



UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
INSTITUTO DE CIÊNCIA E TECNOLOGIA - CÂMPUS DE SOROCABA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Valdemir Sales Matias Junior

**METODOLOGIA PARA AVALIAÇÃO DE TRANSFORMADORES DE ATÉ
24,2 kV ATRAVÉS DE TÉCNICAS DE APRENDIZADO DE MÁQUINA
PARA DETERMINAÇÃO DO ÍNDICE DE SAÚDE**

Sorocaba, SP

2023



METODOLOGIA PARA AVALIAÇÃO DE TRANSFORMADORES DE ATÉ
24,2 kV ATRAVÉS DE TÉCNICAS DE APRENDIZADO DE MÁQUINA
PARA DETERMINAÇÃO DO ÍNDICE DE SAÚDE

Valdemir Sales Matias Junior

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração Sistemas de Energia, do Instituto de Ciência e Tecnologia da Universidade Estadual Paulista "Júlio de Mesquita Filho", Câmpus de Sorocaba, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Fernando Pinhabel Marafão

Sorocaba, SP

2023

M433m	<p>Matias Junior, Valdemir Sales</p> <p>Metodologia para avaliação de transformadores de até 24,2 kv através de técnicas de aprendizado de máquina para determinação do índice de saúde / Valdemir Sales Matias Junior. -- Sorocaba, 2023</p> <p>87 p. : il., tabs.</p> <p>Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Instituto de Ciência e Tecnologia, Sorocaba</p> <p>Orientador: Fernando Pinhabel Marafão</p> <p>1. Maquinas eletricas - Manutenção e reparos. 2. Transformadores eletricos. 3. Isoladores e isolamentos elétricos - Óleos. 4. Aprendizado do computador. 5. Vida útil (Engenharia). I. Título.</p>
-------	--

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca do Instituto de Ciência e Tecnologia, Sorocaba. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.



CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Metodologia para avaliação de transformadores de até 24,2 kV através de técnicas de aprendizado de máquina para determinação de índice de saúde

AUTOR: VALDEMIR SALES MATIAS JUNIOR

ORIENTADOR: FERNANDO PINHABEL MARAFÃO

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica, área: Automação pela Comissão Examinadora:

Prof. Dr. FERNANDO PINHABEL MARAFÃO (Participação Virtual)
Departamento de Engenharia de Controle e Automação / Instituto de Ciência e Tecnologia UNESP Campus de Sorocaba

Prof. Dr. ALEXANDRE CÂNDIDO MOREIRA (Participação Virtual)
Núcleo de Inovação, Pesquisa e Ensino em Mecatrônica - NIPEM / Universidade Federal de São João del-Rei

Prof. Dr. LEOPOLDO ANDRÉ DUTRA LUSQUINO FILHO (Participação Virtual)
Departamento de Engenharia de Controle e Automação / Câmpus de Sorocaba

Prof. Dr. WESLEY ANGELINO DE SOUZA (Participação Virtual)
Departamento Acadêmico de Elétrica (DAELE) / Universidade Tecnológica Federal do Paraná - UTFPR / Câmpus de Cornélio Procópio

São João da Boa Vista, 30 de junho de 2023

Verônica Liberali Messias
Supervisora Técnica de Seção
Seção Técnica de Graduação e Pós-Graduação

Dedico aos meus pais, familiares e amigos, que sempre me deram apoio e contribuíram para a minha formação e desenvolvimento deste trabalho.

AGRADECIMENTOS

Agradeço imensamente aos meus pais pelos esforços e incentivos que sempre praticaram para me proporcionar educação. E aos meus irmãos, pelo companheirismo e por toda força que sempre me deram.

Agradeço com muito apreço a recepção, simpatia, consideração e orientação do Prof. Dr. Fernando Pinhabel Marafão.

Grato a todos os professores do Programa de Pós-Graduação em Engenharia Elétrica do Instituto de Ciência e Tecnologia de Sorocaba. Aos meus colegas do laboratório GASI, onde tive um bom ambiente para desenvolver as pesquisas e troca de conhecimentos.

O presente trabalho foi realizado com apoio do subsídio com processo nº 2016/08645-9, Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP).

A imaginação é mais importante que o conhecimento. O conhecimento é limitado, enquanto a imaginação abraça o mundo inteiro, estimulando o progresso, e dando origem à evolução.

Albert Einstein

RESUMO

Transformadores de potência têm importância fundamental para o sistema elétrico de potência e a avaliação de suas condições de saúde é essencial para a operação confiável desses equipamentos, possibilitando ações de manutenção em tempo adequado e melhorando o planejamento de recursos energéticos e financeiros. Este trabalho apresenta uma metodologia para avaliação da condição de transformadores de potência de até 24,2 kV em termos do índice de saúde, ou *Health Index*, com aplicação de três algoritmos de aprendizado de máquina (AM) supervisionados na abordagem de regressão baseados em modelos múltiplos, denominados Random Forest (RF), Categorical Boosting (CatBoost) e Light Gradient Boosted Machine (LightGBM). A metodologia proposta utiliza um conjunto de dados formado por resultados de análises de qualidade do óleo isolante e cromatográfica, que é a base para geração de dados sintéticos, tendo como referência a evolução dos parâmetros de teste ao longo de 14 meses de operação de um transformador real da mesma classe de tensão. Dessa maneira, dobrando o número de amostras do conjunto, passando de 531 para 1062 amostras, as quais são aplicadas como os recursos de entrada para a determinação de valores de índice de saúde a partir da metodologia clássica e posteriormente pelas técnicas de aprendizado de máquina propostas. Para a implementação dos modelos propostos, o conjunto de dados passou pela etapa de pré-processamento e divisão, com 80% das amostras destinadas para treinamento dos modelos e 20% reservadas para testes. Os indicadores de desempenho e métricas de avaliação adequados para abordagem de regressão foram considerados nos resultados dos algoritmos para verificar os melhores desempenhos. A abordagem de regressão com os 13 atributos do conjunto de dados apresentou bons resultados em comparação com outros trabalhos da literatura, e o modelo Categorical Boosting (CatBoost) apresentou o melhor desempenho entre os propostos. A metodologia foi aplicada a um estudo de caso, utilizando os dados de análises físico-químicas e cromatográficas de oito transformadores de potência da mesma classe de tensão do conjunto de dados analisado, obtendo os estados de saúde e comparando com a avaliação de estado de saúde feita por especialistas. Como resultado, a metodologia indicou os transformadores a serem priorizados em intervenções de manutenção e o fatores ligados a degradação de transformadores, mostrando-se uma ferramenta estratégica para a gestão de transformadores.

Palavras-chave: transformadores de potência; índice de saúde; avaliação de transformadores; aprendizado de máquina supervisionado; modelos múltiplos.

ABSTRACT

Power transformers are of fundamental importance for the electric power system and the assessment of their health conditions is essential for the management of this equipment, enabling maintenance actions in a timely manner and improving the planning of energy and financial resources. This work presents a methodology for evaluating the condition of power transformers up to 24.2 kV in terms of the health index, with the application of three supervised machine learning (ML) algorithms in the regression approach based on models multiple, called Random Forest (RF), Categorical Boosting (CatBoost) and Light Gradient Boosted Machine (LightGBM). The proposed methodology uses a dataset formed by the results of the insulating oil and chromatographic quality analysis, which is the basis for generating synthetic data, having as reference the evolution of the test parameters over 14 months of operation of a transformer of the same voltage class. In this way, doubling the number of samples in the set, going from 531 to 1062 samples, which are applied as input resources for the determination of health index values from the classical methodology and later by the proposed machine learning techniques. For the implementation of the proposed models, the data set went through the pre-processing and division stage, with 80% of the samples destined for model training and 20% reserved for testing. The performance indicators and evaluation metrics suitable for the regression approach are considered in the results of the algorithms to verify the best performances. The regression approach with the 13 attributes of the data set presents good results compared to other works in the literature, and the Categorical Boosting model (CatBoost) presented the best performance among the proposed ones. The methodology was applied to a case study, using data from physical-chemical and chromatographic analyzes of eight power transformers of the same voltage class as the analyzed data set, obtaining the health states and comparing them with the state of health assessment. health by experts. As a result, the methodology indicated the transformers to be prioritized in maintenance interventions and the factors linked to the degradation of transformers, being a strategic tool for the management of transformers.

Keywords: power transformers, health index, transformer evaluation, supervised machine learning, ensemble learning.

LISTA DE ILUSTRAÇÕES

Figura 1 – Esquema do sistema elétrico com transformadores de potência.	18
Figura 2 – Transformador trifásico e seus principais componentes.	20
Figura 3 – Estrutura de um transformador de distribuição monofásico.	21
Figura 4 – Análise de falhas de componentes de transformadores de distribuição. ...	23
Figura 5 – Avaliação de transformadores de potência baseada em condições.	25
Figura 6 – Técnicas de interpretação DGA mais conhecidas, seus gases, razões de gases e falhas correspondentes.	27
Figura 7 – Degradação de condição teórica de um transformador.	35
Figura 8 – Diagrama operacional do índice de saúde convencional.	36
Figura 9 – Critérios para avaliar a condição técnica em função do valor HI e idade. ...	40
Figura 10 – Diagrama com número de fatores de diagnóstico reduzido.	42
Figura 11 – O fluxo de trabalho generalizado para resolver problemas usando AM. ...	47
Figura 12 – Regressão Random Forest.	52
Figura 13 – Diagrama da metodologia proposta para predição de HI.	56
Figura 14 – Fator de Dissipação.	59
Figura 15 – Distribuição dos valores de tensão interfacial.	60
Figura 16 – Rigidez Dielétrica.	61
Figura 17 – Distribuição de valores de Teor de Água.	62
Figura 18 – Total de Gases Combustíveis.	63
Figura 19 – Diagrama esquemático para o cálculo do índice de saúde.	64
Figura 20 – Distribuição de intervalos de índice de Saúde.	64
Figura 21 – Distribuição de intervalos de índice de Saúde com dados sintéticos.	66
Figura 22 – boxplot com valores das variáveis normalizadas.	67
Figura 23 – Correlação de atributos.	68
Figura 24 – Maiores correlações.	70
Figura 25 – Random Forest Regressor.	71
Figura 26 – Cat Boost Regressor.	71
Figura 27 – LGBM Regressor.	71
Figura 28 – Comparação de valores previstos de Cat Boost Regressor com valores de referência.	72

LISTA DE TABELAS

Tabela 1 – Modos de falha de transformadores de distribuição aéreos.	23
Tabela 2 – Técnicas de medição e níveis limite de acordo com as normas.	25
Tabela 3 – Ensaio para óleo mineral isolante.	29
Tabela 4 – Análise físico-química em óleo isolante.	31
Tabela 5 – Fatores de pontuação e pesos para níveis de gás.	37
Tabela 6 – Avaliação de transformadores com base no fator AGD.	38
Tabela 7 – Fatores de pontuação e pesos para parâmetros de teste de óleo.	38
Tabela 8 – Avaliação de transformadores com base no fator AQO.	39
Tabela 9 – Pontuação do índice de saúde.	39
Tabela 10 – Critérios de índice de saúde para ações de manutenção de transformadores.	40
Tabela 11 – Conjunto de Dados de Análises Físico-Químicas e Cromatográficas.	57
Tabela 12 – Atributos com dados do tipo float.	58
Tabela 13 – Taxa de Crescimento de Análises.	65
Tabela 14 – Atributos do conjunto com dados sintéticos.	66
Tabela 15 – Diferença de limites inferior e superior de valores dos atributos.	67
Tabela 16 – Análise de Desempenho dos Modelos.	69
Tabela 17 – Análise de desempenho com recursos reduzidos.	70
Tabela 18 – Comparação dos valores preditos da Regressão Catboost com os valores reais.	72
Tabela 19 – Resultados de índice de saúde de transformadores.	73
Tabela 20 – Análise dos transformadores classificados na condição ruim.	73
Tabela 21 – Características dos transformadores de potência avaliados.	75
Tabela 22 – Dados de análises físico-química e cromatográfica para estudo de caso.	75
Tabela 23 – Resultados de índice de saúde de transformadores do estudo de caso. .	76

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ANEEL	Agência Nacional de Energia Elétrica
AT	Alta Tensão
BT	Baixa Tensão
CatBoost	Categorical Boosting
CIGRÉ	Conseil International dès Grands Réseaux Electriques
DGA	Dissolved Gas Analysis
DT	Decision Tree
HI	Health Index(Índice de Saúde)
IEC	International Electrotechnical Commission
IEEE	Institute of Electrical and Electronic Engineers
LightGBM	Light Gradient Boosted Machine
LSTM	Long Short-term Memory
MT	Média Tensão
NBR	Norma Técnica Brasileira
OMI	Óleo Mineral Isolante
PPM	Partes Por Milhão
RF	Random Forest
SEP	Sistema Elétrico de Potência
SIN	Sistema Interligado Nacional
TP	Transformador de Potência

LISTA DE SÍMBOLOS

CO	Monóxido de Carbono
CO_2	Dióxido de Carbono
H_2	Gás hidrogênio
C_2H_2	Gás acetileno
C_2H_4	Gás etileno
CH_4	Gás metano
C_2H_6	Gás etano
N_2	Gás nitrogênio
O_2	Gás oxigênio
$\Delta T(XY)$	Intervalo de detecção de falha
$\Delta T(YZ)$	Intervalo de iminência de falha
I_R	Corrente nominal RMS total
I_h	Corrente no harmônico h
h	Ordem do harmônico.

SÚMARIO

1	INTRODUÇÃO	14
1.1	Contexto e Motivação	14
1.2	Objetivos	16
1.2.1	Objetivos Específicos	16
1.3	Organização do Trabalho	16
2	REFERENCIAIS TEÓRICOS	18
2.1	Transformadores de Potência	18
2.2	Falhas em Transformadores	19
2.3	Métodos de Diagnóstico	24
2.3.1	Análise dos Gases Dissolvidos	26
2.3.2	Análises Físico-Químicas em Óleos Isolantes	28
2.3.3	Testes Dedicados para Diagnóstico de Falhas Incipientes	31
2.3.3.1	<i>Metodologias Elétricas para Diagnóstico de Falhas Incipientes</i>	32
2.3.3.2	<i>Análises de Vibração, Acústica e Termográfica</i>	33
2.4	Gestão de Transformadores e Tomada de Decisão de Manutenção	34
2.4.1	Avaliação de Transformadores por meio de Índice de Saúde	36
2.4.2	Evolução dos Métodos de Índice de Saúde	41
2.5	Considerações Finais do Capítulo	45
3	MODELOS DE REGRESSÃO PARA PREDIÇÃO DE ÍNDICE DE SAÚDE DE TRANSFORMADORES	46
3.1	Aprendizado de Máquina	46
3.2	Regressores Baseados em Modelos Múltiplos	51
3.2.1	Random Forest (RF)	51
3.2.2	Categorical Boosting (CatBoost)	52
3.2.3	Light Gradient Boosting Machine (LGBM)	53
3.3	Métricas de Avaliação	54
3.4	Considerações Finais do Capítulo	55
4	METODOLOGIA PROPOSTA	56
4.1	Etapas de Desenvolvimento dos Modelos	56
4.2	Análise dos Dados	58
4.3	Determinação do Índice de Saúde	63
4.3.1	Avaliação entre os três algoritmos de regressão	69
4.4	Considerações Finais do Capítulo	73

5	ESTUDO DE CASO	75
5.1	Transformadores Avaliados	75
5.2	Análises dos resultados físico-químicos e cromatográficos em relação ao índice de saúde	76
6	CONCLUSÃO	77
6.1	Sugestões para Trabalhos Futuros	78
6.2	Trabalhos Publicados	78
	REFERÊNCIAS	79
	APÊNDICE A – DADOS DE ANÁLISES CROMATOGRÁFICAS E FÍSICO-QUÍMICA DE TRANSFORMADORES PARA ESTUDO DE CASO	86

1 INTRODUÇÃO

1.1 Contexto e Motivação

Os transformadores de potência são fundamentais para o sistema elétrico de potência (SEP) porque são os responsáveis pela adequação dos níveis de tensão do Sistema Interligado Nacional (SIN), viabilizando a transmissão e distribuição de energia pelo extenso território nacional (IARONKA, 2019). Nos sistemas elétricos de potência típicos, a energia é gerada com tensões de 6 kV a 25 kV e os transformadores de potência elevam a tensão a um nível entre 110 kV e 765 kV para realizar a transmissão a longa distância com perdas reduzidas, então, outros transformadores abaixam a tensão para a faixa de 13,8 kV a 34,5 kV para fazer a distribuição local e, finalmente, permitir que a energia elétrica seja usada de forma segura em lares, escritórios e fábricas, com tensões tão baixas quanto 127 V (CHAPMAN, 2013).

Como um equipamento importante no sistema elétrico, o estado de operação dos transformadores está relacionado à operação segura de todo o sistema. Assim, é de grande importância conhecer a condição do transformador e tomar medidas preventivas (REMA; CARVALHO; BONATTO, 2022). A estimativa da vida útil restante de um transformador de potência pode viabilizar a melhoria de utilização do ativo, otimizar planejamentos de manutenções e ações para aumentar a confiabilidade do sistema elétrico de potência por diminuição de falhas.

Durante a vida útil destes equipamentos é necessário estabelecer uma estratégia de manutenção que assegure o nível apropriado de confiabilidade e de uma vida útil operacional otimizada (CIGRE.GT-A2.05, 2013). Dessa forma, há grande interesse por parte de empresas do setor elétrico em aprimorar o monitoramento das condições dos subsistemas dos transformadores. O desenvolvimento de métodos que representem fielmente o estado de saúde dos transformadores de potência ou indiquem falhas iminentes são fundamentais para o gerenciamento dos ativos (CIGRE.GT-A2.23, 2006).

Na avaliação de transformadores, é necessário realizar a compilação de análises das condições de vários componentes, com uso de parâmetros de operação. De acordo com as experiências de exploração, recomenda-se que os dados obtidos sejam generalizados na forma de um indicador, geralmente referido como índice de saúde, ou *health index* (BOHATYREWICZ; PŁOWUCHA; SUBOCZ, 2019). Isso permite apresentar sucintamente o estado geral do transformador na forma de um único indicador numérico ou classificatório, o que é mais compreensível ao nível de gestão das empresas.

O índice de saúde pode ser determinado com base em um número grande e

relativamente pequeno de parâmetros específicos. O que possibilita a criação de indicadores de complexidade variável. Ao mesmo tempo, é necessário conhecimento especializado que leve em consideração elementos como a construção e o tipo do transformador, princípios de operação e o envolvimento de tecnologias avançadas de diagnóstico. Os algoritmos de índice de saúde assumem diferentes formas, incluindo os sistemas especialistas, algoritmos inteligentes usando lógica difusa, redes neurais artificiais e sistemas baseados no modelo matemático de Markov (BOHATYREWICZ; PŁOWUCHA; SUBOCZ, 2019).

A metodologia de índice de saúde integra uma matriz de riscos que vem sendo sistematicamente utilizada na avaliação de riscos de processo nas empresas, para associar índice de saúde a um índice de impacto e assim priorizar as potenciais aplicações de sistemas de monitoramento nos ativos mais críticos. Também permite uma comparação entre vários transformadores com diferentes parâmetros. Mas a obtenção de dados sistêmicos de falha de transformadores não é de fácil acesso, diante de dificuldades envolvidas na coleta de informações de diferentes empresas e a restrição imposta pelas concessionárias para disponibilizar seus dados e suas informações em um ambiente de competitividade (TAMURA et al., 2022).

O desenvolvimento de metodologias para avaliação de transformadores de potência que contemplem os parâmetros de operação disponíveis e relevantes para determinação do estado global do transformador através de técnicas de inteligência artificial, pode prover indicativos para a gestão de ativos de forma efetiva, apoiando decisões de gerenciamento e substituição de equipamentos, do ponto de vista operacional e financeiro (OLIVEIRA, 2021).

A maior parte dos dispositivos de monitoramento contínuo de transformadores e ferramentas de avaliação da condição ainda são projetados e aplicados nos transformadores de maior porte, os transformadores de menor porte acabam tendo menor frequência na avaliação da condição de integridade (KABIR; FOGGO; YU, 2018). Métodos baseados em análises cromatográficas e físico-químicas obtêm resultados sólidos, mas tais métodos ainda têm custos elevados para transformadores de distribuição, se forem comparados com transformadores de grande porte. No contexto das concessionárias de energia, o objetivo em geral é equilibrar a escala composta por custo e risco em um cenário de recursos limitados (FLAUZINO; NUNES, 2020).

É necessário que as concessionárias identifiquem com sucesso os transformadores de distribuição que são de maior risco para evitar a interrupção do fornecimento de energia aos usuários finais. No entanto, dada a quantidade de transformadores de distribuição presentes na rede de distribuição, estes não são monitorados por processos automatizados (SHIL; ANDERSON, 2019). Normalmente não possuem sensores, transformadores de instrumentos e outros equipamentos para monitorar sua integridade, os problemas de falha são capturados basicamente quando uma interrupção é identificada, seguida de investigação

e, talvez, substituições.

Sendo assim, este trabalho propõe a utilização de resultados de análises cromatográficas e físico-químicas de transformadores de distribuição para determinação do índice de saúde a partir da metodologia clássica e posteriormente com a aplicação de técnicas de aprendizado de máquina para construção de modelos de avaliação da condição geral com parâmetros disponíveis. Com a proposta de contribuir na identificação de transformadores com a integridade comprometida, na priorização de intervenções, seleção de métodos de testes dedicados e monitoramento dos ativos mais críticos e contribuir com a gestão de manutenção e segurança operacional.

1.2 **Objetivos**

O objetivo deste trabalho é o desenvolvimento de uma metodologia para a avaliação do estado de saúde geral de transformadores de distribuição, baseando-se no método clássico de índice de saúde, e através da aplicação de técnicas de aprendizado de máquina supervisionado, a fim de contribuir no acompanhamento da degradação dos ativos e na identificação do momento adequado para intervenções de manutenção.

1.2.1 **Objetivos Específicos**

Considerando o objetivo principal deste trabalho, foram estabelecidos os seguintes objetivos específicos:

- Gerar dados sintéticos de análises cromatográficas e físico-químicas que pudessem ser usados para treinamento e teste dos modelos propostos.
- Desenvolver uma metodologia de avaliação a partir de aprendizado de máquina supervisionado para análise do estado geral de integridade de transformadores, através de um índice de simples interpretação.
- Comparar os resultados obtidos dos modelos de regressão para predição de índice de saúde, com os resultados da metodologia clássica, e avaliar o desempenho dos modelos de aprendizado de máquina;
- Analisar os resultados elencando as possíveis ações a serem tomadas pela gestão de ativos.

1.3 **Organização do Trabalho**

Este trabalho está estruturado da seguinte forma:

Capítulo 2 - Apresenta uma revisão sobre componentes construtivos de transformadores de potência, principais modos de falhas, métodos de diagnóstico, testes mais específicos, abordagens de gestão e tomada de decisão de manutenção e metodologias de avaliação por meio do índice de saúde.

Capítulo 3 - Apresenta a teoria em que as técnicas de aprendizado de máquina aplicadas neste trabalho são embasadas, especialmente modelos de aprendizado de máquina supervisionado.

Capítulo 4 - Aborda sobre o tratamento do conjunto de dados utilizado e o desenvolvimento da metodologia proposta para a avaliação dos transformadores de potência, descrevendo a implementação dos modelos de aprendizado de máquina.

Capítulo 5 - Trata sobre um estudo de caso aplicando a metodologia proposta na avaliação de transformadores de potência, a partir de dados de análises destes equipamentos.

Capítulo 6 - Apresenta a conclusão do trabalho, indicando o modelo proposto que obteve maior precisão na predição do índice de saúde.

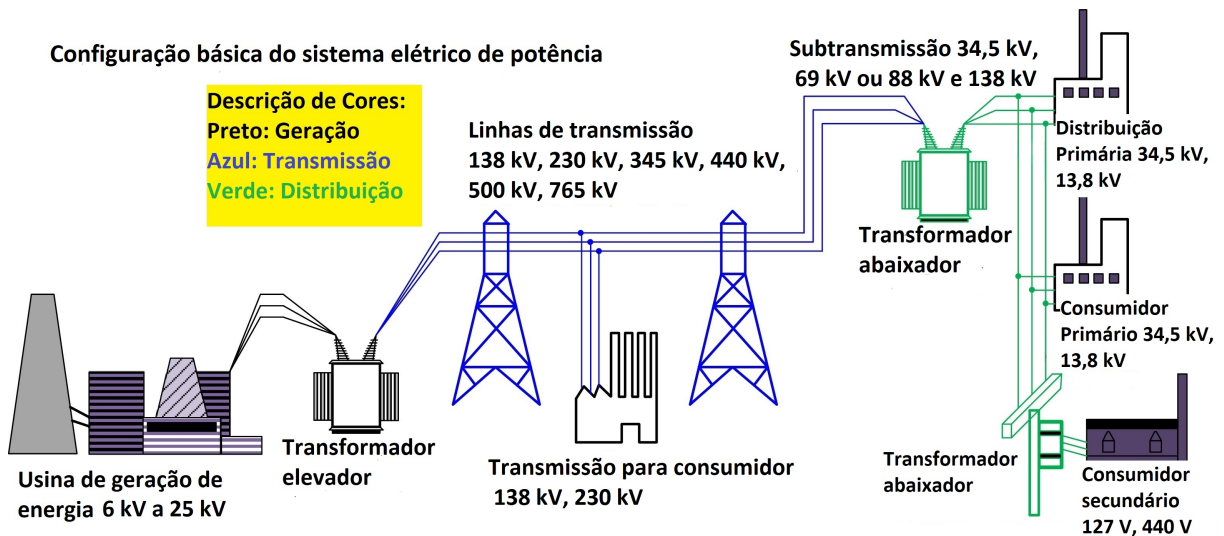
2 REFERENCIAIS TEÓRICOS

Este capítulo aborda as principais características construtivas de transformadores de distribuição, a classificação das principais causas de falhas e os componentes mais afetados. Seguindo com a descrição de métodos de obtenção de dados para monitoramento da condição de subsistemas; métodos de avaliação de parâmetros para prever as tendências de estado geral de transformadores. Finalizando com estratégias de apoio a tomada de decisão na gestão desses ativos, em aspectos financeiros e operacionais.

2.1 Transformadores de Potência

Um transformador é um dispositivo que converte, por meio da ação de um campo magnético, a energia elétrica CA de uma dada frequência e nível de tensão em energia elétrica CA de mesma frequência, mas outro nível de tensão (CHAPMAN, 2013). Idealmente, um transformador converte um nível de tensão CA em outro nível de tensão sem afetar a potência elétrica real fornecida. Se um transformador elevar o nível de tensão de um circuito, ele deverá diminuir a corrente para manter a potência de entrada no dispositivo igual à potência de saída. No sistema elétrico há diferentes tipos de transformadores, que possuem características específicas quanto à classe de tensão, potência e propósitos (por exemplo, amostragem de tensão, amostragem de corrente e transformação de impedância). Na Figura 1 são apresentados os tipos de transformadores comumente encontrados nos sistemas de geração, transmissão, e distribuição de energia elétrica.

Figura 1 – Esquema do sistema elétrico com transformadores de potência.



Fonte: (RONCERO-CLEMENTE; ROANES-LOZANO, 2018).

Nas grandes usinas geradoras o nível de tensão na saída dos geradores está normalmente na faixa de 6kV a 25 kV. No caso das hidroelétricas e termelétricas os geradores são do tipo síncrono operando na frequência nominal de 60 Hz, que é a frequência dos sistemas elétricos brasileiros. A tensão de saída dos geradores é ampliada a níveis mais altos por meio dos transformadores elevadores das usinas. Isto é feito para viabilizar as transmissões a média e longa distâncias, diminuindo-se desta forma, a corrente elétrica e, portanto possibilitando o uso de cabos condutores de bitolas razoáveis, com adequados níveis de perdas joule e de queda de tensão ao longo das linhas de transmissão.

As tensões usuais de transmissão adotadas no Brasil, em corrente alternada, podem variar de 138 kV até 765 kV incluindo neste intervalo as tensões de 230 kV, 345 kV, 440 kV e 500 kV. Os sistemas ditos de subtransmissão contam com níveis mais baixos de tensão, tais como 34,5 kV, 69 kV ou 88 kV e 138 kV e alimentam subestações de distribuição, cujos alimentadores primários de saída operam usualmente em níveis de 13,8 kV e 34,5 kV. Junto aos pequenos consumidores existe uma outra redução do nível de tensão para valores entre 127 V e 440 V, na qual operam os alimentadores secundários. As redes com tensões nominais iguais ou superiores a 230 kV são denominadas de Redes em EHV - Extra Alta Tensão e no Brasil formam a chamada rede “Básica” de transmissão. As redes com tensões nominais iguais e entre 69 kV e 138 kV são denominadas Redes em AT – Alta Tensão. As redes com tensão nominal entre 1 kV e 69 kV são denominadas Redes em MT – Média Tensão (ou em Tensão Primária) e os sistemas com tensões abaixo de 1 kV formam as Redes em Baixa Tensão (ou em Tensão Secundária).

2.2 Falhas em Transformadores

Com o aumento do tempo de operação dos transformadores, suas condições internas mudam, degradando-se gradativamente e aumentando o risco de ocorrência de falhas. Quando o transformador é novo, ele possui suficiente rigidez dielétrica e mecânica para suportar condições não usuais de operação do sistema, mas com o passar dos anos ou ocorrência de eventos no sistema, a isolamento do equipamento sofre gradativa degradação, até o ponto em que o transformador é incapaz de suportar eventos, como curto-circuitos e sobretensões transitórias (WANG; VANDERMAAR; SRIVASTAVA, 2002).


A tendência de falha do transformador e outros aspectos do ciclo de vida dependem dos principais eventos, como desgastes elétricos, térmicos, mecânicos e químicos (BAI; GAO; LIU, 2013). A causa raiz da falha refere-se ao motivo principal da ocorrência da falha e pode ser classificado como: projeto, fabricação ou material, transporte, manuseio ou armazenamento, perda de pressão de aperto, instalação em campo, manutenção imprópria, reparo impróprio, sobrecarga anormal, sobretensão, sobreaquecimento, descarga atmosférica, curto-circuito externo, distúrbios sísmicos, aplicação imprópria, poluição externa,

perda de refrigeração, vandalismo, deterioração anormal, danos colaterais e desconhecido (TAMURA et al., 2022).

Os transformadores de potência são equipamentos complexos que dependem da interação de um conjunto de componentes para o seu funcionamento adequado. Estes possuem características construtivas específicas para cada aplicação e padrões definidos para a operação destinada, podem ter as mesmas especificações caso sejam fabricados na mesma série. Embora os transformadores de usinas, subestações e o transformador de distribuição tenham os mesmos princípios de funcionamento e componentes-chave principais, como isolamento, enrolamentos, núcleo, etc., esses transformadores diferem em complexidade e tamanho (TRAN et al., 2020a).

Os transformadores são circuitos trifásicos que podem ser construídos de duas maneiras. Uma forma é simplesmente tomar três transformadores monofásicos e ligá-los em um banco trifásico. Outra forma é construir um transformador trifásico que consiste em três conjuntos de enrolamentos que envolvem um núcleo comum. Um transformador trifásico apenas é mais leve, menor, de custo mais baixo e ligeiramente mais eficiente. Por outro lado, o uso de três transformadores monofásicos separados tem a vantagem de que cada unidade do banco pode ser substituída individualmente no caso de ocorrer algum problema (CHAPMAN, 2013). Um transformador trifásico com seus principais componentes é ilustrado na Figura 2, contendo buchas de alta e baixa tensão, bobinas, núcleo, óleo, trocadores de calor, tanque e comutador.

Figura 2 – Transformador trifásico e seus principais componentes.




Fonte: (MURUGAN; RAMASAMY, 2019).

Neste trabalho é dado enfoque aos transformadores de distribuição que possuem como meio isolante o óleo mineral, portanto, a seguir são descritos os componentes associados ao funcionamento destes transformadores de potência, com destaque para aqueles com maior relação à ocorrência de falhas. Com objetivo de simplificar a apresentação

dos componentes, a Figura 3 mostra a estrutura de um transformador de distribuição monofásico.

Figura 3 – Estrutura de um transformador de distribuição monofásico.



Fonte: (TRAN et al., 2020a)

Na Figura 3, os principais componentes dos transformadores de distribuição são núcleo, enrolamentos, tanque, isolamento e buchas.

- Núcleo

O núcleo do transformador é feito de aço silício. Este núcleo é usado para transmitir a energia das bobinas primárias para as bobinas secundárias do transformador através da indução eletromagnética. O núcleo falha devido à magnetização CC ou deslocamento do aço do núcleo durante a construção do transformador. A laminação do núcleo também pode descascar e aumentar as perdas e o calor devido à corrente parasita.

- Enrolamentos

Os enrolamentos são os condutores enrolados ao redor do membro do núcleo. Um transformador consiste em um enrolamento primário e um ou mais enrolamentos

secundários conectados por meio de um campo eletromagnético. Os enrolamentos geram força magnetomotriz que é transportada pelo núcleo para outros enrolamentos para mudanças de tensão. A falha mais frequente nos enrolamentos é devido a curto-circuitos ou sobretensões transitórias.

- Tanque

O tanque é a proteção física para o núcleo do transformador e enrolamentos, bem como é um recipiente de óleo para resfriar o transformador. A falha do tanque do transformador pode ocorrer em qualquer lugar devido a vazamento de óleo, material de isolamento perde a função de isolamento, amassados. Vazamento de óleo pode danificar rapidamente o transformador e gerar incêndio.

- Isolamento

O isolamento entre os enrolamentos em transformadores é geralmente fornecido pelo óleo do transformador. Aos processos de oxidação e aumento do tamanho das partículas coloidais podem gerar partículas condutoras, elevar a temperatura no interior do transformador e, por fim, danificar o isolamento do óleo.

- Buchas

São usadas para fornecer isolamento durante o roteamento dos terminais do enrolamento através do tanque para conexão com o sistema de energia. O principal modo de falha da bucha é o curto-circuito. Pode ser devido a falhas materiais no isolamento ou devido a danos. O dano pode ocorrer devido a sabotagem, durante o transporte ou peças transportadas pelo ar de outro equipamento com falha. Danos, rachaduras na porcelana e juntas ruins proporcionam a entrada de água no interior da isolação da bucha levando à sua falha.

- Comutador

Comutador é utilizado para regular a tensão de saída de um transformador alterando o número de voltas em um enrolamento. Para transformadores de distribuição, o comutador não pode ser trocado enquanto o transformador estiver energizado, só pode ser trocado depois de isolar o transformador do circuito. Portanto, o dano causado por uma falha do comutador raramente acontece.

Em (TRAN et al., 2020a), são categorizados modos de falhas de transformadores de distribuição aéreos, com os principais componentes, núcleo, enrolamentos, tanque, isolamento, buchas e outros. Além da classe de falhas, frequência de falhas de transformadores, taxa de falhas de transformadores e nível de impacto da operação conforme a Tabela 1. Pode-se ver que vários modos de falha elétricos, mecânicos, químicos e térmicos podem ocorrer, esses modos de falha geralmente produzem sintomas elétricos, mecânicos, químicos ou térmicos.


Tabela 1 – Modos de falha de transformadores de distribuição aéreos.

Componente	Classe Falha	Modo Falha	Frequência Falha	Impacto Operacional
Isolamento	Química/Mecânica	Acúmulo de água no óleo/papel	Alta	Alto
	Química/Térmica	Envelhecimento de óleo/papel		
	Térmica	Degradação térmica de óleo/papel		
Enrolamento	Elétrica/Mecânica	Curto-circuito entre espiras/fios	Média	Alto
		Curto-circuito à terra		
	Magnética/Mecânica	Curvatura do condutor, falha no sistema de fixação, instabilidade axial e deformação do condutor Movimentação de enrolamento Flambagem		
Buchas	Elétrica/Mecânica	Curto-circuito dentro de camadas classificadas por capacitância	Média	Alto
	Mecânica/Térmica	Expansão térmica da bucha		
	Mecânica	Falha da bucha por danos na porcelana		
Tanque	Mecânica/Térmica	Ruptura interna Vazamento	Baixa	Baixo
Núcleo	Elétrica/Mecânica	Aterramento múltiplo	Baixa	Baixo
		Núcleo não aterrado		
	Mecânica/Térmica	Laminações de núcleo de curto-circuito Deformação do núcleo		
Outros	Desconhecidos	Erros operacionais, falta de manutenção e falhas do sistema de proteção	Baixa	N/A

Fonte: (TRAN et al., 2020a)

Uma análise de falhas de componentes de transformadores de distribuição apresentada em (SINGH; SINGH; SINGH, 2019), com base em dados de 348 transformadores de distribuição de várias potências, é mostrada na Figura 4. O resultado indica que 42% dos transformadores falharam devido a falha de isolamento, 15% devido a falha de enrolamento, 14% devido a falha de buchas, 7% devido a falha de óleo, 4% devido a falha de núcleo e 3% devido a falha de tanque.

Figura 4 – Análise de falhas de componentes de transformadores de distribuição.



Fonte: (SINGH; SINGH; SINGH, 2019).

De acordo com (ZHANG; GOCKENBACH, 2008), (ABU-SIADA; ISLAM, 2012),

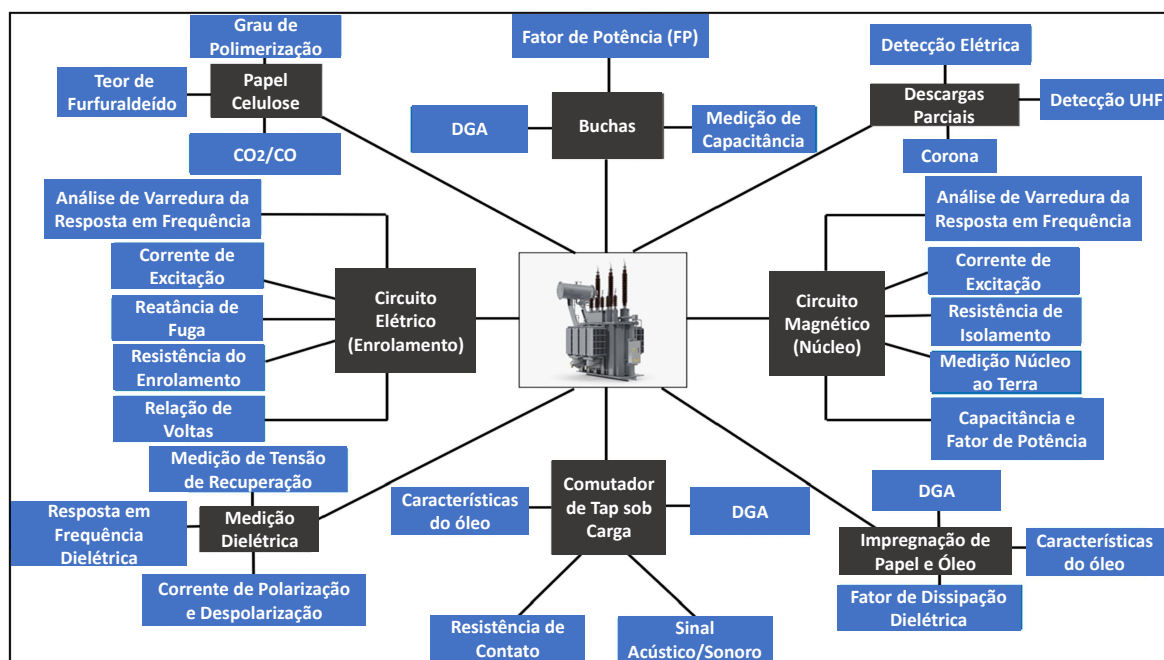
(JALBERT et al., 2012), a condição de integridade do transformador é regida por sua condição de isolamento de papel-óleo. As alterações nesses fatores podem indicar a iminência de falhas ou a deterioração das partes do transformador (CIGRE.GT-B3/B5.A2.01, 2017). Na pesquisa realizada por (SONI; MEHTA, 2021), sobre classificação de falhas em componentes de transformadores de grande porte e suas causas, a classificação 'Core' é utilizada para danos globais à parte interna do transformador e diz respeito às situações em que não é uma parte específica. Nota-se que do ponto de vista elétrico, as descargas atmosféricas e os surtos de comutação são mais propensos a falhas nos isolamentos do núcleo, bem como dos enrolamentos. Além disso, deformações do enrolamento e estresses mecânicos podem afetar os processos de resfriamento e causar o aumento súbito de temperatura devido às forças de curto-circuito (BACHA; SOUAHLIA; GOSSA, 2012). Tais causas e consequências também são as mais comuns nos transformadores de distribuição também, conforme a Tabela 1 e a Figura 4.

2.3 Métodos de Diagnóstico

A implementação de sistemas de monitoramento e a realização de diagnóstico periódico em transformadores proporcionam o acompanhamento de suas condições de operação, identificando anormalidades e possibilitando a tomada de decisão quanto a medidas para evitar ou minimizar a ocorrência de falhas (MARTINS et al., 2022). O monitoramento da condição operativa, a análise do estado e o diagnóstico de falhas são atividades efetivas que contribuem para garantir a continuidade da operação dos transformadores (REMA; CARVALHO; BONATTO, 2022). (ABU-ELANIEN; SALAMA, 2010) define os métodos de teste de diagnóstico em suas formas de duas partes, monitoramento de condição (MC) e avaliação de condição (AC). MC refere-se a todos os testes elétricos, químicos e físicos que são usados coletivamente para a o desenvolvimento de ferramentas de AC, que determinam a condição de integridade geral de transformadores. A Figura 5 ilustra o exemplo de vários testes de MC que podem ser aplicados em subsistemas de transformadores de potência.

As facilidades geradas pelos avanços das tecnologias de testes e desenvolvimento de sensores, permitiram a implementação de sistemas de monitoramento das condições operacionais de transformadores e seus acessórios, como buchas, comutadores sob carga, motoventiladores, dentre outros. A utilização desses sistemas tem o objetivo de minimizar a ocorrência de falhas, dado que a coleta de dados e apresentação de resultados pode ser feita em tempo real, possibilitando a detecção e avaliação imediata de eventuais problemas, sem que os mesmos evoluam a uma condição de falha para que sejam identificados (BECHARA, 2010). Trata-se de sistemas de custo relativamente elevados, que utilizam ferramentas, métodos, dispositivos e sensores especiais para análise de diversos parâmetros de operação. Por exemplo, a presença de gases e umidade no óleo isolante, o estágio de desgaste de contatos do comutador, fator de potência, descargas parciais em buchas e etc.

Figura 5 – Avaliação de transformadores de potência baseada em condições.



Fonte: (SONI; MEHTA, 2021).

O MC permite maior conhecimento da condição de transformadores e melhor definição de quando e qual tipo de manutenção é requerida. A Tabela 2 apresenta as técnicas para monitoramento da condição de parâmetros de transformadores de distribuição.

Tabela 2 – Técnicas de medição e níveis limite de acordo com as normas.

Técnica de Medição	Padronização	Limite para Classe de Tensão de Distribuição		
		Normal	Suspeito	Ruim
Temp. do ponto quente (classe de isolamento 150)	IEEE C57.91-1995, IEC 60076-7	<95°C	95 -100°C	>100°C
Fator de potência	IEC 60422	<=0.1%	0.1-0.5%	>0.5%
Distorção harmônica de tensão	IEEE 519-2014	THD(Uf) => 5%	5%	>5%
Nível de ruído (para transformador de potência 50 kVA)	IEC 60076-10(2001), IEEE C57.12.90(2006)	39-42 dB	42-45 dB	>45 dB
Umidade (saturação percentagem)	IEEE 62-1995	0-20%	21-30%	>30%
Razões de voltagens	IEC 60076-3 2000, IEEE C57.12.90	<=0.1%	>=0.2% a <=0.5%	>=0.5%
Resistência do enrolamento	IEC 60076-3 2000	<1%	>= 1% a <=4%	>=5%
Resistência do núcleo	IEC 60076-3 2000	>=1000 MOhm	>=100 MOhm	<=10 MOhm
Impedância de curto-circuito	IEC 60076-5 2000	<=1%	1%<=2%	>=5%
Análise de gás dissolvido	IEEE C57-104-2008	0-1920	1920-4630	>=4630
Razão CO2/CO	IEC 60599 1999	>=3-10	<=3	>=10
Rigidez dielétrica	IEC 60422-2005	>=50kV/mm	<=50-40kV/mm	<=40kV/mm
Tensão interfacial	IEC 60422	>=28 dyne/cm	28-22 dyne/cm	<=22 dyne/cm
Espectroscopia no domínio frequência	IEC 60422 2005	<=2.2% (Seca)	>=2.2 e<=4.8%	>=4.8%
			Úmido moderado	Muito Úmido

Fonte: (TRAN et al., 2020a)

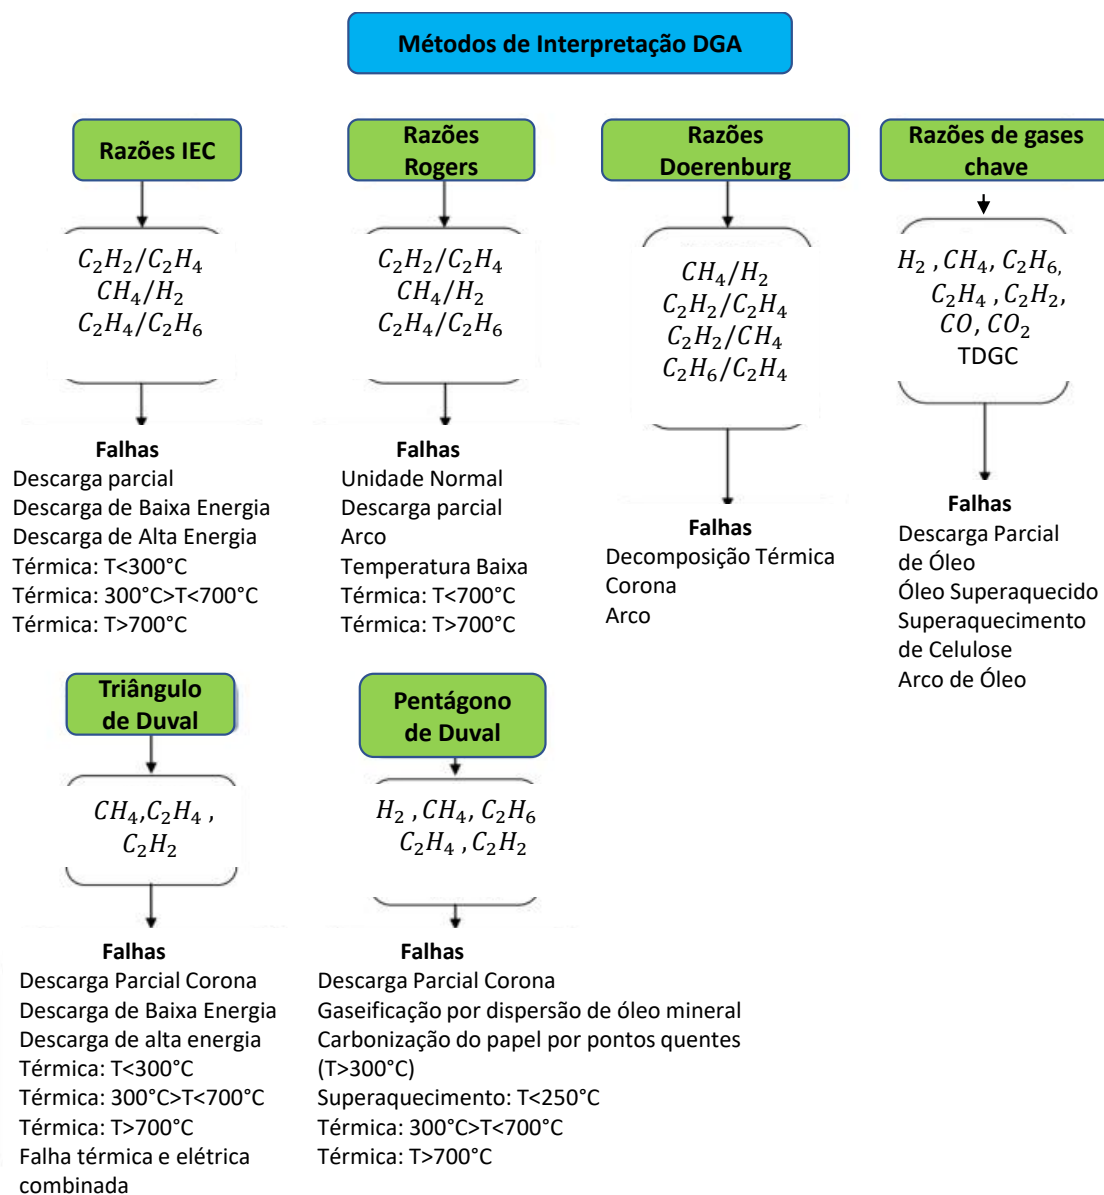
Todas as técnicas de medição devem estar em conformidade com os padrões especificados. Os padrões e limites de várias técnicas de medição fornecidos na Tabela 2 são derivados dos padrões IEEE e IEC.

2.3.1 Análise dos Gases Dissolvidos

Entre os diversos métodos de monitoramento de condições de parâmetros ou diagnóstico de falhas incipientes de transformadores, destacam-se os métodos baseados na análise dos gases dissolvidos em óleo isolante (DGA - Dissolved Gas Analysis). Esta análise ocorre através do uso de técnicas como a cromatografia gasosa (BAKAR; ABU-SIADA; ISLAM, 2014). A DGA está entre as principais técnicas preditivas, não-invasivas e de custo viável, utilizadas para a detecção de falhas em transformadores imersos em óleo mineral isolante (MARQUES, 2018), não necessita que o equipamento seja tirado de serviço, evitando a parada no fornecimento de energia elétrica. É reconhecida por ser robusta, confiável e utilizada pela maioria das empresas do setor elétrico e fabricantes de equipamentos, sendo de conhecimento comum e de validade comprovada em todo o mundo após a publicação de manuais relevantes como o padrão (IEEE-C57.104, 2019) e o (CIGRE, 2019) que apresenta formas de interpretações avançadas em DGA.

A análise dos gases dissolvidos consiste na extração de amostras do óleo isolante para submeter à uma cromatografia gasosa, ou seja, a um processo de análise química instrumental a fim de se identificar e quantificar os níveis de gases dissolvidos no óleo. Os métodos de Doernenburg (IEEE-C57.104, 2019), de Rogers (ROGERS, 1978), Triângulo de Duval (DUVAL, 2002) e IEC 60599 (DUVAL; DEPABLA, 2001), são alguns dos métodos de interpretação de falhas a partir dos gases dissolvidos, sendo que estes estabelecem critérios para classificação do tipo de falha ocorrida em transformadores através da razão entre as concentrações de gases dissolvidos no óleo. O método IEC 60599 é um dos métodos mais utilizados pelas empresas de energia, sendo que utiliza a relação entre cinco gases comumente gerados em condição de falha: hidrogênio (H_2), acetileno (C_2H_2), etileno (C_2H_4), etano (C_2H_6) e metano (CH_4). Em geral, estes métodos permitem detectar dois tipos de falhas, a elétrica e a térmica, e se baseiam na comparação das concentrações de gases dissolvidos com um *benchmark* contendo valores típicos de concentrações de gases. A Figura 6 mostra de forma geral as técnicas de interpretação DGA mais conhecidas, seus gases, razões de gases e falhas correspondentes. A análise DGA pode propor possíveis fontes de falha, como arco voltaico, descargas parciais (DP), faíscas de baixa energia, sobrecarga severa e superaquecimento. O método da razão de Doerneburg examina as razões (CH_4/H_2), (C_2H_2/C_2H_4) e (C_2H_6/C_2H_2), a análise pode propor a existência de decomposição térmica, o efeito corona (descargas parciais de baixa intensidade) e a situação de arco voltaico (descargas parciais de alta intensidade).

Figura 6 – Técnicas de interpretação DGA mais conhecidas, seus gases, razões de gases e falhas correspondentes.



Fonte: (BARKAS; CHRONIS; PSOMOPOULOS, 2022).

As razões de Rogers, como os métodos de razões IEC, usam as razões (C_2H_2/C_2H_4), (CH_4/H_2) e (C_2H_4/C_2H_6), podem indicar que a operação do transformador é normal, a existência de descarga parcial, arco ou possível falha térmica para bandas de temperatura específicas, conforme descrito na Figura 6. O triângulo de Duval examina a concentração no óleo dos gases (CH_4), (C_2H_4) e (C_2H_2). De acordo com essas concentrações, esse método pode identificar sete categorias de falha, como descargas parciais de acordo com sua energia (corona, DPs de baixa e alta energia), falha térmica em faixas específicas (até $300^\circ C$, entre $300^\circ C$ e $700^\circ C$ e superior a $700^\circ C$), bem como a situação combinada, incluindo falhas elétricas e térmicas. O caso do pentágono de Duval examina os principais gases

(H_2), (CH_4), (C_2H_6), (C_2H_4) e (C_2H_2), e categoriza as possíveis falhas como descargas parciais do tipo corona, gaseificação de óleo mineral, carbonização de papel por pontos quentes, superaquecimento e falhas térmicas na faixa de temperatura 300° C e 700° C, bem como falhas térmicas por temperaturas superiores a 700° C.

A composição dos gases produzidos depende do tipo de anormalidade apresentada, sendo que o diagnóstico é feito a partir da avaliação individual dos níveis de determinados gases, chamados de gases chave, da interpretação da correlação entre gases e sua evolução ao longo da utilização do transformador (BECHARA, 2010).

2.3.2 Análises Físico-Químicas em Óleos Isolantes

Os óleos minerais isolantes são utilizados em equipamentos elétricos empregados na geração, transmissão e distribuição da energia elétrica. O monitoramento e a manutenção da qualidade do óleo são essenciais para assegurar a operação confiável destes equipamentos (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 2017). A norma (NBR 7036, 2022) especifica os requisitos para o transporte, recebimento, armazenagem, montagem, instalação, comissionamento, energização e manutenção de transformadores de distribuição imersos em líquido isolante, com classe de tensão até 36,2 kV, monofásicos ou trifásicos, novos ou usados.

O guia (IEEE-C57.106, 2015) apresenta recomendações sobre testes de óleo isolante e procedimentos de avaliação, além de referências a métodos de condicionamento e recuperação de líquidos isolantes dielétricos convencionais de petróleo (minerais); os níveis em que esses métodos se tornam necessários; e as rotinas para restaurar a resistência à oxidação, quando necessário, pela adição de inibidores de oxidação. A intenção é auxiliar na avaliação do óleo mineral do equipamento e ajudar operadores a manter o óleo em condições de uso.

O óleo mineral isolante em serviço está sujeito à deterioração devido às condições de uso, podendo ficar submetido a reações de oxidação devido à presença de metais e/ou compostos metálicos, que agem como catalisadores. Como consequência podem ocorrer mudanças de cor, formação de compostos ácidos e, em um estágio avançado da oxidação, precipitação de borra, que podem prejudicar as propriedades elétricas. A deterioração de outros materiais que possam interferir no funcionamento adequado do equipamento elétrico e diminuir sua vida útil pode também ser indicada por mudanças nas propriedades do óleo (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 2017).

Diversos ensaios podem ser aplicados aos óleos minerais isolantes em equipamentos elétricos. Os ensaios relacionados na Tabela 3, classificados como grupo 1, são considerados suficientes para determinar se as condições do óleo são adequadas para operação contínua e sugerir o tipo de ação corretiva necessária, onde aplicável. Os ensaios não estão relacionados

em ordem de prioridade.

Tabela 3 – Ensaios para óleo mineral isolante

Propriedade	Grupo a	Subseção	Norma
Cor e aparência	1	5.2	ABNT NBR 14483
Densidade b	1	5.3	ABNT NBR 7148
Fator de perdas dielétricas	1	5.4	ABNT NBR 12133
Índice de neutralização (acidez)	1	5.5	ABNT NBR 14248 ABNT NBR 14448
Rigidez dielétrica	1	5.6	ABNT NBR IEC 60156
Tensão interfacial	1	5.7	ABNT NBR 6234
Teor de água	1	5.8	ABNT NBR 10710
Sedimento e borra	2	5.9	ANEXO A
Teor de inibidor c	2	5.10	ABNT NBR 12134
Bifenilas policloradas (PCB)	3	5.11	ABNT NBR 13882
Compatibilidade	3	5.12	ABNT NBR 14274
Enxofre corrosivo d	3	5.13	ABNT NBR 10505
Estabilidade à oxidação d	3	5.10	ABNT NBR 10504 ABNT NBR 15362
Partículas (contagem de partículas)	3	5.14	ISO 4407 ABNT NBR 14275
Ponto de fluidez b	3	5.15	ABNT NBR 11349
Ponto de fulgor e combustão b	3	5.16	ABNT NBR 11341
Resistividade	3	5.4	ASTM D 1169
Teor de DBDS	3	5.17	ABNT NBR 16412
Teor de passivador c	3	5.18	ABNT NBR 16270
Viscosidade cinemática b	3	5.19	ABNT NBR 10441
Análise de gases dissolvidos (AGD)	1	5.20	ABNT NBR 7070 ABNT NBR 7274
Metais	2	5.21	ASTM D 7151
Ferrografia analítica e quantitativa	2	5.22	

a O Grupo 1 possui ensaios de rotina, o Grupo 2 possui ensaios complementares e o Grupo 3 possui ensaios investigativos.
b Não essencial, mas pode ser utilizado para estabelecer identificação do tipo de óleo.
c Restrito a óleos inibidos ou passivados.
d Exigido apenas em circunstâncias especiais (ver a subseção aplicável).

Fonte: (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 2017)

- Cor e aparência

A cor de um óleo isolante é determinada pela luz transmitida e é expressa por um valor numérico baseado na comparação com uma série de padrões de cores. Não é uma propriedade crítica, mas pode ser útil para avaliação comparativa. Um número de cor que aumenta rapidamente ou muito alto pode ser uma indicação de deterioração ou contaminação do óleo.

- Densidade

A densidade é usada para identificação do tipo de óleo. Em climas frios, a densidade do óleo pode ser importante na determinação de sua adequabilidade para uso. Por exemplo, cristais de gelo formados a partir de água separada podem flutuar no óleo de alta densidade e levar à abertura de arco elétrico na fusão posterior. Não há evidência de que a densidade seja afetada pela deterioração normal do óleo.

- Fator de perdas dielétricas e resistividade

Estes parâmetros são muito sensíveis à presença de contaminantes polares solúveis, produtos de envelhecimento ou colóides no óleo. As alterações nos níveis de contaminantes podem ser monitoradas pela medição destes parâmetros mesmo quando

a contaminação for tão pequena que esteja próxima do limite da detecção química. A determinação de perdas dielétricas pode ser realizada por meio da medição do fator de potência ou do fator de dissipação. Limites aceitáveis para estes parâmetros dependem muito do tipo do equipamento. Entretanto, valores altos do fator de dissipação dielétrica ou valores baixos de resistividade, podem afetar prejudicialmente o fator de potência e/ou a resistência de isolamento do equipamento elétrico.

- Índice de neutralização

Índice de neutralização (acidez) do óleo é a medida dos componentes ácidos presentes no óleo. O índice de neutralização de um óleo usado decorre da formação de produtos da oxidação ácida. Os ácidos e outros produtos de oxidação afetarão, em conjunto com a água e contaminantes sólidos, o dielétrico e outras propriedades do óleo. Os ácidos têm um impacto na degradação dos materiais celulósicos e podem também ser responsáveis pela corrosão de peças de metal de um transformador. A taxa de aumento da acidez de um óleo em serviço é um indicador da taxa de envelhecimento do óleo.

- Rigidez dielétrica

Rigidez dielétrica é uma medida da capacidade do óleo resistir à solicitação elétrica. O óleo seco e limpo apresenta uma rigidez dielétrica inerentemente alta. Água livre e partículas sólidas, particularmente estas últimas em combinação com altos níveis de água dissolvida, tendem a migrar para regiões de alta solicitação elétrica e reduzir drasticamente a rigidez dielétrica. A medida da rigidez dielétrica, portanto, serve principalmente para indicar a presença de contaminantes, como água ou partículas. Um valor baixo de rigidez dielétrica pode indicar que um ou mais destes elementos está presente. Entretanto, uma alta rigidez dielétrica não indica necessariamente a ausência de contaminantes.

- Tensão interfacial

A tensão interfacial entre o óleo e a água é um ensaio para se detectar contaminantes polares solúveis e produtos de oxidação. Esta característica varia com rapidez durante os estágios iniciais de envelhecimento, mas tende a estabilizar quando a deterioração é ainda moderada. Uma rápida diminuição da tensão interfacial pode também ser uma indicação de problemas de compatibilidade entre o óleo e alguns materiais do transformador (vernizes, gaxetas etc.) ou de contaminação durante o enchimento com óleo. Para transformadores em sobrecarga, a deterioração dos materiais é rápida e a tensão interfacial é uma ferramenta para a detecção da deterioração.

- Teor de Água

Dependendo da quantidade de água, da temperatura do isolamento e do grau de envelhecimento do óleo, o teor de água dos óleos isolantes influenciam: na rigidez

dielétrica do óleo, no isolamento celulósico, na taxa de envelhecimento do óleo e da isolação celulósica. O teor de água no óleo e na isolação sólida tem portanto um impacto significativo na condição operativa e na vida útil do transformador. As duas principais fontes de aumento de teor de água no sistema isolante do transformador são entrada de umidade da atmosfera e degradação do isolamento celulósico. Nos equipamentos elétricos isolados a óleo mineral, a água está presente no óleo na forma dissolvida e eventualmente como um hidrato adsorvido por produtos polares de envelhecimento (água ligada) em óleos muito oxidados. Partículas, como fibras de celulose também podem reter alguma água.

Os ensaios descritos são os ensaios mínimos exigidos para monitorar o óleo e assegurar que este está adequado para serviço contínuo. De maneira complementar, alguns testes são feitos para garantir a condição do óleo para isolamento, bem como para fins de resfriamento e esses são temperatura do ponto de fulgor, temperatura do ponto de fluidez, teores de enxofre, densidade do óleo e, mais importante, viscosidade do óleo, uma vez que decide a circulação do óleo entre a estrutura do enrolamento. Alguns dos mencionados acima são descritos na Tabela 4, que é um exemplo de laudo de ensaio em óleo isolante em operação realizado por especialistas.

Tabela 4 – Análise físico-química em óleo isolante

ANÁLISES FÍSICO-QUÍMICAS	MÉTODO	NBR 10576:2017 Menor 36,2 kV	RESULT. Anterior	RESULT. Atual
Teor de água (ppm) - Medido	NBR 10710	máximo 40	13	18
Teor de água (ppm) - 20°C - Corrigido	-	-	-	-
Fator de Potência a 100°C (%)	NBR 12133	máximo 20,00	3,50	3,60
Rigidez Dielétrica - Calota (kV)	NBR IEC 60156	mínimo 40	75	75
Índice de neutralização (mgKOH/g)	NBR 14248	máximo 0,20	0,06	0,06
Tensão Interfacial (mN/m)	NBR 6234	mínimo 20,0	20,8	20,1
Cor	NBR 14483	-	2	2
Densidade Relativa 20/4°C (g/mL)	NBR 7148	-	854	853
Aspecto Visual	-	-	LÍMPIDO	LÍMPIDO

Fonte: (Próprio Autor)

Portanto, as análises físico-químicas são realizadas para avaliar alterações das propriedades do óleo isolante, os resultados são utilizados para estabelecer procedimentos de manutenção preventiva a fim de evitar falhas precoces e estender a vida útil de transformadores.

2.3.3 Testes Dedicados para Diagnóstico de Falhas Incipientes

Além dos métodos de monitoramento de condições de parâmetros ou tipos de testes mais comuns, vários testes dedicados podem ser conduzidos em transformadores para exploração detalhada de falhas incipientes e identificação dos efeitos na vida útil

dos transformadores de potência. Nesta subseção, alguns testes especiais capazes de detectar severidades de falhas são descritos. A análise dos gases dissolvidos é um método que permite a realização com o equipamento em serviço, evitando a parada para testes que a exigem, o que gera maior disponibilidade e redução de custos (MARTINS et al., 2022). Então, ao se notar algum desvio no perfil de gás analisado, o equipamento pode ser acompanhado com período de amostragem diferenciada ou com a realização de testes mais dedicados, especiais e complexos.

2.3.3.1 Metodologias Elétricas para Diagnóstico de Falhas Incipientes

- Análise Harmônica

A análise harmônica é bastante conhecida devido à influência de cargas não lineares e sua natureza auxiliar harmônica no perfil de tensão e corrente em toda a rede do sistema elétrico. Como os harmônicos (ou componentes harmônicas) causam problemas de qualidade de energia, é necessário que sejam utilizados indicadores para a quantificação e análise dos efeitos dos harmônicos (TEIXEIRA, 2009). Em relação aos transformadores, o fator K é utilizado para se calcular o aumento do aquecimento de um transformador devido à circulação de correntes harmônicas. O fator K pode ser calculado através da equação (2.1).

$$FatorK = \sum_{h=1}^{h \max} \left(\frac{I_h}{I_R} \right)^2 * h^2 \quad (2.1)$$

Em que,

I_R - Corrente nominal RMS total;

I_h - Corrente no harmônico h;

h - Ordem do harmônico.

Um outro fator também utilizado para se quantificar a diminuição do carregamento de um transformador na presença de harmônicos é o fator de perdas harmônicas, que representa o aquecimento efetivo gerado no transformador como resultado de uma determinada corrente harmônica.

- Análise de Corrente de Polarização e Despolarização

A análise de corrente de polarização e despolarização é uma metodologia de teste não destrutiva para examinar as propriedades dielétricas do isolamento do transformador. Esta metodologia pode avaliar separadamente o isolamento de papel, óleo e outras juntas de isolamento suportadas (SONI; MEHTA, 2021).

- Análise de Resistência do Enrolamento

A análise de resistência do enrolamento do transformador, a principal determinação deste teste é que toda a estrutura do enrolamento seja devidamente montada e os mínimos detalhes sejam identificados para que durante o processo de energização ou as horas de operação sejam efetivamente utilizadas (SONI; MEHTA, 2021).

- *Análise de Descargas Parciais*

As análises de descargas parciais são adequadas para diagnóstico de isolação, pois são direcionados para descargas internas ou recorrentes na isolação, não sendo considerado medições de capacitância, apresentam componentes de perda de potência contribuindo para um aumento no fator de dissipação (BISHOP et al., 1996). Detecções de descargas parciais diminuem a resistência do isolamento com o passar do tempo, levando a uma falha total, parcial ou colapso do isolamento. Assim, as medições de descargas parciais podem ser determinadas dentro de um aparelho, similar a um cabo de força ou um transformador, fornecendo ao engenheiro de isolamento as valiosas evidências sobre as áreas de maior desconformidade e deficiências na montagem (AMORIM; RODRIGUES, 2022).

2.3.3.2 *Análises de Vibração, Acústica e Termográfica*

Técnicas de análise de vibração são utilizadas para identificação de problemas em máquinas elétricas, incluindo transformadores. Dispositivos de instrumentação como acelerômetros e outros mecanismos de análise de vibração podem ser dedicados aos transformadores para detectar a vibração interna do núcleo, falhas na blindagem e partes móveis. Além disso, os analisadores de vibração ajudam a detectar e rastrear os danos mecânicos mais comuns (frouxidão, desalinhamento, desbalanceamento e outros problemas) para equipamentos sujeitos a vibração. Devido à deformação mecânica, a vibração produz ruído. (SHENGCHANG et al., 2001).

Algumas falhas internas básicas como efeito corona e arcos elétricos criam a ionização que interrompe as partículas de ar circundantes. Um dispositivo de instrumentação ultrassônico pode detectar sons de alta frequência formados por esses efeitos e os decodifica em faixas de áudio perceptíveis (BLACKBURN et al., 1998). Sons podem ser codificados e investigados por meio de software de análise espectral de ultrassom para um julgamento mais preciso (BREZAK; FILIPOVIĆ-GRČIĆ, 2017). Normalmente, os aparelhos elétricos devem ser silenciosos, no entanto, alguns aparelhos como transformadores podem criar um zumbido contínuo ou alguns ruídos mecânicos robustos, portanto, não deve ser confundido com ruídos irregulares, trepidantes, estalos e outros ruídos elétricos. Além disso, os sensores ultrassônicos também são úteis para encontrar vazamentos de ar em tanques de transformadores e disjuntores isolados a gás (ANSI/NETA-MTS, 2019).

Um dos métodos de análise de temperatura sem contato são os termovisores, são câmeras que detectam a energia infravermelha invisível e transformam esses dados em

uma imagem térmica representativa. As câmeras infravermelhas são mais frequentemente usadas para examinar, pois mesmo o aparelho funcionando no estado típico, podem existir pontos quentes (SEDIGHI et al., 2020). O teste de termografia é utilizado para verificar a temperatura da superfície de determinadas partes do transformador, principalmente o sistema de refrigeração e pontos de conexão de terminais das buchas. De acordo com os ajustes do aparelho empregado no teste, pode-se verificar quais alterações de temperatura são mais significativas em relação à temperatura de referência e se determinar um plano de ação para corrigir o problema (BECHARA, 2010).

Os métodos de diagnósticos para detecção, quantificação, localização e reconhecimento de problemas em transformadores apresentados e outros existentes, representam o que há de melhor na prática de manutenção. No entanto, alguns métodos, como a emissão acústica, por exemplo, não permitem quantificar os níveis de descargas parciais, ao passo que o método elétrico para descargas parciais dificulta a localização da fonte dos sinais internos. Sendo assim, a melhor estratégia é fazer uso do melhor método para o transformador em análise e, se possível, fazer uso de vários métodos simultaneamente. Porém, por questões operacionais, nem sempre o melhor método é de aplicação mais fácil, o que faz a etapa de seleção da metodologia a ser aplicada complexa e com várias variáveis que devem ser analisadas em cada caso.

2.4 Gestão de Transformadores e Tomada de Decisão de Manutenção


Um dos parâmetros que definem a operação e o planejamento de uma concessionária de energia elétrica é a condição de integridade dos transformadores, com base nas condições de saúde e, conseqüente vida útil remanescente dos ativos (CIGRE.GT-A2.05, 2013). Tal entendimento pode beneficiar as empresas do setor a preparar um plano financeiro adequado para estimar o custo futuro de manutenção e substituição das unidades transformadoras (ALQUDSI; EL-HAG, 2019).

As pesquisas realizadas para ajudar as empresas a reduzir seus custos de manutenção de transformadores são comumente chamadas de Transformer Asset Management (TAM), ou gerenciamento dos ativos transformadores. O (TAM), conforme (ZHANG; GOCKENBACH, 2008), define um conjunto estratégico de atividades futuras de manutenção e substituição para o ativo transformador, com base em métodos de teste de diagnóstico da condição de integridade do ativo. O objetivo final do (TAM) é garantir a confiabilidade do sistema de potência dentro de uma plataforma econômica. Conforme já apresentado, em (ABU-ELANIEN; SALAMA, 2010), são definidos os métodos de teste de diagnóstico em suas formas de duas partes, monitoramento de condição (MC) e avaliação de condição (AC). As práticas TAM são bem aproveitadas quando são compostas por

AC e informações financeiras, considerando o risco associado com base na carga que ele alimenta.

É apresentado em (MARTINS et al., 2022), como a avaliação da condição deve ser capaz de detectar uma mudança de condição que seja relativamente menos significativa do que a alteração que pode levar à falha de um transformador. A Figura 7 ilustra uma situação teórica de degradação da condição em função do tempo para um transformador.

Figura 7 – Degradação de condição teórica de um transformador.



Fonte: (MARTINS et al., 2022)

Com a identificação da alteração da condição é possível ter melhores decisões de gerenciamento desses ativos, aumentando e direcionando a realização de testes de monitoramento da condição. Além disso, as intervenções devem ser realizadas com intervalo de tempo menor que $\Delta T[XY] + \Delta T[YZ]$ de forma que a falha não ocorra. A implantação de planos de monitoramento preditivo de qualquer natureza pressupõe que é esperado detectar-se, ao longo da vida operativa dos equipamentos, defeitos incipientes que possam ser sanados a partir da realização de manutenções preventivas não sistemáticas (aperiódicas) e que o monitoramento de condição sendo praticado é econômica e tecnicamente justificável (MARTINS et al., 2022).

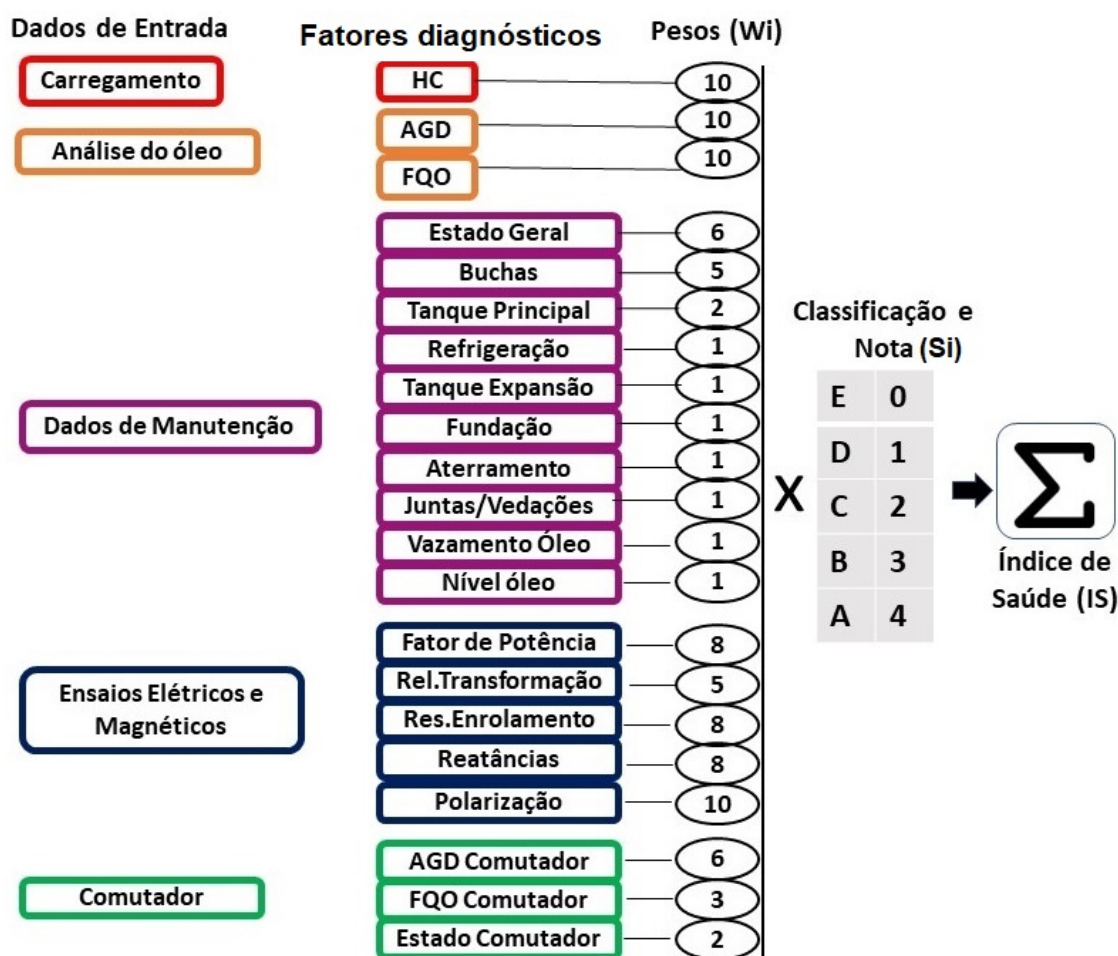
No gerenciamento de transformadores, observa-se que mais importante do que ter todos os dados de diversos parâmetros não compilados, é ter os dados necessários no tempo adequado para a tomada de decisão de gestão, para aumentar e melhor direcionar a realização de testes de monitoramento da condição, decisão esta que impacta diretamente na relação custo benefício da técnica de monitoramento. Com o advento de técnicas de inteligência artificial e outras tecnologias de computação, é cada vez mais vantajoso a aplicação desses modelos na determinação do índice de saúde. Para auxílio no gerenciamento de transformadores, diversos estudos e implementações utilizam a avaliação da condição baseada em índice de saúde para identificar alterações da condição geral de integridade dos equipamentos, conforme apresentado a seguir.

2.4.1 Avaliação de Transformadores por meio de Índice de Saúde

O Índice de Saúde é um método de avaliação de condição de transformadores que tem como base vários critérios relacionados a fatores de condição de degradação de longo prazo, que resultam cumulativamente no fim da função dos ativos operacionais. O seu resultado descreve a condição de integridade geral de um ativo, sendo uma ferramenta de gerenciamento e identificação das necessidades de investimento, como priorizar o investimento de capital e os programas de manutenção (HERNANDA et al., 2014).

O Índice de Saúde representa uma ferramenta prática que combina os resultados das observações operacionais, inspeções de campo e testes no local e em laboratório em um índice objetivo e quantitativo, fornecendo a saúde geral do ativo (JAHROMI et al., 2009), o diagrama com o processo convencional de cálculo é apresentado na Figura 8. Os resultados de índice de saúde diferem dos testes de condições que enfatizam a descoberta de defeitos e deficiências que precisam de correção ou remediação para manter o ativo em operação durante algum período.

Figura 8 – Diagrama operacional do índice de saúde convencional.



Fonte: (Silva et al., 2021)

A obtenção de registros dos fatores diagnósticos é a primeira etapa no processo de cálculo de índice de saúde, o número de fatores diagnósticos de entrada pode variar de acordo com os métodos desenvolvidos. Os três primeiros, histórico de carregamento, análise de gases dissolvidos e análise físico-químicas do óleo são os que têm maiores pesos. Para o cálculo do Índice de Saúde final, é necessário primeiro o índice de saúde para cada fator de diagnóstico considerado.

A determinação do índice de saúde utiliza um sistema de pontuação em que cada subcomponente do transformador possui uma faixa de pontuação estabelecida e recomendada por normatizações internacionais como (IEEE-C57.104, 2019), (IEEE-C57.91, 2012), e recebe pontuações de acordo com o seu estado. Cada um dos fatores diagnósticos possui um fator de ponderação/peso, (W_i), de acordo com sua importância na probabilidade de o transformador apresentar falha ou não. Assim, de acordo com o resultado da análise realizada para cada um dos fatores diagnósticos, o critério é classificado em cinco faixas (A, B, C, D ou E) e sua pontuação correspondente (4, 3, 2, 1, 0), (S_i), é multiplicada pelo seu respectivo peso. Os resultados são somados e divididos pela soma dos pesos (W_i), conforme a equação (2.2).

$$IS_{FD} = \frac{\sum_{i=1}^n S_i * W_i}{\sum_{i=1}^n W_i} \quad (2.2)$$

(IS_{FD}) é o índice de saúde para cada fator de diagnóstico e o número de fatores diagnósticos usados é expresso por (n). Neste trabalho, os fatores considerados para determinação do índice de saúde são as análises de gases dissolvidos e físico-químicas do óleo, seus procedimentos de cálculo são descritos a seguir.

Para obtenção do índice de saúde de fator análise de gases dissolvidos, os resultados dos testes de gases são pontuados, de acordo com a concentração encontrados (em ppm), como ilustrado na Tabela 5.

Tabela 5 – Fatores de pontuação e pesos para níveis de gás.

Gás	Si						Wi
	1	2	3	4	5	6	
H ₂	<=100	100-200	200-300	300-500	500-700	>=700	2
CH ₄	<=75	75-125	125-200	200-400	400-600	>=600	3
C ₂ H ₆	<=65	65-80	80-100	100-120	120-150	>=150	3
C ₂ H ₄	<=50	50-80	80-100	100-150	150-200	>=200	3
C ₂ H ₂	<=3	3-7	7-35	35-50	50-80	>=80	5
CO	<=350	350-700	700-900	900-1100	1100-1400	>=1400	1
CO ₂	<=2500	<=3000	<=4000	<=5000	<=7000	>=7000	1

Fonte: (CHITNAVIS; BHASME, 2017).

Sendo C₂H₂ o gás de maior importância com peso (Wi)=5, seguido por CH₄, C₂H₆ e C₂H₄ com peso (Wi)=3, H₂ com peso (Wi)=2 e os demais com peso (Wi)=1. O índice

de saúde de fator análise de gases dissolvidos (AGD) é calculado pela equação (2.3), tendo como base os fatores de pontuação e pesos para níveis de gás da Tabela 5.

$$IS_{AGD} = \frac{\sum_{i=1}^7 Si * Wi}{\sum_{i=1}^7 Wi} \quad (2.3)$$

A avaliação de transformadores, e sua nota, de acordo com a avaliação de índice de saúde de fator análise de gases dissolvidos é mostrada na Tabela 6.

Tabela 6 – Avaliação de transformadores com base no fator AGD.

Nota	Condição	Fator AGD
4	Bom	AGD < 1,2
3	Aceitável	1,2 <= AGD < 1,5
2	Atenção	1,5 <= AGD < 2
1	Ruim	2 <= AGD < 3
0	Muito Ruim	AGD >= 3

Fonte: (CHITNAVIS; BHASME, 2017).

A análise do fator de qualidade do óleo isolante emprega ensaios físico-químicos de amostras do óleo isolante para realizar a avaliação dos elementos presentes. Os parâmetros, valores limite e os fatores de peso são recomendados pelo (IEEE-C57.106, 2015), (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 2017) e IEC 60505 para o uso continuado de óleo isolante. Tendo para cada parâmetro as pontuações e pesos apresentados na Tabela 7.

Tabela 7 – Fatores de pontuação e pesos para parâmetros de teste de óleo.

Parâmetros	T <= 69 kV	69 kV < T < 230 kV	230 kV <= T	Si	Wi
Rigidez Dielétrica (kV) (2 mm gap)	> 45	>= 52	>= 60	1	3
	35-45	45-52	50-60	2	
	30-35	35-45	40-50	3	
	<=30	<=35	<=40	4	
Tensão Interfacial (dyne/cm)	>=25	>=45	>=45	1	2
	20-25	35-45	35-45	2	
	15-20	30-35	30-35	3	
	<=15	<=30	<=30	4	
Acidez (mg KOH/g oil)	<=0.05	<=0.04	<=0.03	1	1
	0.05-0.1	0.04-1.0	0.03-0.07	2	
	0.1-0.2	1.0-0.15	0.07-0.10	3	
	>=0.2	>=0.15	>=0.10	4	
Fator de Dissipação (Em 90°)		<0.1		1	3
		0.1-0.5		2	
		0.5-1.0		3	
		>=1.0		4	
Cor		<=1.5		1	2
		1.5-2.0		2	
		2.0-2.5		3	
		>=2.5		4	
Teor de Água (ppm)		<=20		1	4
		20-30		2	
		30-40		3	
		>40		4	

Fonte: (CHITNAVIS; BHASME, 2017).

O índice de fator FQO pode ser determinado por meio da equação (2.4) e sua nota final é obtida de acordo com os fatores de pontuação e pesos para parâmetros de teste de óleo da Tabela 7. A avaliação de transformadores com base no fator AQO é feita conforme as classificações da Tabela 8.

$$IS_{FQO} = \frac{\sum_{i=1}^6 Si * Wi}{\sum_{i=1}^6 Wi} \quad (2.4)$$

Tabela 8 – Avaliação de transformadores com base no fator AQO.

Nota	Condição	Fator AQO
4	Bom	AQO < 1,5
3	Aceitável	1,5 ≤ AQO < 2
2	Atenção	2 ≤ AQO < 3
1	Ruim	3 ≤ AQO < 3,5
0	Muito Ruim	3,5 ≤ AQO ≤ 4

Fonte: (CHITNAVIS; BHASME, 2017).

Com os valores obtidos para cada fator diagnóstico calcula-se o Índice de Saúde (IS) final, que é o fator de multiplicação entre o fator de índice de saúde HIFj e a ponderação de cada parâmetro Kj, dividido pela pontuação máxima e multiplicado por 100, conforme a equação (2.5). Para determinar HIFj, o valor dos resultados da avaliação de cada parâmetro A, B, C, D, E serão convertidos em números de 4 a 0. O valor de A significa 4, B significa 3, C significa 2, D significa 1 e E significa 0. Os detalhes de HIFj e Kj para cada parâmetro são mostrados na Tabela 9.

Tabela 9 – Pontuação do índice de saúde.

Nº	Condição do Transformador/ Parâmetro/ Fator	Peso (Kj)	Avaliação da condição	Pontuação(HIFj)
1	DGA	10	A,B,C,D,E	4,3,2,1,0
2	Histórico de carregamento	10	A,B,C,D,E	4,3,2,1,0
3	Fator de potência	10	A,B,C,D,E	4,3,2,1,0
4	Qualidade do óleo	8	A,B,C,D,E	4,3,2,1,0
5	Condição Transformador	6	A,B,C,D,E	4,3,2,1,0
6	Casquilho	5	A,B,C,D,E	4,3,2,1,0
7	Corrosão do Tanque Principal	2	A,B,C,D,E	4,3,2,1,0
8	Equipamento de refrigeração	2	A,B,C,D,E	4,3,2,1,0
9	Corrosão do tanque de óleo	1	A,B,C,D,E	4,3,2,1,1
10	Fundação	1	A,B,C,D,E	4,3,2,1,2
11	Aterramento	1	A,B,C,D,E	4,3,2,1,3
12	Juntas e vedações	1	A,B,C,D,E	4,3,2,1,4
13	Conectores	1	A,B,C,D,E	4,3,2,1,5
14	Vazamentos de óleo	1	A,B,C,D,E	4,3,2,1,6
15	Nível de óleo	1	A,B,C,D,E	4,3,2,1,7
16	Relação de Voltas	5	A,B,C,D,E	4,3,2,1,8
17	Resistência do Enrolamento	8	A,B,C,D,E	4,3,2,1,9
18	Reatância de Vazamento	8	A,B,C,D,E	4,3,2,1,10
19	Índice de polarização	10	A,B,C,D,E	4,3,2,1,11
20	DGA do LTC	6	A,B,C,D,E	4,3,2,1,12
21	Qualidade do óleo LTC	3	A,B,C,D,E	4,3,2,1,13
22	LTC geral	2	A,B,C,D,E	4,3,2,1,14

Fonte: (CHITNAVIS; BHASME, 2017).

$$IS_{final} = \frac{\sum_{j=1}^n K_j \times HIF_j}{\sum_{j=1}^n 4K_j} \times 100\% \tag{2.5}$$

O índice de integridade geral é normalizado para um critério de condição máximo 100 e 0 para o menor número de critério de condição, onde < 40% representa a condição de integridade “boa” de um transformador de potência e 100% indica condição de integridade “ruim” de um transformador de potência.

A saída do índice de saúde (IS) pode atuar como a entrada principal para a tomada de decisões de manutenção. A Tabela 10 fornece categorias de resultados de (IS) que correlacionam o nível de condição do transformador e a ação de manutenção necessária.

Tabela 10 – Critérios de índice de saúde para ações de manutenção de transformadores

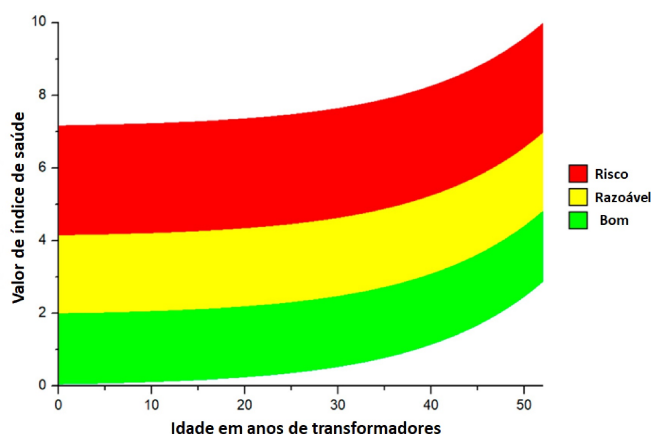
Índice de Saúde	Condição	Ações de Manutenção
0-40	Bom	Inspeção
40-80	Razoável	Conserto e reforma
80-100	Ruim	Substituição

Fonte: (MURUGAN; RAMASAMY, 2019).

Portanto, as porcentagens de (IS) são divididas em faixas, indicando a condição do transformador como boa, razoável ou ruim. Posteriormente, três etapas de tarefas de manutenção são sugeridas para transformadores de potência em relação a cada classe de nível de condição.

O índice de saúde também pode ser correlacionado com a idade do transformador, mas segundo (BOHATYREWICZ; PŁOWUCHA; SUBOCZ, 2019), a idade baixa não significa necessariamente boa condição, transformadores mais novos podem ter defeitos em desenvolvimento e não podem ser negligenciados na avaliação.

Figura 9 – Critérios para avaliar a condição técnica em função do valor HI e idade.



Fonte: (BOHATYREWICZ; PŁOWUCHA; SUBOCZ, 2019).

Outro ponto diz respeito aos transformadores que ultrapassaram o tempo de operação esperado. Alguns deles, ainda em estado técnico relativamente bom considerando sua idade, podem ser erroneamente classificados como arriscados no contexto de operação posterior e podem ser colocados fora de serviço, conforme representado na Figura 9.

2.4.2 Evolução dos Métodos de Índice de Saúde

As metodologias para determinar o índice de saúde de transformadores mudam de acordo com os parâmetros considerados e a própria técnica de cálculo do índice. Os parâmetros considerados devem ter boa representação sobre a condição de integridade do equipamento, além disso, os seus registros devem ter confiabilidade (JÜRGENSEN; GODIN; HILBER, 2017). A inclusão de dados sem confiabilidade pode levar a conclusões errôneas sobre a real situação que se encontra o transformador, prejudicando o julgamento por parte dos gestores. A quantidade de parâmetros de entrada também pode variar dentre os métodos existentes (OLIVEIRA, 2021). De acordo com (Jürgensen, Godin e Hilber, 2017), os dados já disponíveis devem ser considerados primeiro, e apenas se viável economicamente, medições complementares devem ser realizadas.

Em (BOHATYREWICZ; PŁOWUCHA; SUBOCZ, 2019), um método de cálculo do índice de saúde que visa melhorar a eficácia geral da avaliação é apresentado. O algoritmo proposto é baseado em diagnósticos de óleo conduzidos regularmente e dados de manutenção facilmente disponíveis para permitir a estimativa e atualização do estado de saúde do dispositivo em intervalos curtos do ponto de vista operacional. Este método foi comparado a outro algoritmo de índice de saúde construído a partir dos mesmos parâmetros, mas com pesos diferentes e uma filosofia alternativa de avaliação de resultados. Os dois métodos de cálculo do índice de saúde foram testados em uma população de 96 transformadores de potência e, em seguida, comparados com os resultados obtidos com um sistema especialista, que se baseia em testes de diagnóstico muito mais avançados para determinar a condição técnica da unidade. Os resultados do experimento mostram que a seleção adequada de fatores de ponderação dos parâmetros de condição técnica do transformador durante o cálculo do índice de integridade pode ajudar a simplificar sua avaliação, mantendo uma precisão satisfatória em comparação com um método especializado altamente avançado.

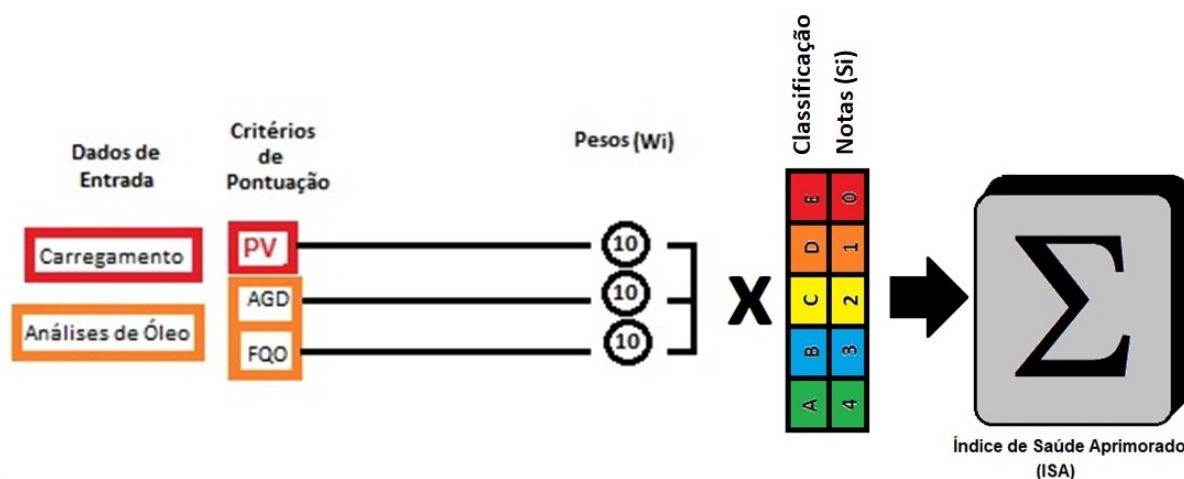
Assim sendo, (ABU-ELANIEN; SALAMA; IBRAHIM, 2012) apresenta um método para calcular um índice de saúde para transformadores (para tensão operacional de 69 kV ou menos) com base na análise de compostos furânicos em óleo, análise de gás dissolvido e outros resultados de análise físico-química do óleo como meio de calcular o índice de saúde, usando a teoria da *lógica fuzzy*. Nesta abordagem, dados reais de operação de 90 transformadores foram usados para testar o método proposto. Os resultados foram comparados com os resultados calculados para o mesmo conjunto de transformadores por uma empresa experiente de consultoria em gerenciamento de ativos e avaliação de saúde.

A comparação mostra que os resultados são confiáveis.

Uma metodologia de diagnóstico aprimorada para estimar a saúde de transformadores de potência, considerando a combinação de dois conceitos-chave foi desenvolvida por (Silva et al., 2021). A primeira foca em estabelecer um novo critério para diagnosticar a isolação sólida do transformador, considerando sua deterioração de acordo com sua carga diária, se basea em normas internacionais e pode estimar a degradação da isolação do transformador em serviço. A segunda propõe a redução do número de fatores de diagnóstico utilizados para obter o índice de saúde, utilizando apenas as análises de óleo (DGA, Fator de Qualidade do Óleo (OQF)) e as curvas de carga diária, em PU, para cada transformador, permitindo a investigação da saúde sem a necessidade de desligar o transformador e, conseqüentemente, tornando o processo mais simples, menos oneroso, minimizando o ciclo para obter o índice de saúde e permitindo realizar a gestão do ativo de forma regular.

A Figura 10 mostra a redução do número de fatores de diagnóstico utilizados para obter o índice de saúde, utilizando apenas as análises de óleo (DGA, Fator de Qualidade do Óleo (OQF)) e as curvas de carga diária, em PU, para cada transformador.

Figura 10 – Diagrama com número de fatores de diagnóstico reduzido.



Fonte: (Silva et al., 2021).

A proposta oferece duas vantagens quando comparado ao padrão HI padrão: A primeira é no que diz respeito à possibilidade de reduzir o tempo necessário para a obtenção de resultados de avaliações consecutivas, pois os fatores diagnósticos utilizados são de fácil obtenção e baixo custo, permitindo um monitoramento mais frequente, robusto e eficaz; A segunda é na melhora de eficiência dos resultados do índice, pois a metodologia proposta permite observar a degradação da isolação sólida do transformador (perda de vida útil) em serviço.

Estratégias de aprendizado de máquina (AM) são propostas em (ALQUDSI; EL-HAG, 2019) para a previsão da condição geral de integridade do isolamento de transformadores de distribuição de média tensão, com base em seus resultados de teste de óleo. Para validar a abordagem apresentada, os algoritmos de AM foram testados em dois bancos de dados de mais de 1.000 amostras de óleos de transformadores de média tensão com classificações na ordem de dezenas de (MVA). Os resultados do teste de óleo foram adquiridos de transformadores em serviço (durante o período de amostragem de óleo) de duas empresas de serviços públicos diferentes na região do golfo. O procedimento ilustrado visa simular um cenário realista de como a concessionária se beneficiaria do uso de diferentes ferramentas de AM para entender o índice de integridade do isolamento de seus transformadores. Em uma primeira etapa, três diferentes cenários de treinamento e teste de dados foram usados com várias ferramentas de reconhecimento de padrões para classificar a condição de integridade do transformador, com base no conjunto completo de recursos de teste de entrada. Na segunda etapa, as mesmas ferramentas de reconhecimento de padrões foram usadas com três cenários de treinamento/teste para um número reduzido de recursos de teste. Além disso, um modelo reduzido desenvolvido anteriormente foi a base para reduzir o número necessário de testes para cálculos do índice de saúde do transformador. Verificou-se que a redução do número de testes não influenciou na precisão dos modelos de previsão de AM, o que é considerado uma vantagem significativa em termos de redução de custos de gerenciamento de ativos de transformadores.

Uma Rede Neural de Regressão Geral (GRNN) com propriedade não linear e que pode trabalhar com medições sem quantização foi avaliada por (ISLAM; LEE; HETTIWATTE, 2017). O GRNN permite que medições multidimensionais sejam combinadas por meio de um sistema de ponderação e pontuação ideal para calcular um índice quantitativo de integridade dos transformadores de potência. A ponderação de cada teste foi atribuída com base em uma função contínua interpolada suavemente. A eficácia do modelo foi validada contra classificações de especialistas e conjuntos de dados publicados na literatura.

Em (JAISWAL; BALLAL; TUTAKNE, 2017), uma Rede Neural Artificial (RNA) de quatro camadas é utilizada para avaliar o estado de saúde do transformador de distribuição. A RNA inclui uma camada de entrada, uma camada de saída e duas camadas ocultas. Os dados de 84 diferentes padrões de transformadores de distribuição foram coletados para treinar uma rede neural artificial. Os resultados dos testes experimentais da RNA proposta são 97,62% compatíveis com os resultados fornecidos pela concessionária. Em (ABU-ELANIEN; SALAMA; IBRAHIM, 2011), uma abordagem de RNA foi feita para classificar a condição do transformador com base no valor HI previsto. O modelo foi uma RNA feed-forward com duas camadas ocultas (quatro e dois neurônios, respectivamente) que foi treinada em medições reais de 59 transformadores em funcionamento. Com base nos resultados do teste, 97% das amostras de teste foram classificadas corretamente com

base em um problema de condição de três classes. Pode-se observar que a RNA pode fornecer um resultado confiável, mas este método requer muitos dados, principalmente para arquiteturas com muitas camadas. A mesma abordagem também foi aplicada em outros trabalhos relacionados (LEAL et al., 2009), (FARAG; MOHANDÉS; AL-SHAIKH, 2001).

Em (TRAN et al., 2020b) é apresentado um método online de monitoramento da integridade dos transformadores do serviço de distribuição usando dados de um sistema de aquisição e análise de dados em tempo real localizado no transformador. Os resultados podem ser fornecidos aos operadores de serviços públicos quase em tempo real, permitindo que eles avaliem o status do transformador de distribuição e tomem medidas para evitar ou mitigar falhas dispendiosas de transformadores e interrupções de serviço. Após uma análise minuciosa das possíveis técnicas de monitoramento não invasivas, a temperatura máxima do óleo, a vibração, a carga do transformador e o fator de potência foram escolhidos como parâmetros monitorados, e o índice de integridade geral é determinado usando lógica difusa. Um estudo de caso é implementado em um transformador de distribuição específico para mostrar as vantagens do método proposto.

Em (DENG et al., 2015), os autores partem do fato de que a concentração de gases é afetada por muitos fatores e consideram um modelo de previsão construído pela seleção razoável dos maiores fatores de correlação para ajudar a melhorar a precisão da previsão de gases. O algoritmo de florestas aleatórias é usado para prever as tendências de gás e a avaliação do desempenho da previsão é realizada por índices de avaliação apropriados. Em comparação com a previsão da máquina de vetores de suporte, é comprovada a vantagem do método de florestas aleatórias para a previsão de gás dissolvido em óleo de transformador de potência.

Seguindo com propostas de modelos de aprendizado de máquina para prever a concentração de gases dissolvidos e avaliar a condição de saúde de transformadores. A abordagem proposta por (MAHRUKH; LIAN; BIN, 2020) usou o algoritmo de aprendizado de máquina para detectar a falha inceptiva do transformador precocemente, usando o modelo *Long Short-term Memory* (LSTM) de série temporal e o algoritmo *Random Forest*. A abordagem usa dados online em tempo real que são adquiridos de um sistema de monitoramento online de análise de gás dissolvido (DGA). Os dados são pré-processados para obter variáveis altamente correlacionadas usando correlação estatística e saída quadrada de regressão. O modelo de série temporal de floresta aleatória e o modelo LSTM usado para treinar o modelo, ambas as técnicas funcionam de forma eficaz durante o teste. Por fim, foi feita a comparação dos dois métodos, os resultados indicam que o método *Random Forest* consegue uma melhor previsão do teor de gases dissolvidos no transformador de potência para evitar falhas de isolamento.

2.5 Considerações Finais do Capítulo

Este capítulo apresentou os principais componentes de transformadores e as principais causas de falhas, abordando métodos de testes de diagnóstico para o monitoramento da condição de diversos parâmetros de operação e métodos para avaliação geral da integridade com destaque para modelos de HI.

Considerando as questões discutidas, muitas das técnicas propostas demandam monitoramento de vários parâmetros para sua composição, não se adequando a realidade dos transformadores de distribuição. Outras utilizam-se de métodos de cálculos que não possuem capacidades avançadas para combinação dos fatores, o que pode ser melhorado com técnicas de aprendizado de máquina. A inserção das opiniões de especialistas de maneira qualitativa também se demonstra como carência dos métodos propostos. Dessa forma, a elaboração de uma metodologia de HI considerando os parâmetros de monitoramento disponíveis, com o apoio de técnicas mais avançadas de combinação dos fatores, pode fornecer, aos gestores e operadores, uma ferramenta de auxílio a tomada de decisão, adaptada a sua realidade.

3 Modelos de Regressão para Predição de Índice de Saúde de Transformadores

Este capítulo se dedica a fundamentação teórica dos algoritmos de aprendizado de máquina (AM) supervisionados aplicados nesta proposta, que são os algoritmos regressores baseados em modelos múltiplos, denominados Random Forest (RF), Categorical Boosting (CatBoost) e Light Gradient Boosted Machine (LightGBM). Apresenta as principais etapas para resolver problemas usando técnicas de aprendizado de máquina e descreve as métricas mais empregadas na avaliação de modelos de regressão.

3.1 Aprendizado de Máquina

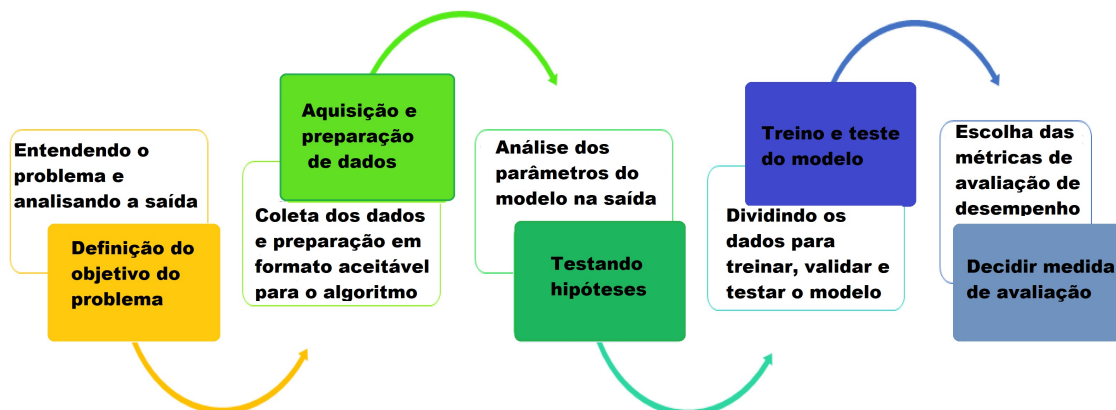
Aprendizado de máquina é a ciência (e a arte) de programar computadores para que eles possam aprender com os dados (Aurélien Géron, 2019). Um programa aprende a partir da experiência E , em relação a uma classe de tarefas T , com medida de desempenho P , se seu desempenho em T , medido por P , melhora com E (Mitchell, 1997). Algoritmos de aprendizado de máquina têm sido amplamente utilizados em diversas tarefas, que podem ser divididas em preditivas e descritivas. Em tarefas preditivas, algoritmos de aprendizado de máquina são aplicados a conjuntos de dados de treinamento rotulados para induzir um modelo preditivo capaz de prever, para um novo objeto representado pelos valores de seus atributos preditivos, o valor de seu atributo alvo. Modelos preditivos podem ser utilizados, por exemplo, para, a partir de seus sintomas, prever o estado de saúde de um paciente. Nessas tarefas, em geral são utilizados algoritmos de aprendizado que seguem o paradigma de aprendizado supervisionado (FACELI et al., 2021). O termo supervisionado vem da simulação da presença de um 'supervisor externo', que conhece, por exemplo, o verdadeiro diagnóstico do novo paciente. Essa informação é usada para guiar o processo de aprendizado na extração de um modelo com boa capacidade preditiva.

Em tarefas de descrição, ao invés de prever um valor, algoritmos de aprendizado de máquina extraem padrões dos valores preditivos de um conjunto de dados. Como não fazem uso do conhecimento do 'supervisor externo', esses algoritmos usam o paradigma de aprendizado não supervisionado. As tarefas preditivas se distinguem pelo valor de rótulo a ser predito: número discreto ou categórico, no caso de tarefas de classificação; e números contínuos, no caso de tarefas de regressão (FACELI et al., 2021).

Para resolver problemas usando aprendizado de máquina, de maneira geral, são

realizadas etapas típicas, a Figura 11 ilustra o fluxo de trabalho generalizado das etapas que devem ser seguidas para alcançar a solução desejada (VAISH et al., 2021).

Figura 11 – O fluxo de trabalho generalizado para resolver problemas usando AM.



Fonte: (VAISH et al., 2021)

Na primeira etapa, é preciso ter uma visão geral do sistema considerado no problema (Tewari e Dwivedi, 2019a). É importante o apoio de um especialista do domínio, pois é com o conhecimento a respeito do problema que é possível identificar significados para os conjuntos de dados e possíveis relações entre eles. Além disso, formas de visualizar os dados obtidos são de grande ajuda por fornecer ao especialista do domínio uma maneira fácil e intuitiva de observar os resultados do agrupamento. O conhecimento do especialista no domínio dos dados pode ser considerado nas várias etapas.

Em muitos dos casos, é aconselhável a consulta ao especialista nos dados para se utilizar a solução mais adequada. O especialista no domínio pode decidir também que um subconjunto dos objetos deve ser utilizado para suas análises.

Na segunda etapa são consideradas as operações de aquisição e pré-processamento realizadas no conjunto de dados antes de ser utilizado pelos algoritmos de aprendizado de máquina propostos. Essas operações abrangem o uso de técnicas de amostragem, tratamentos para dados desbalanceados, modificações para adequação dos tipos de atributo, limpeza dos dados, integração de dados, transformações dos dados e redução de dimensionalidade. Técnicas de pré-processamento de dados são frequentemente utilizadas para melhorar a qualidade dos dados por meio da eliminação ou minimização dos problemas existentes em dados não processados ou não tratados depois de sua coleta. (FACELI et al., 2021). Tarefas de pré-processamento realizadas no conjunto de dados podem ser:

- Integração de dados;
- Eliminação manual de atributos;
- Amostragem de dados;

- Redução de dimensionalidade;
- Limpeza de dados;
- Balanceamento de dados;
- Transformação de dados;
- Criação de novos dados a partir dos existentes.

Não existe ordem fixa para aplicação das diferentes técnicas de pré-processamento e podem ser aplicadas de forma diferente para modelos.

Quanto mais dados utilizados em algoritmos de aprendizado de máquina, maior tende a ser a acurácia do modelo e menor a eficiência computacional do processo indutivo, pois um número muito grande de objetos pode tornar o tempo de processamento muito longo. Para se obter um bom compromisso entre eficiência e acurácia, geralmente trabalha-se com uma amostra, subconjunto dos dados ou são aplicadas estratégias de aumento de dados. Neste trabalho, foram realizadas a integração de conjuntos de dados, a criação de dados sintéticos e criação de atributos para ajudar na acurácia dos modelos, não foi necessário fazer redução de dimensionalidade, ou seja, a redução do número de atributos.

Conjuntos de dados podem apresentar má qualidade, como ruídos, dados inconsistentes (que não combinam ou contradizem valores de outros atributos do mesmo objeto), redundantes (quando dois ou mais objetos têm os mesmos valores para todos os atributos, quando dois ou mais atributos têm os mesmos valores para todos os objetos), ou incompletos (com ausência de valores para alguns dos atributos em parte dos dados). A forma mais comum de inconsistência é quando há amostras representadas por atributos com todos os valores iguais, mas com classes diferentes. A redundância é dada pela repetição de linhas na base de dados.

Várias técnicas de aprendizado de máquina são limitadas à manipulação de valores de determinados tipos, por exemplo, apenas valores numéricos ou apenas valores simbólicos. E por isso pode ser necessário realizar transformações nos dados, como conversão simbólico-numérico, conversão numérico-simbólico, transformação de atributos numéricos. Uma transformação muito utilizada é a normalização de dados. A normalização de dados é recomendável quando os limites de valores de atributos distintos são muito diferentes, para evitar que um atributo predomine sobre outro (a menos que isso seja importante). Quando recomendada, ela é aplicada a cada atributo individualmente e pode ocorrer de duas formas: Por amplitude e por distribuição.

A normalização por amplitude pode ser por reescala ou padronização. A primeira define uma nova escala de valores, limites mínimo e máximo, para todos os atributos. A segunda define um valor central e um valor de espalhamento comuns para todos os

atributos. Na normalização por reescala, também chamada normalização min-max, são inicialmente definidos os valores mínimo (min) e máximo (max) para os novos valores de cada atributo. Depois, as operações a seguir são realizadas para cada atributo. Primeiro, o menor valor do atributo (menor) é subtraído de cada valor. Cada valor resultante é em seguida dividido pela diferença entre o maior e o menor valores originais do atributo, (maior – menor). Cada novo valor é depois multiplicado pela diferença entre os valores limites da nova escala, max – min. No final, o valor min é somado a cada valor produzido. Essas operações são representadas pela Equação (3.1). Para que os limites superior e inferior sejam 1 e 0, respectivamente, basta fazer max = 1 e min = 0.

$$V_{novo} = min + \frac{V_{atual} - menor}{maior - menor} * (max - min) \quad (3.1)$$

Para a normalização por padronização, a cada valor do atributo a ser normalizado é adicionada ou subtraída uma medida de localização e o valor resultante é em seguida multiplicado ou dividido por uma medida de escala. Com isso, diferentes atributos podem ter limites inferiores e superiores distintos, mas terão os mesmos valores para as medidas de escala e espalhamento. Se as medidas de localização e de escala forem a média (μ) e a variância (σ), respectivamente, os valores de um atributo são convertidos para um novo conjunto de valores com média 0 e um desvio padrão igual a 1, que é obtido se for utilizada a Equação (3.2) nos valores originais dos atributos.

$$V_{Novo} = \frac{V_{Atual} - \mu}{\sigma} \quad (3.2)$$

A normalização por distribuição muda a escala de valores de um atributo. Um exemplo dessa normalização é a aplicação da função para ordenar os valores do atributo a ser normalizado e a substituição de cada valor pela posição que ele ocupa no ranking (por exemplo, a aplicação dessa normalização aos valores 1, 5, 9 e 3 gera, respectivamente, os valores 1, 3, 4 e 2). Se todos os valores originais forem distintos, o resultado é uma distribuição uniforme.

Dados multivariados permitem ainda análises da relação entre dois ou mais atributos. Por exemplo, para atributos quantitativos, o espalhamento de um conjunto de dados é mais bem capturado por uma matriz de covariância, em que cada elemento é a covariância entre dois atributos. A covariância entre dois atributos mede o grau com que os atributos variam juntos, seu valor depende da magnitude dos atributos, ou seja, a medida de covariância é afetada pela escala de variação de valores dos atributos avaliados. O resultado com valor próximo de 0 indica que os atributos não têm um relacionamento linear, um valor positivo indica que os atributos são diretamente relacionados. Quando o valor de um dos atributos aumenta, o do outro também aumenta. O contrário ocorre se a covariância for negativa.

A medida de covariância é afetada pela escala de variação de valores dos atributos avaliados. Assim, dois atributos com variação de valores elevada (por exemplo, na escala dos milhares) podem apresentar um valor de covariância maior que dois atributos mais semelhantes entre si, mas de menor variação de valores (por exemplo, na escala entre 0 e 1). Por isso, não é possível avaliar o relacionamento entre dois atributos observando apenas a covariância entre eles. A medida de correlação elimina esse problema retirando a influência da variação dos valores. Como resultado, ela apresenta uma indicação mais clara da força da relação linear entre dois atributos. Por isso, a correlação é mais utilizada para explorar dados multivariados que a covariância (FACELI et al., 2021). A matriz de correlação apresenta a correlação entre cada possível par de atributos de um conjunto de dados.

Na terceira etapa, para um melhor desempenho dos modelos implementados, são realizadas análises dos seus hiperparâmetros. Os hiperparâmetros são significativos, pois regulam diretamente o comportamento do algoritmo de treinamento e têm um grande impacto no desempenho do modelo (NAGARAJ et al., 2022). No entanto, surge o desafio de identificar qual é o conjunto ideal de hiperparâmetros a ser usado. A tentativa de determinação pode ser manualmente, mas leva mais tempo para desenvolver vários modelos. Como resultado, a abordagem de busca em grade (do inglês Grid Search) foi desenvolvida.

O objetivo da abordagem de busca em grade de hiperparâmetros é descobrir as melhores configurações de hiperparâmetros para que o modelo possa fazer previsões otimizadas. A busca em grade obtém todos os hiperparâmetros especificados e diferentes combinações de seus valores para calcular o desempenho. Cada combinação é investigada e os melhores valores dos hiperparâmetros são escolhidos (NAGARAJ et al., 2022).

Na quarta etapa, são realizadas as divisões dos dados, que podem ser em dois conjuntos: o conjunto de treinamento e o conjunto de teste (GERON, 2019). Como esses nomes indicam, o modelo é treinado usando o conjunto de treinamento e o teste é feito usando o conjunto de teste. A taxa de erro em novos casos é chamada de erro de generalização (ou erro fora da amostra) e, ao avaliar o modelo no conjunto de teste, obtém-se uma estimativa desse erro. Esse valor informa o desempenho do modelo em instâncias que nunca viu antes. Se o erro de treinamento for baixo (ou seja, o modelo comete poucos erros no conjunto de treinamento), mas o erro de generalização for alto, isso significa que seu modelo está superajustando os dados de treinamento.

É comum usar 80% dos dados para treinamento e manter 20% para teste. No entanto, isso depende do tamanho do conjunto de dados: se ele contiver 10 milhões de instâncias, manter 1% significa que seu conjunto de teste conterà 100.000 instâncias, provavelmente mais do que o suficiente para obter uma boa estimativa do erro de generalização (GERON, 2019).

A quinta e última etapa trata das métricas de avaliação de desempenho dos

modelos. A avaliação de um algoritmo de aprendizado de máquina pode ser realizada segundo diferentes aspectos, tais como acurácia do modelo gerado, compreensibilidade do conhecimento extraído, tempo de aprendizado, requisitos de armazenamento do modelo, entre outros (FACELI et al., 2021). Considerando que os modelos tratados nessa proposta de mestrado são preditivos, a discussão será concentrada em medidas relacionadas com o desempenho obtido nas predições realizadas por modelos preditivos e com abordagem de regressão.

3.2 Regressores Baseados em Modelos Múltiplos

O termo modelos múltiplos é utilizado para identificar um conjunto de preditores cujas decisões individuais são combinadas ou agregadas de alguma forma para predizer o rótulo de novos exemplos (Dietterich, 1997). A combinação de múltiplos modelos de árvores em comitês (*ensembles*) tem se mostrado competitiva e é uma abordagem frequentemente empregada para aumentar o desempenho preditivo de modelos (FACELI et al., 2021).

O Ensemble usa basicamente dois métodos (NAGARAJ et al., 2022):

- Bagging

Cria um novo subconjunto de treinamento usando os dados de treinamento alterados e fundamenta o resultado final em uma votação majoritária.

Exemplo: Random Forest.

- Boosting

Constrói modelos sequenciais que conectam alunos fracos a alunos fortes para uma precisão ideal no modelo final.

Exemplo: ADA Boost, XG Boost.


Nesta pesquisa, os regressores baseados em modelos múltiplos denominados Random Forest (RF), Categorical Boosting (CatBoost) e Light Gradient Boosted Machine (LightGBM) são aplicados para comparação de seus desempenhos.

3.2.1 Random Forest (RF)

Algoritmos Random Forest (RF) consistem em uma coordenação de preditores de árvores de decisão, então pode ser classificado como um preditor *ensemble* (CUTLER; CUTLER; STEVENS, 2012). Cada árvore é construída independentemente usando uma subamostra diferente dos dados. A floresta aleatória é um método de aprendizado de conjunto pela implementação de agregação de *bootstrap*. Ele gera um conjunto de dados de treinamento separando aleatoriamente N , enquanto N é o tamanho do conjunto de

treinamento original. Ele é usado para construir árvores individuais para cada recurso ou recursos combinados com o objetivo de mitigar problemas de alta variância e alto viés dos resultados finais da previsão, reduzindo uma correlação entre as árvores levando a uma saída cumulativa de árvores de decisão, conforme mostrado na Figura 12. Em contraste com os modelos lineares, o modelo RF é capaz de lidar com interações não lineares entre características e alvos. (LIAW; WIENER, 2002).

Figura 12 – Regressão Random Forest.



Fonte: (LIAW; WIENER, 2002)

Florestas aleatórias são uma combinação de preditores de árvores, de modo que cada árvore depende dos valores de um vetor aleatório amostrado independentemente e com a mesma distribuição para todas as árvores da floresta. O erro de generalização para florestas converge até um limite à medida que o número de árvores na floresta aumenta. O erro de generalização de uma floresta de classificadores de árvores depende da força das árvores individuais na floresta e da correlação entre elas (BREIMAN, 2001).

De acordo com (CUTLER; CUTLER; STEVENS, 2012), quando o número de árvores em um modelo RF tende ao infinito, o erro é minimizado. O número de árvores é um hiperparâmetro determinado pelo desenvolvedor, e é variável dependendo da aplicação. Porém, depois de uma determinada quantidade de árvores, a performance do modelo tende a permanecer constante, ou seja, mesmo aumentando o número de árvores o modelo não obterá melhoras em performance, apenas irá consumir mais recursos computacionais.

3.2.2 Categorical Boosting (CatBoost)

Categorical Boosting (CatBoost) é uma modificação do algoritmo de aumento de gradiente (PROKHORENKOVA et al., 2018). O aumento de gradiente é um método de aprendizado de máquina amplamente aplicado em problemas de regressão e classificação.

Ele gera um modelo preditivo na forma de um conjunto de modelos preditivos fracos, geralmente árvores de decisão (FRIEDMAN, 2001). A ideia principal do CatBoost é combinar sequencialmente muitos modelos fracos (um modelo com desempenho ligeiramente melhor do que a chance aleatória) e, assim, por meio da busca gulosa, criar um forte modelo preditivo competitivo. Como o aumento de gradiente ajusta as árvores de decisão sequencialmente, as árvores ajustadas aprenderão com os erros das árvores anteriores e, portanto, reduzirão os erros. Este processo de adicionar uma nova função às existentes continua até que a função de perda selecionada não seja mais minimizada.

Todos os algoritmos de aumento de gradiente clássicos sofrem de overfitting causado pelo problema de estimativas de gradiente pontuais enviesadas devido os gradientes usados em cada etapa serem estimados usando os mesmos pontos de dados nos quais o modelo atual foi construído. Para lidar com esse gradiente tendenciosos, autores propuseram modificações nos algoritmos originais, uma delas e utilizada pelo CatBoost pode ser encontrada em (PROKHORENKOVA et al., 2018), a modificação consiste em um novo esquema para calcular os valores das folhas ao selecionar a estrutura da árvores.

Na maioria dos algoritmos de aumento de gradiente, a construção das próximas árvores é composta de duas etapas, que consistem da escolha da estrutura da árvore e a definição dos valores nas folhas. Para escolher a melhor estrutura, o algoritmo enumera as divisões, cria arvores com as divisões, define os valores das folhas, pontua as árvores e seleciona a melhor divisão. Os valores na folhas são calculadas por uma técnica de aproximação de gradiente (FRIEDMAN, 2001). No CatBoost em específico a segunda etapa é mantido o padrão da maioria dos algoritmos de aumento de gradiente, porem a primeira etapa é realizada pela versão modificada (PROKHORENKOVA et al., 2018).

3.2.3 Light Gradient Boosting Machine (LGBM)

Light Gradient Boosting Machine (LightGBM) estende o algoritmo de aumento de gradiente adicionando um tipo de seleção automática de recursos e focando em exemplos de aumento com grandes gradientes. Ele é baseado em árvores de decisão para aumentar a eficiência do modelo e reduzir o uso de memória usando amostragem unilateral baseada em gradiente (GOSS) e agrupamento de recursos exclusivos (EFB), que atende às limitações de um algoritmo baseado em histograma. (HAN et al., 2022)

O algoritmo foi proposto por (KE et al., 2017), consiste da combinação de duas técnicas, o Gradient-based One-Side Sampling (GOSS) e a Exclusive Feature Bundling (EFB). Em árvores de decisão para aumento de gradiente, devido não haver pesos nativos para instâncias das árvores, as instâncias sub treinadas contribuirão para o ganho de informação. Para evitar isso, o GOSS reduz as amostras das instâncias de dados de tal forma que mantém apenas as instâncias com gradientes grandes, ou seja, é assumido um limiar mínimo que as instâncias devem alcançar, as instâncias que não ativem esse

limiar são descartadas aleatoriamente. Fazendo isso o GOSS obtém uma precisão maior de estimativa de ganho de informação do que quando são descartadas instância uniformemente aleatórias.

3.3 Métricas de Avaliação

A avaliação de um algoritmo de aprendizado de máquina supervisionado é normalmente realizada por meio da análise do desempenho do preditor gerado por ele na rotulação de novos objetos, não apresentados previamente em seu treinamento (Monard e Baranauskas, 2003). Medidas de erros bem conhecidas e usadas em abordagens de regressão são o erro absoluto médio (MAE - Mean Absolute Error), o erro quadrático médio (MSE - Mean Squared Error), raiz do erro quadrático médio (RMSE - Root Mean Absolute Error) e o r-quadrado, ou coeficiente de determinação (R^2).

O erro absoluto médio (MAE) consiste na média das distâncias entre valores preditos e reais (WILLMOTT, 2005), conforme a Equação (3.3). Diferentemente do (MSE) e do (RMSE), essa métrica não 'pune' tão severamente os *outliers* do modelo. Essa medida apresenta valor mínimo 0 e não apresenta valor máximo.

$$MAE = \frac{1}{M} \sum_{i=1}^M |y_i - y'_i| \quad (3.3)$$

Em que M representa o número de amostras, y_i é o valor conhecido e y'_i é o valor predito pelo modelo.

O Erro Quadrático Médio (MSE) consiste na média do erro das previsões ao quadrado. Considera-se a diferença entre o valor predito pelo modelo e o valor real, eleva-se o resultado ao quadrado, faz-se a mesma coisa com todos os outros pontos, soma-os, e dividi-se pelo número de elementos preditos. Quanto maior esse número, pior o modelo. Essa métrica apresenta valor mínimo 0, sem valor máximo, e é descrita pela Equação (3.4).

$$MSE = \frac{1}{M} \sum_{i=1}^M (y_i - y'_i)^2 \quad (3.4)$$

Uma vez que essa métrica eleva o erro ao quadrado, predições muito distantes do real aumentam o valor da medida muito facilmente, o que a torna uma métrica de avaliação excelente para problemas nos quais grandes erros não são tolerados, como é o caso de exames médicos e projeções de preços. Entretanto, um ponto negativo dessa métrica é a falta de interpretabilidade direta, uma vez que, para predição de valores de unidade u , a unidade do (MSE) seria u^2 .

Tendo em vista essa diferença de unidades, o (RMSE) entra como uma forma de melhorar a interpretabilidade da métrica, acertando a unidade. Entretanto, essa medida,

assim como o (MSE), penaliza previsões muito distantes da real. O (RMSE) é descrito pela Equação (3.5).

$$RMSE = \sqrt{\frac{1}{M} \sum_{i=1}^M (y_i - y'_i)^2} \quad (3.5)$$

o R-Quadrado, ou Coeficiente de Determinação (R^2), é uma métrica que visa expressar a quantidade da variância dos dados que é explicada pelo modelo construído. Essa medida calcula qual a porcentagem da variância que pôde ser prevista pelo modelo de regressão e, portanto, mostra o quão próximo as medidas reais estão do modelo (CAMERON; WINDMEIJER, 1997). (R^2) é dado pela Equação (3.6).

$$R^2 = 1 - \frac{\sum_{i=1}^M (y_i - y'_i)^2}{\sum_{i=1}^M (y_i - y''_i)^2} \quad (3.6)$$

O valor do (R^2) varia de 0 a 1 e pode ser representado em porcentagem. Por exemplo, um $R^2 = 75\%$ indica que 75% da variância dos dados podem ser explicados pelo modelo construído, enquanto os outros 25%, teoricamente, se tratariam de uma variância residual.

3.4 Considerações Finais do Capítulo

O capítulo aprestou o embasamento teórico necessário para o entendimento e aplicação dos algoritmos de aprendizado de máquina desta dissertação. Primeiramente foi apresentado como se dão as etapas típicas para resolver problemas usando aprendizado de máquina. Logo após, foi explicado sobre os algoritmos de aprendizado de máquina utilizados para o desenvolvimento dos métodos considerados. Por último, foram apresentadas as principais métricas de avaliação utilizadas para comparar e validar os métodos propostos nessa dissertação.

4 Metodologia Proposta

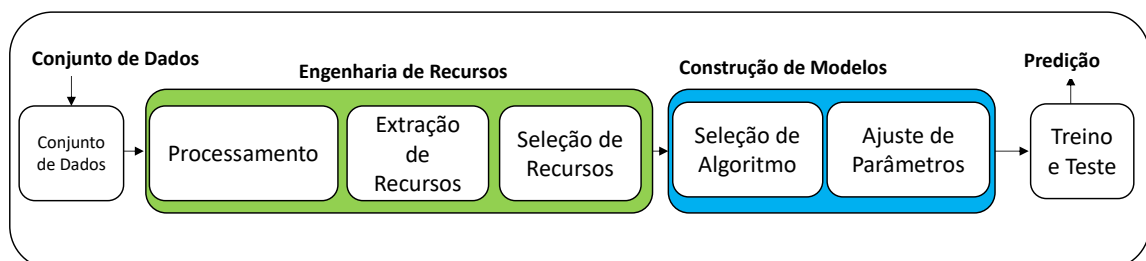
Este capítulo apresenta a metodologia proposta para a avaliação da condição de transformadores em termos de índice de saúde, utilizando um conjunto de dados formado por resultados das análises de qualidade do óleo isolante e cromatográfica, que são utilizados na geração de dados sintéticos, como parâmetros de entrada para a determinação de valores de índice de saúde a partir da metodologia clássica, e posteriormente por técnicas de aprendizado de máquina nas abordagens de regressão.

4.1 Etapas de Desenvolvimento dos Modelos

As etapas típicas de desenvolvimento de modelos de aprendizado de máquina, de forma geral são apresentadas na Figura 13. A primeira etapa consiste na análise das características presentes no conjunto de dados, isso permite a descoberta de padrões e tendências que podem fornecer informações importantes para compreender o processo que gerou os dados e sua distribuição.

Na segunda etapa, realiza-se o pré-processamento de dados, que é um procedimento frequentemente utilizado para melhorar a qualidade dos dados por meio da eliminação ou minimização de problemas antes da aplicação de modelos. Por último, a terceira etapa, realiza a implementação dos modelos de aprendizado de máquina para predição de índice de saúde e suas avaliações. O desenvolvimento da metodologia é descrito no restante deste capítulo.

Figura 13 – Diagrama da metodologia proposta para predição de HI.



Fonte: Próprio Autor.

Todo o processo de aplicação das técnicas propostas é feito com a biblioteca de aprendizado de máquina *Scikit-Learn*, de código aberto, com a linguagem de programação *Python*. As fases de treinamento e teste indicadas em (VAISH et al., 2021) são consideradas

para o desenvolvimento da metodologia. A avaliação de desempenho dos modelos é feita por meio das métricas adequadas para a abordagem de regressão.

O conjunto de dados é formado por 531 resultados de análises de qualidade do óleo isolante e cromatográfica de transformadores de potência com diversas idades e tensão de até 24,2 kV. Possui 14 variáveis contínuas, sendo: os gases hidrogênio (H_2), oxigênio (O_2), nitrogênio (N_2), metano (CH_4), monóxido de carbono (CO), dióxido de carbono (CO_2), etileno (C_2H_4), etano (C_2H_6), acetileno (C_2H_2) e fatores do óleo isolante Dibenzil Dissulfeto (DBDS), fator de dissipação, tensão interfacial, rigidez dielétrica e teor de água. Uma parte contendo 61 amostras foi obtida de (ARIAS RICARDO; MEJIA LARA, 2018) e 470 amostras obtidas de (ARIAS RICARDO; MEJIA LARA, 2020). As duas partes do conjunto de dados têm origem de trabalhos com propostas de avaliação de transformadores, por conta disso, os procedimentos de coleta e tratamento foram facilitadas, acelerando a implementação de modelos de aprendizado de máquina. A Tabela 11 mostra 14 amostras do conjunto de dados, com os valores das análises físico-químicas e cromatográficas de transformadores de distribuição.

Tabela 11 – Conjunto de Dados de Análises Físico-Químicas e Cromatográficas

	H2	O2	N2	CH4	CO	CO2	C2H4	C2H6	C2H2
1	2845	5860	27842	7406	32	1344	16684	5467	7
2	12886	61	25041	877	83	864	4	305	0
3	2820	16400	56300	144	257	1080	206	11	2190
4	1099	70	37520	545	184	1402	6	230	0
5	3210	3570	47900	160	360	2130	4	43	4
6	13500	343	36500	3150	113	984	5	1230	1
7	10200	11900	33700	573	87	611	0	162	0
8	3	15459	41347	5	68	902	12	2	13
9	16	2470	59600	8	520	2660	5	8	2
10	488	11861	48353	13	85	1957	29	23	0
11	4	26100	60600	1	206	1440	13	0	13
12	4	21800	46200	0	75	655	3	0	11
13	254	592	60300	14	376	2500	5	9	0
14	23349	2475	28011	5045	156	48	5588	3532	2951

	DBDS	Fator Dissipacao	Tensao Interfacial	Rigidez Dieletrica	Teor de Agua
1	19	1	45	55	0
2	45	1	45	55	0
3	1	1	39	52	11
4	87	4.58	33	49	5
5	1	0.77	44	55	3
6	1	4.93	37	52	6
7	1	3.53	45	55	5
8	5	0.58	41	71	6
9	164	0.29	44	56	4
10	164	0.27	37	72	10
11	5	1.32	40	56	4
12	0	0.65	42	53	5
13	205	0.44	42	42	6
14	0	1	52	70	2

Fonte: Próprio Autor.

Para a integração dos dois conjuntos de dados, foram identificados os atributos comuns presentes em ambos os conjuntos a serem combinados. Para a avaliação da

condição de saúde de transformadores, todos os 14 atributos contribuem para a estimativa do valor do atributo alvo, o índice de saúde a ser encontrado. Porém, para a determinação do índice de saúde a partir da metodologia utilizada nessa abordagem e para a geração de dados sintéticos, foi necessário eliminar o atributo Dibenzil Dissulfeto (DBDS) do conjunto integrado. O atributo dibenzil dissulfeto (DBDS) foi excluído porque não é utilizado para o cálculo do atributo-alvo (índice de saúde) nesta abordagem e por não fazer parte da geração de dados sintéticos.

4.2 Análise dos Dados

Considerando que a análise das características presentes em um conjunto de dados permite a descoberta de padrões e tendências que podem fornecer informações importantes para compreender como os dados estão organizados ou o processo que os gerou, foram aplicadas técnicas estatísticas, como covariância e correlação e técnicas de visualização para uma melhor compreensão da distribuição dos dados e suporte à escolha de formas de abordar o problema.

A Tabela 12 contém as informações dos atributos após serem convertidos do tipo numérico int (inteiro) para float (valor fracionário) em todo o conjunto, além da verificação da ausência de valores nulos, que não foram encontrados. A conversão para float foi realizada porque durante a construção dos modelos de aprendizado de máquina, um alerta sobre a necessidade do tipo de dado ser float foi recebido no ambiente de programação. O atributo total de gases combustíveis (TGC) foi criado através de engenharia manual de atributos, com base na avaliação da condição de transformadores, tendo como base a soma de gases do guia (IEEE-C57.104, 2019).

Tabela 12 – Atributos com dados do tipo float

Índice de intervalo: 531 entradas, 0 a 530				
Colunas de dados (total de 14 colunas)				
Índice	Coluna	Contagem não nula	Tipo de dado	
0	H2	Não nulo	Float64	
1	O2	Não nulo	Float64	
2	N2	Não nulo	Float64	
3	CH4	Não nulo	Float64	
4	CO	Não nulo	Float64	
5	CO2	Não nulo	Float64	
6	C2H4	Não nulo	Float64	
7	C2H6	Não nulo	Float64	
8	C2H2	Não nulo	Float64	
9	Fator de Dissipacao	Não nulo	Float64	
10	Tensao Interfacial	Não nulo	Float64	
11	Rigidez Dieletrica	Não nulo	Float64	
12	Teor de Agua	Não nulo	Float64	
13	TGC	Não nulo	Float64	


Fonte: Próprio Autor.

Para verificar a confiabilidade dos valores do conjunto de dados, foram aplicadas

técnicas de visualização, análises de máximos e mínimos das variáveis, análise da concentração dos valores e comparação com os valores de testes físico-químicos e cromatográficos definidos em normas.

O fator de dissipação (ou fator de potência) é a medida das perdas dielétricas em um líquido isolante elétrico, quando este é submetido a um campo elétrico em corrente alternada. O fator de potência é medido em porcentagem (%) e o procedimento de teste é realizado a 100° C. O máximo para transformadores de tensão menor que 36,2 kV é 20%. A Figura 14 mostra a concentração dos valores de fator de dissipação do conjunto de dados.

Figura 14 – Fator de Dissipação.




Fonte: Próprio Autor.

A maior parte dos registros está no intervalo entre 0 e 1%, outros valores no intervalo entre 2 e 5%, 6 transformadores apresentam valores acima de 20%, que é o valor máximo admitido em norma. O valor máximo do conjunto de dados é 75%. A análise do fator de dissipação é um teste útil no controle de qualidade do óleo sendo indicativo de contaminação do óleo ou a degradação do óleo em serviço.

Outra análise realizada diz respeito aos valores e distribuição da tensão interfacial do óleo. Na interface de separação entre dois líquidos imiscíveis ou entre um líquido e um gás, forma-se uma força de atração entre as moléculas, denominada de tensão interfacial (GODINHO, 2009). Essa propriedade é afetada pela presença de substâncias polares, mesmo em pequenas quantidades, pois estas além de afetar as propriedades elétricas do óleo, possuem centros ativos que aceleram o seu envelhecimento. A medida da tensão interfacial é representada pela força necessária para que um anel de platina rompa a

interface água/óleo. A Figura 15 mostra a distribuição de valores de tensão interfacial. Dentre os transformadores avaliados no conjunto, nenhum tem tensão interfacial abaixo de 20 (mN/m) e a maior concentração está no intervalo de 40 a 50 (mN/m).

Figura 15 – Distribuição dos valores de tensão interfacial.




Fonte: Próprio Autor

A medida desse parâmetro no sistema água-óleo visa exatamente inferir a quantidade de substâncias polares presentes no óleo, uma vez que tais substâncias tendem a concentrar-se na interface do sistema. Quanto maior a concentração de substâncias polares, menor o valor da tensão interfacial. A norma (NBR 6234, 2015) especifica o método do anel para a determinação da tensão interfacial óleo-água, em óleo mineral isolante utilizado em equipamentos elétricos. Este método de ensaio é frequentemente aplicado para óleos em serviço como uma indicação do grau de deterioração, o valor mínimo é de 20 (mN/m), porém a avaliação desses valores limites depende do laboratório em que são feitas as análises e do sistema. A quantificação dessa propriedade é utilizada como um meio de avaliar e monitorar o estado de oxidação do óleo e também avaliar indiretamente o estado de degradação do papel, uma vez que esses compostos polares são oriundos da oxidação tanto do óleo quanto do papel.

A rigidez dielétrica é a medida da capacidade dos óleos isolantes para suportar tensões elétricas sem apresentar ruptura do dielétrico. A norma (NBR IEC 60156, 2019) especifica o método para determinação da rigidez dielétrica à frequência industrial. O procedimento de análise é realizado em um aparelho específico, onde uma amostra de óleo é submetida a um campo elétrico crescente, até que ocorra a disrupção, o valor mínimo é de 40 (kV). Contaminantes, como água, sedimentos e partículas condutoras reduzem a

rigidez dielétrica do óleo isolante. A combinação destes contaminantes tendem a reduzir a rigidez dielétrica em um grau maior do que os mesmos contaminantes isoladamente. A distribuição de rigidez dielétrica é vista na Figura 16. Nota-se que existem registros nos intervalos entre 25 a 40 (kV), o que está em desacordo com o limite de norma. Os transformadores que possuem esses valores de rigidez dielétrica podem ser os que possuem risco e pior integridade. Porém, a maior parte dos registros está acima de 40 (kV), com mais de 200 transformadores distribuídos entre 50 e 55 (kV).

Figura 16 – Rigidez Dielétrica.



Fonte: Próprio Autor

A água no óleo isolante, mesmo que em pequenas quantidades, é muito prejudicial, pois é atraída para as zonas de maior estresse elétrico. A água acelera a degradação tanto da isolação celulósica quanto do próprio óleo isolante, liberando mais água neste processo de deterioração. A distribuição dos valores de teor de água é mostrada na Figura 17.

A maior parte dos valores de teor de água está abaixo de 40 (ppm), mas há valores significativos acima do limite de norma. A rigidez dielétrica do sistema isolante é uma função direta do conteúdo de água. Em equilíbrio dinâmico, a água migra tanto da isolação sólida para o óleo isolante quanto o inverso, em função das mudanças de temperatura de operação. A norma (NBR 10710, 2022) especifica um método para determinação do teor de água em líquidos isolantes elétricos, através do método coulométrico de Karl Fischer, o valor máximo admitido na norma é 40 (ppm).

Figura 17 – Distribuição de valores de Teor de Água.



Fonte: Próprio Autor


Um método considerável para monitorar a deterioração do material isolante do transformador envolve o cálculo do volume total de gases liberados. O volume total de gases envolvidos é um indicador da magnitude das falhas incipientes, conforme o guia (IEEE-C57.104, 2019). Este guia fornece formas de avaliação da condição do transformador usando quatro classificações de acordo com o total de gases combustíveis (TGC), o total de gases combustíveis é a soma dos gases hidrogênio (H_2), metano (CH_4), monóxido de carbono (CO), etileno (C_2H_4), etano (C_2H_6) e acetileno (C_2H_2).

A classificação de número 1 indica melhor condição do transformador, com (TGC) de 720 (ppm) ou menos. A classificação de número 2 é definida se o transformador tiver (TGC) no intervalo de 721 a 1920 (ppm), indica o nível de gás combustível maior que o normal. Qualquer gás combustível individual que exceda os níveis especificados deve requerer investigação adicional.

A classificação de número 3 tem o (TGC) no intervalo de 1921 a 4630 (ppm), indica um alto nível de decomposição. Qualquer gás combustível individual que exceda os níveis especificados deve também requerer investigação adicional. A última classificação é a de número 4, com (TGC) maior que 4630 (ppm) indica decomposição excessiva. A operação contínua pode resultar em falha do transformador e intervenções imediatas são necessárias.

A Figura 18 mostra a distribuição dos valores do total de gases combustíveis dos transformadores do conjunto de dados. A maior parte dos transformadores do conjunto de dados possui (TGC) de até 1000 (ppm), o que indica, principalmente, as classificações 1 e 2, de acordo com o guia (IEEE-C57.104, 2019).

Figura 18 – Total de Gases Combustíveis.



Fonte: Próprio Autor

De forma geral, a maior parte dos valores das análises de qualidade do óleo isolante e cromatográfica dos transformadores do conjunto está dentro dos limites estabelecidos em normas e guias de referência. São valores de análises de transformadores em serviço tipicamente encontrados.

4.3 Determinação do Índice de Saúde

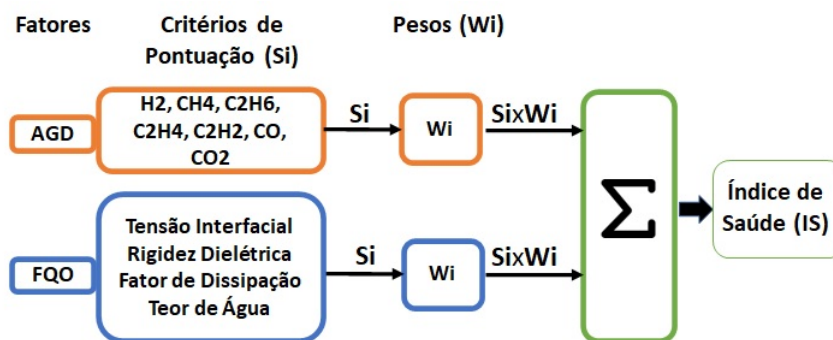
Para a aplicação dos modelos preditivos a fim de encontrar valores de índice de saúde, o conjunto de dados precisa ter os atributos preditivos e o atributo alvo, que neste caso é o índice de saúde de transformadores. Para obtenção dos valores do índice de saúde base, foram utilizados como critérios de pontuação os valores dos gases hidrogênio (H_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4), acetileno (C_2H_2), monóxido de carbono (CO), dióxido de carbono (CO_2) e resultados de análises do óleo isolante, fator de dissipação, tensão interfacial, rigidez dielétrica e teor de água para o cálculo de índice de saúde através da metodologia clássica apresentada no Capítulo 2.

A Figura 19 mostra o diagrama esquemático para o cálculo do índice de saúde a partir da metodologia clássica. São considerados os impactos dos fatores individuais na condição técnica do transformador. O sistema de pontuação de cada fator possui uma faixa de pontuação estabelecida e recomendada por normatizações internacionais como (IEEE-C57.104, 2019), (IEEE-C57.91, 2012), e recebe pontuações de acordo com o seu

estado.

De acordo com o resultado da análise realizada para os dois fatores diagnósticos, o critério é classificado em cinco faixas (A, B, C, D ou E) e sua pontuação correspondente (4, 3, 2, 1, 0), é multiplicada pelo seu respectivo peso. Os resultados são somados e divididos pela soma dos pesos.


Figura 19 – Diagrama esquemático para o cálculo do índice de saúde.



Fonte: Próprio Autor

Com o cálculo de índice de saúde realizado, a distribuição dos valores de 0 a 100 é mostrada na Figura 20. A maior parte dos resultados de índice de saúde está no intervalo entre 20 e 50, isso significa que a maioria dos transformadores é avaliada em estado bom ou razoável, pois o índice de saúde indica maior degradação quanto mais próximo de 100.

Figura 20 – Distribuição de intervalos de índice de Saúde.



Fonte: Próprio Autor.

Essa concentração reflete os valores das análises de gases dissolvidos e de qualidade

do óleo, em que a maior parte dos transformadores está dentro dos limites estabelecidos em normas e por isso caracterizam majoritariamente boa ou razoável condição de saúde.

Com objetivo de contribuir para o melhor desempenho dos modelos de regressão, dados sintéticos são criados a partir das amostras existentes, tendo como base o aumento percentual, em 14 meses, dos resultados das análises físico-químicas e cromatográfica de um transformador em operação da mesma classe de tensão e potência. A Tabela 13 mostra resultados de análises do transformador considerado e a taxa de crescimento dos valores depois de 14 meses .

As taxas de crescimento são consideradas para o cálculo das novas amostras do conjunto de dados, assumindo a mudança correlacionada das variáveis. As novas amostras são uma projeção dos resultados das análises físico-químicas e cromatográfica de cada transformador no conjunto, resultando em um novo conjunto de dados com o dobro de amostras. A Tabela 14 apresenta informações do tipo de dado e composição do conjunto com dados sintéticos.

Tabela 13 – Taxa de Crescimento de Análises

ANÁLISES FÍSICO-QUÍMICAS	RESULT. Anterior	RESULT. Atual	Taxa de Crescimento (%)
Teor de água (ppm) - Medido	13	18	38.46
Teor de água (ppm) - 20°C - Corrigido	-	-	-
Fator de Potência a 100°C (%)	3.50	3.60	2.85
Rigidez Dielétrica - Calota (kV)	75	75	- 3.84
Tensão Interfacial (mN/m)	20.8	20.1	- 3.36
ANÁLISES CROMATOGRÁFICA	RESULT. Anterior	RESULT. Atual	Taxa de Crescimento (%)
H2	5	40	700
O2	17900	6500	- 63.68
N2	43100	68600	59.16
CH4	2	19	850
CO	116	546	370
CO2	7430	12440	67
C2H4	9	20	122
C2H6	15	31	106
C2H2	0	0	0
Total de Gases	68577	88196	28
TGC	147	656	346

Fonte: Próprio Autor.

Com os dados sintéticos, novamente o cálculo de índice de saúde foi realizado e a distribuição dos valores é mostrada na Figura 21. É um resultado esperado, pois cada amostra teve a taxa de mudança simulada de 14 meses, tempo em que transformadores em operação normal não têm alterações grandes de integridade. A maior parte dos resultados de índice de saúde continua no intervalo entre 20 e 50. Mesmo que pequenos, os números de transformadores com índice de saúde maiores que 70 tiveram aumento, que é positivo para o treinamento dos modelos preditivos.


No desenvolvimento de modelos de aprendizado de máquina é importante atentar

Tabela 14 – Atributos do conjunto com dados sintéticos

Índice de intervalo: 1062 entradas, 0 a 1061				
Colunas de dados (total de 14 colunas)				
Índice	Coluna	Contagem não nula	Tipo de dado	
0	H2	Não nulo	Float64	
1	O2	Não nulo	Float64	
2	N2	Não nulo	Float64	
3	CH4	Não nulo	Float64	
4	CO	Não nulo	Float64	
5	CO2	Não nulo	Float64	
6	C2H4	Não nulo	Float64	
7	C2H6	Não nulo	Float64	
8	C2H2	Não nulo	Float64	
9	Fator de Dissipacao	Não nulo	Float64	
10	Tensao Interfacial	Não nulo	Float64	
11	Rigidez Dieletrica	Não nulo	Float64	
12	Teor de Agua	Não nulo	Float64	
13	TGC	Não nulo	Float64	

Fonte: Próprio Autor.

Figura 21 – Distribuição de intervalos de índice de Saúde com dados sintéticos.



Fonte: Próprio Autor.

para a necessidade de transformação numérica dos atributos do conjunto de dados (FACELI et al., 2021). Isso geralmente ocorre quando os limites inferior e superior de valores dos atributos são muito diferentes, o que leva a uma grande variação de valores, ou ainda quando vários atributos estão em escalas diferentes. A Tabela 15 mostra a grande diferença de limites inferior e superior de valores dos atributos.

Nota-se a grande diferença de escalas nos valores de atributos do conjunto de dados, valores mínimos, médias e máximos têm grande diferenças de escalas. Os valores de tensão interfacial têm o valor máximo 57, bem diferente do valor máximo de CO₂, que é 41583, esse tipo de situação impacta diretamente em resultados de modelos.

Tabela 15 – Diferença de limites inferior e superior de valores dos atributos


Valores	CO	CO2	Tensão Interfacial	Rigidez Dielétrica
Mínimo	10	48	20	26
Máximo	8131	41583	57	75

Fonte: Próprio Autor.

Para deixar os dados adequados para aplicação de modelos, foi realizada a transformação de dados chamada de normalização. Com a normalização, o objetivo foi mudar os valores das variáveis numéricas no conjunto de dados para uma escala comum, sem distorcer as diferenças nos intervalos de valores.

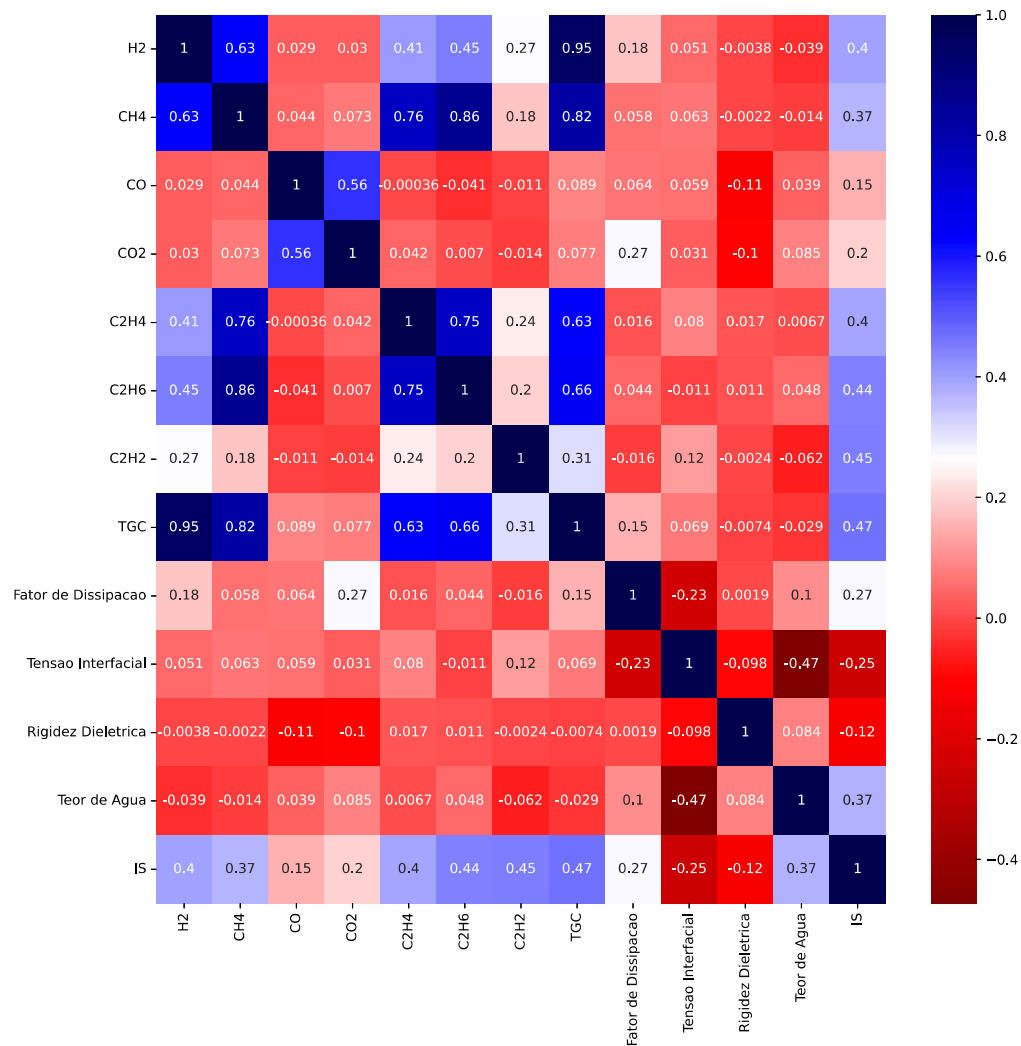
Nesta abordagem, aplica-se a normalização por amplitude, que pode ser por reescala e por padronização. Os pacotes *StandardScaler* para padronização e *MinMaxScaler* para normalização da biblioteca de aprendizado de máquina *scikit-learn* da linguagem *Python* foram utilizadas para fazer a transformação dos dados. A Figura 22 apresenta o boxplot com os dados dentro de um determinado intervalo, geralmente de 0 a 1. O *MinMaxScaler* transforma os dados escalando recursos para um determinado intervalo, dimensiona os valores para um intervalo de valor específico sem alterar a forma da distribuição original.

Figura 22 – boxplot com valores das variáveis normalizadas.



Fonte: Autor

Figura 23 – Correlação de atributos.



Fonte: Próprio Autor

A Figura 23 apresenta a correlação entre atributos do conjunto de dados em estudo. A intensidade da cor azul indica o nível de correlação entre os atributos, o C2H6 tem o valor 0,44, o C2H2 tem o valor 0,45 e o TGC tem o valor 0,47. Os três são os mais correlacionados com o índice de saúde, e por isso podem ter boa representatividade para predição de valores do atributo alvo.

Para a seleção do melhor modelo, utilizou-se da metodologia apresentada na seção 3.1. Para uma avaliação justa entre os algoritmos, utilizou-se os conjuntos de treino e teste para treinar e calcular as métricas respectivamente. O teste é utilizado para a escolha do melhor algoritmo de aprendizado de máquina para o modelo, o regressor com os melhores resultados é o algoritmo base para o modelo final. Os hiperparâmetros para os modelos neste trabalho foram pré-ajustados usando uma pesquisa de grade distribuída.

4.3.1 Avaliação entre os três algoritmos de regressão

Depois de aplicar todos os três algoritmos com o conjunto de dados, incluindo as amostras sintéticas geradas, o desempenho destes é comparado para avaliar qual apresenta as melhores métricas. O MAE, MSE, RMSE e R² são apresentados para todos os modelos na Tabela 16.

Tabela 16 – Análise de Desempenho dos Modelos.

Modelo	MAE	MSE	RMSE	R ²
Random Forest Regressor	1.5041	6.5819	2.5655	0.9462
Cat Boost Regressor	0.7830	2.0964	1.4479	0.9838
LGBM Regressor	1.0104	2.9541	1.7187	0.9781

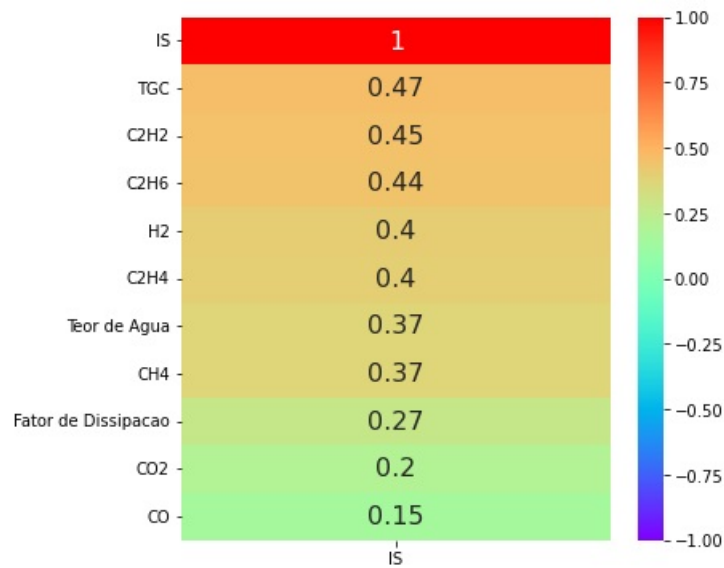
Fonte: Próprio Autor

Pode-se observar que o Cat Boost Regressor teve os melhores resultados em todas as métricas comparadas. Com base nos experimentos, comprovou-se a superioridade do Cat Boost Regressor em relação aos outros algoritmos. Logo, esse foi escolhido como regressor para o modelo de determinação de índice de saúde.

Para avaliação da metodologias desenvolvida nesse trabalho em comparação com outros métodos, considerou-se a proposta desenvolvida em (LEAUPRASERT et al., 2020), na qual concluiu-se que os 46 entre 89 atributos originados de diferentes resultados de testes históricos, inspeção visual, testes elétricos, isolamento de papel, de óleo e análise de gases dissolvido (DGA) foram os recursos de teste concisos de maior significância estatística no problema de regressão do valor índice de saúde. Foi considerado também a importância de trabalhar com a quantidade adequada de uma série de variáveis de entrada para reduzir um custo computacional, overfitting e ocasionalmente melhorar o desempenho dos modelos.

A abordagem de recursos reduzidos apresentada neste trabalho lida com 10 atributos. A Figura 24 mostra o resultado da seleção dos atributos que possuem maior correlação com o índice de saúde. Alguns dos atributos selecionados são: o TGC, que é um método para monitorar a deterioração do material isolante do transformador e envolve o cálculo do volume total de gases combustíveis; ; O hidrogênio (H₂) e o metano (CH₄) que revelam a presença de eventuais falhas no interior do transformador.

Figura 24 – Maiores correlações.



Fonte: Próprio Autor

Os resultados obtidos aplicando as técnicas de regressão com recursos reduzidos foram semelhantes aos modelos com 14 atributos, conforme a Tabela 17. O algoritmo Cat Boost Regressor continua tendo o melhor desempenho dentre os 3 algoritmos, com o desempenho muito próximo do modelo com atributos completos.

Tabela 17 – Análise de desempenho com recursos reduzidos.


Modelo	MAE	MSE	RMSE	R ²
Random Forest Regressor	1.5699	5.8790	2.4246	0.9525
Cat Boost Regressor	1.1008	3.0963	1.7596	0.9760
LGBM Regressor	1.2760	4.0503	2.0125	0.9694

Fonte: Próprio Autor

O impacto desses resultados ajudaria as empresas de serviços elétricos a reduzir o custo com testes em tempo inadequado e com manutenção, reduzindo o número de testes para determinação do índice de saúde de transformadores.


As comparações entre valores de índice de saúde preditos pelos algoritmos e o índice de saúde de referência do conjunto de dados são ilustradas nos gráficos de dispersão das Figuras 25, 26 e 27.

Figura 25 – Random Forest Regressor.



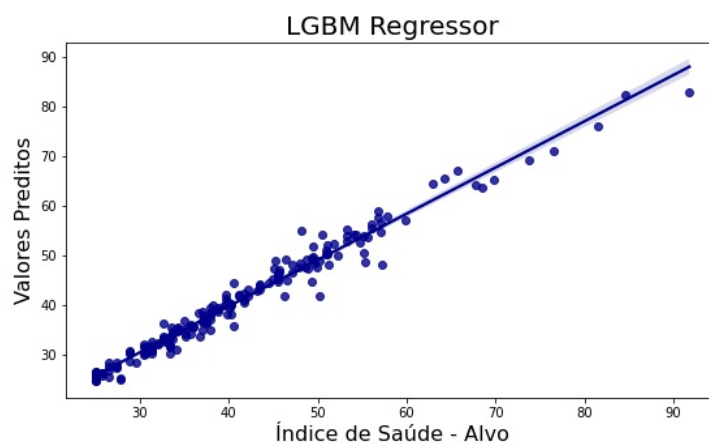
Fonte: Próprio Autor

Figura 26 – Cat Boost Regressor.



Fonte: Próprio Autor


Figura 27 – LGBM Regressor.



Fonte: Próprio Autor

O algoritmo Cat Boost Regressor é o modelo com melhores métricas, ele realiza os melhores resultados previstos com os menores MAE, MSE, RMSE e maior R2 entre os outros algoritmos. Uma comparação entre os valores de índice de saúde previstos pelo Cat Boost Regressor e os valores de referência do conjunto de dados é ilustrada na Figura 28.

Figura 28 – Comparação de valores previstos de Cat Boost Regressor com valores de referência.



Fonte: Próprio Autor

O erro percentual entre os valores preditos pelo Cat Boost Regressor com os valores de referência de índice de saúde são mostrados na Tabela 18. A amostra de teste 208 é a que apresenta o maior erro percentual, mas ainda assim é um valor que não compromete fortemente a análise de integridade geral de um transformador.

Tabela 18 – Comparação dos valores preditos da Regressão Catboost com os valores reais.

Nº Testes	Valores Reais	Valores Preditos	Erro Percentual
0	54.78	53.95	1.54%
1	33.33	31.39	6.18%
2	64.19	64.97	-1.20%
3	30.55	30.56	-0.03%
4	56.01	55.90	0.20%
...
208	45.67	42.23	8.15%
209	45.06	47.61	-5.36%
210	43.51	41.75	4.22%
211	47.83	48.02	-0.40%
212	51.23	51.40	-0.33%

Fonte: Próprio Autor

Os valores preditos de índice de saúde de transformadores do conjunto de teste foram divididos em faixas, indicando a condição do transformador como Bom, Razoável ou Ruim, conforme a Tabela 19.

Tabela 19 – Resultados de índice de saúde de transformadores

Índice de Saúde	Condição	Nº Transformadores
0-40	Bom	126
40-80	Razoável	85
80-100	Ruim	2

Fonte: Próprio Autor

Para verificar a capacidade do modelo Cat Boost Regressor na determinação de valores de índice de saúde para transformadores, os dois transformadores com índice de saúde na faixa de condição Ruim, tiveram os valores dos atributos analisados, conforme a Tabela 20.

Tabela 20 – Análise dos transformadores classificados na condição ruim.

	H2	O2	N2	CH4	CO	CO2	C2H4	C2H6	C2H2
1	757	289	57400	1700	1730	24900	2280	755	12
2	2183	192	43380	1061	183	5730	1308	646	2
	TGC	Fator Dissipacao	Tensao Interfacial	Rigidez Dieletrica	Teor de Agua	IS			
1	7234	42.1	24	51	77	99.5			
2	5383	1	42	28	31	91.82			

Fonte: Próprio Autor

Os dois transformadores têm o total de gases combustíveis (TGC) elevados, de acordo com o guia (IEEE-C57.104, 2019), o TGC maior que 4630 (ppm) indica decomposição excessiva, o que reforça os valores elevados de índice de saúde encontrados.

Outros valores em desacordo com normas são o fator de dissipação do transformador 1, que está acima do valor máximo de 20%, normalizado pela NBR 12133. A rigidez dielétrica do transformador 2 está com valor menor que o mínimo de 40 (kV), valor referência da NBR IEC 60156. E o teor de água do transformador 1 está acima do valor de referência da NBR 10710, que é 40 (ppm). Estes são indicativos de degradação nos transformadores e reforçam os valores de índice de saúde determinados pela metodologia proposta.

4.4 Considerações Finais do Capítulo

Este capítulo abordou a formulação da metodologia de avaliação de transformadores de potência proposta. Os dados foram analisados para identificar tendências, distribuições e relações dos atributos. Sobre o tratamento antes da utilização por modelos propostos, destacou-se a importância da análise de confiabilidade dos valores do conjunto de dados e o ganho na geração de dados sintéticos para a aplicação dos algoritmos.

A utilização do método de monitoramento baseado na avaliação a partir de técnicas de aprendizado de máquina, alinhado às experiências de especialistas e com testes já

estabelecidos, torna a proposta interessante. Essa perspectiva é muito importante para tomada de decisão e intervenções de transformadores. O gerenciamento financeiro e operacional também têm ganhos por essa abordagem.

5 Estudo de Caso

A metodologia proposta para avaliação de transformadores de potência, desenvolvida no Capítulo 4, pode ser aplicada como um sistema de avaliação de transformadores de instalações elétricas. Assim, esse capítulo apresenta o estudo da avaliação de 4 transformadores da mesma classe de tensão do conjunto de dados utilizado neste trabalho.

5.1 Transformadores Avaliados

A Tabela 21 apresenta as principais características dos 4 transformadores trifásicos avaliados. Com relação aos dados de monitoramento, foram obtidas análises laboratoriais das condições do óleo isolante (análises físico-químicas e de gases dissolvidos). Os dados foram extraídos de laudos técnicos realizados por laboratórios e um exemplo é apresentado no Apêndice A.

Tabela 21 – Características dos transformadores de potência avaliados.

Transformador	Tensão(kV)	Potência(kVA)	Tipo de óleo	Ano Fabr.	Sist. Refrig.
T1	23,1/0,38	300	Mineral	2017	ONAN
T2	23,1/0,38	500	Mineral	1973	ONAN
T3	24,2/0,38	500	Mineral	1987	ONAN
T4	23,1/0,38	750	Mineral	1989	ONAN

Fonte: Próprio Autor

Os dados das análises físico-química e cromatográfica dos transformadores para o estudo de caso foram compilados em formato tabular, como visto na Tabela 22.

Tabela 22 – Dados de análises físico-química e cromatográfica para estudo de caso.

ID	H2	O2	N2	CH4	CO	CO2	C2H4	C2H6	C2H2
1	40	6500	68600	19	546	12440	20	31	0
2	75	5400	30800	15	169	2050	11	2	0
3	5	13700	40600	2	94	2360	4	4	0
4	21	26600	69000	0	78	2650	2	1	0
	TGC	Fator de Dissipacao	Tensao Interfacial	Rigidez Dieletrica	Teor de Agua	Estado	IS		
1	656	3,6	20,1	75	18	Normal	36,31		
2	272	0,37	36,4	75	7	Normal	25,55		
3	109	6,22	23,8	50	33	Normal	40,68		
4	102	2,6	16,6	78	16	Normal	33,55		

Fonte: Próprio Autor

Constam ainda na Tabela 22, a coluna chamada Estado, com as condições determinadas por especialistas dos laboratórios onde as análises foram feitas, que baseiam-se em normas. E a coluna IS, que contém valores de índice de saúde dos transformadores, determinados pela metodologia proposta nesta dissertação.

Todos os transformadores foram avaliados em estado normal de operação pelos especialistas, os valores de índice de saúde resultantes da metodologia proposta estão de acordo com os diagnósticos dos especialistas, com destaque para o valor de índice de saúde 40,68, do transformador 3, que significa a condição razoável, diferente da determinação dos especialistas, como mostrado na Tabela 23.

Mas na análise feita por especialistas não há valores numéricos que representam o estado ou condição do transformador, e sim estados como normal, alerta e crítico, por exemplo. Um dos ganhos da representação por valores de índice de saúde é a possibilidade de acampamento da evolução da condição de integridade de transformadores.

Tabela 23 – Resultados de índice de saúde de transformadores do estudo de caso.

Índice de Saúde	Condição	Nº Transformadores
0-40	Bom	3
40-80	Razoável	1
80-100	Ruim	0

Fonte: Próprio Autor

A condição do transformador 3 foi determinada pela metodologia como Razoável, mas o valor 40,68 tem uma diferença muito pequena de 40, ou seja, da condição considerada como Bom. Como a análise realizada nos laboratórios é baseada em normas, se nenhum valor das análises físico-químicas ou cromatográfica estiver fora de valores estabelecidos em normas, a determinação do estado é como normal, desconsiderando a proximidade de uma variável do valor estabelecido em norma e não indicando a evolução da degradação.

5.2 Análises dos resultados físico-químicos e cromatográficos em relação ao índice de saúde

Todos os transformadores considerados no estudo de caso têm baixo valor de total de gases combustíveis, o que é um dos indicativos de transformadores em bom estado. Além disso, todos os transformadores têm o valor do gás C₂H₂ zerado, que também não representa degradação acentuada nos transformadores.

O transformador 3 do estudo de caso, na Tabela 22, com o maior índice de saúde, tem o valor de teor de água 33 (ppm), que ainda está abaixo do valor 40 (ppm) estabelecido em norma, mas é um valor mais elevado em relação aos outros transformadores e pode ser considerado para análise da evolução histórica e sua relação com outra variável.

6 Conclusão

O índice de integridade do transformador fornece uma compreensão intuitiva da condição geral de um único transformador ou até mesmo de uma frota de transformadores. É prático em termos de gerenciamento e manutenção de ativos. Além disso, ele pode integrar uma variedade de dados de monitoramento de condição que refletem a condição em um índice global para auxiliar nas decisões do gerenciamento. Entre os métodos para calcular o índice de integridade do transformador, os métodos baseados em soma de pontuação ponderada são amplamente aceitos pelas concessionárias por sua praticidade e podem ser realizados rapidamente. Em contraste, os métodos baseados em algoritmos de inteligência artificial são preferíveis aos estudiosos. Os índices de saúde clássicos são frequentemente usados em termos de abordagens baseadas em soma de pontuação ponderada. A chave para obter um índice de saúde confiável usando tais métodos depende da determinação razoável dos pesos. Portanto, a experiência de especialistas humanos desempenha um papel decisivo nesse processo. O presente trabalho apresentou o desenvolvimento de uma metodologia para avaliação da condição de transformadores de potência, com aplicação à um estudo de caso com dados reais de análises dos equipamentos. A metodologia é apoiada na avaliação da condição de transformadores através da predição do índice de saúde.

Nos resultados da aplicação da metodologia ao estudo de caso, dentre os quatro transformadores avaliados, um deles resultou em classificação diferente da feita por especialistas com base em normas, e os demais classificados no mesmo estado de integridade. Nesses casos, seria conveniente analisar os dados de análises físico-química e cromatográfica de forma crítica nos equipamentos.

A metodologia proposta permite a estimativa do índice de saúde de transformadores, através de técnicas de aprendizado de máquina e correlação de parâmetros, ainda que considerando um banco de dados relativamente pequeno. A combinação das técnicas permitiu uma redução dos parâmetros necessários para estimativa do índice de saúde, com bons resultados de predição. Assim, somada às experiências de especialistas e testes bem estabelecidos, a proposta torna-se promissora como ferramenta para auxiliar na tomada de decisões e intervenções de manutenção nos transformadores em operação, com impactos positivos para o gerenciamento financeiro e operacional dos ativos do sistema elétrico. Deste modo, tal metodologia pode ajudar indústrias e empresas do setor elétrico a reduzir os custos e tempo com testes para o cálculo do índice de saúde, com melhorias para o planejamento da manutenção (preditiva) e na vida útil dos transformadores.

6.1 Sugestões para Trabalhos Futuros

Para prosseguimento aos estudos realizados nesta dissertação, sugere-se os seguintes temas para trabalhos futuros:

- Consideração de um conjunto de dados maior, com dados de mais transformadores da mesma classe de tensão.
- Implementação de um método de determinação de índice de saúde com redes neurais artificiais para comparação com os modelos de regressão.
- Avaliação das respostas do modelo proposto em uma gama de transformadores com um período longo em operação e próximos do final de sua vida útil, analisando o desempenho da metodologia nestas situações.
- Utilização dos resultados de transformadores com índice de saúde que indica degradação elevada para desenvolvimentos de métodos de classificação de falhas.

6.2 Trabalhos Publicados

Durante o mestrado, publicou-se um trabalho relacionado com avaliação de transformadores de potência. Um projeto de negócio foi escrito e premiado no "Transforme sua pesquisa em negócio", um programa realizado pela Fundação Fórum Campinas Inovadora (FFCi) com o objetivo de estimular a criação de novas empresas a partir do resultado de pesquisas científicas.

- MATIAS, V. S. J. et al. Aplicação de Aprendizado de Máquina na Predição do Índice de Integridade de Transformadores de Potência. XIX Encontro Regional Ibero-americano do CIGRE, Foz do Iguaçu, Brasil, 2023, pp. 1-8. ISBN 978-65-00-63038-1.
- Projeto vencedor do Programa "Transforme sua pesquisa em negócio", na categoria "Destaque melhor modelo de negócio área de energia e petróleo", em Setembro de 2022, pela equipe "Transform I.A". Título do projeto: Manutenção Preditiva de Transformadores de Potência com Aplicação de IA para Previsão de Falhas.

Referências

- ABU-ELANIEN, A. E.; SALAMA, M. Asset management techniques for transformers. *Electric Power Systems Research*, v. 80, n. 4, p. 456–464, 2010. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779609002405>>.
- ABU-ELANIEN, A. E. B.; SALAMA, M. M. A.; IBRAHIM, M. Determination of transformer health condition using artificial neural networks. In: *2011 International Symposium on Innovations in Intelligent Systems and Applications*. [S.l.: s.n.], 2011. p. 1–5.
- ABU-ELANIEN, A. E. B.; SALAMA, M. M. A.; IBRAHIM, M. Calculation of a health index for oil-immersed transformers rated under 69 kv using fuzzy logic. *IEEE Transactions on Power Delivery*, v. 27, n. 4, p. 2029–2036, 2012.
- ABU-SIADA, A.; ISLAM, S. A new approach to identify power transformer criticality and asset management decision based on dissolved gas-in-oil analysis. *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 19, n. 3, p. 1007–1012, 2012.
- ALQUDSI, A.; EL-HAG, A. Application of machine learning in transformer health index prediction. *Energies*, v. 12, n. 14, 2019. ISSN 1996-1073. Disponível em: <<https://www.mdpi.com/1996-1073/12/14/2694>>.
- AMERICAN NATIONAL STANDARD. *ANSI NETA MTS*: Standard for maintenance testing specifications for electrical power equipment and systems. [S.l.], 2019.
- AMORIM, H.; RODRIGUES, T. B. Transformadores a seco e o desafio do monitoramento on-line. *X WORKSPOT- 10th International Workshop on Power Transformers, Transmission and Distribution Equipment, Substations, Materials and Emerging Technologies*, CIGRE, BR, n. 10, p. 8, 2022.
- ARIAS RICARDO; MEJIA LARA, J. Corrosive sulphur effect in power and distribution transformers failures and treatments. *Engineering Failure Analysis*, Elsevier BV, v. 92, p. 240–267, out. 2018. Disponível em: <<https://doi.org/10.1016/j.engfailanal.2018.05.018>>.
- ARIAS RICARDO; MEJIA LARA, J. *Data for: Root cause analysis improved with machine learning for failure analysis in power transformers*. Mendeley, 2020. Disponível em: <<https://data.mendeley.com/datasets/rz75w3fkxy/1>>.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *NBR 6234*: Óleo mineral isolante - determinação da tensão interfacial de óleo-água pelo método do anel - método de ensaio. Rio de Janeiro, 2015. 8 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *NBR 10576*: Óleo mineral isolante de equipamentos elétricos - diretrizes para supervisão e manutenção. Rio de Janeiro, 2017. 46 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *NBR IEC 60156*: Líquidos isolantes — determinação da rigidez dielétrica à frequência industrial — método de ensaio. Rio de Janeiro, 2019. 20 p.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *NBR 10710*: Líquido isolante elétrico - determinação do teor de água - método coulométrico de karl fischer. Rio de Janeiro, 2022. 13 p.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *NBR 7036*: Recebimento, armazenagem, instalação e manutenção de transformadores de distribuição até a classe de tensão de 36,2 kv, imersos em líquido isolante. Rio de Janeiro, 2022. 27 p.

BACHA, K.; SOUAHLIA, S.; GOSSA, M. Power transformer fault diagnosis based on dissolved gas analysis by support vector machine. *Electric Power Systems Research*, Elsevier BV, v. 83, n. 1, p. 73–79, fev. 2012. Disponível em: <<https://doi.org/10.1016/j.epsr.2011.09.012>>.

BAI, C. fen; GAO, W.-S.; LIU, T. Analyzing the impact of ambient temperature indicators on transformer life in different regions of chinese mainland. *The Scientific World Journal*, Hindawi Limited, v. 2013, p. 1–10, 2013. Disponível em: <<https://doi.org/10.1155/2013/125896>>.

BAKAR, N. A.; ABU-SIADA, A.; ISLAM, S. A review of dissolved gas analysis measurement and interpretation techniques. *IEEE Electrical Insulation Magazine*, v. 30, n. 3, p. 39–49, 2014.

BARKAS, D. A.; CHRONIS, I.; PSOMOPOULOS, C. Failure mapping and critical measurements for the operating condition assessment of power transformers. *Energy Reports*, v. 8, p. 527–547, 2022. ISSN 2352-4847. Technologies and Materials for Renewable Energy, Environment and Sustainability. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352484722012914>>.

BECHARA, R. *Análise de falhas de transformadores de potência*. 118 p. Dissertação (Mestrado) — Escola Politécnica da Universidade de São Paulo, SÃO PAULO, 2010.

BISHOP, M.; BARANOWSKI, J.; HEATH, D.; BENNA, S. Evaluating harmonic-induced transformer heating. *IEEE Transactions on Power Delivery*, v. 11, n. 1, p. 305–311, 1996.

BLACKBURN, T.; PHUNG, B.; LIU, Z.; JAMES, R. On-line partial discharge measurement on instrument transformers. In: *Proceedings of 1998 International Symposium on Electrical Insulating Materials. 1998 Asian International Conference on Dielectrics and Electrical Insulation. 30th Symposium on Electrical Insulating Ma.* [S.l.: s.n.], 1998. p. 497–500.

BOHATYREWICZ, P.; PŁOWUCHA, J.; SUBOCZ, J. Condition assessment of power transformers based on health index value. *Applied Sciences*, MDPI, v. 9, n. 22, p. 4877, 2019.

BREIMAN, L. *Machine Learning*, Springer Science and Business Media LLC, v. 45, n. 1, p. 5–32, 2001. Disponível em: <<https://doi.org/10.1023/a:1010933404324>>.

BREZAK, D.; FILIPOVIĆ-GRČIĆ, D. Improvement of ultrasonic method for testing of power transformers. *Procedia Engineering*, v. 202, p. 189–201, 2017. ISSN 1877-7058. Special issue of the 4th International Colloquium "Transformer Research and Asset Management". Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877705817342467>>.

CAMERON, A.; WINDMEIJER, F. An r-squared measure of goodness of fit for some common nonlinear regression models. *Journal of Econometrics*, North-Holland Publishing Company, v. 77, n. 2, p. 329–342, abr. 1997. ISSN 0304-4076.

CHAPMAN, S. J. *Fundamentos de máquinas elétricas*. [S.l.]: AMGH editora, 2013.

CHITNAVIS, K.; BHASME, N. R. Review of critical analysis for life estimation of power transformer. In: *2017 4th International Conference on Power, Control and Embedded Systems (ICPCES)*. [S.l.: s.n.], 2017. p. 1–6.

CIGRE. Advances in dga interpretation. *CIGRE D1/A2 Technical Brochure*, n. 771, p. 1–77, 2019.

CIGRE.GT-A2.05. *Guia de Manutenção para Transformadores de Potência*. [S.l.]: CIGRE, 2013.

CIGRE.GT-A2.23. *Gerenciamento de Dados para Monitoramento e Avaliação da Condição Operativa de Transformadores (GDMT)*. [S.l.]: CIGRE, 2006.

CIGRE.GT-B3/B5.A2.01. *Guia de manutenção centrada na confiabilidade*. [S.l.]: CIGRE, 2017.

CUTLER, A.; CUTLER, D. R.; STEVENS, J. R. Random forests. In: *Ensemble Machine Learning*. Springer New York, 2012. p. 157–175. Disponível em: <https://doi.org/10.1007/978-1-4419-9326-7_5>.

DENG, K.; XIONG, W.; ZHU, L.; ZHANG, H.; LI, Z. Prediction of dissolved gas in power transformer oil based on random forests algorithm. In: *2015 5th International Conference on Electric Utility Deregulation and Restructuring and Power Technologies (DRPT)*. [S.l.: s.n.], 2015. p. 1531–1534.

DUVAL, M. A review of faults detectable by gas-in-oil analysis in transformers. *IEEE Electrical Insulation Magazine*, v. 18, n. 3, p. 8–17, 2002.

DUVAL, M.; DEPABLA, A. Interpretation of gas-in-oil analysis using new iec publication 60599 and iec tc 10 databases. *IEEE Electrical Insulation Magazine*, v. 17, n. 2, p. 31–41, 2001.

FACELI, K.; LORENA, A.; GAMA, J.; ALMEIDA, T. D.; CARVALHO, A. D. *Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina, 2nd Edition*. [S.l.]: LTC, 2021.

FARAG, A.; MOHANDÉS, M.; AL-SHAIKH, A. Diagnosing failed distribution transformers using neural networks. *IEEE Transactions on Power Delivery*, v. 16, n. 4, p. 631–636, 2001.

FLAUZINO, R.; NUNES, I. Health index and hierarchizing scale methodologies for prioritizing on-line monitoring of power transformers and reactors in the brazilian transmission grid. *48th CIGRE SESSION 2020, PARIS*, CIGRE, v. 48, n. A2-309, p. 11, 2020.

FRIEDMAN, J. H. Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, Institute of Mathematical Statistics, v. 29, n. 5, p. 1189–1232, 2001. ISSN 00905364. Disponível em: <<http://www.jstor.org/stable/2699986>>.

- GERON, A. *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow*. [S.l.]: 2nd. ed. O'reilly, 2019. ISBN 978-1-492-03264-9.
- GODINHO, M. *Determinação da tensão interfacial de óleos isolantes usando análise de imagens e espectroscopia no infravermelho próximo*. 96 p. Dissertação (Mestrado) — Universidade Estadual de Goiás - Unidade Universitária de Ciências Exatas e Tecnológicas (UnUCET), Goiás, 2009.
- HAN, J.; KIM, S. Y.; LEE, J.; LEE, W. H. Brain age prediction: A comparison between machine learning models using brain morphometric data. *Sensors*, v. 22, n. 20, 2022. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/22/20/8077>>.
- HERNANDA, I. G. N. S.; MULYANA, A.; ASFANI, D. A.; NEGARA, I. M. Y.; FAHMI, D. Application of health index method for transformer condition assessment. In: *TENCON 2014 - 2014 IEEE Region 10 Conference*. IEEE, 2014. Disponível em: <<https://doi.org/10.1109/tencon.2014.7022433>>.
- IARONKA, O. *Metodologia para dimensionamento do projeto dielétrico de transformadores*. 91 p. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Santa Catarina, 2019.
- IEEE-C57.104. Ieee guide for the interpretation of gases generated in mineral oil-immersed transformers. *IEEE Std C57.104-2019 (Revision of IEEE Std C57.104-2008)*, p. 1–98, 2019.
- IEEE-C57.106. Ieee guide for acceptance and maintenance of insulating mineral oil in electrical equipment. *IEEE Std C57.106-2015 (Revision of IEEE Std C57.106-2006)*, p. 1–38, 2015.
- IEEE-C57.91. Ieee guide for loading mineral-oil-immersed transformers and step-voltage regulators. *IEEE Std C57.91-2011 (Revision of IEEE Std C57.91-1995)*, p. 1–123, 2012.
- ISLAM, M. M.; LEE, G.; HETTIWATTE, S. N. Application of a general regression neural network for health index calculation of power transformers. *International Journal of Electrical Power and Energy Systems*, v. 93, p. 308–315, 2017. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061517307238>>.
- JAHROMI, A.; PIERCY, R.; CRESS, S.; SERVICE, J.; FAN, W. An approach to power transformer asset management using health index. *IEEE Electrical Insulation Magazine*, v. 25, n. 2, p. 20–34, 2009.
- JAISWAL, G. C.; BALLAL, M. S.; TUTAKNE, D. R. Ann based methodology for determination of distribution transformer health status. In: *2017 7th International Conference on Power Systems (ICPS)*. [S.l.: s.n.], 2017. p. 133–138.
- JALBERT, J.; GILBERT, R.; DENOS, Y.; GERVAIS, P. Methanol: A novel approach to power transformer asset management. *IEEE Transactions on Power Delivery*, v. 27, n. 2, p. 514–520, 2012.
- KABIR, F.; FOGGO, B.; YU, N. Data driven predictive maintenance of distribution transformers. In: *2018 China International Conference on Electricity Distribution (CICED)*. [S.l.: s.n.], 2018. p. 312–316.

- KE, G.; MENG, Q.; FINLEY, T.; WANG, T.; CHEN, W.; MA, W.; YE, Q.; LIU, T.-Y. Lightgbm: A highly efficient gradient boosting decision tree. In: GUYON, I.; LUXBURG, U. V.; BENGIO, S.; WALLACH, H.; FERGUS, R.; VISHWANATHAN, S.; GARNETT, R. (Ed.). *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2017. v. 30. Disponível em: <https://proceedings.neurips.cc/paper_files/paper/2017/file/6449f44a102fde848669bdd9eb6b76fa-Paper.pdf>.
- LEAL, A. G.; JARDINI, J. A.; MAGRINI, L. C.; AHN, S. U. Distribution transformer losses evaluation: A new analytical methodology and artificial neural network approach. *IEEE Transactions on Power Systems*, v. 24, n. 2, p. 705–712, 2009.
- LEAUPRASERT, K.; SUWANASRI, T.; SUWANASRI, C.; POONNOY, N. Intelligent machine learning techniques for condition assessment of power transformers. In: *2020 International Conference on Power, Energy and Innovations (ICPEI)*. [S.l.: s.n.], 2020. p. 65–68.
- LIAW, A.; WIENER, M. Classification and Regression by randomForest. *R News*, v. 2, n. 3, p. 18–22, 2002. Disponível em: <<http://CRAN.R-project.org/doc/Rnews/>>.
- MAHRUKH, A. W.; LIAN, G. X.; BIN, S. S. Prediction of power transformer oil chromatography based on lstm and rf model. In: *2020 IEEE International Conference on High Voltage Engineering and Application (ICHVE)*. [S.l.: s.n.], 2020. p. 1–4.
- MARQUES, A. P. *Diagnóstico otimizado de transformadores de potência mediante a integração de técnicas preditivas*. 195 p. Tese (Doutorado) — Universidade Federal de Goiás, Goiás, 2018.
- MARTINS, A. C. P.; SILVA, T. C.; SESSA, C. D.; AL, E. Análise cromatográfica dos gases dissolvidos em óleo mineral isolante - aplicação geral e estudo de caso inovador em transformador. *X WORKSPOT- 10th International Workshop on Power Transformers, Transmission and Distribution Equipment, Substations, Materials and Emerging Technologies*, CIGRE, BR, n. 10, p. 9, 2022.
- MURUGAN, R.; RAMASAMY, R. Understanding the power transformer component failures for health index-based maintenance planning in electric utilities. *Engineering Failure Analysis*, Pergamon, v. 96, p. 274–288, 2 2019. ISSN 1350-6307.
- NAGARAJ, P.; V, M.; K, M. S.; A, N. V. R.; G, D.; C, C. K. R. Ensemble machine learning (grid search and random forest) based enhanced medical expert recommendation system for diabetes mellitus prediction. In: *2022 3rd International Conference on Electronics and Sustainable Communication Systems (ICESC)*. [S.l.: s.n.], 2022. p. 757–765.
- OLIVEIRA, M. *Metodologia para avaliação de transformadores de potência através de Health index e modelo de envelhecimento*. 120 p. Dissertação (Mestrado) — Universidade Federal de Santa Maria, SANTA MARIA, RS, 2021.
- PROKHORENKOVA, L.; GUSEV, G.; VOROBEOV, A.; DOROGUSH, A. V.; GULIN, A. Catboost: unbiased boosting with categorical features. In: BENGIO, S.; WALLACH, H.; LAROCHELLE, H.; GRAUMAN, K.; CESA-BIANCHI, N.; GARNETT, R. (Ed.). *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2018. v. 31. Disponível em: <https://proceedings.neurips.cc/paper_files/paper/2018/file/14491b756b3a51daac41c24863285549-Paper.pdf>.

REMA, G.; CARVALHO, A.; BONATTO, B. D. Análise do estado de transformadores de potência a partir do monitoramento online da condição operativa. *X WORKSPOT-10th International Workshop on Power Transformers, Transmission and Distribution Equipment, Substations, Materials and Emerging Technologies*, CIGRE, BR, n. 10, p. 14, 2022.

ROGERS, R. R. Ieee and iec codes to interpret incipient faults in transformers, using gas in oil analysis. *IEEE Transactions on Electrical Insulation*, EI-13, n. 5, p. 349–354, 1978.

RONCERO-CLEMENTE, C.; ROANES-LOZANO, E. A multi-criteria computer package for power transformer fault detection and diagnosis. *Applied Mathematics and Computation*, v. 319, p. 153–164, 2018. ISSN 0096-3003. Recent Advances in Computing. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0096300317301285>>.

SEDIGHI, A.; KAFIRI, A.; SEHHATI, M.; BEHDAD, F. Life estimation of distribution transformers using thermography: A case study. *Measurement*, v. 149, p. 106994, 2020. ISSN 0263-2241. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0263224119308607>>.

SHENGCHANG, J.; PING, S.; YANMING, L.; DAKE, X.; JUNLING, C. The vibration measuring system for monitoring core and winding condition of power transformer. In: *Proceedings of 2001 International Symposium on Electrical Insulating Materials (ISEIM 2001). 2001 Asian Conference on Electrical Insulating Diagnosis (ACEID 2001). 33rd Symposium on Electrical and Ele.* [S.l.: s.n.], 2001. p. 849–852.

SHIL, P.; ANDERSON, T. Distribution transformer health monitoring and predictive asset maintenance. In: . [S.l.: s.n.], 2019.

Silva, D. G. T.; Silva, H. J.; MARAFAO, F. P.; PAREDES, H. K. M.; GONCALVES, F. A. S. Enhanced health index for power transformers diagnosis. *Engineering Failure Analysis*, v. 126, p. 105427, 2021. ISSN 1350-6307. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1350630721002879>>.

SINGH, J.; SINGH, S.; SINGH, A. Distribution transformer failure modes, effects and criticality analysis (fmeca). *Engineering Failure Analysis*, v. 99, p. 180–191, 2019. ISSN 1350-6307. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1350630717308750>>.

SONI, R.; MEHTA, B. Review on asset management of power transformer by diagnosing incipient faults and faults identification using various testing methodologies. *Engineering Failure Analysis*, Elsevier BV, v. 128, p. 105634, out. 2021. Disponível em: <<https://doi.org/10.1016/j.engfailanal.2021.105634>>.

TAMURA, L. F.; COSTA, E. C. M.; NASCIMENTO, F. A.; BECHARA, R. Análise de falhas em transformadores de potência. *X WORKSPOT- 10th International Workshop on Power Transformers, Transmission and Distribution Equipment, Substations, Materials and Emerging Technologies*, CIGRE, BR, n. 10, p. 9, 2022.

TEIXEIRA, D. A. *Análise das distorções harmônicas – estudo de caso de um sistema industrial*. 128 p. Dissertação (Mestrado) — Programa de Pós-Graduação de Engenharia Elétrica da UFMG, Minas Gerais, 2009.

- TRAN, Q. T.; DAVIES, K.; ROOSE, L.; WIRIYAKITIKUN, P.; JANJAMPOP, J.; SANSEVERINO, E. R.; ZIZZO, G. A review of health assessment techniques for distribution transformers in smart distribution grids. *Applied Sciences*, v. 10, n. 22, 2020. ISSN 2076-3417. Disponível em: <<https://www.mdpi.com/2076-3417/10/22/8115>>.
- TRAN, Q. T. T.; DAVIES, K.; ROOSE, L.; DOAN, B. V.; NGUYEN, N. Q. Online distribution service transformer health assessment using real-time grid energy monitor. In: *2020 IEEE Kansas Power and Energy Conference (KPEC)*. [S.l.: s.n.], 2020. p. 1–6.
- VAISH, R.; DWIVEDI, U.; TEWARI, S.; TRIPATHI, S. Machine learning applications in power system fault diagnosis: Research advancements and perspectives. *Engineering Applications of Artificial Intelligence*, v. 106, p. 104504, 2021. ISSN 0952-1976. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0952197621003523>>.
- WANG, M.; VANDERMAAR, A.; SRIVASTAVA, K. Review of condition assessment of power transformers in service. *IEEE Electrical Insulation Magazine*, v. 18, n. 6, p. 12–25, 2002.
- WILLMOTT, K. Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. *Climate research.*, Inter-Research, Amelinghausen, Germany :, v. 30, n. 1, 2005. ISSN 0936-577X.
- ZHANG, X.; GOCKENBACH, E. Asset-management of transformers based on condition monitoring and standard diagnosis [feature article]. *IEEE Electrical Insulation Magazine*, v. 24, n. 4, p. 26–40, 2008.

APÊNDICE A – Dados de Análises Cromatográficas e Físico-Química de Transformadores para Estudo de Caso

Status da Análise CR: Normal

Equipamento:	Transformador	Motivo:	Manutenção preventiva	Data da Coleta:	20/08/2022
Nº Série:	----	TAG:		Temp. Ambiente (°C):	13
Tensão(kV):	23	Vol. Óleo (Litros):		Temp. Óleo (°C):	17
Potência(kVA):	300	Tipo de Óleo:	óleo mineral isolante	Temp. Amostragem (°C):	17
Fabricante:	----	CDC/Óleo:	em vazio	Umidade Rel. (%):	60
Identificação:	----	Sist. Refrig.:	ONAN	Ponto de Amostragem:	Tampa Inspeção
Ano Fabr.:	2017	Sist. Preserv.:	membrana	Operando:	Sim
Instalação:	Flash	Temp. Enrolamento:	17		

ANÁLISE CROMATOGRÁFICA NBR 7070 - Gases dissolvidos (ppm)	HISTÓRICO DE RESULTADOS			Taxa de Crescimento (% ao mês)	RESULTADO
	-	-	-		
Hidrogênio (H2)	-	-	-	-	75
Oxigênio (O2)	-	-	-	-	5400
Nitrogênio (N2)	-	-	-	-	30800
Metano (CH4)	-	-	-	-	15
Monóxido de Carbono (CO)	-	-	-	-	169
Dióxido de Carbono (CO2)	-	-	-	-	2050
Etileno (C2H4)	-	-	-	-	11
Etano (C2H6)	-	-	-	-	2
Acetileno (C2H2)	-	-	-	-	ND
Total de Gases	-	-	-	-	38522
Total de Gases Combustíveis (TGC)	-	-	-	-	272

Nota1: Atividade de coleta de amostra realizada pelo cliente.

DIAGNÓSTICO

ENSAIO CROMATOGRÁFICO

- Resultados indicam condições normais.
- Reamostragem após um ano.