amostra do PEDITRAFO**

The screenshot shows the 'Inclusão de Amostras' window. At the top, it identifies the substation as 'AFI' and the transformer as '139413'. A table lists several gas analysis reports with the following columns: Data, Empresa, Relatório, Razões IEC, H2, O2, N2, CH4, CO, and CO2. The first row is highlighted in blue. Below the table, there are input fields for 'Num. Relatório', 'Data amostra', 'Cd Transformador', 'Cd Subestacao', 'Nome Empresa', and 'Recomendacao'. There are also fields for gas volumes (H2, O2, N2, CH4, CO, CO2) and a dropdown for 'Coleta após desgaseificação?' set to 'NÃO'. 'Incluir' and 'Sair' buttons are at the bottom right.

Fonte: (Aquino *et al.*, 2011b).

## 4.2 Diagnóstico inteligente de falhas em transformadores utilizando DGA

Dhiman, Sharma e Chandra (2021) propõem uma abordagem moderna que integra ANN e classificadores de máquina com dados de DGA para superar as limitações do método tradicional da IEC. O trabalho identifica que o método IEC de três razões, embora amplamente utilizado, apresenta limitações críticas quando os dados das razões de gases divergem ligeiramente dos limites precisos estabelecidos pelas normas. Além disso, transformadores frequentemente apresentam múltiplas falhas simultâneas que os métodos tradicionais não conseguem captar adequadamente.

Sendo assim, Dhiman, Sharma e Chandra (2021) propõem a integração de técnicas de IA para superar esses desafios, particularmente em cenários onde as razões de gases situam-se na fronteira entre duas zonas de falha, ou também quando ocorrem múltiplas falhas no equipamento, além de quando os dados possuem variabilidade devido a incertezas de medição. O trabalho propõe integração de três técnicas, sendo elas:

- **Bagged Tree Classifier:** Método de *ensemble* (método no qual os modelos de ML utilizam o resultado de cada modelo na definição de um único resultado, obtendo-se assim um valor final único) que treina múltiplas Árvores de Decisão em subconjuntos aleatórios dos dados, reduzindo *overfitting* (erro devido ao modelo se adaptar aos dados de treinamento, aprendendo detalhes e erros, assim dificultando novos resultados com outros dados);

- ***Fine Tree Classifier***: Árvore de decisão com alta resolução, capturando padrões complexos através de múltiplas divisões;
- **ANN**: Arquitetura de múltiplas entradas e saída única (MISO, *Multiple Input, Single Output*), sendo as entradas as três razões IEC ( $L_1, L_2, L_3$ ) e a saída os tipos de falhas.

Para a ANN, o treinamento utiliza o algoritmo de *Levenberg-Marquardt*, com função de ativação logística sigmoide nas camadas ocultas, para introduzir não linearidades. O estudo utilizou banco de dados contendo 389 amostras de transformadores, divididas em 273 amostras para treinamento (70%), 58 amostras para validação (15%) e 58 amostras para teste (15%). A implementação foi realizada no MATLAB.

Os resultados evidenciaram o desempenho superior dos modelos inteligentes em comparação aos métodos tradicionais de diagnóstico. O classificador Bagged Tree alcançou a maior acurácia de validação obtendo 99,5%, seguido de perto pelo modelo Fine Tree com 99%. Adicionalmente, a ANN demonstrou alta consistência no mapeamento das falhas, registrando acurácias de 98,2% na etapa de treinamento, 96,09% na validação e 97,81% na fase de teste.

O trabalho incluiu análise detalhada por meio de matrizes de confusão e curvas ROC, demonstrando robusta capacidade de discriminação entre diferentes tipos de falha. A ANN, apesar de ligeiramente inferior ao Bagged Tree, apresentou melhor generalização em dados de teste completamente novos (97,81% vs. resultados do Bagged Tree não separados para teste).

Porém, o trabalho reconhece suas limitações, como, por exemplo, o uso de um *dataset* relativamente pequeno (389 amostras) e o foco exclusivo em razões IEC tradicionais como entradas, sem realizar análise de séries temporais ou de tendências evolutivas das falhas. Os autores sugerem dicas para trabalhos futuros, como a incorporação de técnicas de interpretabilidade, a integração de redes neurais profundas para análise temporal e a validação em múltiplos bancos de dados públicos.

### **4.3 Monitoramento e diagnóstico de um transformador de potência: análise de gases dissolvidos no óleo e análise térmica**

O trabalho desenvolvido por (Almeida *et al.*, 2007) teve como objetivo principal a criação de um sistema computacional inteligente para o monitoramento e o diagnóstico de falhas incipientes em transformadores de potência imersos em óleo. A pesquisa buscou solucionar as limitações diagnósticas e as incertezas geradas pelos métodos analíticos tradicionais, especificamente o problema de "não decisão", que ocorre quando os gases não se enquadram em nenhuma falha tabelada na norma internacional IEC (2022). Além da análise química, o estudo objetivou aprimorar o monitoramento do carregamento térmico do transformador por meio da predição da temperatura no topo do óleo.

Para contornar as imprecisões matemáticas e as não linearidades do processo de formação de gases, os autores empregaram técnicas de Inteligência Computacional, com destaque para a aplicação de Sistemas Fuzzy e de ANN. Foram desenvolvidos três sistemas fuzzy distin-

tos, cujas bases de regras expandiram os limites da norma IEC (2022) para cobrir todas as combinações possíveis de gases, e uma rede neural do tipo MLP, treinada pelo algoritmo de *back-propagation*, para realizar o mapeamento não-linear das falhas. Em paralelo, a pesquisa integrou os dados de um equipamento de leitura *online* (Hydran M2) para gerar um pré-diagnóstico baseado na tendência de evolução do total de gases combustíveis e utilizou modelos matemáticos não lineares, como o modelo polinomial NARX, nas versões caixa cinza e caixa preta, para o cálculo da temperatura interna do óleo.

Os resultados obtidos confirmaram a eficácia da inteligência artificial aplicada à manutenção preditiva, culminando no desenvolvimento bem-sucedido de um software integrador. Na avaliação da cromatografia gasosa, a topologia de rede neural MLP e um dos modelos fuzzy otimizados atingiram uma taxa de acerto de 91% na identificação das falhas em dados reais, superando os diagnósticos convencionais. Os sistemas fuzzy demonstraram alta precisão na identificação de ocorrências críticas, como sobreaquecimentos superiores a 700°C e descargas de alta energia. Por fim, na análise térmica, o modelo polinomial não linear NARX do tipo "caixa cinza" apresentou o melhor desempenho na estimação da temperatura do equipamento, mostrando-se superior aos métodos tradicionais recomendados pela norma IEEE (2019).

Apesar da união da rede neural com a lógica fuzzy ter superado as normas tradicionais, alcançando 91% de acerto, conforme o estudo de ALMEIDA *et al.* (2007), é evidenciado que a IA ainda depende fortemente da correta escolha das variáveis de entrada e que sistemas mal calibrados podem herdar as mesmas indecisões dos métodos matemáticos clássicos

#### 4.4 Posicionamento da pesquisa atual

Os trabalhos relacionados demonstram a evolução no campo do diagnóstico de transformadores, em que cada trabalho apresenta suas respectivas características, como, por exemplo, um sistema baseado em regras que avalia a viabilidade da IA em relação a métodos clássicos e o uso de *Deep Learning* (DL) e classificadores avançados que melhoram a acurácia, tratando múltiplas falhas com foco em interpretabilidade.

Esta pesquisa busca desenvolver um sistema utilizando ANN, SVM e k-NN em *datasets* públicos complementares, visando à validação em múltiplas bases de dados, garantindo assim generalização e aplicação prática. Os trabalhos anteriores focam em um algoritmo ou em um conjunto de dados específico, enquanto esta pesquisa propõe uma abordagem comparativa entre as técnicas, com metodologia atualizada e validada.

Apesar dos avanços, identificam-se lacunas importantes que esta pesquisa busca contribuir para preencher, sendo elas:

- **Comparação Limitada:** Poucos trabalhos comparam ANN, SVM e métodos tradicionais sob as mesmas condições experimentais e *datasets*;
- **Reprodutibilidade:** Muitos trabalhos não disponibilizam código ou *datasets* completos para validações independentes;

- **Análise Temporal:** Exploração limitada de como os modelos lidam com a progressão temporal das falhas.

## 5 METODOLOGIA

Este trabalho tem como objetivo desenvolver um sistema de diagnóstico de falhas em transformadores de potência com desempenho superior aos métodos tradicionais citados pelas normas. Por meio da implementação de três métodos inteligentes de classificação — ANN, SVM e K-NN —, aplicados à análise de DGA para identificar os tipos de falha, conforme a norma IEC (2022). A implementação foi realizada em Python, permitindo comparar o desempenho das três técnicas sob as mesmas condições experimentais.

O fluxo metodológico compreende as etapas de coleta de dados, pré-processamento, divisão do conjunto de dados, treinamento dos modelos e avaliação de desempenho. A abordagem comparativa permite identificar a técnica de melhor desempenho para aplicações práticas de manutenção preditiva em transformadores.

### 5.1 Base de dados

Os dados utilizados foram obtidos do *dataset* público *DGA - Dissolved Gas Analysis*, do autor Pereira (2025), disponível na plataforma Kaggle. O banco de dados apresenta as concentrações dos gases  $H_2$ ,  $CH_4$ ,  $C_2H_6$ ,  $C_2H_4$  e  $C_2H_2$ , distribuídas em colunas e expressas em partes por milhão (ppm), e a variável categórica de rótulo de falha está na coluna *Fails*, que indica a condição diagnóstica de cada amostra. O *dataset* contempla sete categorias diagnósticas padronizadas, cuja nomenclatura segue as convenções estabelecidas pelas normas (IEC, 2022) e IEEE (2019) para interpretação de resultados de DGA. Na Tabela 6 pode-se verificar a quantidade de amostras para cada tipo de falha.

**Tabela 6 – Distribuição das classes de falha no *dataset* original**

Classe	Descrição	Quantidade	Percentual (%)
T3	Falha térmica de alta temperatura ( $> 700\text{ }^\circ\text{C}$ )	879	21,18
D2	Descarga elétrica de alta energia	770	18,55
NF	Operação normal ( <i>Normal Functioning</i> )	740	17,83
D1	Descarga elétrica de baixa energia	598	14,41
T1	Falha térmica de baixa temperatura ( $< 300\text{ }^\circ\text{C}$ )	463	11,16
PD	Descarga parcial ( <i>Partial Discharge</i> )	351	8,46
T2	Falha térmica de temperatura média ( $300\text{--}700\text{ }^\circ\text{C}$ )	349	8,41
<b>Total</b>		<b>4.150</b>	<b>100,00</b>

**Fonte: Elaborado pelo autor.**

O *dataset* possui 4150 amostras, uma quantidade significativa para a realização de uma análise mais profunda, e inclui uma variável importante, intitulada *Normal Functioning* (NF), que indica o transformador em funcionamento normal, sem falhas. Essa variável permite que os classificadores diferenciem o estado saudável do estado de falha, condição mais próxima da realidade e evitando falsos positivos.

A distribuição das classes revela um desequilíbrio moderado entre as categorias, com a classe T3 concentrando 21,18% das amostras e as classes PD e T2 respondendo por menos de 9% cada. Esse tipo de assimetria é recorrente em datasets de diagnóstico de transformadores, uma vez que falhas graves, como descargas parciais, tendem a ser menos frequentes do que as falhas térmicas de alta temperatura. O desequilíbrio entre classes impõe desafios adicionais ao treinamento de classificadores, pois modelos treinados sem estratégias de balanceamento tendem a enviesar suas predições em favor das classes majoritárias, comprometendo o desempenho nas classes menos representativas.

## 5.2 Ambiente computacional

A implementação foi realizada em Python, mais especificamente no software Spyder, utilizando as bibliotecas Scikit-learn para SVM e K-NN, e Keras/TensorFlow para a ANN. A manipulação dos dados foi realizada com Pandas e NumPy, enquanto as visualizações foram geradas com Matplotlib e Seaborn. O ambiente de desenvolvimento foi configurado no Jupyter Notebook, permitindo documentar, de forma integrada, o código com os resultados.

A Tabela 7 apresenta as bibliotecas utilizadas no projeto.

**Tabela 7 – Bibliotecas Python utilizadas**

<b>Biblioteca</b>	<b>Funcionalidade</b>
Pandas	Manipulação de dados
NumPy	Operações numéricas
Scikit-learn	SVM, K-NN e métricas
TensorFlow/Keras	Redes neurais
Matplotlib/Seaborn	Visualização

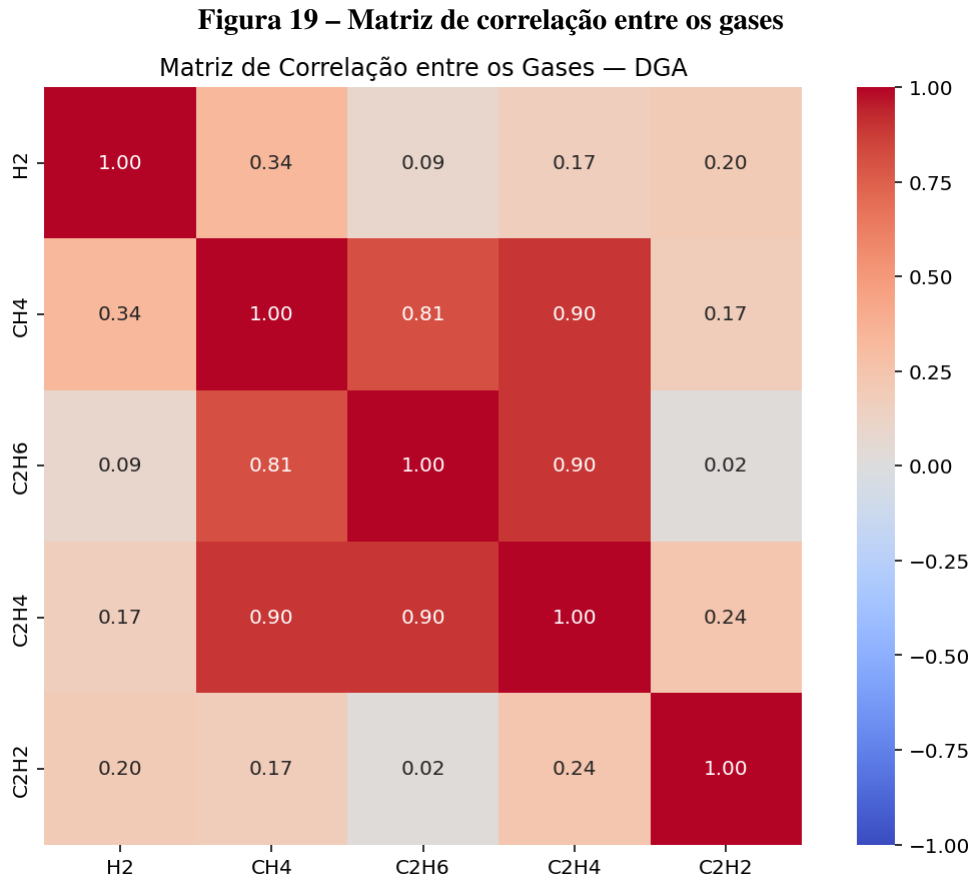
**Fonte: Elaborado pelo autor.**

## 5.3 Pré-processamento dos dados

O pré-processamento de dados é uma etapa fundamental em projetos de aprendizado de máquina, responsável por transformar dados brutos em um conjunto consistente, confiável e adequado ao treinamento de modelos. Conforme Barbosa (2023), a qualidade dos dados de entrada influencia diretamente na capacidade de generalização dos classificadores supervisionados. No contexto da análise de gases dissolvidos, essa preparação assume importância ainda maior, pois as concentrações dos gases apresentam grande variabilidade entre transformadores em razão de fatores como fabricante, nível de tensão, potência e histórico operacional, gerando distribuições fortemente assimétricas e a presença de valores extremos que precisam ser tratados antes do treinamento.

Primeiramente, foi construída a matriz de correlação dos gases utilizando o método aplicado diretamente aos atributos, conforme a Figura 19. Essa matriz serve para relacionar

linearmente os atributos; isto é, gases altamente correlacionados apresentam valores próximos de 1 (um).



**Fonte: Elaborado pelo autor.**

Ao se analisar a Figura 19, observa-se que as três maiores relações são  $C_2H_4/C_2H_6$ ,  $C_2H_4/CH_4$  e  $CH_4/C_2H_6$ . Isso indica que, no *dataset*,  $CH_4$ ,  $C_2H_6$  e  $C_2H_4$  variam conjuntamente; ou seja, quando a presença de um dos gases aumenta, a tendência é que os outros também aumentem.

Essas relações podem parecer erradas à primeira vista, pois diferem das propostas pela norma IEC (2022), que define como razões fundamentais de diagnóstico  $C_2H_2/C_2H_4$ ,  $CH_4/H_2$  e  $C_2H_4/C_2H_6$ . Porém, justamente por  $CH_4$ ,  $C_2H_6$  e  $C_2H_4$  serem altamente correlacionados, utilizá-los como atributos independentes introduziria redundância nos classificadores. As razões propostas pela norma reduzem essa redundância ao capturar a proporção entre os gases, que varia conforme o tipo e a intensidade de cada tipo de falha, preservando, assim, as informações distintas relevantes para o diagnóstico.

### 5.3.1 Remoção de *outliers*

Antes da remoção de *outliers*, verificou-se a presença de dados faltantes no *dataset* por meio de ferramentas da biblioteca *Pandas*. Verificou-se que todas as colunas possuem valo-

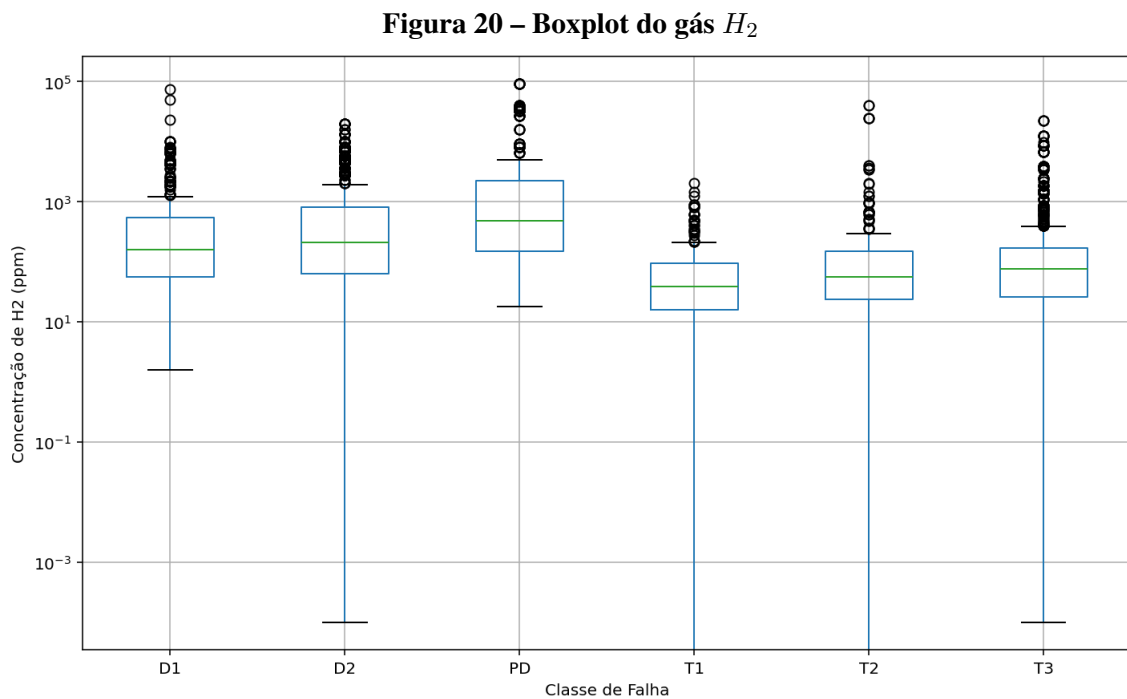
res preenchidos, não havendo nenhuma variável nula ou *NaN*, o que dispensa a aplicação de técnicas como o método *Missing Completely at Random* (MCAR).

Para a remoção de *outliers*, utilizou-se o método baseado em desvios-padrão, também com a biblioteca Pandas. O critério adotado considera como *outlier* qualquer amostra cujo valor se afaste mais de 3 desvios-padrão da média da variável, sendo os limites calculados conforme as Equações 9 e 10.

$$\text{Limite inferior} = \mu - (3 \times \sigma), \quad (9)$$


$$\text{Limite superior} = \mu + (3 \times \sigma), \quad (10)$$

onde  $\mu$  representa a média e  $\sigma$  o desvio padrão da variável analisada. Amostras com valores inferiores ao limite inferior ou superiores ao limite superior são consideradas *outliers* e removidas do conjunto de dados. Antes do cálculo, a classe NF foi separada para evitar a remoção de *outliers*. Essa decisão se justifica pela análise das Figuras 20, 21, 22, 23 e 24.




**Fonte: Elaborado pelo autor.**

Figura 21 – Boxplot do gás  $CH_4$




Fonte: Elaborado pelo autor.

Figura 22 – Boxplot do gás  $C_2H_6$




Fonte: Elaborado pelo autor.

Figura 23 – Boxplot do gás  $C_2H_4$



Fonte: Elaborado pelo autor.

Figura 24 – Boxplot do gás  $C_2H_2$



Fonte: Elaborado pelo autor.

É possível perceber que a classe NF apresenta concentrações de gases significativamente menores do que as das classes de falha, com medianas próximas a  $10^0$  ppm, o que é fisicamente esperado em transformadores saudáveis. Caso o *boxplot* fosse calculado incluindo a classe NF, amostras legítimas de falha seriam erroneamente identificadas como *outliers* e removidas. Após a remoção dos *outliers* nas demais classes de falha, a classe NF foi reincorporada ao conjunto, compondo o *dataset* final utilizado nas etapas subsequentes. Após a limpeza dos dados, foi salvo um novo arquivo no formato .csv para a próxima etapa.

### 5.3.2 Cálculo das razões dos gases

A partir dos dados limpos obtidos na etapa anterior, foram calculadas as três razões de gases fundamentais de diagnóstico, conforme a norma IEC (2022) mencionada anteriormente. Essas razões constituem os atributos de entrada para os classificadores de aprendizado de máquina, em substituição às concentrações absolutas dos gases.

Um aspecto crítico no cálculo das razões de gases é a presença de valores muito próximos de zero nos denominadores, o que pode resultar em razões numericamente instáveis. A norma IEC (2022) estabelece um limite mínimo nas concentrações de gases a serem utilizados, sendo esse valor de 0,1 ppm, acima do qual concentrações de gases abaixo do valor não são consideradas significativas para fins de diagnóstico; sendo assim, para as amostras pertencentes às classes de falha (D1, D2, PD, T1, T2 e T3), apenas as amostras em que todos os gases apresentavam concentrações iguais ou superiores a 0,1 ppm.

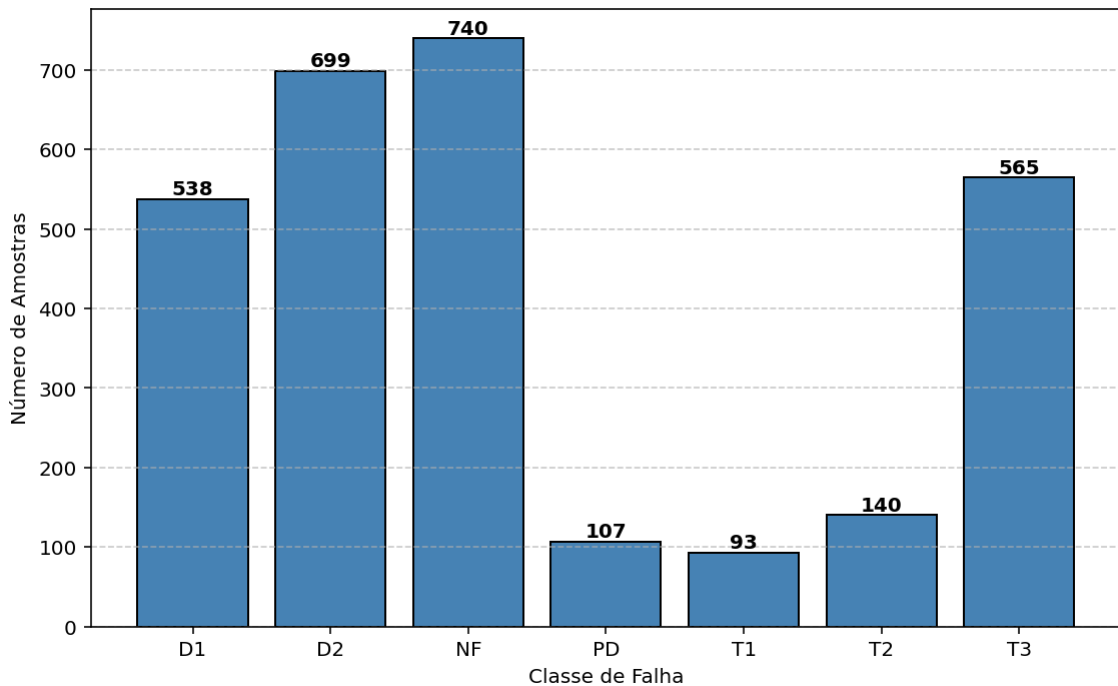
Contudo, a aplicação desse critério na classe NF (*Normal Functioning*) tornou-se inviável, uma vez que transformadores em operação saudável apresentam concentrações de gases muito reduzidas, frequentemente próximas ou abaixo do limite de detecção. O uso do filtro em todos os gases da classe NF resultaria na eliminação de praticamente todo o conjunto de amostras dessa classe (restando apenas 54 amostras após a aplicação do filtro). Logo, os classificadores se tornariam imprecisos ao distinguir o estado normal de funcionamento das condições de falha. Por essa razão, optou-se por uma abordagem diferenciada para a classe NF, na qual o filtro não foi aplicado.

Após o processamento independente de cada grupo, as razões calculadas para as classes de falha e para a classe NF foram reunidas em um único conjunto, e o resultado final foi exportado para um novo arquivo .csv, contendo as três razões calculadas e o respectivo rótulo de classe para cada amostra, constituindo a base de entrada para as etapas subsequentes de balanceamento, divisão e treinamento dos modelos de classificação.

### 5.3.3 Balanceamento das classes

Após as etapas de limpeza dos dados, verificou-se a necessidade de balanceamento das classes. Para isso, foi verificada a distribuição das classes, conforme a Figura 25.

**Figura 25 – Distribuição após a limpeza dos dados**




**Fonte: Elaborado pelo autor.**

Na Figura 25, nota-se que a classe NF é a que possui mais amostras, resultado esperado, pois não passou pela mesma limpeza das demais classes. A principal análise aqui é que D2, D1 e T3 possuem um número de amostras maior do que o de PD, T1 e T2. Isso representa um problema, pois as classes com mais amostras tendem a enviesar o treinamento, deixando as outras classes sub-representadas, isto é, com menor acurácia justamente nelas, afetando a confiabilidade da métrica acurácia. Assim, foi necessário o balanceamento dos dados e, para isso, utilizou-se a técnica *Synthetic Minority Over-sampling Technique* (SMOTE), da biblioteca *imbalanced-learn*. O SMOTE gera amostras sintéticas para as classes minoritárias, não por simples cópia de dados existentes, mas pela criação de novos pontos interpolados entre amostras reais próximas entre si. Dessa forma, o conjunto de dados se torna equilibrado sem que o modelo simplesmente memorize exemplos repetidos.

Contudo, o SMOTE isolado pode introduzir amostras em regiões de fronteira entre classes; assim, foi adotada a variante SMOTETomek, que combina o SMOTE com a técnica de Tomek Links, na qual, após gerar as amostras sintéticas, remove os pares de pontos de outras classes que estejam muito próximos na fronteira de separação. O resultado é um conjunto de dados ao mesmo tempo balanceado e com fronteiras entre classes bem definidas, conforme ilustrado na Figura 26.

**Figura 26 – Distribuição após SMOTETomek**



**Fonte: Elaborado pelo autor.**

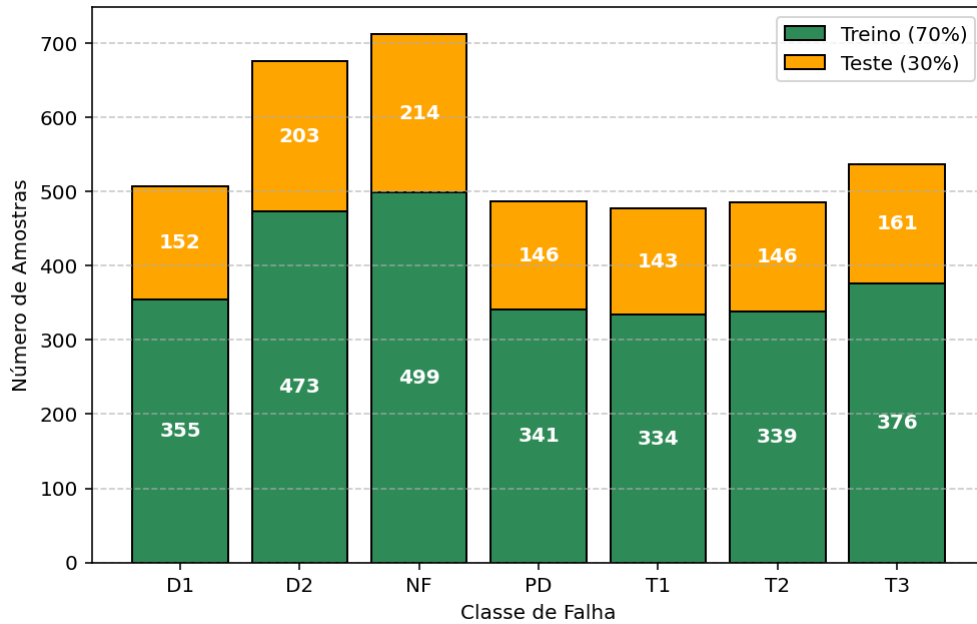
É importante ressaltar que, por padrão, o SMOTE gera amostras sintéticas nas classes minoritárias até que todas igualem à classe majoritária. Nesse caso, todas as classes teriam 740 amostras, o que poderia levar a *overfitting*. Para evitar isso, o parâmetro *sampling strategy* do SMOTE permite definir um limite de amostras a serem geradas por classe, conforme utilizado neste trabalho, garantindo um balanceamento mais controlado sem distorcer a distribuição original dos dados.

#### 5.3.4 Divisão do conjunto de dados

Após o balanceamento, o conjunto de dados foi dividido em dois subconjuntos: treino e teste, utilizando a função *train\_test\_split* da biblioteca *scikit-learn*. A proporção adotada foi de 70% para treino e 30% para teste.

Um aspecto relevante foi o uso do parâmetro *stratify*, que garante que a proporção entre as classes seja mantida tanto no conjunto de treino quanto no de teste. Sem esse parâmetro, a divisão seria puramente aleatória, o que poderia resultar em subconjuntos com distribuições desiguais entre as classes, comprometendo tanto o treinamento quanto a avaliação do modelo. Na Figura 27, é possível verificar quantas amostras foram separadas para treino e para teste.

Figura 27 – Distribuição no Treino



Fonte: Elaborado pelo autor.

#### 5.4 Otimização de hiperparâmetros

A otimização de hiperparâmetros dos modelos de ML consiste em encontrar as melhores combinações possíveis dessas variáveis, a fim de alcançar um modelo com o melhor desempenho possível para os dados de entrada. Para encontrar essas combinações, foi escolhido o método *RandomizedSearchCV*, tendo em vista que seu desempenho foi extremamente superior às tentativas manuais de escolha e superior ao outro método testado, o *GridSearchCV*.

O método *GridSearchCV* testa todas as combinações possíveis, o que sempre resultará na melhor combinação. Porém, para métodos com muitos hiperparâmetros, como a ANN, seu uso tornou-se inviável devido ao custo computacional. Por outro lado, o *RandomizedSearchCV* funciona sorteando aleatoriamente um número fixo de combinações para serem testadas, o que torna o código computacionalmente mais barato. Uma dúvida pode surgir nessa escolha: como garantir que os melhores hiperparâmetros foram encontrados se as combinações são sorteadas aleatoriamente? A resposta é que não há garantia; o *RandomizedSearchCV* encontra a melhor combinação apenas entre os valores sorteados.

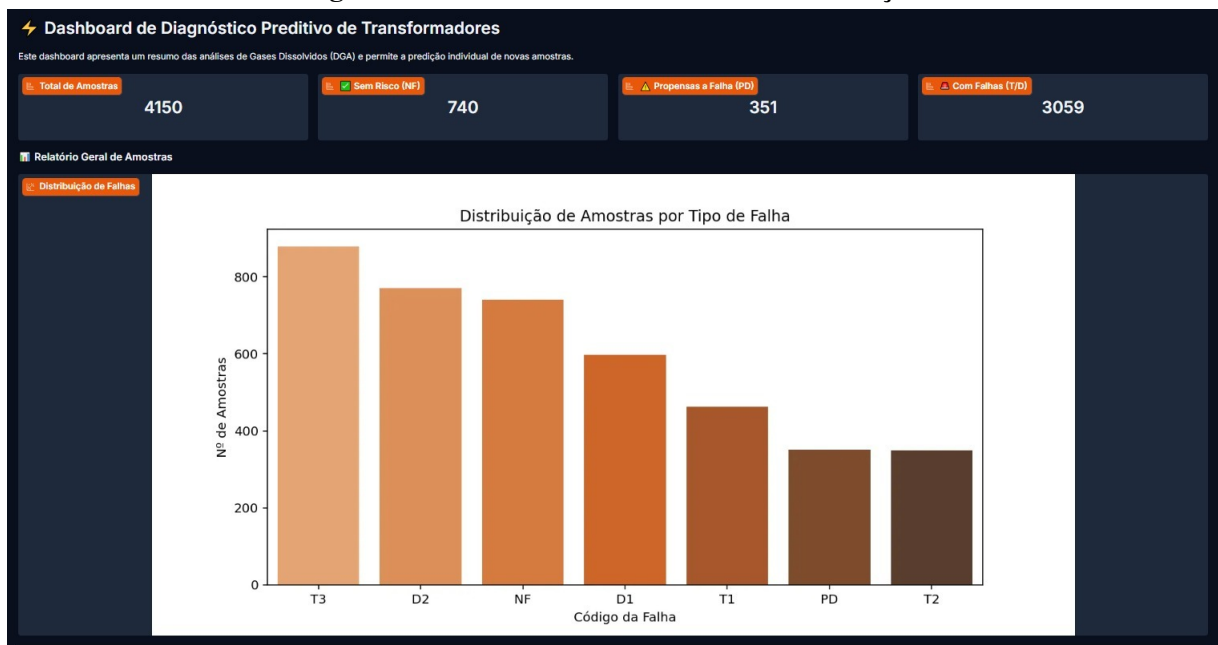
Na prática, isso não representou um problema relevante, pois o risco de ignorar boas combinações é controlado pelo parâmetro *n iter*, que determina o número de combinações a serem sorteadas. Logo, quanto maior o *n iter*, maior o espaço de busca e menor a chance de perder uma combinação relevante.

## 5.5 Sistema de visualização de dados

Para implementar o sistema de visualização de dados, conforme o último objetivo específico, utilizou-se a biblioteca Gradio, que permite transformar funções em Python em interfaces web interativas, sem a necessidade de conhecimentos em desenvolvimento web.

Sua utilização baseou-se no modelo treinado para a criação de uma interface composta por duas seções principais. Na primeira seção, conforme a Figura 28, tem-se um *dashboard* geral, que apresenta as estatísticas do conjunto de dados utilizado pelo modelo, apresentando o total de amostras e a distribuição por classe de falha do *dataset* original.

**Figura 28 – Dashboard do sistema de visualização**



**Fonte: Elaborado pelo autor.**

Já na figura 29, tem-se uma seção de predição individual, na qual o usuário insere as concentrações dos cinco gases dissolvidos em ppm. Com isso, obtém-se como saída a classe de falha diagnosticada pelo modelo, acompanhada do nível de confiança de cada classe. Sua validação será apresentada no capítulo seguinte.

**Figura 29 – Sistema de visualização**



**Fonte: Elaborado pelo autor.**

## 6 RESULTADOS E DISCUSSÕES

### 6.1 Métodos tradicionais de diagnóstico

#### 6.1.1 Razões de gases

A primeira etapa da análise de resultados consistiu em aplicar a metodologia normativa de razões de gases prevista pela norma IEC (2022) e replicada pela ABNT (2026) ao conjunto completo de 4.150 amostras do *dataset* utilizado neste trabalho. A implementação seguiu rigorosamente os limiares estabelecidos na Tabela 5, calculando-se as três razões características  $C_2H_2/C_2H_4$ ,  $CH_4/H_2$  e  $C_2H_4/C_2H_6$ , e atribuindo-se a cada amostra uma das seis classes de falha (PD, D1, D2, T1, T2, T3) ou o rótulo “Indefinido”, quando nenhuma combinação de razões satisfazia os intervalos normativos. O objetivo deste experimento foi estabelecer uma linha de base (*baseline*) que permitisse mensurar o ganho efetivo proporcionado pelos algoritmos de aprendizado supervisionado discutidos na seção subsequente.

Os resultados obtidos evidenciam, de forma contundente, as limitações apontadas na literatura quanto à aplicação isolada do método das razões de gases. Do total de 4.150 amostras processadas, 1.301 (31,3%) não puderam ser enquadradas em nenhuma das classes previstas na norma e foram classificadas como “Indefinido”. Dentre essas, 1.201 (28,9% do total) correspondiam a falhas reais, cujos padrões de razões situavam-se fora dos intervalos rígidos da tabela de razões de gases da IEC (2022). Tal comportamento confirma a observação de Dhi-man *et al.* (2024), segundo a qual o método das três razões falha sistematicamente quando os valores divergem ligeiramente dos limites normativos, deixando uma parcela significativa das amostras sem diagnóstico conclusivo. A Tabela 8 sintetiza os indicadores gerais de cobertura e de acurácia obtidos.

**Tabela 8 – Resumo da classificação pelo método das razões de gases IEC 60599**

Indicador	Quantidade	Percentual
Total de amostras	4.150	100,0%
Amostras classificadas pela norma	2.849	68,7%
Amostras indefinidas (sem diagnóstico)	1.301	31,3%
↪ Indefinidos que são falhas reais	1.201	28,9%
Amostras NF no <i>dataset</i>	740	17,8%
Acurácia global (com Indefinidos)		33,35%
Acurácia sobre amostras classificadas		49,00%

**Fonte: Elaborado pelo autor.**

A acurácia global obtida pelo método tradicional foi de 33,35%, considerando-se as amostras “Indefinido” como classificações incorretas, conforme exposto na Tabela 8. Mesmo restringindo-se à análise das 2.849 amostras (68,7% do total) que o método conseguiu classificar, a acurácia subiu para apenas 49%, indicando que praticamente metade dos diagnósticos emitidos pela norma estavam equivocados quando confrontados com os rótulos verdadeiros do *dataset*. Este resultado confirma o levantamento bibliográfico de Zhang *et al.* (2022), que aponta

taxas de acerto frequentemente inferiores a 60% para métodos clássicos de razões aplicados a bases de dados reais e diversificadas.

A análise por classe, apresentada na Tabela 9, revela padrões particularmente preocupantes quanto à confiabilidade do método normativo. A classe NF (transformadores em condição normal de operação) apresentou precisão e *recall* iguais a zero, evidenciando que a tabela de razões da IEC 60599 (2019) é estruturalmente incapaz de identificar transformadores saudáveis, uma vez que a norma não prevê faixas de razões para a ausência de falha. Esta limitação é crítica do ponto de vista da manutenção preditiva, pois 17,8% das amostras do *dataset* correspondem a equipamentos sem defeito e que, pelo critério normativo, foram inevitavelmente classificados como falhas inexistentes ou como “Indefinido”.

**Tabela 9 – Relatório de classificação do método IEC 60599 (amostras efetivamente classificadas)**

Classe	Precisão	Recall	F1-score	Suporte
D1	0,40	0,87	0,55	252
D2	0,94	0,29	0,44	504
NF	0,00	0,00	0,00	640
PD	0,67	0,76	0,71	95
T1	0,22	0,88	0,35	303
T2	0,71	0,80	0,75	297
T3	0,90	0,58	0,71	758
<i>Acurácia</i>				0,49
<i>Média macro</i>	0,55	0,60	0,50	2.849
<i>Média ponderada</i>	0,56	0,49	0,45	2.849

**Fonte: Elaborado pelo autor.**

Outro ponto relevante diz respeito ao desequilíbrio entre precisão e *recall* observado nas classes de falha. As classes D2 e T3 apresentaram alta precisão (0,94 e 0,90, respectivamente), porém *recall* reduzido (0,29 e 0,58), o que significa que, embora os diagnósticos emitidos sejam confiáveis quando ocorrem, o método deixa de identificar uma grande proporção dos casos reais dessas falhas. Em contraste, as classes D1 e T1 exibiram comportamento oposto, com *recall* elevado (0,87 e 0,88), mas precisão muito baixa (0,40 e 0,22), indicando um elevado número de falsos positivos e uma tendência do método a categorizar amostras de forma excessiva quando caem em regiões de fronteira entre zonas de falha (Sun; Huang; Huang, 2012).

Os resultados aqui apresentados confirmam, portanto, a hipótese central deste trabalho de que a aplicação isolada da tabela de razões da IEC 60599 (2019) não é suficiente para garantir diagnósticos precisos e abrangentes em transformadores de potência. As fronteiras rígidas entre as classes, a ausência de uma região explícita para a condição normal de operação e a impossibilidade de tratar amostras com múltiplas falhas simultâneas constituem limitações intrínsecas da metodologia normativa, conforme já discutido por Dhiman *et al.* (2024). Tais deficiências justificam plenamente a adoção de algoritmos supervisionados de aprendizado de máquina, capazes de aprender padrões não lineares a partir dos dados, generalizar para amostras situadas em regiões de fronteira e contemplar a classe NF de forma nativa, conforme será demonstrado nas seções seguintes.

### 6.1.2 Método de Duval

De forma análoga ao método de razões de gases (método de Rogers), aplicou-se o método do Triângulo de Duval às mesmas 4.150 amostras do *dataset* utilizado neste trabalho, seguindo as zonas de falha estabelecidas por IEC (2022) e ABNT (2026). A implementação calcula os percentuais relativos dos três Gases-Chave ( $\text{CH}_4$ ,  $\text{C}_2\text{H}_4$  e  $\text{C}_2\text{H}_2$ ) e atribui cada amostra a uma das sete regiões previstas pelo método: PD, D1, D2, T1, T2, T3 ou DT, esta última correspondente à zona residual resultante da combinação de falhas térmicas e elétricas. Diferentemente do método das razões IEC, o Triângulo de Duval garante por construção que toda amostra com soma não nula dos três Gases-Chave receba alguma classificação, eliminando a categoria “Indefinido” e restando apenas duas amostras descartadas (ND) por apresentarem concentração zero dos três gases.

**Tabela 10 – Distribuição das predições pelo Triângulo de Duval 1**

Classe predita	Quantidade	Percentual
T1	1.058	25,5%
T3	802	19,3%
DT	725	17,5%
D1	679	16,4%
T2	638	15,4%
PD	143	3,4%
D2	103	2,5%
ND	2	0,0%
<b>Total</b>	<b>4.150</b>	<b>100,0%</b>

**Fonte: Elaborado pelo autor.**

A distribuição das predições obtidas, apresentada na Tabela 10, evidencia uma dispersão considerável entre as classes, com predominância de T1 (25,5%) e T3 (19,3%), enquanto D2 recebeu apenas 2,5% das predições. A acurácia global do método foi de 35,46%, valor ligeiramente superior ao obtido pela tabela de razões IEC (33,35%) quando esta é avaliada sobre o conjunto completo, mas ainda assim insuficiente para uma aplicação confiável em manutenção preditiva. Esse desempenho corrobora as observações de Dhiman *et al.* (2024), segundo as quais o Triângulo de Duval, embora mais robusto do que os métodos puramente baseados em razões, mantém limitações inerentes à rigidez de suas fronteiras geométricas e à incapacidade de representar o estado normal de operação.

A análise do relatório de classificação por classe, sintetizada na Tabela 11, revela padrões particularmente importantes para a discussão das limitações do método. A classe NF apresentou novamente precisão e *recall* iguais a zero, confirmando que, assim como a tabela de razões da IEC 60599 (2019), o Triângulo de Duval não contempla uma região para transformadores em condição normal de operação, o que constitui uma falha estrutural grave para um sistema de diagnóstico preditivo. Das 738 amostras NF avaliadas, 658 (89%) foram erroneamente classificadas como T1 e outras 42 como T2, fenômeno explicado por Sun, Huang e Huang (2012), que destaca que amostras saudáveis tendem a apresentar baixíssimas concentrações de  $\text{C}_2\text{H}_2$

e C<sub>2</sub>H<sub>4</sub>, posicionando-se naturalmente nas regiões inferiores do triângulo, associadas a falhas térmicas de baixa intensidade.

**Tabela 11 – Relatório de classificação do Triângulo de Duval 1**

Classe	Precisão	Recall	F1-score	Suporte
PD	0,78	0,32	0,45	348
D1	0,65	0,74	0,69	598
D2	0,52	0,07	0,12	770
T1	0,19	0,45	0,26	440
T2	0,20	0,41	0,27	314
T3	0,67	0,62	0,65	866
DT	0,00	0,00	0,00	0
NF	0,00	0,00	0,00	738
<i>Acurácia</i>				0,35
<i>Média macro</i>	0,38	0,33	0,31	4.074
<i>Média ponderada</i>	0,44	0,36	0,35	4.074

**Fonte: Elaborado pelo autor.**

Outro resultado crítico foi observado na classe D2, que registrou *recall* de apenas 0,07 e precisão de 0,52, apesar de representar uma das falhas mais severas em transformadores de potência, conforme descrito pela IEC 60599 (2019). Somente 54 foram corretamente identificadas, enquanto 487 (63%) foram realocadas à zona residual DT e outras 198 à classe D1. Esse comportamento confirma a observação de Dhiman *et al.* (2024) de que descargas de alta energia frequentemente apresentam composições gasosas situadas em regiões de fronteira entre múltiplas zonas, o que dificulta a discriminação por métodos puramente geométricos baseados em proporções fixas.

As classes T1 e T2 apresentaram comportamento oposto, com *recall* moderado (0,45 e 0,41, respectivamente), mas precisão muito baixa (0,19 e 0,20), indicando elevada taxa de falsos positivos resultante da contaminação dessas regiões por amostras NF e por amostras T3 incorretamente deslocadas para a faixa intermediária. Já as classes D1 e T3 obtiveram os melhores desempenhos do método, com F1-scores de 0,69 e 0,65, respectivamente, o que indica que o Triângulo de Duval é mais eficaz na identificação de falhas com assinaturas gasosas bem definidas e distantes das fronteiras geométricas do gráfico ternário (Campos, 2017). A classe PD, por sua vez, apresentou precisão alta (0,78) mas *recall* baixo (0,32), indicando que, embora os diagnósticos de descargas parciais emitidos pelo método sejam confiáveis, a maioria das amostras reais dessa classe situa-se fora do critério estrito de %CH<sub>4</sub> ≥ 98% estabelecido pela norma.

Os resultados aqui apresentados consolidam a conclusão obtida na seção anterior, demonstrando que mesmo o Triângulo de Duval, considerado por Campos (2017) como um dos métodos gráficos mais confiáveis para a interpretação da DGA, é insuficiente quando aplicado isoladamente a um conjunto de dados real e diversificado. Suas limitações estruturais, ausência de zona NF, fronteiras geométricas rígidas e a existência de uma zona residual DT que absorve grande parte das falhas mal classificadas reforçam a necessidade de abordagens baseadas em aprendizado de máquina, capazes de aprender automaticamente as fronteiras de decisão a partir

dos dados e de incorporar nativamente a classe de operação normal no processo de diagnóstico, conforme será demonstrado nas seções seguintes.

## 6.2 Métodos de *Machine Learning* aplicados

### 6.2.1 *K-NN* aplicado em DGA

O algoritmo K-Nearest Neighbors (K-NN) foi implementado para classificar falhas em transformadores de potência com base nos gases dissolvidos no óleo isolante ( $H_2$ ,  $CH_4$ ,  $C_2H_6$ ,  $C_2H_4$  e  $C_2H_2$ ). O K-NN é um classificador baseado em aprendizagem supervisionada que utiliza o critério de similaridade por distância no espaço  $d$ -dimensional para determinar a classe de uma nova amostra com base nos  $k$  vizinhos mais próximos. Conforme destacado por Kherif *et al.* (2021), o desempenho do K-NN depende fortemente da métrica de distância, do número de vizinhos e da forma de ponderação das respostas, sendo necessário um processo criterioso de otimização desses hiperparâmetros. Na etapa de pré-processamento, o *dataset* contendo 4.150 amostras foi submetido à remoção de valores nulos e duplicatas, resultando em 2.758 amostras válidas, distribuídas em sete classes de falha, conforme a norma IEC 60599 (D1, D2, T1, T2, T3, PD e NF). Para a normalização das *features*, utilizou-se o *PowerTransformer* com o método Yeo-Johnson, que reduziu a assimetria dos dados para valores próximos de zero, tornando a distribuição dos gases mais adequada para classificadores baseados em distância.

**Tabela 12 – Distribuição das classes do *dataset* após pré-processamento.**

Classe	Amostras	Proporção (%)
NF	707	25,63
T3	578	20,96
D1	354	12,84
D2	336	12,18
T1	325	11,78
T2	240	8,70
PD	218	7,90
<b>Total</b>	<b>2.758</b>	<b>100,00</b>

**Fonte: Elaborado pelo autor.**

A otimização dos hiperparâmetros foi conduzida por meio do *RandomizedSearchCV* com validação cruzada de 10 *folds*, explorando 200 combinações aleatórias que incluíram o número de vizinhos ( $K = 1$  a 30), a métrica de distância (*euclidean*, *manhattan*, *minkowski*) e o esquema de ponderação (*uniform*, *distance*). A configuração ótima encontrada foi  $K = 4$ , com métrica *manhattan* e ponderação por distância (*weights = distance*). A acurácia em função de  $K$  revela que a ponderação por distância supera a ponderação uniforme para todos os valores de  $K$  avaliados, evidenciando que vizinhos mais próximos devem exercer maior influência na decisão de classificação (Kherif *et al.*, 2021).

O modelo final apresentou acurácia de 99,12% no conjunto de treino e 89,10% no conjunto de teste (1.165 amostras), com *F1-score* ponderado de 0,8909 e *F1-score macro* de 0,8886,

indicando um desempenho consistente e equilibrado entre as sete classes de falha. A diferença de 10,02% entre as acurácias de treino e de teste caracteriza um nível moderado de *overfitting*, um comportamento esperado em classificadores baseados em distância, nos quais a memorização local dos vizinhos tende a inflar o desempenho no conjunto de treino (Géron, 2019). Ainda assim, o desempenho geral no conjunto de teste demonstra que a parametrização adotada, aliada ao pré-processamento com Yeo-Johnson, mitigou de forma satisfatória a influência da escala dos gases dissolvidos na métrica de distância.

A Tabela 13 apresenta o relatório de classificação detalhado por classe de falha, no qual se observa que a classe NF ( $F1 = 0,9314$ ) alcançou o melhor desempenho, seguida por PD ( $F1 = 0,8940$ ), T1 ( $F1 = 0,8990$ ) e T2 ( $F1 = 0,8942$ ), enquanto a classe D1 apresentou o menor *F1-score* (0,8255). Esse comportamento é atribuído à sobreposição das concentrações de gases entre falhas de natureza semelhante, especialmente entre as descargas elétricas de baixa e alta energia (D1 e D2), o que dificulta a separação no espaço de *features* por meio de classificadores baseados em distância. A classe NF, por possuir concentrações de gases significativamente mais baixas do que as demais, apresenta uma separação natural no espaço  $d$ -dimensional, o que justifica seu elevado desempenho.


**Tabela 13 – Relatório de classificação do modelo K-NN ( $K = 4$ ).**

Classe	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
D1	0,8425	0,8092	0,8255	152
D2	0,8878	0,8966	0,8922	203
NF	0,9426	0,9206	0,9314	214
PD	0,8654	0,9247	0,8940	146
T1	0,8958	0,9021	0,8990	143
T2	0,8912	0,8973	0,8942	146
T3	0,8924	0,8758	0,8840	161
<i>Acurácia</i>	—	—	0,8910	1.165
<i>Média macro</i>	0,8882	0,8894	0,8886	1.165
<i>Média ponderada</i>	0,8912	0,8910	0,8909	1.165

**Fonte: Elaborado pelo autor.**

As confusões mais expressivas ocorrem entre as classes D1 e D2, com 14 amostras de D1 classificadas como D2 e 15 amostras de D2 classificadas como D1, o que reflete a similaridade entre os mecanismos de descarga elétrica de baixa e alta energia que produzem perfis de gases parcialmente sobrepostos. De forma análoga, observa-se confusão entre T2 e T3 (11 amostras de T2 classificadas como T3 e 9 amostras de T3 classificadas como NF), o que é coerente com a natureza térmica dessas falhas, que diferem essencialmente pela faixa de temperatura associada à degradação do óleo isolante. A acurácia *macro avg* de 0,8886 indica um desempenho equilibrado entre as classes, mesmo diante do desbalanceamento do *dataset*, demonstrando que o K-NN, com a parametrização adotada, é capaz de generalizar adequadamente para todas as categorias de falha definidas pela norma. A análise da matriz de confusão, apresentada na Figura 30, permite identificar os principais padrões de erro do classificador.

**Figura 30 – Matriz de confusão do modelo K-NN ( $K = 4$ ).**



**Fonte: Elaborado pelo autor.**

### 6.2.2 SVM aplicado em DGA

A aplicação do algoritmo *SVM* ao conjunto de dados de Análise de Gases Dissolvidos (DGA) resultou em uma acurácia global de 85,84% no conjunto de teste, composto por 1165 amostras, distribuídas entre as sete classes de falha estabelecidas pela norma IEC (2022) e ABNT (2026). O modelo apresentou acurácia de 91,50% no conjunto de treino e 85,84% no conjunto de teste, resultando em uma diferença de 5,66% entre as duas etapas, indicando um nível de *overfitting* controlado e dentro de patamares aceitáveis para problemas de classificação multiclasse com dados de DGA. A Tabela 14 apresenta as métricas de desempenho por classe.


O *F1-score* ponderado obtido foi de 0,8588 e o *F1-score* macro foi de 0,8548, evidenciando equilíbrio entre as classes mesmo diante da variabilidade dos perfis de gases dissolvidos característicos de cada modo de falha. A classe *Normal Functioning* (NF) apresentou o melhor resultado individual, com *F1-score* de 0,9426, indicando que o modelo é capaz de distinguir, com elevada confiabilidade, as condições operacionais normais dos diversos modos de falha. Por outro lado, as descargas de baixa energia (D1) registraram o menor desempenho, com *F1-score* de 0,7475, padrão também observado em outros trabalhos que utilizam técnicas de aprendizado de máquina para DGA, nos quais a sobreposição dos perfis de gases entre falhas de descarga elétrica constitui o principal desafio de classificação. A matriz de confusão apresentada na Figura 31 permite uma análise detalhada dos erros cometidos pelo classificador.

Tabela 14 – Métricas de desempenho do classificador SVM por classe de falha.

Classe	Precisão	Recall	F1-score	Suporte
D1	0,7451	0,7500	0,7475	152
D2	0,8500	0,8374	0,8437	203
NF	0,9657	0,9206	0,9426	214
PD	0,8431	0,8836	0,8629	146
T1	0,8344	0,8811	0,8571	143
T2	0,8936	0,8630	0,8780	146
T3	0,8466	0,8571	0,8519	161
<b>Acurácia</b>	—	—	0,8584	1165
<b>Média macro</b>	0,8541	0,8561	0,8548	1165
<b>Média ponderada</b>	0,8598	0,8584	0,8588	1165

Fonte: Elaborado pelo autor.

Figura 31 – Matriz de confusão do classificador SVM



Fonte: Elaborado pelo autor.

A matriz revela os principais padrões de confusão entre classes, observa-se que a maior fonte de erro está concentrada na confusão entre descargas de baixa energia (D1) e descargas de alta energia (D2), com 26 amostras de D2 classificadas como D1 e 20 amostras de D1 classificadas como D2, comportamento já documentado na literatura devido à similaridade dos gases gerados em ambos os fenômenos de descarga elétrica. De forma análoga, verifica-se confusão expressiva entre as falhas térmicas T1, T2 e T3, com destaque para as 13 amostras de T2 classi-

ficadas como T3 e as 10 amostras de T3 classificadas como T1, o que reflete a transição gradual dos perfis de gases à medida que a temperatura do ponto quente aumenta, o que é consistente com as faixas de temperatura sobrepostas definidas por ABNT (2026). Apesar dessas dificuldades intrínsecas ao problema, o SVM demonstrou desempenho satisfatório, compatível com os resultados reportados em estudos sobre diagnóstico de falhas em transformadores de potência por meio de aprendizado supervisionado.

### 6.2.3 ANN aplicado em DGA

Para a classificação dos modos de falha em transformadores com base nas concentrações dos cinco gases dissolvidos ( $H_2$ ,  $CH_4$ ,  $C_2H_6$ ,  $C_2H_4$  e  $C_2H_2$ ), foi implementada uma ANN do tipo MLP utilizando a biblioteca Keras/TensorFlow. A arquitetura final é composta por uma camada de entrada com cinco neurônios (um para cada gás), camadas ocultas totalmente conectadas com função de ativação parametrizável (ReLU ou tanh), camadas de *Dropout* para regularização e uma camada de saída com sete neurônios e função *softmax*, correspondendo às sete classes-alvo (D1, D2, NF, PD, T1, T2, T3). O treinamento utiliza o otimizador Adam com a função de perda *categorical cross-entropy* e adota *Early Stopping* monitorando a perda de validação para evitar sobreajuste. Em vez de fixar arbitrariamente os hiperparâmetros, foi conduzida uma busca aleatória manual com validação cruzada estratificada em 3 *folds*, amostrando 25 combinações distintas de arquitetura, ativação, taxa de *dropout* e taxa de aprendizado, selecionando-se a que maximizou o F1-macro médio. O espaço de busca explorado é apresentado na Tabela 15.

**Tabela 15 – Espaço de busca de hiperparâmetros da ANN.**

Hiperparâmetro	Valores / Distribuição
Arquitetura (neurônios por camada oculta)	(16), (32), (64), (16,8), (32,16), (48,24), (64,32), (32,16,8)
Função de ativação	ReLU, tanh
Taxa de <i>dropout</i>	Uniforme(0,0; 0,3)
Taxa de aprendizado	Log-uniforme( $10^{-4}$ ; $10^{-2}$ )
Otimizador	Adam
Tamanho do <i>batch</i>	32
Máximo de épocas	200 (com <i>Early Stopping</i> )

**Fonte: Elaborado pelo autor.**

Após a identificação da melhor configuração, aplicou-se a estratégia de *Seed Averaging*, na qual dez modelos independentes são treinados com sementes aleatórias distintas antes da decisão final. O desempenho global obtido pela ANN no conjunto de teste é apresentado na Tabela 16, e a Figura 32 exibe a matriz de confusão resultante. O modelo alcançou acurácia de 89,69 % no conjunto de treinamento e 85,49 % no conjunto de teste, resultando em uma diferença de 4,20 %, valor que indica baixo nível de sobreajuste e capacidade de generalização adequada. Os valores de F1-Score ponderado e F1-Score macro demonstram um desempenho equilibrado entre as sete classes, comportamento desejável em problemas multiclasse com distribuição desbalanceada, conforme destacado.

**Tabela 16 – Métricas globais da ANN no conjunto de teste.**

Métrica	Valor
Acurácia (treino)	89,69 %
Acurácia (teste)	85,49 %
F1-Score (ponderado)	0,8550
F1-Score (macro)	0,8515
<i>Overfitting</i> estimado	4,20 %
Número de classes	7
Estratégia de <i>ensemble</i>	<i>Seed Averaging</i> (10 modelos)

**Fonte: Elaborado pelo autor.**

A ANN apresenta desempenho consistente em todas as sete classes-alvo, com valores de F1-Score variando de 0,7800 (D1) a 0,9260 (NF). A classe NF apresenta o melhor desempenho, com precisão de 0,9463 e *recall* de 0,9065, indicando elevada confiabilidade do modelo na identificação de transformadores em condições normais de operação. Por outro lado, as classes D1 e D2 apresentam os menores valores de F1-Score, o que é de se esperar devido à sobreposição das assinaturas gasosas dessas duas falhas elétricas. A análise detalhada do relatório de classificação é apresentada na Tabela 17.


**Tabela 17 – Relatório de classificação da ANN no conjunto de teste.**

Classe	Precisão	<i>Recall</i>	F1-Score	Suporte
D1	0,7905	0,7697	0,7800	152
D2	0,8473	0,8473	0,8473	203
NF	0,9463	0,9065	0,9260	214
PD	0,8153	0,8767	0,8449	146
T1	0,8493	0,8671	0,8581	143
T2	0,8553	0,8904	0,8725	146
T3	0,8506	0,8137	0,8317	161
<b>Acurácia</b>	—	—	0,8549	1165
<b>Média macro</b>	0,8507	0,8531	0,8515	1165
<b>Média ponderada</b>	0,8558	0,8549	0,8550	1165

**Fonte: Elaborado pelo autor.**

A classe NF apresenta aproximadamente 90,6 % de *recall*, o que reforça a robustez do modelo na discriminação entre transformadores saudáveis e aqueles com falhas incipientes. Já a classe D2 apresenta 85,7 % de *recall*, enquanto a classe T2 apresenta 89,0 %, demonstrando que o modelo lida adequadamente com as classes majoritárias e com falhas térmicas de temperatura média. A análise da matriz de confusão, apresentada na Figura 32, revela que os erros do modelo concentram-se nas regiões do espaço de classes fisicamente esperadas.

**Figura 32 – Matriz de confusão da ANN no conjunto de teste.**



**Fonte: Elaborado pelo autor.**

Os principais erros de classificação observados na matriz de confusão concentram-se em duas regiões críticas, ambas coerentes com a física do problema de DGA. A primeira região corresponde à confusão entre D1 e D2, o que reflete a sobreposição típica entre descargas elétricas de baixa e alta energia. A segunda região envolve as falhas térmicas T1, T2 e T3, comportamento coerente com o fato dessas classes representarem uma escala contínua de temperatura, com fronteiras que se intersectam. Adicionalmente, observa-se que amostras de D1 foram classificadas como PD, o que indica que o modelo apresenta dificuldade em distinguir descargas de baixa energia de descargas parciais.

De forma geral, a acurácia global de 85,49% no conjunto de teste, combinada com um F1-Score macro de 0,8515 e um nível de *overfitting* de apenas 4,20%, demonstra que a ANN, aliada às estratégias de tratamento de dados e otimizadores de hiperparâmetros, constitui uma abordagem eficaz e bem generalizável para o diagnóstico de falhas em transformadores de potência.

### 6.3 Análise comparativa dos modelos

O propósito desta seção vai além da comparação das características de precisão entre os algoritmos de ML apresentados, buscando interpretar os resultados com base nas caracte-

rísticas elétricas e térmicas das falhas classificadas. Essas assinaturas, embora teoricamente distintas, apresentam zonas de sobreposição que dificultam a separação entre classes adjacentes, fenômeno reconhecido na literatura como o principal limitador da acurácia em diagnósticos baseados em DGA. Após o pré-processamento descrito no Capítulo 5, limpeza, normalização via *PowerTransformer*, balanceamento por SMOTE e otimização por *RandomizedSearchCV*, e a divisão do banco de dados em treino e teste, os três classificadores foram avaliados sob condições equivalentes, monitorando-se tanto as métricas de teste quanto o *overfitting*, conforme Tabela 18.

**Tabela 18 – Desempenho global dos modelos**

Métrica	k-NN	SVM (RBF)	ANN (MLP)
Acurácia (treino)	99,12%	91,50%	89,69%
Acurácia (teste)	89,10%	85,84%	85,49%
F1-score macro	0,8886	0,8548	0,8515
F1-score ponderado	0,8909	0,8588	0,8550
<i>Overfitting</i> (treino – teste)	10,02%	5,66%	4,20%
Tratamento de desbalanceamento	SMOTE	SMOTE	SMOTE

Fonte: Elaborado pelo autor.

**Tabela 19 – F1-score por classe de falha**

Classe	k-NN	SVM	ANN
D1	0,83	0,75	0,78
D2	0,89	0,84	0,85
NF	0,93	0,94	0,93
PD	0,89	0,86	0,84
T1	0,90	0,86	0,86
T2	0,89	0,88	0,87
T3	0,88	0,85	0,83

Fonte: Elaborado pelo autor.

A análise do F1-score por classe, apresentada na Tabela 19, revela que a fronteira entre D1 e D2 constitui a região mais crítica do espaço de atributos, uma vez que ambas compartilham componentes gasosos comuns. O SVM apresentou o pior desempenho em D1 ( $F1 = 0,75$ ), gerando falsos positivos ao classificar amostras dessa classe como D2, ao passo que a ANN obteve  $F1 = 0,78$  e o k-NN destacou-se com  $F1 = 0,83$ . As falhas térmicas T1 e T2, que se distinguem pela faixa de temperatura, também apresentaram índices reduzidos nos modelos paramétricos, o que reflete a complexidade física do fenômeno térmico, que não possui uma fronteira natural entre as categorias estabelecidas pela norma. Já a classe NF obteve os maiores valores de F1 em todos os modelos, indicando que transformadores em condição normal possuem assinaturas suficientemente distintas para serem identificados com alta confiança.

A análise das matrizes de confusão, apresentadas na Figura 30, na Figura 31 e na Figura 32, permite quantificar com precisão o comportamento da classe NF, criticamente relevante em manutenção preditiva, dado que falsos positivos (alarmes indevidos) elevam os custos operacionais e falsos negativos representam risco direto (falhas reais classificadas como NF) ao ativo. O k-NN classificou 17 falsos negativos, principalmente confundidos com falhas térmicas

e descargas, e apenas 7 falsos positivos. O SVM apresentou o mesmo padrão, evidenciando um comportamento equivalente ao do k-NN na identificação de transformadores saudáveis. A ANN, por sua vez, com 20 falsos negativos e 9 falsos positivos, foi o modelo mais propenso a interpretar falhas reais como condição normal, como observa-se na Tabela 20. Esse resultado é particularmente relevante porque indica que, embora a ANN apresente o menor *overfitting* global, é o classificador menos seguro do ponto de vista de segurança operacional para a classe NF.

**Tabela 20 – Falsos positivos (FP) e falsos negativos (FN) por classe e por algoritmo**

Classe	k-NN		SVM (RBF)		ANN (MLP)	
	FP	FN	FP	FN	FP	FN
D1	39	38	39	38	35	49
D2	30	33	30	33	41	29
NF	7	17	7	17	9	20
PD	24	17	24	17	30	22
T1	24	17	24	17	22	18
T2	15	20	15	20	21	16
T3	25	23	25	23	23	28
<b>Total</b>	<b>164</b>	<b>165</b>	<b>164</b>	<b>165</b>	<b>181</b>	<b>182</b>

Fonte: Elaborado pelo autor.

**Tabela 21 – Total de erros e percentual em relação ao banco de teste**

Algoritmo	Total de erros	% do banco de teste
k-NN	127	10,90%
SVM (RBF)	165	14,16%
ANN (MLP)	169	14,51%

Fonte: Elaborado pelo autor.

Conforme apresentado na Tabela 21, a ANN foi a classificador com maior quantidade de erros, em contrapartida, também foi o que apresentou o menor *overfitting* (4,20%), evidenciando que o utilização combinada de balanceamento, normalização e busca aleatória de hiperparâmetros foi eficaz em conter o superajuste característico de redes neurais com maior capacidade. O SVM (RBF) apresentou *overfitting* moderado de 5,66%, condizente com a regularização proporcionada pelo parâmetro  $C$  e pela maximização da margem, características que, historicamente, conferem ao SVM boa capacidade de generalização. O k-NN, embora tenha obtido o melhor desempenho de teste, exibiu o maior *overfitting* (10,02%), resultado esperado em razão de sua natureza não paramétrica e de memorização: a acurácia de treino próxima de 99% reflete o fato de que, para valores pequenos de  $k$ , o modelo praticamente reproduz o conjunto de treinamento.

Sob as condições adotadas, o k-NN apresentou o melhor desempenho global no diagnóstico de falhas por DGA, superando SVM e ANN tanto em acurácia bruta quanto em F1-score macro e ponderado, embora ao custo de maior *overfitting* estrutural. As falhas D1 e D2, bem como as térmicas T1 e T2, concentraram os desempenhos mais baixos em todos os modelos, refletindo a conhecida sobreposição entre as faixas de gases característicos dessas tipologias, o que motiva o desenvolvimento de abordagens híbridas. Dessa forma, a escolha entre os classificadores deve considerar não apenas a acurácia, mas também o equilíbrio entre generalização e

capacidade preditiva, o custo computacional, a interpretabilidade e precisão do modelo, sendo a ANN atrativa em cenários que exigem maior estabilidade treino/teste, o SVM indicado para compromisso entre robustez e eficiência, e o k-NN vantajoso quando a base é frequentemente expandida e a transparência da decisão é desejável.

A limitação dos métodos gráficos tradicionais fica evidente ao analisar uma amostra com concentrações de  $H_2 = 200$  ppm,  $CH_4 = 3$  ppm,  $C_2H_6 = 50$  ppm,  $C_2H_4 = 200$ ,  $C_2H_2 = 0$  ppm utilizando a ferramenta Duval Triangle Lab (2018). Por não contemplar uma região específica para transformadores em condição normal de operação (NF), o Triângulo de Duval Figura 33 forçou erroneamente o diagnóstico para uma falha térmica T3. Simultaneamente, a rigidez de fronteiras do Pentágono de Duval Figura 34 gerou uma divergência, classificando a mesma ocorrência como falha elétrica D2. Em contrapartida, a aplicação do algoritmo treinado superou essas inconsistências e a dependência de limiares geométricos estáticos, diagnosticando corretamente a amostra como estado de normalidade (NF), em conformidade com o anexo 2 do estudo publicado por Duval e DePabla (2001).

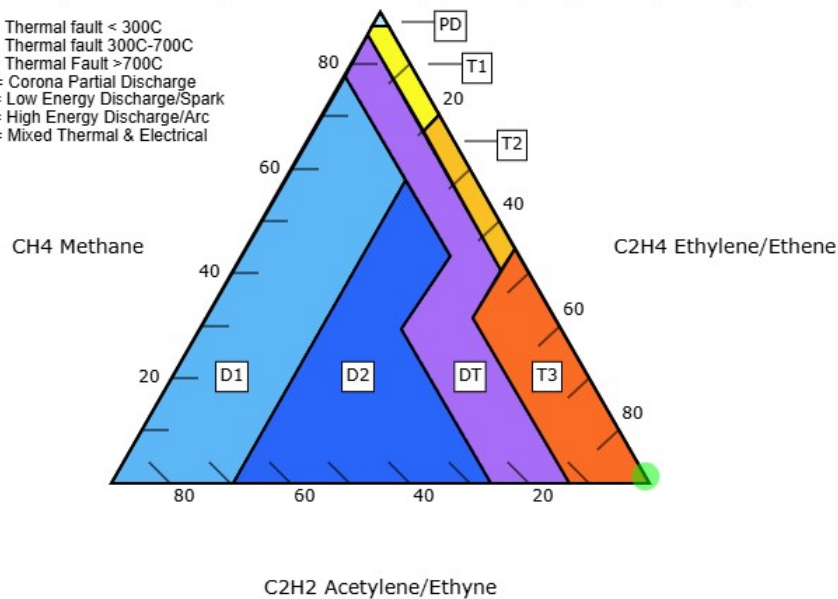
**Figura 33 – Análise realizada por Triângulo de Duval**

## Duval Triangle

### Duval Triangle Fault(s): T3 (Thermal fault > 700 C)

LearnOilAnalysis.com Duval Triangle 1 mineral for illustrative purposes only. Always consult your lab diagnosis & trends

T1 = Thermal fault < 300C  
 T2 = Thermal fault 300C-700C  
 T3 = Thermal Fault >700C  
 PD = Corona Partial Discharge  
 D1 = Low Energy Discharge/Spark  
 D2 = High Energy Discharge/Arc  
 DT = Mixed Thermal & Electrical




Fonte: Lab (2018).

Figura 34 – Análise realizada por Pentágono de Duval

## Duval Pentagon

Duval Pentagon Fault(s): D2 (High Energy Discharge/Arc)



LearnOilAnalysis.com Duval Pentagon 1 for illustrative purposes only. Always consult your lab diagnosis & trends  
Note there are differing weighting options for midpoint determination labs may use based on severity or average coords

T1 = Thermal fault < 300C  
T2 = Thermal fault 300C-700C  
T3 = Thermal Fault >700C  
PD = Corona Partial Discharge  
D1 = Low Energy Discharge/Spark  
D2 = High Energy Discharge/Arc  
S = Strav Gas

Fonte: Lab (2018).

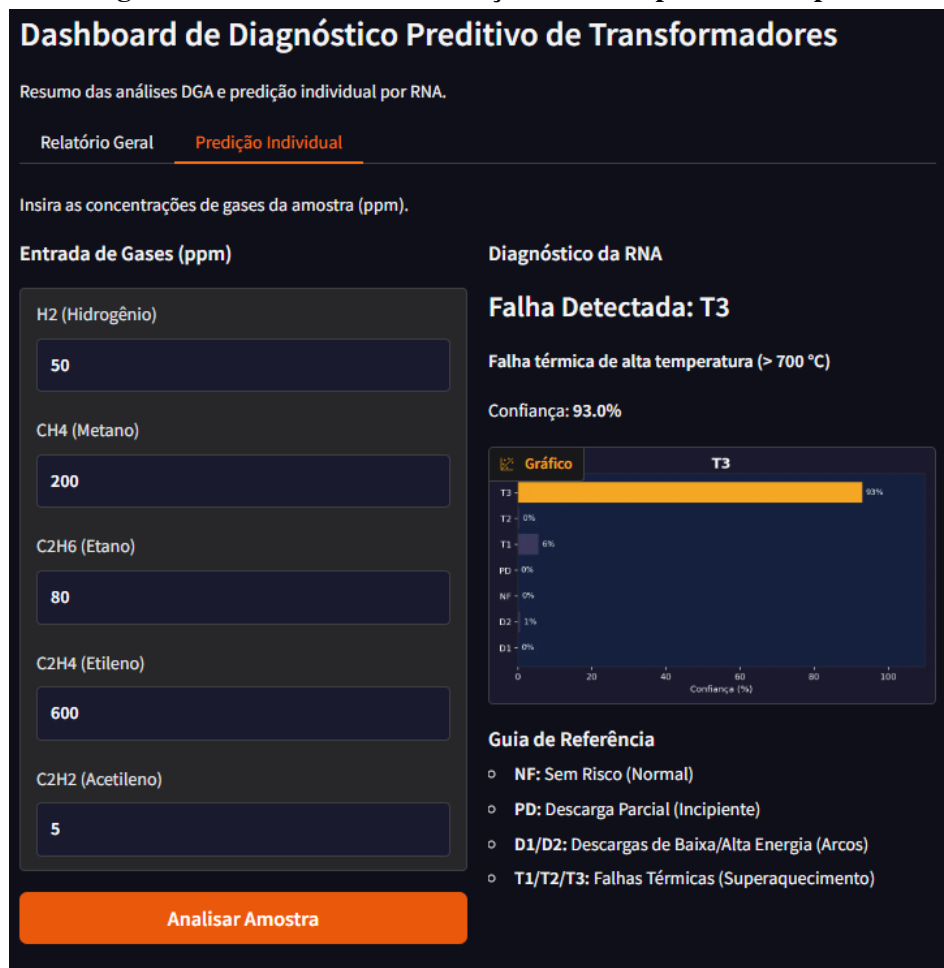
### 6.4 Sistema de visualização de dados

Foi desenvolvido baseado-se do algoritmo de classificação ANN, um sistema de visualização para a validação do método implementado. Para exemplificar seu funcionamento, foram criados três cenários com as seguintes concentrações:

- **Exemplo 1 como objetivo detectar T3:**  $H_2 = 50$  ppm,  $CH_4 = 200$  ppm,  $C_2H_6 = 80$  ppm,  $C_2H_4 = 600$ ,  $C_2H_2 = 5$  ppm
- **Exemlo 2 como objetivo detectar D2:**  $H_2 = 300$  ppm,  $CH_4 = 150$  ppm,  $C_2H_6 = 30$  ppm,  $C_2H_4 = 200$ ,  $C_2H_2 = 400$  ppm
- **Exemplo 3 como objetivo detectar NF:**  $H_2 = 8$  ppm,  $CH_4 = 3$  ppm,  $C_2H_6 = 1$  ppm,  $C_2H_4 = 2$ ,  $C_2H_2 = 0$  ppm

Com os seguintes valores, chegou-se nos respectivos resultados abaixo:

Figura 35 – Sistema de visualização de dados para o Exemplo 1



Fonte: Elaborado pelo autor.

O resultado para o exemplo 1, ilustrado na Figura 35, apresenta concentrações elevadas de  $C_2H_4$  e  $C_2H_6$ , resultando em uma razão  $C_2H_4/C_2H_6$  de aproximadamente 7,5, valor expressivamente acima do limiar normativo para falhas térmicas de alta temperatura (razão maior que 4 é uma característica de falha T3). Já a quantidade reduzida de  $C_2H_2$  descarta a ocorrência de descarga elétrica; assim, o sistema de visualização classificou corretamente a amostra como T3, confirmando a capacidade do modelo de reconhecer a assinatura gasosa típica desse tipo de falha.

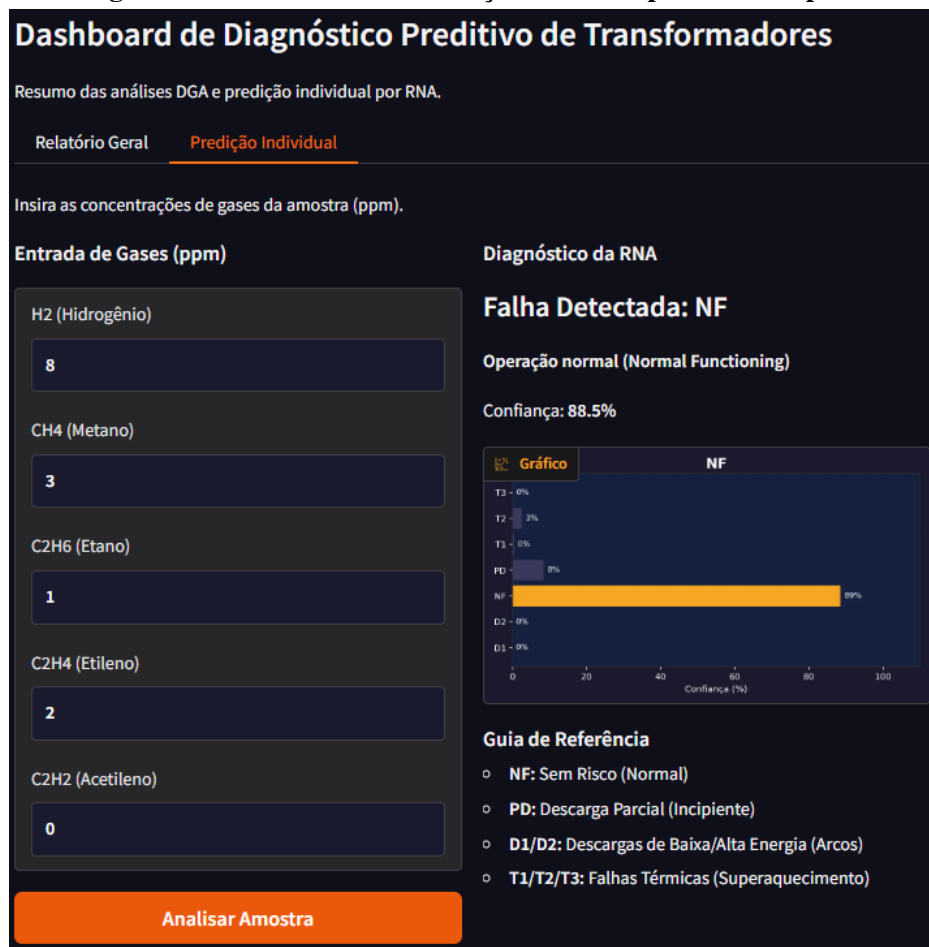
Figura 36 – Sistema de visualização de dados para o Exemplo 2



Fonte: Elaborado pelo autor.

O exemplo 2, apresentado na Figura 36, caracteriza-se pela concentração muito elevada de  $C_2H_2$ , gás cuja presença expressiva é considerada um indicador principal de descargas elétricas. A razão resultante entre  $C_2H_2/C_2H_4$  foi de 2 (razão entre 0,6 e 2,5 é característica de descargas elétricas, em que a razão sendo maior que 1 caracteriza como sendo de alta energia). Esse perfil é coerente com a classe D2 e o visualizador identificou corretamente essa condição.

Figura 37 – Sistema de visualização de dados para o Exemplo 3



Fonte: Elaborado pelo autor.

Por fim, o exemplo 3, exibido na Figura 37, apresenta concentrações extremamente baixas de todos os gases, padrão normal para transformadores em operação saudável, em que a decomposição do óleo isolante é mínima e os gases permanecem em valores baixos. Conforme discutido na seção de pré-processamento, amostras da classe NF apresentam naturalmente esse perfil de baixíssimas concentrações, o que confere separabilidade no espaço de características e justifica o acerto do visualizador ao classificar corretamente a amostra como NF.

Os três exemplos validam o comportamento esperado do sistema de visualização desenvolvido, demonstrando que o modelo é capaz de classificar novas amostras com padrões gasosos de diferentes classes, reforçando a aplicabilidade prática da ferramenta no contexto de manutenção preditiva de transformadores.

## 7 CONCLUSÃO

O presente trabalho teve como objetivo geral desenvolver um classificador de padrões para o diagnóstico preditivo de falhas em transformadores elétricos de potência, com base em dados de DGA. Para isso, foram implementados e avaliados três algoritmos de aprendizado de máquina supervisionados: K-NN, SVM e ANN. Além disso, destaca-se que a análise dos resultados foi comparada com os métodos normativos tradicionais.

A análise dos resultados obtidos permitiu confirmar a hipótese de que o uso de métodos baseados em aprendizado de máquinas supera os métodos tradicionais na tarefa de classificação de falhas em transformadores de potência a partir de dados de DGA. O método das razões de gases, citado nas normas IEC (2022) e ABNT (2026), atingiu acurácia global de 33,35%, enquanto o Triângulo de Duval alcançou 35,46%. Ambos os desempenhos foram considerados insuficientes para uma aplicação confiável na manutenção preditiva. Um resultado particularmente relevante foi a incapacidade estrutural dos métodos normativos de identificar transformadores em condição normal de operação, que correspondia a 17,8% do *dataset*. Tanto o método da norma IEC (2022) quanto o Triângulo de Duval apresentaram precisão igual a zero para essa classe, confirmando que tais metodologias foram desenvolvidas exclusivamente para identificar tipos de falha e são incapazes de reconhecer o estado saudável do equipamento. Essa limitação é crítica para sistemas de manutenção preditiva, que precisam distinguir inequivocamente entre condições normais e anômalas.

Em contraste, os classificadores de ML apresentaram desempenhos superiores, com a ANN e o SVM atingindo, respectivamente 85,49% e 85,84% de acurácia de teste, e o k-NN alcançando 89,103%. Embora o K-NN tenha obtido a melhor acurácia, foi também o modelo que apresentou maior *overfitting*; isso indica que o modelo está memorizando padrões específicos do conjunto de treino em vez de generalizar bem para dados novos, o que compromete sua confiabilidade em aplicações reais de diagnóstico de transformadores. Modelos como a ANN e o SVM, por outro lado, constroem superfícies de decisão otimizadas durante o treinamento, conseguindo separar classes distintas e apresentando menor *overfitting* entre o treino e o teste.

No que se refere à identificação preditiva de falhas, os classificadores inteligentes apresentaram-se como ferramentas estratégicas para a manutenção baseada em condição, possibilitando a detecção de falhas incipientes antes que evoluam para defeitos catastróficos. A adoção de sistemas baseados em ML mostra-se eficaz para reduzir as falhas inesperadas em transformadores, contribuindo diretamente para a confiabilidade e a continuidade do fornecimento de energia elétrica. Dessa forma, conclui-se que a integração entre métodos consagrados de DGA e algoritmos de ML constitui um caminho promissor para o diagnóstico preditivo, unindo a base normativa já consolidada à flexibilidade e à capacidade de generalização proporcionadas pela inteligência artificial.

## 7.1 Trabalhos Futuros

Como sugestões para trabalhos futuros, destacam-se as seguintes abordagens:

- **Predição em tempo real:** Com um banco de dados gerado por sensores e registradores, é possível desenvolver um algoritmo que analise, em tempo real, as medições dos gases emitidos pelo isolante. Esse avanço seria importante para maior eficácia na manutenção preditiva.
- **Outros modelos de IA:** Embora o SVM e o ANN, além de comprovados como excelentes modelos nesse trabalho, sejam os mais recomendados pela literatura para DGA, o estudo com outros modelos pode ser válido em algumas situações, como a busca por um custo computacional menor.
- **Pré-processamento dos dados por outros métodos:** Para a limpeza dos dados, métodos diferentes do boxplot podem ser utilizados, o que pode resultar em um banco de dados com melhor desempenho. Além disso, outros métodos de balanceamento, além do SMOTE, podem gerar diferentes resultados.
- **Outro otimizador de hiperparâmetros:** Além dos mencionados *Randomized Search* e *Grid Search*, outros métodos baseados em otimização bayesiana, como o Optuna, podem ser integrados nos modelos.
- **Diagnóstico múltiplo:** Os modelos atuais assumem uma única classe de falha por amostra. Desenvolver um classificador multirrótulo possibilitaria diagnosticar vários tipos de falhas simultaneamente.
- **Integração com outros parâmetros de monitoramento:** A utilização conjunta dos dados de DGA com outras variáveis operacionais, como corrente elétrica, tensão, temperatura do ambiente, temperatura do óleo, pressão externa do tanque, pressão interna do tanque, fator de potência dielétrico e grau de polimerização do papel isolante, pode melhorar significativamente a qualidade dos diagnósticos. Essa integração enriquece o conjunto de atributos disponíveis, permitindo identificar correlações entre diferentes indicadores e, assim, aumentar a precisão na avaliação das condições do equipamento.

## REFERÊNCIAS

- ABB . **Transformadores de Potência e Reatores de Derivação**. [S.l.], 1999. 104 p. Catálogo.
- ABDULLAEV, A. *et al.* Power transformer failures: analysis of failure types and causative factors. **Electric Power Systems Research**, v. 220,, p. 109123, May 2025.
- ABNT . **ABNT NBR 5462**: Confiabilidade e manutenibilidade. Rio de Janeiro: ABNT, 1994.
- ABNT . **ABNT NBR 7070**: Amostragem de gases e óleo mineral isolante de equipamentos elétricos e análise dos gases livres e dissolvidos. Rio de Janeiro: ABNT, 2006.
- ABNT . **ABNT NBR 7274**: Equipamentos elétricos em serviço preenchidos com óleo mineral isolante — recomendações para interpretação dos gases dissolvidos e análise de gás livre. Rio de Janeiro: ABNT, 2026.
- ALMEIDA, O. M. *et al.* Monitoramento e diagnóstico de um transformador de potência: Análise de gases dissolvidos no Óleo e análise térmica. **Anais do IV CITENEL - Congresso de Inovação Tecnológica em Energia Elétrica**, Araxá, Minas Gerais,, 2007.
- AQUINO, N. A. *et al.* Sistema inteligente para diagnóstico de transformadores de potência com base na análise de gases dissolvidos. *In*: REVISTA CONTROLE AUTOMAÇÃO. 2011. **Anais [...]** [S.l.: s.n.], 2011. p. 30152–30526.
- AQUINO, R. R. de *et al.* Sistema inteligente de manutenção preditiva de transformadores de potência: PREDITRAFO. **Anais do VI CITENEL - Congresso de Inovação Tecnológica em Energia Elétrica**, Fortaleza,, 2011.
- BARBOSA, J. D. M. **Manutenção preditiva com recurso a inteligência artificial**. 2023. Dissertação (Mestrado) — Faculdade de Ciências e Tecnologia da Universidade de Coimbra 2023.
- BARBOSA, T. M. *et al.* Development of software based on the duval triangle method. *In*: IEEE. 2016 12TH IEEE INTERNATIONAL CONFERENCE ON INDUSTRY APPLICATIONS (INDUSCON). 2016, Brazil. **Anais [...]** Brazil, 2016. p. 1–8.
- BECHARA, R. A. **Análise de falhas de transformadores de potência**. Uberlândia: Editora UFU, 2010.
- CAMPOS, M. Método do triângulo de duval para análise dos óleos isolantes silicone e éster natural. **Revista Eletricidade Moderna**, v. 45,, p. 1–10, July 2017.
- DALLAMUTA, J.; HOLZMANN, H. A. (Ed.). **Engenharia elétrica: desenvolvimento e inovação tecnológica**. Ponta Grossa, PR: Atena, 2021. Formato: PDF. Inclui bibliografia. Página 17 consultada. ISBN 978-65-5706-773-4.
- DCTECH. **Entendendo o sistema de um Cromatógrafo Gasoso (CG)**, . 2018. Disponível em: <https://www.dctech.com.br/entendendo-um-sistema-de-cromatografia-gasosa-cg/>. Acesso em: 05 mai. 2026.
- DHIMAN, P.; SHARMA, A.; CHANDRA, S. Intelligent diagnosis of transformer faults using dissolved gas analysis (dga) and machine learning techniques. **IEEE Access**, Piscataway v. 9,, p. 33689–33697, 2021.
- DHIMAN, R. *et al.* Intelligent diagnosis of transformer faults using dga. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 31,, p. 210–220, March 2024.

- DUVAL, M.; DEPABLA, A. Interpretation of gas-in-oil analysis using new iec publication 60599 and iec tc 10 databases. **IEEE Electrical Insulation Magazine**, IEEE v. 17, n. 2, p. 31–41, 2001.
- ENRIQUEZ, A. R. S. **Diagnóstico de Falhas em Transformadores de Potência através da Análise de Gases Dissolvidos usando Rede Neural Artificial**. 2020. Dissertação (Mestrado) — Universidade Federal do Maranhão – UFMA 2020.
- FACELI, . **Inteligência Artificial: uma abordagem de aprendizado de máquina**. Rio de Janeiro: LTC, 2011.
- FILHO, G. L. **Comparação entre os critérios de diagnósticos por análise cromatográfica de gasses dissolvidos em óleo isolante de transformador de potência**. 2012. Dissertação — Universidade de São Paulo - USP 2012.
- FILHO, J. M. **Manual de equipamentos elétricos: 4.ed**. Rio de Janeiro: LTC, 2013.
- FILHO, J. M. **Proteção de sistemas elétricos de potência: 3.ed**. Rio de Janeiro: LTC, 2024.
- FRONTIN, S. O. **Equipamentos de alta tensão — prospecção e hierarquização de inovações tecnológicas**. 1. ed. Brasília: Finatec, 2013.
- GUO, G. *et al.* Knn model-based approach in classification. *In*: MEERSMAN, R.; TARI, Z.; SCHMIDT, D. C. (Ed.). ON THE MOVE TO MEANINGFUL INTERNET SYSTEMS 2003: COOPIS, DOA, AND ODBASE. 2888 de **Lecture Notes in Computer Science.**, 2003, Berlin, Heidelberg. **Anais [...]** Berlin, Heidelberg: Springer, 2003. p. 986–996.
- GÉRON, . **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn e TensorFlow**. Rio de Janeiro: Alta Books, 2019.
- IEC . **IEC 60599**: Mineral oil-filled electrical equipment in service – guidance on the interpretation of dissolved and free gases analysis. Geneva: IEC, 2022.
- IEEE . **IEEE C57.104**: Ieee guide for the interpretation of gases generated in oil-immersed transformers. New York: IEEE, 2019.
- KHAN, M. A. M. Ai and machine learning in transformer fault diagnosis: A systematic review. **American Journal of Advanced Technology and Engineering Solutions**, v. 01., p. 290–318, fev. 2025.
- KHERIF, O. *et al.* Accuracy improvement of power transformer faults diagnostic using knn classifier with decision tree principle. **IEEE Access**, v. 9., p. 81693–81701, 2021.
- KULKANI, S. V.; KHAPARDE, S. A. **Transformer Engineering: Design, Technology, and Diagnostics**. 2. ed. Boca Raton: CRC Press, Taylor & Francis Group, 2012. ISBN 9781439852919.
- LAB, O. A. **Tool for DGA diagnostic**, . 2018. Disponível em: [https://oilanalysislab.com/Oil\\_Analysis\\_Downloads/LW/DGA/](https://oilanalysislab.com/Oil_Analysis_Downloads/LW/DGA/). Acesso em: 28 jun. 2026.
- LI, F.-F. **The mission of AI is not to replace humans, but to understand and empower the human mind**, . 2025. Citado em: Future Quote – Dr. Fei-Fei Li on Amplifying Human Potential Through AI. Disponível em: <https://thetuitioncenter.com/future-quote-dr-fei-fei-li-on-amplifying-human-potential-through-ai/>. Acesso em: 22 nov. 2025.
- LIMA, R. d. **Diagnóstico de falhas em transformadores de potência pela análise de gases dissolvidos em óleo isolante com a utilização de redes neurais**. dezembro 2016. Monografia (Especialização) — Coordenação do Curso de Especialização em Automação Industrial, Belo

Horizonte – MG dezembro 2016. Trabalho submetido à banca examinadora como requisito para obtenção do certificado de especialista.

LORENA, A. C.; CARVALHO, A. C. P. L. F. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada (RITA)**, XIV, n. 2, p. 43–67, 2007.

MENDONÇA, C. A. *et al.* Diagnóstico de transformadores de potência com base na análise dos gases dissolvidos: revisões anteriores. **Revista Sinergia**, São Paulo v. 16, n. 2, p. 114–120, 2015.

MILASCH, M. **Manutenção de transformadores em líquido isolante**. São Paulo; Itajubá, MG: Escola Federal de Engenharia: Edgard Blücher, 1984. Inclui bibliografia.

MYERS, S. D.; KELLY, J. J.; PARRISH, R. H. **A Guide to Transformer Maintenance**. 2nd printing, 1988. ed. Akron, Ohio: Transformer Maintenance Institute, Division of S. D. Myers, Inc., 1981.

Operador Nacional do Sistema Elétrico (ONS). **O Sistema em Números**, . 2025. <https://www.ons.org.br/paginas/sobre-o-sin/o-sistema-em-numeros>. Acesso em: 10 nov. 2025.

PEIXINHO, A. Z. **Análise dos Gases Dissolvidos em Óleo Isolante de Transformador Elevador de Alta Potência: Estudo de Caso**. 2024. Monografia — UNIVERSIDADE ESTADUAL PAULISTA – UNESP 2024.

PEREIRA, L. F. **DGA - Dissolved Gas Analysis**, . 2025. Banco de dados. Acesso em: 03 dez. 2025. Disponível em: <https://www.kaggle.com/datasets/luizflaviopereira/dga-dissolved-gas-analysis>.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. [S.l.]: Pearson, 2021.

SUN, H.-C.; HUANG, Y.-C.; HUANG, C.-M. A review of dissolved gas analysis in power transformers. **Energy Procedia**, v. 14., p. 1220–1225, January 2012.

UMANS, S. D. **Máquinas elétricas de Fitzgerald e Kingsley**: [recurso eletrônico]. Porto Alegre: AMGH, 2014.

VAN, A. S. **Power transformer reliability modelling**. 2010. PhD Thesis — Technische Universiteit Eindhoven 2010.

WEG. **Transformador a Seco Pequeno (Até 300 kVA)**, . 2025. Disponível em: [https://www.weg.net/catalog/weg/BR/pt/Gera%C3%A7%C3%A3o%2C-Transmiss%C3%A3o-e-Distribui%C3%A7%C3%A3o/Transformadores-a-Seco/Pequeno-%28At%C3%A9-300kVA%29/Transformador-a-Seco-Pequeno-%28At%C3%A9-300-kVA%29/p/MKT\\_WTD\\_SMALL\\_DRY\\_TYPE\\_TRANSFORMER\\_UP\\_TO\\_300KVA](https://www.weg.net/catalog/weg/BR/pt/Gera%C3%A7%C3%A3o%2C-Transmiss%C3%A3o-e-Distribui%C3%A7%C3%A3o/Transformadores-a-Seco/Pequeno-%28At%C3%A9-300kVA%29/Transformador-a-Seco-Pequeno-%28At%C3%A9-300-kVA%29/p/MKT_WTD_SMALL_DRY_TYPE_TRANSFORMER_UP_TO_300KVA). Acesso em: 21 nov. 2025.

ZHANG, Y. *et al.* Fault diagnosis of transformer using artificial intelligence: a review. **Frontiers in Energy Research**, Lausanne v. 10., p. 1006474, 2022.