

UNIVERSIDADE ESTADUAL PAULISTA

FACULDADE DE ENGENHARIA DE BAURU

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**UMA NOVA METODOLOGIA DE CRITICIDADE PARA
GESTÃO E PRIORIZAÇÃO DE TRANSFORMADORES
DE POTÊNCIA A PARTIR DE MÉTODO MULTICRITÉRIO
E ANÁLISE MULTIVARIADA**

ANDRÉ GIFALLI

BAURU

2025

UNIVERSIDADE ESTADUAL PAULISTA

FACULDADE DE ENGENHARIA DE BAURU

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**UMA NOVA METODOLOGIA DE CRITICIDADE PARA
GESTÃO E PRIORIZAÇÃO DE TRANSFORMADORES
DE POTÊNCIA A PARTIR DE MÉTODO MULTICRITÉRIO
E ANÁLISE MULTIVARIADA**

ANDRÉ GIFALLI

Tese de doutorado apresentada à Universidade Estadual Paulista - UNESP como parte dos requisitos para a obtenção do título de Doutor em Engenharia Elétrica

Orientador: Prof. Dr. André Nunes de Souza

Coorientador: Prof. Dr. Danilo Sinkiti Gastaldello

BAURU

2025

G456n Gifalli, André

Uma nova metodologia de criticidade para gestão e priorização de transformadores de potência a partir de método multicritério e análise multivariada / André Gifalli. -- Bauru, 2025

112 p. : il., tabs.

Tese (doutorado) - Universidade Estadual Paulista (UNESP), Faculdade de Engenharia, Bauru

Orientador: André Nunes de Souza

Coorientador: Danilo Sinkiti Gastaldello

1. Transformador de Potência. 2. Criticidade. 3. Análise Multicritério. 4. Análise Multivariada. 5. Aprendizado Supervisionado. I. Título.

ATA DA DEFESA PÚBLICA DA TESE DE DOUTORADO DE ANDRÉ GIFALLI, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.

Aos 14 dias do mês de fevereiro do ano de 2025, às 10h, por meio de Videoconferência, realizou-se a defesa de TESE DE DOUTORADO de ANDRÉ GIFALLI, intitulada **UMA NOVA METODOLOGIA DE CRITICIDADE PARA GESTÃO E PRIORIZAÇÃO DE TRANSFORMADORES DE POTÊNCIA A PARTIR DE MÉTODO MULTICRITÉRIO E ANÁLISE MULTIVARIADA**. A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. ANDRÉ NUNES DE SOUZA (Orientador(a) - Participação Presencial) do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru, Prof. Dr. SHIGEAKI LEITE DE LIMA (Participação Virtual) do(a) Departamento de Engenharia Elétrica / Universidade Federal do Maranhão, Prof. Dr. HÉLIO ELI SUETA (Participação Virtual) do(a) Divisão Científica de Planejamento, Análise e Desenvolvimento Energético / Instituto de Energia e Ambiente - IEE / USP, Prof. Dr. PEDRO DA COSTA JUNIOR (Participação Presencial) do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. LEONARDO NEPOMUCENO (Participação Presencial) do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru. Após a exposição pelo doutorando e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, o discente recebeu o conceito final: APROVADO. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo(a) Presidente(a) da Comissão Examinadora.

Prof. Dr. ANDRÉ NUNES DE SOUZA

IMPACTO POTENCIAL DESSA PESQUISA

Essa pesquisa foi viabilizada pela parceria público-privada entre o Laboratório de Sistemas de Potência e Técnicas Inteligentes (LSISPOTI), da Faculdade de Engenharia de Bauru (FEB) da Universidade Estadual Paulista (UNESP), e a CPFL Energia, por meio do projeto de Pesquisa, Desenvolvimento & Inovação (PD&I) PD-00063-3067/2019. A metodologia desenvolvida, contribui para a gestão do ativo transformador de potência, permitindo a priorização de ativos críticos da empresa com base em critérios técnicos, operacionais e econômicos. Os impactos abrangem desde o aumento da confiabilidade no fornecimento de energia elétrica, essencial para a sociedade, até a otimização de recursos financeiros, promovendo a sustentabilidade econômica e ambiental. De modo geral, os resultados impulsionam avanços nas práticas de gestão de ativos baseadas em dados, promovendo decisões mais assertivas e fundamentadas. Além disso, consolidam a cooperação entre a universidade e a indústria, gerando benefícios diretos para a sociedade e para o setor elétrico.

POTENTIAL IMPACT OF THIS RESEARCH

This research was made possible through the public-private partnership between the Laboratory of Power Systems and Intelligent Techniques (LSISPOTI) at the School of Engineering of Bauru (FEB) of São Paulo State University (UNESP) and CPFL Energia, under the Research, Development Innovation (RDI) project PD-00063-3067/2019. The methodology developed in this thesis contributes to the management of power transformer assets, enabling the prioritization of critical assets within the company based on technical, operational, and economic criteria. The impacts range from increased reliability in electricity supply, which is essential for society, to the optimization of financial resources, promoting economic and environmental sustainability. Overall, the results drive advances in data-driven asset management practices, fostering more assertive and informed decision-making. Furthermore, they strengthen collaboration between academia and industry, delivering direct benefits to society and the power sector.

Dedico este trabalho à minha família, em especial à minha esposa Izabella C. S. Gifalli e aos meus pais e irmãos, por todo amor, apoio, confiança e incentivo em todo trajeto traçado durante este período importante da minha vida.

AGRADECIMENTOS

Agradeço primeiramente a Deus por me dar a oportunidade de desenvolver esta tese, me abençoando com muita saúde e com uma família muito especial que sempre esteve ao meu lado.

Expresso minha mais profunda gratidão ao **Prof. Dr. André Nunes de Souza** e sua família, por quem tenho enorme admiração, carinho e respeito. Sou eternamente grato pela paciência, pelo companheirismo, pelos conselhos, pelas orientações e pelas oportunidades que tornaram possível enfrentar e superar os desafios dessa jornada de pós-graduação. Seu apoio moldou não apenas o meu aprendizado acadêmico, mas também contribuiu significativamente para o meu crescimento como profissional e ser humano.

Agradeço o meu coorientador **Prof. Dr. Danilo Sinkiti Gastaldello** pela amizade, pelo companheirismo e pelas orientações durante essa trajetória.

Agradeço à empresa CPFL Energia por viabilizar o desenvolvimento desta tese e disponibilizar os dados e informações necessárias para o seu desenvolvimento.

Agradeço à **Camila de Freitas Albertin, Floriano Torres Neto, João Carneiro, Talita Mazon e Helen Veloso Vendrameto** pelo apoio, disponibilidade e incentivo ao longo dessa jornada.

Agradeço à todos os integrantes que passaram pelo Laboratório de Sistemas de Potência e Técnicas Inteligentes (LSISPOTI).

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 88887.704285/2022-00 pelo apoio financeiro.

Agradeço muito à minha família, em especial à minha esposa **Izabella Cristina Santana Gifalli** que foi compreensiva e sempre me apoiou. Aos meus pais, Ronaldo e Cecilia, pelo incentivo, compreensão e apoio que tiveram comigo durante o desenvolvimento deste trabalho.

Por fim, agradeço ao programa de Pós-Graduação em Engenharia Elétrica da Universidade Estadual Paulista Júlio de Mesquita Filho - Faculdade de Engenharia de Bauru pela oportunidade de desenvolver esta pesquisa.

“A satisfação está no esforço e não apenas na realização final.”
(Mahatma Gandhi)

RESUMO

A crescente demanda por energia elétrica, aliada a questões ambientais e financeiras, e consequentemente a infraestrutura do sistema, fomenta a necessidade do aprimoramento da gestão de ativos críticos, como os transformadores de potência, fundamentais para a infraestrutura do sistema elétrico. A literatura atual apresenta limitações, como o uso de metodologias de criticidade baseadas exclusivamente em aspectos de manutenção preditiva, métodos normativos e abordagens unidimensionais, como a vida útil do equipamento, sem integrar outros aspectos técnicos, operacionais e econômicos. Nesse contexto, este trabalho teve como objetivo desenvolver uma nova metodologia de criticidade para gestão e priorização de ativos, utilizando um método multicritério, análise multivariada e aprendizado supervisionado. Para alcançar esse objetivo, foram analisados dados técnicos, operacionais e econômicos de 355 transformadores de potência em operação. A classificação e determinação dos ativos críticos são baseadas no conceito da matriz de risco, que relaciona a probabilidade e o impacto dessa falha. O índice do impacto é calculado utilizando o método multicritério de Análise Hierárquica dos Processos (AHP), enquanto que para a probabilidade de falha é considerado o índice de saúde dos transformadores. Devido à subjetividade envolvida na atribuição dos pesos das variáveis neste processo, foi desenvolvido um algoritmo classificador baseado no método *k-Nearest Neighbors* (KNN) combinado com o método de análise multivariada (*Principal Component Analysis* - PCA). Os resultados indicam que a aplicação do método AHP promoveu a colaboração entre diferentes setores da concessionária, possibilitando o estabelecimento de critérios claros para determinar os parâmetros de maior impacto e ponderar seus respectivos pesos. Contudo, a subjetividade no processo de definição dos pesos ainda representa um desafio. Para superar essa limitação, foram integrados os métodos KNN e PCA, permitindo a redução da dimensionalidade do problema e a classificação da criticidade de forma supervisionada. Por fim, os resultados obtidos permitem que os gestores de manutenção identifiquem os ativos críticos que requerem monitoramento prioritário, possibilitando uma análise da criticidade real dos equipamentos. Além disso, a metodologia auxilia na criação de cenários de investimentos de médio e longo prazo, promovendo maior previsibilidade nos gastos operacionais e de capital. Essa abordagem também contribui para a preservação ambiental, ao mitigar o risco de falhas catastróficas e seus impactos.

Palavras-chave: Transformador de Potência, Criticidade, Análise Multicritério, Análise Multivariada, Aprendizado Supervisionado.

ABSTRACT

The increasing demand for electricity, combined with environmental and financial concerns and the consequent impact on system infrastructure, fosters the need to enhance the management of critical assets such as power transformers, which are fundamental to the electrical system infrastructure. The current literature presents limitations, such as the use of criticality methodologies based exclusively on predictive maintenance aspects, normative methods, and one-dimensional approaches, such as equipment lifespan, without integrating other technical, operational, and economic factors. In this context, this study aimed to develop a new criticality methodology for asset management and prioritization, using a multicriteria method, multivariate analysis, and supervised learning. To achieve this objective, technical, operational, and economic data from 355 power transformers in operation were analyzed. The classification and determination of critical assets are based on the risk matrix concept, which relates the probability of failure to its impact. The impact index is calculated using the Analytic Hierarchy Process (AHP) multicriteria method, while the failure probability is assessed based on the transformer health index. Due to the subjectivity involved in assigning variable weights in this process, a classification algorithm was developed based on the *k-nearest neighbors algorithm (KNN)* combined with the *Principal Component Analysis (PCA)* method. The results indicate that applying the AHP method fostered collaboration among different sectors of the utility, enabling the establishment of clear criteria to determine the most impactful parameters and assign their respective weights. However, subjectivity in defining these weights remains a challenge. To overcome this limitation, the *KNN* and *PCA* methods were integrated, allowing for dimensionality reduction and supervised classification of criticality. Finally, the obtained results enable maintenance managers to identify critical assets requiring priority monitoring, allowing for a more precise assessment of equipment criticality. Additionally, the proposed methodology supports the creation of medium- and long-term investment scenarios, enhancing the predictability of operational and capital expenditures. This approach also contributes to environmental preservation by mitigating the risk of catastrophic failures and their impacts.

Keywords: Power Transformers, Criticality, Multicriteria Analysis, Multivariate Analysis, Supervised Learning.

LISTA DE FIGURAS

2.1	Estrutura Básica de um Transformador de Potência a óleo.	32
2.2	Ciclo de Operação e de Manutenção de Transformadores.	32
2.3	Concentrações Relativas de Gases por Temperatura e Tipos de falhas.	35
2.4	Descrição de uma Matriz de Risco.	37
3.1	Publicações Entre 2010 e 2024 na Base <i>Scopus</i>	39
3.2	Mapa Sobreposto de Evolução das Áreas de Pesquisa por Período.	41
3.3	Diagrama Estratégico do Tema Motor para o Período 2020 a 2024.	42
3.4	Modelo Representativo dos Parâmetros que Compõem o <i>HI</i> de Transformadores de Potência.	44
3.5	Metodologia de Manutenção Baseada no Risco.	47
3.6	Estrutura para Tomada de Decisão de Manutenções em Transformadores Operando.	48
3.7	Metodologia <i>ITFM</i>	49
4.1	Modelo de Estrutura Hierárquica - AHP.	52
4.2	Representação de Diferentes Padrões de Distribuição em um <i>Q-Q Plot</i>	60
4.3	Exemplo do Método <i>KNN</i>	63
5.1	Fluxograma da Metodologia do Método Multicritério.	67
5.2	Distribuição dos Índices de Impacto para os 355 Transformadores.	70
5.3	Fluxograma da Metodologia do Cálculo do Índice de Saúde do Transformador.	71
5.4	Matriz de Risco para um Transformador com (I_{SAT}) igual a 70 e (I_{IMP}) igual a 33.	74

5.5	Fluxograma da Metodologia para Classificação da Criticidade Utilizando os Métodos <i>PCA</i> e <i>KNN</i>	75
6.1	Histogramas e <i>Q-Q Plots</i> das Variáveis CO ₂ , Relação DEC, Relação FEC e Número de Clientes.	80
6.2	Histogramas e <i>Q-Q Plots</i> das variáveis C ₂ H ₆ , CO, Tensão Interfacial e Valor do Ativo Societário.	81
6.3	Matriz de Correlação dos Critérios Relacionados ao Índice de Impacto.	82
6.4	Matriz de Correlação dos Critérios Relacionados ao Índice de Saúde.	83
6.5	Representação Percentual das Separações por Classe: Número de Clientes Atendidos, Distância da Base e Potência Nominal do Transformador.	84
6.6	Representação Percentual das Separações por Classe: Valor do Ativo Societário, Idade, Relação DEC e FEC.	85
6.7	Matriz de Comparação Paritária Consolidada.	86
6.8	Pesos Consolidados de Cada Critério com os Desvios Padrões do <i>EVM</i>	87
6.9	Gráfico <i>Boxplot</i> do Índice de Impacto dos Transformadores.	88
6.10	1º Gráfico <i>Boxplot</i> dos Critérios de Impacto para os Índices: Muito Baixo e Muito Alto	89
6.11	2º Gráfico <i>Boxplot</i> dos Critérios de Impacto para os Índices: Muito Baixo e Muito Alto	90
6.12	Distribuição dos Índices de Saúde para os 355 Transformadores.	92
6.13	Matriz de Risco dos 355 Transformadores.	93
6.14	Gráfico <i>Scree Plot</i> das Componentes Principais.	94
6.15	Projeção dos Coeficientes das Componentes Principais e Gráfico (<i>Biplot</i>).	95
6.16	Projeção dos Coeficientes das Componentes Principais Classificados Incorretamente.	96
6.17	Matriz de Confusão da Etapa de Treinamento - <i>KNN</i>	97
6.18	Matriz de Confusão da Etapa de Teste - <i>KNN</i>	97

6.19	Distribuição das Amostras Originais e Amostras Sintéticas Criadas pelo Método <i>SMOTE</i> no Espaço de 3 Dimensões (CP1, CP2 e CP3).	99
6.20	Matriz de Confusão da Etapa de Treinamento - <i>KNN-SMOTE</i>	99
6.21	Matriz de Confusão da Etapa de Teste - <i>KNN-SMOTE</i>	100
6.22	Matriz de Confusão do Algoritmo Classificador para os 355 Transformadores. .	101
6.23	<i>Dashboard</i> do Sistema Relacionado à Criticidade dos Transformadores. . . .	103

LISTA DE TABELAS

3.1	Descritores de Busca na Base <i>Scopus</i> e Dados de Co-citação.	39
5.1	Valores e Notas (w') dos Grupos Para Cada Critério: Número de Clientes, Distância da Base, Potência Nominal, Valor Ativo Societário e FEC.	69
5.2	Valores e Notas (w') dos Grupos Para Cada Critério: DEC, Idade, Subestação (SE) Transmissão Risco Regulatório e Cargas Críticas.	69
5.3	Relações para Cálculo do FC	72
5.4	Pontuações (Si) e Pesos (Wi) para o Cálculo do AGD	72
5.5	Pontuações (Si') e Pesos (Wi') para o Cálculo do AFQ	72
5.6	Notas para as Condições dos Fatores FC , AGD e AFQ	73
6.1	Resultados dos Indicadores de Consistência dos Julgamentos Paritários.	87
6.2	Valores Médios do Parâmetro (S/S_n) e Quantidades das Condições - (FC).	91
6.3	Valores Médios dos Parâmetros e Quantidades das Condições - (AFQ).	91
6.4	Média dos Critérios do Fator (AGD) e Quantificação das Condições.	92
6.5	Coeficientes das Componentes Principais (Autovetores).	94
6.6	Métricas de Desempenho do Classificador da Criticidade dos Transformadores.	101

LISTA DE QUADROS

2.1	Periodicidades e Tolerância para a Realização das Atividades de Manutenção dos Transformadores e Autotransformadores.	34
3.1	Critérios, Pesos e Pontuações do <i>HI</i>	45
4.1	Escala Fundamental de Saaty.	53
5.1	Índice de Saúde e Expectativa de Vida de Transformadores de Potência.	73
6.1	Tipos de Variáveis Utilizadas na Metodologia.	79

LISTA DE SIGLAS

AHP – Análise Hierárquica dos Processos
AGD – Fator de Análise de Gases Dissolvidos
AFQ – Fator de Análise Físico-Química
ANN – *Artificial Neural Network*
BP-NN – *Back Propagation Neural Network*
CAPEX – *Capital Expenditure*
CP – Componentes Principais
DEC – Duração Equivalente de Interrupção por Unidade Consumidora
DGA – *Dissolved Gas Analysis*
FC – Fator de Carregamento
FEC – Frequência Equivalente de Interrupção por Unidade Consumidora
FMEA – *Failure Mode and Effects Analysis*
GA – Gestão de Ativos
GCI – *Geometric Consistency Index*
GEP – *Gene Expression Programming*
GRNN – *General Regression Neural Network*
HI – *Health index*
IA – Inteligência Artificial
IC – Índice de Consistência
IoT – *Internet of things*
ITFM – *Integrated Transformer Fleet Management*
kNN – *k-Nearest Neighbors*
KMO – *Kaiser-Meyer-Olkin*
MBC – Manutenção Baseada na Condição
MBT – Manutenção Baseada no Tempo
MCBT – Monitoramento da Condição Baseada no Tempo
MCC – Manutenção Centrada na Confiabilidade

MCOL – Monitoramento da Condição Online

MCPSE – Manual de Controle Patrimonial do Setor Elétrico

PCA – *Principal Component Analysis*

PAS-55 – Especificação Disponível Publicamente 55

PSO – *Particle Swarm Optimization*

RC – Razão de Consistência

RTP – Revisão Tarifária Periódica

SE – Subestação

LISTA DE SÍMBOLOS

- A – Matriz de comparação paritária no método AHP.
- AGD – Fator de Análise de gases dissolvidos.
- AFQ – Fator de Análise físico-química.
- a_{ij} – Elemento i, j da matriz de comparação paritária.
- A_{ij} – Elemento consolidado da matriz agregada.
- CR – Razão de Consistência no método AHP.
- $d(x, y)$ – Distância Euclidiana entre dois pontos x e y .
- d_{ij} – Diferença entre postos no coeficiente de Spearman.
- F_C – Fator de carregamento.
- GCI – Índice de consistência geométrica.
- G – Número de grupos calculado pelo método de Sturges.
- H_α – Entropia de Shannon relacionada à diversidade de opiniões.
- H_β – Entropia de Shannon para a variação entre prioridades.
- H_γ – Entropia de Shannon para prioridades agregadas.
- I_{IMP} – Índice de impacto de um transformador.
- I_{SAT} – Índice de saúde de um transformador.
- k – Número de vizinhos mais próximos no algoritmo KNN.
- MRE – Erro relativo médio.
- N – Ordem da matriz de comparação ou número de critérios.
- N' – Número total de observações (transformadores avaliados).
- p_{ij} – Prioridade normalizada no método AHP.
- R – Transformador avaliado na base de dados.
- r_{ij} – Coeficiente de correlação entre variáveis i e j .
- r_s – Coeficiente de correlação de Spearman.
- S – Carregamento médio mensal de um transformador.
- S^* – Indicador de consenso no método AHP.
- S_n – Potência nominal do transformador.
- s_{ij} – Coeficiente de correlação parcial entre variáveis i e j .
- S_i – Pontuação atribuída para cada faixa de valores na análise AGD ou AFQ .
- u_j – Componente principal j no PCA.
- $W'_{t,R}$ – Nota atribuída ao grupo do critério t para o transformador R .
- W_i – Peso de cada gás ou parâmetro na análise AGD ou AFQ .
- w_i – Peso relativo do critério i .

w_j – Autovetor correspondente à componente principal j .
 w_k – Peso atribuído ao participante k .
 w_t – Peso relativo associado ao critério t , derivado do AHP.
 x_{norm} – Valor normalizado utilizando o método Min-Max.
 Z – Dados projetados no espaço das componentes principais.
 Δw_i – Erro relativo no cálculo dos pesos.
 λ_j – Autovalor associado à componente principal j .
 λ_{max} – Maior autovalor da matriz de comparação.
 $\bar{x}$ – Média de uma variável x .
 Σ – Matriz de covariância usada no *PCA*.

SUMÁRIO

CAPÍTULO 1 –INTRODUÇÃO	23
1.1 Contextualização	23
1.2 Relevância e Motivação	24
1.3 Objetivos	25
1.4 Metodologia da Pesquisa	26
1.5 Originalidade	26
1.6 Publicações Relacionadas à Tese	27
1.7 Estrutura do Documento	28
 CAPÍTULO 2 –FUNDAMENTAÇÃO TEÓRICA: GESTÃO DO ATIVO TRANSFOR- MADOR DE POTÊNCIA	 29
2.1 Considerações Iniciais	29
2.2 Gestão de Ativos	29
2.3 Transformador de Potência	31
2.3.1 Degradação do Sistema Isolante	34
2.3.2 Risco	36
2.4 Considerações Finais	37
 CAPÍTULO 3 –REVISÃO BIBLIOGRÁFICA	 38
3.1 Considerações Iniciais	38
3.2 Análise Quantitativa e Qualitativa	38
3.3 Estudo de Anterioridade	43
3.3.1 Índice de Saúde	43
3.3.2 Criticidade	46

3.4	Considerações Finais	50
CAPÍTULO 4 – MÉTODOS DE ANÁLISE MULTICRITÉRIO, ANALISE MULTI-VARIADA E APRENDIZADO SUPERVISIONADO		51
4.1	Considerações Iniciais	51
4.2	Análise Multicritério	51
4.2.1	Estrutura Hierárquica	52
4.2.2	Comparações Paritárias	52
4.2.3	Pesos Relativos Usando o Método do Principal Autovetor	54
4.2.4	Consistência das Comparações	55
4.3	Análise Multivariada e Aprendizado Supervisionado	57
4.3.1	Análise Exploratória dos Dados	58
4.3.2	Análise de Componentes Principais	60
4.3.3	<i>K-Nearest Neighbors (KNN)</i>	62
4.3.4	<i>Synthetic Minority Oversampling Technique (SMOTE)</i>	63
4.4	Considerações Finais	65
CAPÍTULO 5 –DIRETRIZES METODOLÓGICAS		66
5.1	Considerações Iniciais	66
5.2	Análise Hierárquica dos Processos (AHP)	66
5.2.1	Método do Cálculo do Índice de Impacto - (<i>I_{IMP}</i>)	66
5.3	Método do Cálculo do Índice de Saúde - (<i>I_{SAT}</i>)	70
5.4	Criticidade	73
5.5	Análise de Componentes Principais e Algoritmo <i>KNN</i>	74
5.6	Considerações Finais	77
CAPÍTULO 6 –RESULTADOS		78
6.1	Considerações Iniciais	78
6.2	Análise Exploratória dos Dados	78
6.3	Análise Multicritério	86
6.3.1	Matriz de Comparação Paritária, Pesos Relativos e Indicadores de Consistência	86

6.3.2	Índices de Impacto - (I_{IMP})	88
6.4	Índices de Saúde - (I_{SAT})	91
6.5	Criticidades dos Transformadores	93
6.6	Análise Multivariada e Aprendizado Supervisionado	93
6.6.1	Algoritmo de Classificação KNN	96
6.6.2	Algoritmo de Classificação KNN e $SMOTE$	98
6.7	Aplicação Prática da Metodologia	102
6.8	Considerações Finais	104
CAPÍTULO 7 –CONCLUSÕES		105
7.1	Sugestões para Continuidade do Trabalho	106
REFERÊNCIAS		107

Capítulo 1

INTRODUÇÃO

1.1 Contextualização

A energia elétrica é um insumo básico para a humanidade, integrando os seres humanos na busca do desenvolvimento social, político e econômico. No cenário atual, observa-se uma crescente demanda por energia de qualidade, caracterizada por maior confiabilidade, continuidade no fornecimento e custos reduzidos. Esta demanda, associada ao aumento da complexidade e da extensão das redes elétricas, impõe desafios significativos ao setor, que necessita adotar metodologias e tecnologias para mitigar falhas em equipamentos e otimizar a operação dos sistemas CGEE (2017).

Uma pesquisa realizada em seis órgãos reguladores, quatro empresas de tecnologia da informação e trinta empresas de energia, que representaram 56% do consumo e 70% da capacidade instalada na América Latina em 2014, revelou que quase 70% das empresas já praticam análises de riscos e econômicas dos ativos críticos. Esse cenário reflete a crescente adoção de sistemas de Gestão de Ativos (GA), alinhados às diretrizes da *Publicly Available Specification (PAS-55)* e da norma ISO 55000, que preconizam o equilíbrio entre custo, risco e desempenho ao longo do ciclo de vida dos ativos KARDEC et al. (2014), GLYCON e ZAMPOLL (2012).

A implantação desses sistemas inclui ferramentas como sistema de informação geográfico e sistemas supervisórios, que permitem a coleta, armazenamento e análise em tempo real dos dados, facilitando o diagnóstico da condição dos ativos e a tomada de decisões baseadas em indicadores de desempenho, como taxa de falhas, custo do ciclo de vida e confiabilidade. Além disso, boas práticas, como inspeções periódicas e auditorias, garantem que as manutenções ocorram de forma planejada e com a periodicidade adequada. Empresas que implementam essas metodologias conseguem antecipar falhas, prolongar a vida útil dos equipamentos e otimizar os custos de manutenção e substituição, assegurando maior confiabilidade operacional e alinhamento estratégico com os objetivos empresariais. Contudo, o processo ainda enfrenta desafios, como integração de sistemas computacionais e altos custos iniciais de implantação e a complexidade no controle sistematizado das informações ZAMPOLLI et al. (2011, 2014).

No contexto dos transformadores de potência, desafios significativos incluem a necessidade de aprimorar a qualidade e a padronização de dados coletados, reduzir erros de medição e aumentar a precisão no diagnóstico de falhas incipientes. Além disso, há a necessidade de avançar no uso de ferramentas de mineração de dados para lidar com informações incompletas e incorporar tecnologias emergentes, como (*Internet of Things - IoT*),

computação em nuvem e *big data*. A integração de diferentes métodos de avaliação, considerando fatores externos também se mostra essencial, uma vez que múltiplos fatores influenciam diretamente no desempenho desses ativos. Tecnologias modernas, como sensores inteligentes e sistemas de autodiagnóstico, têm potencial para transformar a gestão preditiva e a detecção de falhas, embora enfrentem barreiras relacionadas a custos e complexidade de implementação.

Diante desse cenário, embora métodos tradicionais de manutenção preditiva e preventiva, aliados ao planejamento anual de manutenção, já contribuam para a confiabilidade operacional dos transformadores, é necessário avançar para uma abordagem mais integrada de gestão de ativos. Esse conceito deve oferecer aos especialistas uma visão holística, que permita não apenas maximizar a confiabilidade dos equipamentos, mas também gerar valor estratégico para as empresas ao equilibrar custos, riscos e desempenho ao longo do ciclo de vida dos ativos.

Esses desafios estão diretamente relacionados ao objetivo deste trabalho, que propõe uma nova metodologia de criticidade para transformadores de potência, voltada para superar limitações como o elevado número de resultados a serem analisados, a subjetividade nos processos decisórios e a falta de integração de variáveis multidisciplinares. Ao integrar ferramentas de análise multicritério e análise multivariada, a metodologia possibilita uma análise mais detalhada do estado real dos equipamentos, priorizando os ativos críticos para monitoramento e manutenção. Isso facilita não apenas o planejamento de ações de curto prazo, mas também a elaboração de cenários estratégicos de médio e longo prazo para substituição de ativos e otimização de recursos. Dessa forma, o trabalho contribui para uma gestão de ativos, sustentável e alinhada às exigências operacionais e financeiras do setor elétrico.

1.2 Relevância e Motivação

Os transformadores de potência são ativos críticos do sistema elétrico, desempenhando um papel fundamental na transmissão e distribuição de energia. Eles representam um dos maiores investimentos imobilizados das subestações, com vida útil estimada entre 20 e 35 anos, podendo ser prorrogada para até 60 anos quando submetidos a manutenções adequadas ABU-ELANIEN e SALAMA (2010), WANG, VANDERMAAR e SRIVASTAVA (2002). No entanto, fatores como a degradação natural do sistema isolante e os estresses eletromecânicos decorrentes de curtos-circuitos limitam sua confiabilidade, exigindo uma gestão eficiente para evitar falhas catastróficas ZHONG (2011).

Segundo dados do Banco de Preços Regulatório EPE (2022), o investimento em *Capital Expenditure* (CAPEX) para um transformador de potência de 100 MVA é, em média, de aproximadamente 13,5 milhões de reais. Portanto, uma falha deste ativo acarreta um impacto financeiro direto nessa ordem de magnitude, além de potenciais impactos operacionais e de segurança.

Esses equipamentos tornaram-se significativamente mais confiáveis nos últimos anos, resultado do esforço contínuo da indústria em aprimorar a tecnologia e as práticas de gestão.

Uma pesquisa realizada por CIGRE (2024) analisou mais de 35 mil transformadores em operação, fabricados entre 1919 e 2020, registrando 1.204 falhas e 1.916 falhas graves (descarte do equipamento) de 66 concessionárias em 27 países. O estudo demonstrou uma melhoria significativa na confiabilidade dos transformadores de potência ao longo dos anos, com a taxa média de falhas igual a 0,27%.

As falhas relacionadas à parte ativa do transformador (37%) mostraram-se o principal contribuinte para as

falhas graves, independentemente da classe de tensão do transformador. Além disso, a taxa de falha aumenta conforme a classe de tensão se eleva, sendo mais alta em transformadores na classe de tensão de 700 kV (1,46%) e mais baixa (0,23%) na classe de 138 a 230 kV.

Ainda segundo a pesquisa, aproximadamente um quarto de todas as falhas graves resultaram em explosão e, dessas, houve uma probabilidade de 50% de ocorrência de incêndio. A proteção diferencial e o relé *Buchholz* são os dispositivos mais comuns em todas as classes de tensão para detecção de falhas graves.

Apesar dos avanços nas práticas de manutenção preditiva e preventiva, as metodologias atuais de gestão desses ativos apresentam limitações importantes que dificultam a tomada de decisões estratégicas pelos gestores. As principais limitações identificadas na literatura (capítulo 2) incluem:

- **Dificuldade na Identificação de Variáveis Relevantes para Criticidade de Transformadores:** A identificação de variáveis relevantes na criticidade de transformadores é um desafio significativo, especialmente em empresas que gerenciam um grande número de ativos. A principal dificuldade reside no número elevado de dados e informações disponíveis, provenientes de ensaios técnicos, como grau de polimerização, cromatografia gasosa físico-químico, além de dados técnicos, operacionais e econômicos;
- **Falta de integração multivariada:** A maioria dos estudos considera apenas algumas variáveis, concentrando-se em aspectos normativos e em métodos tradicionais, como a vida útil do equipamento, sem incorporar uma análise multidisciplinares que integre fatores técnicos, operacionais e econômicos; e
- **Subjetividade na tomada de decisão:** Métodos baseados na avaliação de especialistas tendem a ser subjetivos e não padronizados, pois dependem de conhecimentos específicos e de experiências prévias, o que pode dificultar a priorização objetiva dos transformadores críticos.

Diante desse cenário, a presente pesquisa tem como motivação o desenvolvimento de uma nova metodologia que busca preencher essas lacunas existentes. Com essa proposta, espera-se oferecer uma ferramenta de suporte estratégico para os gestores, capaz de aprimorar a classificação da criticidade, otimizar os planos de manutenção e contribuir para a sustentabilidade e eficiência do sistema elétrico.

1.3 Objetivos

O objetivo desta tese consiste em desenvolver uma nova metodologia de criticidade que auxilie na priorização e gestão de transformadores de potência, utilizando métodos de análise multicritério, multivariáveis e aprendizado supervisionado. Para atingir este objetivo, as seguintes etapas foram definidas:

- **Revisão sistemática da literatura e estudo bibliométrico:** Elaboração de uma revisão abrangente da literatura, utilizando análises quantitativas e qualitativas para identificar as principais lacunas nas metodologias atuais e mapear os avanços científicos relacionados às metodologias de manutenção, índice de saúde e criticidade de transformadores de potência;
- **Levantamento e obtenção de dados:** Coleta e construção de um banco de dados estruturado com informações técnicas, operacionais e econômicas de 355 transformadores de potência de uma distribuidora com concessão no estado de São Paulo;

- **Estudo e seleção de métodos de análise multicritério, multivariada e aprendizado supervisionado:** Análise detalhada e seleção dos métodos de análise multicritério multivariada e aprendizado supervisionado com base em suas características estatísticas, capacidade de redução de dimensionalidade e identificação de padrões para a classificação da criticidade dos ativos;
- **Análise exploratória dos dados:** Realização de uma análise exploratória preliminar para identificar padrões, variáveis relevantes e possíveis correlações entre os dados, servindo de base para a construção do modelo;
- **Implementação dos modelos/algoritmos:** Implementação dos modelos em linguagem *Python*. A etapa envolve a definição dos hiperparâmetros e ajuste dos modelos; e
- **Interpretação e validação do modelo:** Análise dos resultados obtidos, com interpretação das variáveis críticas, avaliação do ajuste geral do modelo e validação de sua aplicabilidade prática na priorização da criticidade e gestão dos transformadores.

Com estas etapas, busca-se fornecer uma ferramenta que integre múltiplas variáveis e permita uma avaliação holística dos transformadores, mitigando a subjetividade na priorização e possibilitando a criação de cenários estratégicos de médio e longo prazo para substituição e repotencialização desses ativos críticos.

1.4 Metodologia da Pesquisa

A metodologia de investigação científica considerada neste trabalho, utiliza métodos sistemáticos de revisão da literatura e bibliométricos para possibilitar uma análise objetiva dos resultados, evitando viés tendencioso da pesquisa de revisão. Com isso, foram definidos questionamentos para o campo científico, estruturando duas questões:

- Qual é o estado da arte nas práticas de gestão do ativo transformador de potência?
- Quais processos, métodos e ferramentas são utilizados para classificar o nível de criticidade destes equipamentos?

Esses questionamentos foram descritos como pontos de pesquisa A - Gestão de Ativos e B - Criticidade. Para realizar a análise bibliométrica, foi utilizado o *software SciMAT* que segundo COBO et al. (2012), além de ser um *software* de mapeamento científico de código aberto, oferece métodos, algoritmos e medições de qualidade e desempenho para realização de todos os estágios do mapeamento científico, desde o pré-processamento dos dados até a visualização dos resultados.

1.5 Originalidade

A originalidade desta tese está no desenvolvimento de uma nova metodologia de criticidade para gestão e priorização de transformadores de potência a partir de análise multicritério, multivariada e aprendizado supervisionado.

Na literatura são encontradas metodologias de criticidade que consideram poucas variáveis de análise e que normalmente estão atreladas apenas aos aspectos de manutenção preditiva, pois neste caso são considerados métodos normativos na tomada de decisão. Além disso, alguns trabalhos utilizam o conceito de vida útil do equipamento como fator preponderante na atribuição do nível de criticidade.

Com isso, essa pesquisa propõe a utilização de um método de análise multicritério, facilitando a escolha de variáveis que estão presentes no processo de gestão dos transformadores, tais como: técnicas, econômicas e operacionais em virtude da complexidade na classificação crítica destes ativos, pois na maioria das vezes essas variáveis surgem de forma simultânea, dificultando a identificação de uma correlação.

Como os métodos de análise multicritério dependem, exclusivamente, das experiências dos especialistas para classificação das variáveis mais significativas na análise da criticidade, empregou-se nesta tese um algoritmo classificador supervisionado (*KNN*) e um método de análise multivariada (*PCA*).

1.6 Publicações Relacionadas à Tese

1. GIFALLI, André; BONINI NETO, Alfredo; NUNES DE SOUZA, André; PINAL DE MELLO, Renan; IKESHOJI, Marco Akio; GARBELINI, Enio; TORRES NETO, Floriano. Fault detection and normal operating condition in power transformers via pattern recognition artificial neural network. *Applied System Innovation*, v. 7, p. 41, 2024;
2. GIFALLI, André; NUNES DE SOUZA, André; SINKITI GASTALDELLO, Danilo. Análise multivariada de atributos de transformadores de potência. In: 2º Congresso da Pós-graduação da Faculdade de Engenharia de Bauru, 2023, Bauru-SP;
3. TORRES NETO, Floriano; MAZON, Talita; NUNES DE SOUZA, André; SINKITI GASTALDELLO, Danilo; GIFALLI, André; NASCIMENTO SIMÕES, Agnes. Nanotecnologia e ferramentas inteligentes em monitoramento de transformadores de potência. In: Prêmio Nacional de Gestão de Ativos Engenheiro Amauri Reigado, 2022;
4. GIFALLI, André; NUNES DE SOUZA, André; SINKITI GASTALDELLO, Danilo; IKESHOJI, Marco Akio; CARNEIRO, João Carlos; TORRES, Floriano; TAVARES, Afonso Cesar. Criticality methodology for power transformer maintenance prioritization through multicriteria methods. In: CLAGTEE 2022, XIV Latin-American Congress on Electricity Generation and Transmission, 2022, Rio de Janeiro;
5. GIFALLI, André; NUNES DE SOUZA, André; SINKITI GASTALDELLO, Danilo. Desenvolvimento de uma metodologia de criticidade para priorização da manutenção de transformadores através de método multicritério e análise multivariada. In: 1º Congresso da Pós-graduação da Faculdade de Engenharia de Bauru, 2022, Bauru-SP;
6. GIFALLI, André; NUNES DE SOUZA, André; SINKITI GASTALDELLO, Danilo; IKESHOJI, Marco Akio; SANTANA, Gustavo Vinicius; VELOSO VENDRAMETO, Helen. Impactos da gestão de ativos de transformadores de potência na qualidade da energia elétrica. In: XIV Conferência Brasileira sobre Qualidade da Energia Elétrica, 2021; e
7. GIFALLI, André; NUNES DE SOUZA, André; SINKITI GASTALDELLO, Danilo. Desenvolvimento de metodologia para análise de criticidade de transformadores de potência utilizando algoritmos de aprendizagem de máquina. In: X Seminário da Pós-graduação em Engenharia Elétrica, 2020, Bauru-SP.

1.7 Estrutura do Documento

O presente trabalho está dividido nos seguintes capítulos:

- **Capítulo 2:** Neste capítulo é apresentada uma breve fundamentação teórica sobre a importância do ativo transformador de potência e as principais diretrizes utilizadas para a gestão desses ativos;
- **Capítulo 3:** Neste capítulo são apresentados os resultados da revisão sistemática da literatura, destacando os trabalhos de maior relevância relacionados a metodologia de criticidade, vida útil e matriz de risco para gestão e priorização de transformadores de potência;
- **Capítulo 4:** Neste capítulo é apresentada uma breve revisão bibliográfica sobre os métodos de análise multicritério, aprendizado supervisionado e análise multivariada. Além disso, apresentam-se também conceitos sobre análise exploratória de dados e métricas de desempenho de algoritmos de aprendizado de máquina.
- **Capítulo 5:** Neste capítulo as diretrizes metodológicas propostas para a classificação da criticidade dos transformadores de potência são descritas;
- **Capítulo 6:** Este capítulo apresenta os resultados obtidos a partir da metodologia descrita no capítulo anterior; e
- **Capítulo 7:** Este capítulo apresenta as conclusões e diretrizes para a continuidade da pesquisa.

Capítulo 2

FUNDAMENTAÇÃO TEÓRICA: GESTÃO DO ATIVO TRANSFORMADOR DE POTÊNCIA

2.1 Considerações Iniciais

Os transformadores de potência são ativos inerentes ao funcionamento do Sistema Elétrico de Potência (SEP) e a saída de operação deste equipamento, seja ele de subestação de transmissão ou subestação de distribuição, pode causar impactos financeiros indesejáveis para as concessionárias, ou seja, as empresas públicas ou privadas do setor elétrico consideram que o gerenciamento desses ativos é de extrema importância, pois está relacionado à forma de administrar os riscos com eficiência, tomada de decisões de investimentos capazes de acarretar o maior rendimento possível, reduzir perdas e garantir confiabilidade e qualidade dentro de um mercado.

Este capítulo tem o objetivo de apresentar uma breve fundamentação teórica das principais diretrizes relacionadas à gestão de ativos, metodologias de manutenção de transformadores de potência e critérios para diagnóstico de falhas relacionadas à degradação do sistema de isolamento interno.

2.2 Gestão de Ativos

O processo de Gestão de Ativos (GA) é uma atividade focada nos ativos tangíveis (sistemas e equipamentos) da empresa. No caso do transformador de potência, o processo de gestão engloba atividades como: aquisição; comissionamento; operação; manutenção; modernização; descomissionamento e descarte. Esse processo fomenta a agregação de valor, equilibrando os custos financeiros, ambientais e sociais, riscos, qualidade de serviços e desempenho. Além disso, a tomada de decisões estratégicas, relacionadas às fases do ciclo de vida do investimento, é de extrema importância, visto que é um equipamento de alto valor agregado AMADI-ECHENDU e MAFUTSANA (2016).

O documento que deu origem às discussões em nível global sobre GA foi a *British Standards Institution (BSI)* - PAS 55, elaborado em 2004 pelo *Institute of Asset Management (IAM)* a partir de uma necessidade de linguagem comum sobre o assunto, proposta em um seminário conduzido no Reino Unido no ano de 2002. Posteriormente, em 2008 o documento foi revisado com a participação de inúmeras organizações, países e indústrias. A PAS 55

apresenta diretrizes para boas práticas de GA, abrangendo estratégias de manutenção do ciclo de vida.

O documento PAS 55 foca na necessidade de efetuar um planejamento estratégico (planejar), executar e implementar os projetos (executar), elaborar verificações de modo a detectar avarias ou melhorias na implantação do projeto (verificar) e por fim realizar alguns ajustes nos pontos divergentes verificados no passo anterior. Dessa maneira, os ativos ou projetos da organização são avaliados constantemente ao longo do seu ciclo de vida, com a preocupação de otimizar todas as etapas deste.

Segundo KARDEC et al. (2014) a PAS 55 e a NBR ISO 55000 se assemelham em diversos aspectos, como por exemplo: o alinhamento de objetivos, a abordagem baseada em riscos e a visão ao longo prazo. No entanto, pela existência de inúmeros países na criação da ISO 55000, essa norma proporcionou novos conceitos que não faziam parte da PAS 55, entre eles: o foco na GA físicos, a necessidade de produção de valor pelas organizações, a elevada relação entre aspectos financeiros e técnicos e ênfase na comunicação e nas partes interessadas.

Um conceito fundamental na GA é que a tomada de decisão varia em complexidade e criticidade, demandando abordagens distintas conforme o impacto envolvido. Decisões simples podem se basear na cultura organizacional, enquanto decisões de maior relevância exigem processos sistemáticos e multidisciplinares.

Conforme GFMAM (2014), as principais áreas de decisão englobam a análise de cenários para a substituição ou aquisição de ativos no contexto de investimentos de capital, a definição de requisitos que suportem os objetivos de gestão de ativos nas atividades de manutenção e operação, o equilíbrio entre custos e benefícios nas decisões de renovar, manter, revisar ou descartar ativos ao longo de seu ciclo de vida, além de decisões relacionadas à gestão de pessoas, infraestrutura, ferramentas e materiais como parte da estratégia de recursos, e o planejamento de paradas e interrupções dentro das estratégias de interrupções.

No contexto de operações e manutenção, as decisões geralmente consideram a criticidade e o desempenho dos ativos, o uso de técnicas como *Failure Mode and Effect Analysis (FMEA)*, Manutenção Centrada na Confiabilidade (MCC) e entre outras para definição de atividades de manutenção, a documentação de requisitos e padrões e as oportunidades de investimento em melhorias ou substituições para reduzir custos ou necessidades de manutenção. Essa abordagem busca alinhar as decisões ao equilíbrio entre custo, risco e desempenho.

Com relação aos aspectos econômicos relevantes na GA transformador, estes estão atrelados às regras contábeis societárias e regulatórias. Os transformadores de potência são ativos imobilizados que constituem um capital próprio das concessionárias e por possuir vida útil regulatória limitada, atribui-se um período contábil. Assim que os períodos forem decorrendo, gera-se o desgaste natural do equipamento, representando os custos a serem registrados, estes destacados como despesas contábeis. Ressalta-se que o processo contábil para essa conversão gradativa do ativo imobilizado em despesa é denominado depreciação QUEIROZ e GOULART (2014).

No caso do setor elétrico brasileiro, a vida útil regulatória é estabelecida pelo Manual de Controle Patrimonial do Setor Elétrico (MCPSE). Para transformadores de potência, a vida útil regulatória é de 35 anos. Porém, para ativos de concessões o valor a ser considerado é de 30 anos. No caso deste se tornar impróprio, pela obsolescência normal ou excepcional, ou em razão de ocorrência de falhas catastróficas, este pode ser retirado por ocasião da efetiva saída do patrimônio da concessionária, computando-se o resultado da alienação, caso haja valor econômico apurável, como receita eventual ou perda extraordinária, ou seja, a duração de vida útil estimada deste ativo imobilizado, que serve de base para serem determinadas as taxas de depreciação, não coincide, necessariamente, com a duração de sua utilização efetiva.

Caso este prazo de utilização seja superior ao estimado, mantém-se em uso até que seja necessária a sua reforma, recuperação ou substituição. No entanto, quando existe a necessidade de sucateamento ou obsolescência excepcional antes do prazo estimado, pode ocorrer que somente parte das quotas de depreciação tenha sido apropriada. Nesta hipótese, a baixa do bem normalmente acarreta perdas extraordinárias, as quais poderão ser computadas como despesas operacionais, salvo se forem recuperáveis através de seguro ou de indenização de terceiros. Para qualquer um dos casos, existe a necessidade da baixa contábil e que deve ser concomitante à baixa física do bem, isto é, com sua efetiva saída do patrimônio da empresa, e o valor da alienação, caso haja valor econômico apurável, servirá para apuração da receita eventual ou do valor efetivamente perdido (prejuízo para a concessionária) FERREIRA (2020), IUDÍCIBUS (2010).

Além dos aspectos contábeis, a análise econômica na distribuição também considera os indicadores de qualidade da prestação de serviços de energia elétrica, estabelecidos no Módulo 8 do Procedimento de Distribuição (PRODIST). Para avaliar a qualidade em grupos de unidades consumidoras, são empregados os indicadores Duração Equivalente de Interrupção (DEC) e Frequência Equivalente de Interrupção (FEC), que expressam, respectivamente, a duração média e a frequência média das interrupções no fornecimento de energia para um conjunto de consumidores.

Os limites desses indicadores são estabelecidos pela ANEEL e revisados periodicamente durante as Revisões Tarifárias Periódicas (RTP), com o objetivo de promover a melhoria contínua na qualidade dos serviços prestados, garantindo maior confiabilidade e eficiência na distribuição de energia elétrica ANEEL (2021).

Na distribuição, a abordagem dos custos de uma interrupção por ocorrência de falha, manutenção programada ou não, impactam a análise econômica de gestão dos transformadores de um modo diferente da transmissão, pois, isto se deve as características técnicas desse próprio sistema elétrico (possibilidade de transferências de cargas, transformadores reservas, nº de consumidores atendidos, entre outros). Salienta-se que na maioria dos casos, esses indicadores são afetados pelas avarias da rede de distribuição, porém, em caso de falha operacional, também serão alterados significativamente até a substituição do equipamento por um reserva.

Portanto, caracterizada a transgressão dos limites de interrupção no fornecimento de energia elétrica mensal, a compensação ao acessante deve ser providenciada. A compensação leva em consideração o tempo de ultrapassagem do limite, o valor equivalente da hora custo de distribuição e o fator de compensação para o tipo de acessante, sendo também observados os limites trimestrais e anuais e que em caso de transgressões estão sujeitos à compensação (crédito na fatura de energia).


Deste modo, é possível concluir que um dos pilares da GA de ativos físicos (equipamentos) consiste em relacionar variáveis técnicas e econômicas em uma abordagem baseada em criticidade para tomada de decisões em curto, médio e longo prazo. Além disso, a norma, por definição, especifica a necessidade de uma abordagem holística e o conceito de compreensão e conscientização do contexto.

2.3 Transformador de Potência

Transformadores de potência são compostos por múltiplos subsistemas e componentes interdependentes, o que ressalta a importância da detecção precoce de degradações e falhas que podem ocorrer de forma isolada ou concomitante em diferentes partes do equipamento.

A Figura 2.1 ilustra a estrutura básica de um transformador de potência a óleo, dividida em duas partes principais: parte ativa e outros componentes. A parte ativa consiste no núcleo ferromagnético e nos enrolamentos de cobre. Já os outros componentes englobam: tanque principal, trocadores de calor ou radiadores, buchas isoladoras, tanque de expansão do óleo, painel de proteção e comutador de tensão, variando conforme o modelo do equipamento.


Figura 2.1: Estrutura Básica de um Transformador de Potência a óleo.



Fonte: Adaptado de TANG, HALE e THAKER (2014).

As metodologias de manutenção deste ativo iniciam-se ainda nos testes prévios ao comissionamento e se estendem por toda a operação, com o objetivo de garantir a disponibilidade do equipamento com o menor custo possível. Quando anormalidades são detectadas, o diagnóstico adequado torna-se indispensável para avaliar a gravidade da situação e orientar ações corretivas ou preventivas, seja para restaurar as condições operacionais, realizar reparos ou, em última instância, substituir o equipamento CIGRE (2013). A Figura 2.2 ilustra um fluxograma com o ciclo de operação e manutenção de transformadores.

Figura 2.2: Ciclo de Operação e de Manutenção de Transformadores.



Fonte: Retirado de CIGRE (2013).

Uma breve descrição das metodologias empregadas pelas distribuidoras e transmissoras, está descrita a seguir CIGRE (2013, 2011):

- **Manutenção Baseada no Tempo (MBT):** A MBT é realizada em intervalos fixos e predeterminados, independentemente da condição atual do equipamento. Suas ações incluem tarefas preventivas como troca de óleo, lubrificação e substituição de componentes críticos. Embora seja uma abordagem simples e amplamente utilizada, especialmente em equipamentos cuja falha pode acarretar consequências graves, a MBT apresenta limitações. Por ser baseada em intervalos fixos, pode levar à execução desnecessária de atividades de manutenção, aumentando os custos operacionais sem, necessariamente, melhorar a confiabilidade. No entanto, essa metodologia é vantajosa em cenários que exigem planejamento prévio, especialmente em equipamentos que demandam desligamento para manutenção;
- **Manutenção Baseada na Condição (MBC):** A MBC é realizada conforme o estado atual do equipamento, com o objetivo de minimizar a probabilidade de falhas durante sua operação. Essa abordagem fundamenta-se na análise da condição física real do equipamento, considerando fatores como seu uso, eventos ocorridos, desgaste em componentes críticos (como o comutador de *taps*) e o desempenho de equipamentos similares. Para aplicar essa estratégia, é essencial avaliar o estado do equipamento utilizando métodos como Monitoramento de Condição Baseada no Tempo (MCBT), Monitoramento de Condição *Online* (MCOL);
- **Monitoramento de Condição Baseada no Tempo (MCBT) e Monitoramento de Condição *Online* (MCOL):** A avaliação da condição do equipamento pode ser realizada por meio de ações como inspeções visuais, medições e testes, que seguem intervalos regulares e são previamente planejados. Essas atividades geralmente são executadas em conjunto com intervenções de manutenção que requerem o desligamento do equipamento. Os dados obtidos por meio da MCBT são frequentemente utilizados para determinar a necessidade e a extensão da manutenção, seja imediata ou futura. No entanto, essas informações refletem apenas o estado do equipamento em um momento específico, oferecendo uma visão pontual de sua condição. No caso do MCOL, esse consiste em métodos ou medições realizadas enquanto o transformador está em operação, fornecendo informações sobre sua condição. Entre as práticas comuns estão a amostragem de óleo isolante para análise de gases dissolvidos, a utilização de termografia para identificar anomalias térmicas e inspeções visuais simples, como a verificação dos níveis de óleo nas buchas e nos conservadores;
- **Monitoramento *Online* Contínuo:** Essa metodologia consiste no monitoramento contínuo de uma ou mais variáveis do equipamento, geralmente realizado por meio de equipamentos não invasivos. Esse equipamento detecta alterações significativas e comunica imediatamente, por alarmes ou mensagens, qualquer anomalia, permitindo que a equipe tome as ações necessárias de forma rápida. Para ser eficiente, o monitoramento *online* contínuo deve identificar mudanças na condição do equipamento com antecedência suficiente para prevenir falhas. Essa abordagem serve como base para a Manutenção Baseada na Condição, contribuindo para reduzir o risco de falhas inesperadas e potencialmente catastróficas; e
- **Manutenção Centrada na Confiabilidade (MCC) e Análise de Modos de Falha e Efeitos (FMEA):** A MCC adota uma visão holística ao priorizar a preservação da funcionalidade sistêmica do transformador, considerando não apenas a condição técnica do ativo, mas também suas implicações em termos de segurança, meio ambiente e confiabilidade do sistema como um todo. Essa abordagem é complementada pela FMEA, que identifica os modos de falha mais prováveis e suas consequências, permitindo a adoção de medidas preventivas específicas. Essa combinação de ferramentas possibilita um gerenciamento mais eficiente

dos ativos, orientando as decisões de manutenção para maximizar a confiabilidade e minimizar os custos operacionais.

2.3.1 Degradação do Sistema Isolante

A durabilidade de um transformador está intrinsecamente ligada ao estado do seu sistema de isolamento, composto pelo isolamento líquido (óleo isolante) e pelo isolante sólido (geralmente celulose). Enquanto o óleo pode ser substituído ou reprocessado, a degradação irreversível da celulose implica o fim da vida útil do equipamento.

Segundo MARQUES (2019) a degradação do sistema isolante de um transformador de potência é uma das principais causas de problemas que, se não averiguados, podem levar a sua retirada forçada de operação. Essa degradação é causada em decorrência de estresse elétrico, térmico e mecânico, devido às condições operativas que o equipamento é submetido, bem como as reações químicas internas inerentes a este. Além disso, 37% das falhas desses equipamentos na classe de tensão de 138 kV a 700 kV estão relacionadas à parte ativa do transformador (núcleo e enrolamento) CIGRE (2024).

No Brasil, as obrigаторiedades regulamentadas pela ANEEL para assegurar a confiabilidade do ativo transformador é instaurada a partir da resolução normativa nº 906/2020 ANEEL (2020), que define os Requisitos Mínimos de Manutenção (RMM) preditivas (diagnóstico e revisão para prevenção) e preventivas (estratégias de monitoramento e controle para impedir ou amenizar possíveis falhas) para os transformadores de subestação de transmissão. Ressalta-se que esse planejamento das manutenções também é utilizado para os transformadores de subestações de distribuição, porém a obrigаторiedade das periodicidades podem ser alteradas.

O Quadro 2.1 resume as atividades e periodicidades de manutenções. Dentre as atividades de manutenção preventiva estão: verificação da existência de vazamentos de óleo isolante, verificação da existência de vazamentos de gás e entre outras.

Quadro 2.1: Periodicidades e Tolerância para a Realização das Atividades de Manutenção dos Transformadores e Autotransformadores.

Atividades	Periodicidade Máxima	Tolerância
Análise de gases dissolvidos no óleo isolante	6 meses	1 mês
Ensaio físico-químico do óleo isolante	24 meses	4 meses
Manutenção preventiva periódica	72 meses	12 meses

Fonte: Retirado de ANEEL (2020).


Segundo EECKHOUDT, AUTRU e LERAT (2017), a análise de gases dissolvidos em óleo isolante, do inglês *Dissolved Gas Analysis (DGA)*, é uma ferramenta utilizada para diagnosticar o estado operacional dos transformadores, com o intuito de verificar a presença de potenciais falhas e assim nortear as ações necessárias, as quais podem estar relacionadas à realização de ensaios auxiliares de verificação, ou para planejar uma inspeção e manutenção do equipamento.

Contudo, devido ao comportamento não linear observado na produção de gases dissolvidos no óleo de transformadores, o qual está associado a estresses térmicos e elétricos, bem como a reações químicas internas entre

os materiais, diversos métodos convencionais de interpretação e diagnóstico estão amplamente disponíveis na literatura. Entre eles, destacam-se as normas IEC 60599 (2015), ABNT NBR 7274 ABNT (2012), IEEE C57.104 IEEE (2008), além das abordagens baseadas em Rogers e Doerneburg IEEE (2019), o Triângulo de Duval DUVAL (2008), entre outros. Salienta-se que esses métodos são consolidados na literatura, mas ainda não existe um método definitivo para o diagnóstico de falhas em transformadores.

As falhas associadas à degradação da celulose e do óleo em transformadores envolvem diferentes produções de gases. Na falha térmica do óleo, o estresse térmico e elétrico rompe as cadeias de hidrocarbonetos, resultando na formação de gases combustíveis como H_2 , CH_4 , C_2H_2 , C_2H_4 e C_2H_6 . A composição e a quantidade desses gases dependem da energia, da temperatura e da duração do evento. O C_2H_4 predomina em temperaturas acima de $500^\circ C$, enquanto o C_2H_2 se forma em maior quantidade apenas acima de $800^\circ C$, embora traços possam aparecer em temperaturas inferiores. Em condições abaixo de $200^\circ C$, ocorre o *stray gassing*, com produção de H_2 , CH_4 e C_2H_6 , e entre 500 e $800^\circ C$ há carbonização do óleo. Já na falha térmica da celulose, a decomposição térmica gera principalmente CO e CO_2 , iniciando de forma significativa a partir de $105^\circ C$, com carbonização total acima de $300^\circ C$. Valores de CO superiores a 1000 ppm e uma razão CO_2/CO inferior a 3, acompanhados pela formação de hidrocarbonetos, podem indicar falhas no papel isolante. Esses comportamentos permitem correlacionar os gases formados com as temperaturas e os tipos de falhas, auxiliando no diagnóstico de problemas em equipamentos elétricos IEC 60599 (2015). A Figura 2.3 mostra as concentrações relativas de gases aproximadas em relação à temperatura e tipos de falhas

Figura 2.3: Concentrações Relativas de Gases por Temperatura e Tipos de falhas.



Fonte: Adaptado de IEEE (2019).

Em que:

- **RC:** Reações catalíticas entre aço galvanizado e água;
- **DP:** Descargas parciais;
- **SG:** *Stray gassing* (*gases parasitas*) para temperatura $T < 200^\circ C$;
- **OPO:** Superaquecimento do papel ou óleo;
- **CP:** Possível carbonização do papel;
- **T1:** Falha térmica em temperatura $T < 300^\circ C$;
- **T2:** Falha térmica em temperatura entre $300^\circ C < T < 700^\circ C$;

- **T3:** Falha térmica em temperatura $T > 700^{\circ}\text{C}$;
- **D1:** Descarga de baixa energia; e
- **D2:** Descarga de alta energia.

No caso do ensaio físico-químico ABNT (2017), este é utilizado para analisar a qualidade do óleo isolante. Destacam-se a seguir algumas propriedades consideradas nesta tese:

- **Índice de Neutralização (acidez):** Mede a quantidade de componentes ácidos presentes, que se formam devido à oxidação do óleo em operação. Esses ácidos, em conjunto com água e contaminantes sólidos, afetam as propriedades dielétricas e promovem a degradação do isolamento celulósico. Além disso, podem causar corrosão em peças metálicas dos transformadores. A taxa de aumento da acidez é um indicador do envelhecimento do óleo;
- **Rigidez Dielétrica:** Indica a capacidade do óleo de resistir a solicitações elétricas. Óleos limpos e secos apresentam rigidez inerentemente alta, enquanto a presença de água livre e partículas sólidas reduz essa capacidade, especialmente em regiões de alta solicitação elétrica. Assim, valores baixos de rigidez dielétrica indicam contaminação, mas valores altos não garantem ausência de contaminantes;
- **Tensão Interfacial:** Avalia a presença de contaminantes polares solúveis e produtos de oxidação. Durante os estágios iniciais de envelhecimento, essa característica varia rapidamente, estabilizando-se em estágios moderados de deterioração. Uma queda acentuada pode sinalizar incompatibilidade entre o óleo e materiais do transformador ou contaminação durante o enchimento;
- **Teor de Água:** O teor de água no óleo afeta a rigidez dielétrica, o isolamento celulósico e a taxa de envelhecimento do sistema isolante. 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 oxidado; e
- **Coloração:** Determinada pela luz transmitida pelo óleo, pode indicar contaminação ou deterioração, embora não seja uma propriedade crítica.

2.3.2 Risco

Segundo CALDAS (2015), o risco associado a um ativo é determinado pela combinação entre a probabilidade de falha e as consequências (impacto) dessa falha. A probabilidade de falha pode estar fortemente correlacionada com o índice de saúde do ativo, uma vez que se espera que essa probabilidade aumente à medida que ocorre a degradação de sistemas como o isolante, os componentes e outros. A relação entre probabilidade de falha e suas consequências é comumente representada por uma Matriz de Risco (Figura 2.4), uma ferramenta prática para comparar ativos e planejar a manutenção.

Figura 2.4: Descrição de uma Matriz de Risco.



Fonte: Retirado de CALDAS (2015).

2.4 Considerações Finais

Neste capítulo, foi abordada uma fundamentação teórica relevante envolvendo a GA de transformadores de potência, considerando as diretrizes metodológicas e os aspectos técnicos e econômicos envolvidos. Os transformadores de potência são equipamentos críticos, cuja falha pode acarretar impactos financeiros significativos para concessionárias e consumidores. Por isso, a gestão eficiente desses ativos exige uma abordagem integrada e multidisciplinar, que equilibre custos, riscos e desempenho ao longo do ciclo de vida do equipamento.

Foram destacadas as diretrizes internacionais, como a PAS 55 e a ISO 55000, que fornecem bases para a implementação de estratégias eficientes neste processo. Essas normas enfatizam a necessidade de alinhar objetivos organizacionais e técnicos, promover o gerenciamento de riscos e assegurar a sustentabilidade financeira dos ativos.

Além disso, abordaram-se as metodologias de manutenção que são consideradas consolidadas para aumentar a confiabilidade, minimizar riscos e otimizar custos operacionais, com ênfase na prevenção e no diagnóstico precoce de falhas.

Por fim, ressaltou-se a importância da análise detalhada do sistema isolante do transformador, composto por óleo e celulose, como elemento crítico para sua durabilidade. Parâmetros como índice de neutralização, rigidez dielétrica, teor de água e tensão interfacial e coloração foram apresentados como indicadores relevantes para avaliar a condição do óleo isolante e orientar decisões de manutenção. Destacou-se também a análise de gases dissolvidos (DGA) como ferramenta importante para o diagnóstico de falhas térmicas e elétricas.

O desenvolvimento de abordagens sistemáticas e ferramentas de priorização para a gestão de ativos representa uma oportunidade de aprimoramento contínuo, garantindo maior confiabilidade, desempenho e sustentabilidade para o setor elétrico.

Capítulo 3

REVISÃO BIBLIOGRÁFICA

3.1 Considerações Iniciais

Este capítulo apresenta um estudo bibliométrico detalhado sobre os conceitos de índice de saúde e criticidade aplicados à gestão de transformadores de potência. A análise combina abordagens quantitativas e qualitativas para mapear o panorama científico recente, identificar lacunas no conhecimento e destacar tendências emergentes na literatura.

Por meio de uma investigação estruturada em bases de dados científicas, este estudo busca compreender a evolução dos temas relacionados a essa tese. Os resultados são organizados para oferecer uma visão abrangente da produção científica, incluindo a distribuição geográfica das publicações, análises de mapas estratégicos que evidenciam as relações entre os principais tópicos de pesquisa e conexões entre palavras-chave.

3.2 Análise Quantitativa e Qualitativa

Para o desenvolvimento deste estudo bibliométrico, foi utilizada a base de dados *Scopus Elsevier*. Os critérios de inclusão considerados na busca dos estudos iniciais, foram baseados nos títulos, resumos e palavras-chave. Para realizar a busca, foram utilizadas as combinações dos descritores apresentados na Tabela 3.1, considerando os últimos 15 anos (2010 a 2024).

Tabela 3.1: Descritores de Busca na Base Scopus e Dados de Co-citação.


Conjunto	Descritores da Pesquisa	Quantidade de Documentos	Quantidade de Co-citação
A	Power Transformer OR Electrical Transformer OR	115	1142 documentos citaram 90 das 115 publicações
	Oil transformers AND Asset Management		
	OR "Decision Making"AND Risk		
B	Power Transformer OR Electrical Transformer OR	281	2644 documentos citaram 209 das 281 publicações
	Oil transformers AND Criticality OR Prioritize		
	OR Risk Assessment		

Fonte: Elaborado pelo autor.

A partir da análise da Tabela 3.1, evidencia-se que há diferenças significativas na abrangência e relevância dos termos pesquisados. O Conjunto A, composto por descritores como *Asset Management*, *Decision Making* e *Risk*, resultou na identificação de 115 documentos, dos quais 90 foram citados entre 1142 publicações de co-citação. Já o Conjunto B, que incluiu termos como *Criticality*, *Prioritize* e *Risk Assessment*, foi mais abrangente, identificando 281 documentos, com 209 citações em um universo de 2644 documentos analisados por co-citação.

Na Figura 3.1 observa-se a evolução do número de publicações nos últimos 15 anos. O Conjunto B apresentou um número significativamente maior de publicações em todos os períodos analisados, destacando-se principalmente entre 2016-2018 e 2022-2024, com mais de 65 publicações em cada intervalo. Em contraste, o Conjunto A manteve uma produção mais estável, com menos de 25 publicações por período. Entre 2022-2024, ambos os conjuntos mostram crescimento, refletindo o aumento recente de interesse nos temas relacionados.

Figura 3.1: Publicações Entre 2010 e 2024 na Base Scopus.



Fonte: Elaborado pelo autor.

Em uma análise dos países que mais publicaram sobre o tema, China, Estados Unidos, Canada e Índia representam aproximadamente 30% do total das publicações, sendo a China responsável por 17%. Já o Brasil, em menor expressão, possui apenas 2% em relação número total de publicações.

Essas análises permitem concluir que os estudos ainda estão em desenvolvimento científico e, deste modo, a criação de uma nova metodologia de criticidade para gestão e priorização dos transformadores contribui cientificamente neste campo de pesquisa.


Para aprofundar o estudo bibliométrico e mapear a evolução das palavras-chave relacionadas ao tema, foi utilizado o *software SciMAT*. Essa ferramenta permitiu uma análise detalhada dos temas mais relevantes, com base nos dados extraídos da base *Scopus*.

A Figura 3.2 apresenta a evolução das citações e conexões das palavras-chave ao longo do tempo, organizadas em cinco grupos, cada um correspondente a um intervalo de três anos. A primeira coluna representa o período de 2010 a 2012, enquanto a última corresponde ao período de 2022 a 2024. O tamanho dos círculos indica a quantidade de citações de cada palavra-chave em seus respectivos períodos, sendo que círculos maiores representam um número maior de citações. As linhas que conectam os grupos indicam a intensidade da relação entre as palavras-chave, com linhas mais espessas representando conexões mais fortes.

Os maiores nós, como "*Maintenance*", "*Asset Management*" e "*Decision-Making*", sugerem que esses temas possuem maior destaque e impacto na literatura científica analisada. Além disso, temas como "*Health Index*" e "*Risk Assessment*" estão fortemente conectados, indicando uma relação estreita entre a saúde dos equipamentos e a gestão de riscos. Palavras como "*Online Monitoring*" aparecem conectadas a múltiplos temas, sugerindo um papel central na integração de práticas de manutenção e monitoramento.

Algumas palavras emergentes, como "*Artificial Neuron Network*", "*Diagnostics*" e "*Auto-Encoders*", aparecem conectadas em temas mais consolidados, apontando para a incorporação crescente de tecnologias avançadas, como Inteligência Artificial (IA) e técnicas de aprendizado de máquina, no campo da gestão e monitoramento de transformadores de potência.

Na última coluna do mapa, o termo "*Criticality*" aparece como um nó conectado ao termo "*Insulation*". Isso sugere que, embora o termo criticidade esteja presente, ele ainda não é amplamente explorado ou citado neste campo de pesquisa.

Figura 3.3: Diagrama Estratégico do Tema Motor para o Período 2020 a 2024.

Fonte: Elaborado pelo autor a partir do Scimat.

O diagrama estratégico elaborado para o período de 2020 a 2024 destaca "*Health Index*" e "*Gases*" como os termos mais relevantes e consolidados no campo de pesquisa. "*Health Index*" se sobressai com a maior centralidade, indicando sua importância estratégica e forte conexão com outros *clusters*, enquanto "*Gases*" apresenta a maior densidade, refletindo sua coesão interna e desenvolvimento consolidado. Esse posicionamento evidencia que a avaliação da saúde do transformador é um tema central e amplamente discutido, com aplicações práticas significativas e impacto direto na gestão eficiente desse ativo. Esses resultados reforçam a relevância desses tópicos na literatura recente, destacando sua contribuição para o avanço das práticas de manutenção e monitoramento de transformadores.

No quadrante superior esquerdo, temas como "*Decision-Support Systems*" apresenta alta densidade, refletindo que é um tópico consolidado em sua área específica. No entanto, sua centralidade nula indica que esse tema é específico, com menos interações estratégicas com outros *clusters* da pesquisa.

Por outro lado, no quadrante inferior direito, temas como "*Oil*" e "*Oil-Immersed Power Transformers*" aparecem como tópicos estratégicos, mas com menor densidade, sugerindo que, embora sejam importantes no campo de pesquisa, ainda dependem de maior estruturação e estudos aprofundados para se consolidarem.

No quadrante inferior esquerdo, os termos "*Maintenance Strategies*" e "*Feature Selection*" encontram-se na periferia do campo de pesquisa, com baixa densidade e centralidade. Essa posição sugere que esses temas, embora

ainda pouco explorados, têm potencial para crescimento, especialmente se integrados a tópicos estratégicos e bem consolidados.

Essa análise reforça que temas como "*Health Index*" continuam sendo centrais na literatura científica, sendo um dos pilares para a avaliação da saúde de ativos, enquanto tópicos como "*Maintenance Strategies*" e "*Feature Selection*" refletem tendências emergentes. Deste modo, áreas como manutenção e seleção de características apresentam oportunidades para novas pesquisas, contribuindo para o desenvolvimento do campo científico e para soluções mais inovadoras no gerenciamento de transformadores.

No contexto desta tese, a abordagem proposta para avaliação da criticidade dos transformadores busca justamente explorar essas lacunas. Ao propor uma nova metodologia para avaliação da criticidade do equipamento e priorização de ativos, o estudo avança na direção de contribuir para a gestão mais eficiente, alinhando-se aos tópicos centrais discutidos na literatura científica recente.

3.3 Estudo de Anterioridade

Para a realização deste estudo de anterioridade, foram utilizadas as seguintes bases de dados científicas:

- *Scopus Elsevier*;
- *Institute of Electrical and Electronic Engineers – IEEE*;
- Catálogo de teses e dissertações da Capes; e
- Portal Periódico Capes.

3.3.1 Índice de Saúde

O índice de saúde, comumente conhecido por *Health Index (HI)*, constitui uma métrica essencial na GA, utilizada para avaliar quantitativamente a condição geral de um transformador de potência. Este índice proporciona aos gestores de ativos uma compreensão intuitiva da saúde dos equipamentos por meio de um único valor numérico, facilitando a comparação objetiva entre diferentes ativos ou em relação a um valor de referência previamente estabelecido AZMI et al. (2017a).

A aplicação do *HI* é amplamente explorada tanto por concessionárias de energia quanto no meio acadêmico, com diversas metodologias propostas para seu cálculo. Essas metodologias podem ser classificadas em duas categorias principais: métodos baseados na soma ponderada de pontuações e métodos que utilizam algoritmos de IA. Entretanto, não há consenso na literatura sobre uma metodologia padrão para o cálculo do *HI*, levando cada concessionária a desenvolver abordagens próprias, ajustadas às suas necessidades LI et al. (2023), CIGRE (2019).

Em estudos recentes, AZMI et al. (2017b) apresenta e compara 12 propostas distintas para a composição e formulação do *HI* em transformadores de potência, destacando as diferenças e semelhanças entre as abordagens. Em complemento, CIGRE (2021) fornece uma metodologia detalhada para a criação de *HI* aplicados a equipamentos de subestação.

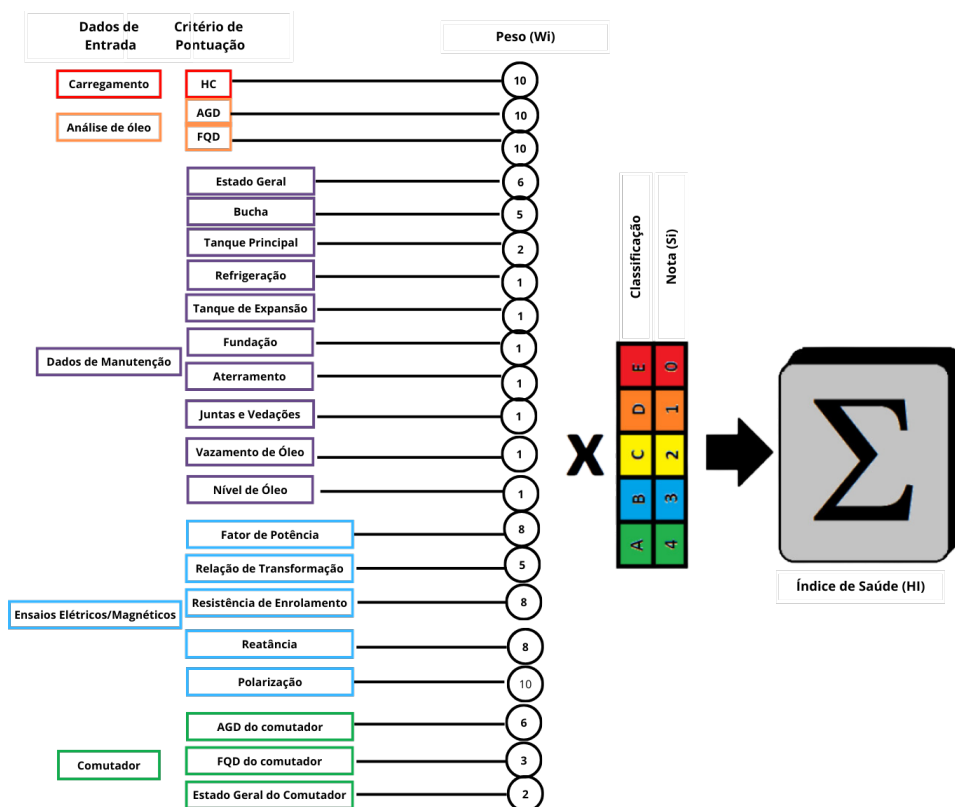
Os métodos baseados na soma ponderada de pontuações determinam o (*HI*) de transformadores por meio da soma das pontuações ponderadas de diferentes parâmetros de condição. Esses métodos utilizam normas técnicas e

resultados de ensaios elétricos e magnéticos para estabelecer as pontuações, enquanto os pesos atribuídos refletem a relevância de cada parâmetro para o desempenho global do transformador ou de seus componentes específicos. Conforme discutido por LI et al. (2023), esses métodos podem ser classificados em três categorias principais:

- **Tipo-I:** O *HI* é calculado como a soma ponderada das pontuações atribuídas a diferentes itens de teste utilizados no monitoramento das condições do transformador DONG, LI e NASSIF (2020), JIANG, CHEN e WANG (2022);
- **Tipo-II:** O *HI* é derivado da soma ponderada das pontuações de todos os componentes individuais do transformador. Como o transformador é composto por diferentes componentes, como enrolamentos, núcleo, tanque de óleo, buchas e acessórios, a avaliação pelo *HI* pode ser realizada em um índice geral ponderado. Este método utiliza estatísticas de falhas de transformadores e a experiência de especialistas para determinar os pesos atribuídos a cada componente SPARLING e AUBIN (2018), FREITAG et al. (2018); e
- **Tipo-III:** O *HI* é obtido pela soma das pontuações ponderadas associadas às diferentes causas de degradação (como elétrica, mecânica, química, etc.), as quais são calculadas a partir de múltiplos dados de condição relacionados a cada tipo de degradação SCATIGGIO e POMPILI (2013).

Um modelo representativo, baseado na soma ponderada de parâmetros com a combinação dos tipos I, II e III, foi implementado para a formulação do Índice de Saúde (*HI*) aplicado a transformadores de potência, conforme ilustrado na Figura 3.4.

Figura 3.4: Modelo Representativo dos Parâmetros que Compõem o *HI* de Transformadores de Potência.



Fonte: Adaptado de SILVA (2020).

Esse modelo representativo foi proposto por CHITNAVIS e BHASME (2017) e considera 22 fatores ou critérios, ponderados de acordo com a Equação (3.1) e com os valores apresentados no Quadro 3.1, conforme ilustrado na Figura 3.4. A metodologia divide o *HI* em duas partes: uma relacionada à condição geral do transformador e outra ao comutador. Os fatores de ponderação 0,6 e 0,4 refletem a proporção de falhas do comutador em relação aos demais componentes.

Cada fator é avaliado com base em um peso (W_i) que reflete sua relevância para a probabilidade de falha do transformador. A pontuação (S_i) de cada fator é atribuída com base em critérios de classificação (A, B, C, D, ou E), associados às pontuações numéricas 4, 3, 2, 1 e 0, respectivamente. Esses valores são multiplicados pelos pesos correspondentes, somados e normalizados pela soma dos pesos.

$$HI = 0,6 \cdot \frac{\sum_{i=1}^{19} S_i W_i}{\sum_{i=1}^{19} W_i} + 0,4 \cdot \frac{\sum_{i=20}^{22} S_i W_i}{\sum_{i=20}^{22} W_i} \quad (3.1)$$

Quadro 3.1: Critérios, Pesos e Pontuações do *HI*.

Item	Fator	W_i	Classificação (S_i)
1	Carregamento (HC)	10	A, B, C, D, E (4, 3, 2, 1, 0)
2	Análise de Gases Dissolvidos (AGD)	10	A, B, C, D, E (4, 3, 2, 1, 0)
3	Análise Físico-química do óleo (FQO)	10	A, B, C, D, E (4, 3, 2, 1, 0)
4	Fator de Potência	8	A, B, C, D, E (4, 3, 2, 1, 0)
5	Estado Geral do Transformador	6	A, B, C, D, E (4, 3, 2, 1, 0)
6	Buchas	5	A, B, C, D, E (4, 3, 2, 1, 0)
7	Tanque Principal	2	A, B, C, D, E (4, 3, 2, 1, 0)
8	Refrigeração	2	A, B, C, D, E (4, 3, 2, 1, 0)
9	Tanque de Expansão	1	A, B, C, D, E (4, 3, 2, 1, 0)
10	Fundação	1	A, B, C, D, E (4, 3, 2, 1, 0)
11	Aterramento	1	A, B, C, D, E (4, 3, 2, 1, 0)
12	Juntas e Vedações	1	A, B, C, D, E (4, 3, 2, 1, 0)
13	Conexões	1	A, B, C, D, E (4, 3, 2, 1, 0)
14	Vazamento de Óleo	1	A, B, C, D, E (4, 3, 2, 1, 0)
15	Nível de Óleo	1	A, B, C, D, E (4, 3, 2, 1, 0)
16	Relação de Transformação	5	A, B, C, D, E (4, 3, 2, 1, 0)
17	Resistência do Enrolamento	8	A, B, C, D, E (4, 3, 2, 1, 0)
18	Reatâncias	8	A, B, C, D, E (4, 3, 2, 1, 0)
19	Polarização	10	A, B, C, D, E (4, 3, 2, 1, 0)
20	AGD do Comutador	6	A, B, C, D, E (4, 3, 2, 1, 0)
21	FQO do Comutador	3	A, B, C, D, E (4, 3, 2, 1, 0)
22	Estado Geral do Comutador	2	A, B, C, D, E (4, 3, 2, 1, 0)

Fonte: Retirado de SILVA (2020).

Evidencia-se a partir da análise do Quadro 3.1 que os critérios relacionados ao sistema de isolamento do transformador (Item 2, 3 e 4) apresentam um peso elevado na ponderação do *HI*, já que como visto na fundamentação teórica a vida útil desse equipamento está intrinsecamente ligada ao estado do seu sistema de isolamento, composto pelo isolamento líquido e sólido.

Os métodos de *HI* baseados em algoritmos de IA, consideram a implementação de redes neurais artificiais

(*Artificial Neural Networks-ANN*) ABU-ELANIEN, SALAMA e IBRAHIM (2011), RIGATOS e SIANO (2016), NURCAHYANTO et al. (2019), redes de propagação reversa (*Back Propagation Neural Network - BP-NN*) BIRLIK, OZGONENEL e KARAGÜL (2016), redes de regressão generalizada (*General Regression Neural Network - GRNN*) TRAPPEY et al. (2015), lógica *fuzzy* ISLAM, LEE e HETTIWATTE (2017), PANWAR et al. (2017), e redes *Bayesianas* LI et al. (2018).

Essas metodologias utilizam dados históricos provenientes de ensaios de manutenção preditiva, como análise termográfica, vibrações, *DGA*, descargas parciais e resposta em frequência. Para a avaliação do envelhecimento dos transformadores, consideram-se parâmetros como grau de polimerização, resistência do enrolamento, compostos furânicos no óleo isolante e entre outros. Esses dados são utilizados como entrada para treinar modelos capazes de classificar o estado de saúde do transformador em categorias como "bom", "moderado" ou "ruim".

Métodos como *ANN* e *GRNN* se destacam pela capacidade de modelar a relação entre os dados de entrada e o *HI*, enquanto técnicas baseadas em lógica *fuzzy* permitem incorporar regras definidas por especialistas para maior precisão na avaliação. Por outro lado, abordagens probabilísticas, como redes *Bayesianas*, mostram-se particularmente eficazes para lidar com incertezas e dados incompletos. Essas ferramentas desempenham um papel fundamental na avaliação da condição dos transformadores, auxiliando na tomada de decisões estratégicas e na priorização de ativos críticos.

3.3.2 Criticidade

Como observado no estudo bibliométrico, o termo criticidade ainda é pouco explorado na literatura sobre gestão de ativos. No entanto, algumas contribuições relevantes foram identificadas e serão apresentadas nessa seção.

De acordo com CIGRE (2021), a criticidade refere-se à avaliação das consequências potenciais associadas à perda de funcionalidade de um ativo e à probabilidade de ocorrência de falhas ao longo do tempo. Esse conceito é fundamental para determinar o nível de prioridade nas ações de manutenção, com o objetivo de garantir a confiabilidade operacional e a qualidade dos serviços. Fatores como o elevado investimento imobilizado e o impacto sistêmico de uma falha são determinantes na avaliação da criticidade de um ativo.

No caso dos transformadores de potência, a gestão exige decisões estratégicas que equilibram os custos de intervenções, como substituição, reforma ou manutenção, com os riscos e consequências associados à falha do equipamento. As possíveis consequências incluem danos estruturais, impactos ambientais, interrupções no fornecimento de energia e prejuízos financeiros. Esses impactos variam conforme fatores como o tipo de carga atendida, a duração da interrupção, a localização do transformador e a disponibilidade de recursos para reparos ou substituição CIGRE (2019).

A avaliação da condição dos transformadores, comumente baseada em índices como o *Transformer Assessment Index (TAI)*, geralmente não considera de forma abrangente as consequências de uma falha, focando apenas na condição técnica do ativo. Portanto, é fundamental integrar análises de condição com estudos de criticidade que incorporem aspectos técnicos, operacionais e econômicos. Métodos como matrizes de pontuação e ferramentas de análise multicritério são recomendados para criar índices de criticidade que representem com precisão a gravidade e o impacto potencial de falhas em diferentes cenários CIGRE (2019).


Conforme destacado em ABNT (2014, 2018), um mesmo tipo de ativo pode apresentar níveis distintos de

criticidade, com escalas que variam amplamente. Além disso, nem todos os ativos representam riscos significativos para a organização, seja em termos econômicos, de reputação, segurança ou impacto ambiental. Essa diversidade apresenta desafios na definição das variáveis técnicas, econômicas e operacionais que devem ser padronizadas no processo de avaliação.

Os modelos de análise de criticidade dos transformadores abrangem uma ampla gama de abordagens, desde metodologias que consideram exclusivamente variáveis técnicas, como análise de gases dissolvidos e propriedades físico-químicas do óleo isolante, até aquelas que integram dados operacionais e de manutenção, como níveis de carregamento, temperaturas de operação e histórico de falhas. Essas análises permitem uma avaliação detalhada da condição técnica do ativo, mas frequentemente deixam de incorporar aspectos amplos, como impactos econômicos, ambientais e operacionais. Nesse contexto, o conceito de criticidade é ampliado ao ser associado à gestão de riscos, considerando não apenas a probabilidade de falhas, mas também as potenciais consequências dessas falhas, como interrupções no fornecimento, custos de reparo e substituição, e impactos na reputação da empresa.

O trabalho proposto por LEANGKRUA (2018) apresenta uma estratégia de manutenção baseada no risco para otimizar os custos de operação e manutenção. Essa metodologia considera dados técnicos e de ensaios de manutenção preditiva, caracterizando o índice de condição geral do transformador e os critérios de avaliação da importância. A avaliação da condição é realizada através de ensaios elétricos, ensaios no óleo isolante e inspeção visual. A classificação ocorre em cinco critérios de criticidade. No caso da importância, considera-se os critérios de criticidade e importância da carga, bem como a consequência da falha. Por fim, a matriz de risco é desenvolvida com o objetivo de avaliar o risco de cada transformador, auxiliando na formulação de uma estratégia de manutenção mais adequada para cada caso. A Figura 3.5 ilustra essa metodologia proposta.

Figura 3.5: Metodologia de Manutenção Baseada no Risco.



Fonte: Elaborado pelo autor a partir de LEANGKRUA (2018).

No contexto de gestão de risco, além de avaliar a criticidade do equipamento, torna-se essencial considerar fatores econômicos e operacionais, buscando assegurar a continuidade no fornecimento de energia. De acordo com


Sousa, SOUSA, SAAVEDRA e LIMA (2018), a análise de risco permite identificar características críticas operacionais e propor soluções que previnam ou minimizem prejuízos financeiros, viabilizando a adoção de abordagens diversificadas para melhorar a confiabilidade dos transformadores.

A gestão eficiente de transformadores de potência exige a avaliação de riscos associados a atrasos no atendimento de curto prazo, planejamentos de médio e longo prazo ou até a retirada imediata dos equipamentos, que representa uma solução mais onerosa financeiramente. Nesse contexto, LIMA, SAAVEDRA e MIRANDA (2015) autores propuseram uma estrutura de diagnóstico e tomada de decisão em dois níveis. No primeiro nível, utiliza-se redes neurais associativas para monitorar e detectar a presença de falhas incipientes nos transformadores. No segundo nível, são avaliados e estimados os riscos envolvidos, considerando fatores como a vida útil, o estado operacional em serviço, o carregamento fornecido e o impacto financeiro, sempre com o objetivo de preservar as demandas e garantir a continuidade do fornecimento de energia.

A Figura 3.6 ilustra as principais etapas desse processo decisório, destacando os seguintes elementos:

- Diagnóstico de falhas, com base na análise de gás dissolvido (DGA), redes neurais associativas e detecção por mudança média;
- Estimativa de risco, avaliando vida útil, condição operacional, carregamento e impacto financeiro; e
- Grau de aversão ao risco, definido pelo operador e Decisão final, que considera a retirada imediata ou o adiamento da retirada do equipamento de serviço.

Figura 3.6: Estrutura para Tomada de Decisão de Manutenções em Transformadores Operando.




Fonte: Elaborado pelo autor a partir de LIMA, SAAVEDRA e MIRANDA (2015).

Em ILGEVICIUS e BABIZKI (2015) é proposto o modelo *Integrated Transformer Fleet Management (ITFM)*, voltado para a gestão integrada de falhas em transformadores. Esse modelo combina o Índice de Saúde (*HI*) e a criticidade dos transformadores (Figura 3.7), em conformidade com as diretrizes das normas PAS 55, DIN VDE 0109 e IEC 61970. A estrutura do *ITFM* organiza a avaliação da condição dos transformadores em três níveis distintos:

- Nível 1: Monitoramento e diagnóstico sem interrupção (*online*), utilizando dados coletados continuamente, como temperatura do óleo, carregamento, análise de gases dissolvidos, compostos furânicos, análise físico-química do óleo e histórico operacional;
- Nível 2: Diagnósticos de rotina que requerem interrupções breves para medições *offline*, como testes elétricos e ensaios básicos; e
- Nível 3: Diagnósticos avançados que exigem interrupções prolongadas, incluindo análises como resposta em frequência, corrente de polarização e despolarização, espectroscopia no domínio da frequência, entre outros.

Os resultados das análises dos níveis 1 e 2 são convertidos em índices pontuados, que se agrupam em oito categorias de risco: mecânico, térmico, dielétrico, comutadores, buchas, sistema de resfriamento, tanque/acessórios e histórico de confiabilidade. Essas categorias contribuem para o cálculo do *HI*, representado por valores numéricos e codificação por cores, que auxiliam na priorização das ações de manutenção. Além disso, o ITFM também considera fatores econômicos, como o impacto financeiro de interrupções no fornecimento, estabilidade do sistema, custos de reparo e penalidades associadas. Essas variáveis são incorporadas ao processo de decisão, permitindo ao gestor definir limites críticos de *HI* (por exemplo, $HI > 30\%$) para identificar e priorizar transformadores em risco antes que falhas ocorram.

Figura 3.7: Metodologia ITFM.



Fonte: Elaborado pelo autor a partir de ILGEVICIUS e BABIZKI (2015).

3.4 Considerações Finais

As metodologias investigadas neste capítulo de estudo bibliométrico apresentam avanços significativos na gestão de ativos críticos, como transformadores de potência, mas ainda possuem deficiências que limitam sua aplicabilidade prática e abrangência. Uma das principais lacunas identificadas é a falta de integração entre variáveis multidisciplinares, especialmente no que se refere à combinação de fatores técnicos, operacionais, econômicos. Grande parte dos métodos analisados, como os baseados no Índice de Saúde (*Health Index – HI*), concentra-se predominantemente na condição técnica do equipamento, deixando de lado aspectos como as consequências econômicas e as implicações sistêmicas de uma falha.

Outro ponto crítico é a dependência de abordagens normativas e unidimensionais, frequentemente baseadas em modelos estáticos ou em somas ponderadas de fatores, sem considerar as inter-relações complexas entre as variáveis. Embora métodos que utilizam IA apresentem potencial, sua aplicação ainda é limitada pela escassez de dados representativos e pela variabilidade nas condições reais de operação dos transformadores. A subjetividade nos processos decisórios também representam um desafio, já que a atribuição de pesos e critérios frequentemente depende da experiência individual dos especialistas, dificultando a padronização e a replicação em diferentes contextos organizacionais.

A tese proposta busca superar essas limitações por meio do desenvolvimento de uma nova metodologia para avaliação de criticidade, que integra ferramentas de análise multicritério e técnicas de análise multivariada. A metodologia utiliza dados técnicos, operacionais e econômicos, tais como: indicadores de continuidade, potência do transformador, número de clientes atendidos, distância da base operacional, valor societário do ativo, idade do equipamento e resultados de ensaios de (*DGA* e físico-químico), promovendo uma visão holística e objetiva na priorização de ativos críticos.

Diferentemente das abordagens existentes, esta tese propõe um alinhamento entre a avaliação técnica da condição do equipamento e suas consequências práticas, como impacto financeiro e continuidade do fornecimento. A integração dessas dimensões promove uma gestão eficiente e sustentável, com foco em ações de manutenção preditiva e no planejamento estratégico de longo prazo. Como resultado, espera-se maior previsibilidade operacional, otimização de recursos e suporte mais robusto à tomada de decisão para os gestores da distribuidora em questão.

Capítulo 4

MÉTODOS DE ANÁLISE MULTICRITÉRIO, ANÁLISE MULTIVARIADA E APRENDIZADO SUPERVISIONADO

4.1 Considerações Iniciais

Como observado nas seções anteriores, a gestão do transformador caracteriza-se por ser um problema complexo em que inúmeros critérios influenciam na tomada de decisão. Com isso, o desenvolvimento de uma nova metodologia de criticidade para ranqueamento dos ativos a partir de dados técnicos, econômicos e operacionais requer a ponderação dos pesos das variáveis, considerando um grau de importância coerente. Uma vez estabelecidos tais critérios e seus pesos, pode-se então mapear os níveis de criticidade de cada ativo.

Deste modo, o objetivo desta seção consiste em apresentar brevemente uma fundamentação teórica a respeito dos métodos de análise multicritério e multivariada utilizados nesta pesquisa para o desenvolvimento desta metodologia de criticidade.

4.2 Análise Multicritério

A escolha do método multicritério de Análise Hierárquica dos Processos (AHP), como o método mais apropriado para atribuição dos pesos das variáveis, foi realizada pelos seguintes aspectos:

- Comprovações científicas para soluções de problemas complexos, evidenciada no trabalho de VAIDYA e KUMAR (2006) que apresenta mais de 154 artigos publicados em revistas e congressos em diferentes áreas temáticas;
- Facilidade de implementação na concessionária, pois o conhecimento dos especialistas foi fundamental para o desenvolvimento desta metodologia; e
- Inexistência de estudos realizados no Brasil que abordem diretamente a análise de criticidade de transformadores de potência utilizando o método AHP, embora o método já tenha sido aplicado em outras regiões,

como evidenciado por SUWANASRI, KUMPALAVALEE e SUWANASRI (2020) na Tailândia e HU et al. (2013) na China.

O método AHP foi desenvolvido por Thomas Lorie Saaty e auxilia na tomada de decisões para solução de problemas complexos, possibilitando a escolha de uma melhor alternativa para solução de problemas. Esse método realiza comparações entre os pares de alternativas, levando em consideração o julgamento das prioridades do decisor/especialista, ou seja, considera aspectos quantitativos e qualitativos, envolvendo também o grau de certeza ou incerteza envolvido no problema a partir da redução de decisões complexas SAATY (2008).


4.2.1 Estrutura Hierárquica

Na AHP, o problema é estruturado em uma hierarquia que geralmente contém:

- **Nível 1:** Objetivo principal (ex.: selecionar um transformador crítico);
- **Nível 2:** Critérios relevantes (ex.: Idade, potência, número de clientes, critério *DGA* e físico-químico e entre outros); e
- **Nível 3:** Alternativas disponíveis (ex.: Transformador com número de série: 10001, 10002 e entre outros).

A organização hierárquica permite decompor o problema em partes mais simples, auxiliando na análise das interdependências entre os elementos. Essa estrutura hierárquica pode conter K níveis, n critérios e m alternativas. Além disso, a decisão deve estar associada aos vários níveis de elementos inter-relacionados, conforme apresentado na Figura 4.1.

Figura 4.1: Modelo de Estrutura Hierárquica - AHP.



Fonte: Elaborado pelo autor a partir de SAATY (1991).

4.2.2 Comparações Paritárias

Após realizada a estrutura hierárquica do problema, deve-se realizar o ajuste das prioridades a partir de comparações paritárias. Portanto, o método baseia-se na comparação entre pares de critérios e subcritérios, se existirem, e na construção de uma matriz quadrada (4.37).

Para caracterização das escalas e intensidades relacionadas, o especialista deve considerar a escala fundamental de Saaty que varia entre 1 e 9, apresentada no Quadro 4.1. Além disso, o modelo não inclui a hierarquia do

problema de decisão com as alternativas, ou seja, é adequado, apenas, para encontrar os pesos em cada categoria ou subcategoria.

Quadro 4.1: Escala Fundamental de Saaty.

Grau de Importância	Definição	Explicação
1	Mesma importância	As duas atividades contribuem igualmente para o objetivo.
3	Importância pequena de uma sobre a outra	A experiência e o julgamento favorecem levemente uma atividade em relação a outra.
5	Importância grande ou essencial	A experiência e o julgamento favorecem fortemente uma atividade em relação a outra.
7	Importância muito grande ou demonstrada	Uma atividade é muito fortemente favorecida em relação à outra; sua denominação de importância é demonstrada na prática.
9	Importância absoluta	A evidência favorece uma atividade em relação à outra com um grau elevado de certeza.

Fonte: Elaborado pelo autor a partir de SAATY (1991).

Após a definição da intensidade de importância e das comparações entre os critérios, elabora-se uma matriz (4.1) quadrada de ordem n (onde n que representa o número de critérios).

$$A = \begin{pmatrix} 1 & a_{12} & a_{13} & \dots & a_{1j} \\ 1/a_{12} & 1 & a_{23} & \dots & a_{2j} \\ 1/a_{13} & 1/a_{23} & 1 & \dots & a_{3j} \\ \dots & \dots & \dots & 1 & \dots \\ 1/a_{1j} & 1/a_{2j} & 1/a_{3j} & \dots & 1 \end{pmatrix} \quad (4.1)$$

Os elementos a_{ij} representam os julgamentos de paridade entre os critérios i e j . A relação entre os valores acima e abaixo da diagonal principal reflete a reciprocidade, ou seja, $a_{ji} = \frac{1}{a_{ij}}$. Isso significa que, se o critério i for considerado a_{ij} vezes mais importante que o critério j , então o critério j será $\frac{1}{a_{ij}}$ vezes mais importante que o critério i . Essa propriedade é uma característica fundamental do método AHP, garantindo a consistência lógica das comparações de pares.

Por exemplo, consideramos a comparação paritária de três critérios para a seleção de veículos de uma empresa de entregas: Custo (C), Eficiência de Combustível (E) e Capacidade de Carga (Ca). A matriz de comparação para esses critérios é estruturada conforme a matriz 4.2:

$$A = \begin{pmatrix} 1 & 1/5 & 1/7 \\ 5 & 1 & 1/2 \\ 7 & 2 & 1 \end{pmatrix} \quad (4.2)$$

Os valores na matriz representam julgamentos de importância relativa entre os critérios:

- $a_{C,E} = 1/5$: Indica que a eficiência de combustível é significativamente mais importante do que o custo;
- $a_{C,Ca} = 1/7$: Mostra que a capacidade de carga é consideravelmente mais importante do que o custo; e
- $a_{E,Ca} = 1/2$: Revela que a capacidade de carga é moderadamente mais importante do que a eficiência de combustível.

Os valores acima da diagonal principal refletem a importância inversa entre os critérios, garantindo reciprocidade e consistência nas comparações. A estruturação da matriz AHP permite estimar os pesos relativos de cada critério, facilitando a tomada de decisões com base em prioridades claras e quantificadas.

Salienta-se que nesta tese a matriz de comparação paritária utilizada no processo AHP possui ordem 10×10 representando os critérios que serão detalhados no Capítulo 5. Para a construção da matriz, foi conduzida uma etapa de julgamento participativo envolvendo 19 colaboradores da concessionária, cada um contribuindo com suas avaliações individuais sobre a importância relativa dos critérios.

A consolidação dessas avaliações foi realizada a partir da construção de uma matriz de decisão agregada, que combina os julgamentos individuais utilizando a média geométrica ponderada. O cálculo do elemento consolidado A_{ij} da matriz **A** é dado pela Equação 4.3.

$$A_{ij} = \exp \left(\frac{\sum_{k=1}^N w_k \ln a_{ij(k)}}{\sum_{k=1}^N w_k} \right) \quad (4.3)$$

Em que: $a_{ij(k)}$ representam os julgamentos de paridade entre os critérios i e j atribuídos pelo participante k ; w_k é o peso associado ao participante k e N : número total de participantes.

A utilização da média geométrica ponderada garante que os julgamentos individuais sejam proporcionalmente considerados na consolidação da matriz. Esta abordagem permite que o resultado final reflita a contribuição coletiva do grupo. Com a matriz consolidada **A**, calculam-se os pesos relativos dos critérios.

4.2.3 Pesos Relativos Usando o Método do Principal Autovetor

Após a elaboração da matriz de comparações paritária, os pesos relativos para cada critério são calculados utilizando o método do autovetor principal (4.4).

$$A\mathbf{w} = \lambda_{\max}\mathbf{w} \quad (4.4)$$

onde: $\mathbf{w}$ representa o vetor de pesos (principal autovetor), $\lambda_{\max}$ é o maior autovalor de **A**.

Após a determinação do maior autovalor e do principal autovetor, o próximo passo é normalizar os autovetores. A normalização é realizada para garantir que a soma de todos os elementos seja igual a 100%, de modo que os valores representem pesos relativos dos critérios. A Equação 4.5 representa esta normalização.

$$w_i = 100 \cdot \frac{w_i}{\sum_{k=1}^n w_k} \quad (4.5)$$

Considerando que o autovetor principal da matriz de comparação paritária apresentada em 4.2 é igual a

$[0, 1098, 0, 4877, 0, 8660]$, os pesos normalizados são calculados como segue:

$$\begin{aligned} w_C &= 100 \cdot \frac{0,1098}{0,1098 + 0,4877 + 0,8660} \approx 7,5\%, \\ w_E &= 100 \cdot \frac{0,4877}{0,1098 + 0,4877 + 0,8660} \approx 33,3\%, \\ w_{Ca} &= 100 \cdot \frac{0,8660}{0,1098 + 0,4877 + 0,8660} \approx 59,2\% \end{aligned} \quad (4.6)$$

Estes pesos refletem a importância relativa de cada critério, mostrando que o critério *Ca* é o mais significativo, seguido por *E* e *C*.

4.2.4 Consistência das Comparações

Como a base do método AHP consiste na realização de julgamentos de valor, pode-se esperar, em alguns casos, avaliações inconsistentes. Dessa forma, GOEPEL (2017), SAATY (1991), ALONSO e LAMATA (2006), TOMASHEVSKII (2015), SIRAJ (2011), TOMASHEVSKII (2014) propõem procedimentos que permitem avaliar a consistência dos julgamentos.

O principal critério de avaliação corresponde ao cálculo da Razão de Consistência (*Consistency Ratio, CR*), que mede o grau de inconsistência da matriz de julgamentos paritários. No caso deste trabalho, utilizou-se o ajuste linear proposto por ALONSO e LAMATA (2006) para calcular o CR, conforme a Equação (4.7).

$$CR = \frac{\lambda_{\max} - N}{2,7699N - 4,3513 - N} \quad (4.7)$$

onde: $\lambda_{\max}$ é o maior autovalor da matriz de comparação e N é a ordem da matriz de comparação.

A Razão de Consistência (*CR*) é uma métrica que avalia o grau de inconsistência dos julgamentos em relação ao esperado em uma matriz de comparação gerada aleatoriamente. Valores de $CR \leq 0,10$ (correspondentes a 10%) são considerados aceitáveis, indicando que a matriz de julgamentos possui um nível adequado de consistência.

Uma outra métrica alternativa para análise de consistência é o *Geometric Consistency Index (GCI)* TOMASHEVSKII (2014, 2015) que mede a consistência utilizando a média geométrica das comparações (4.8). O *GCI* deve satisfazer $GCI < 0,35$ para $n > 4$ a fim de garantir uma consistência aceitável ESCOBAR, AGUARÓN e MORENO-JIMÉNEZ (2004).

$$GCI = \frac{2}{(n-1)(n-2)} \sum_{i < j} \left[\ln(a_{ij}) - \ln\left(\frac{p_i}{p_j}\right) \right]^2 \quad (4.8)$$

onde: a_{ij} são os elementos da matriz de comparação, e p_i e p_j são os pesos relativos das prioridades normalizadas (Equação 4.9) dos critérios i e j , respectivamente.

$$p_{ij} = \frac{a_{ij}}{\sum_{k=1}^N a_{ik}}, \quad (4.9)$$

No método AHP, o vetor próprio principal, também chamado de vetor de prioridades, é calculado a partir da matriz de comparação paritária. Este vetor próprio, associado ao maior autovalor da matriz, $\lambda_{\max}$, é utilizado

para determinar os pesos relativos de cada critério. Esses pesos refletem as prioridades atribuídas com base nos julgamentos realizados.

No entanto, para garantir a confiabilidade das decisões baseadas no AHP, é necessário avaliar os pesos obtidos. Essa avaliação é realizada a partir do cálculo do erro no Método do Vetor Próprio (*Eigenvector Method - EVM*), que mede a discrepância entre o produto da matriz de comparação pelos pesos estimados e os pesos calculados diretamente. Esse erro é matematicamente expresso pela Equação 4.10.

$$\Delta w_i = \sqrt{\frac{1}{n-1} \sum_{k=1}^n \left(\frac{n}{\lambda_{\max}} a_{ik} w_k - w_i \right)^2}, \quad i = 1, \dots, n \quad (4.10)$$

onde a_{ik} são os elementos da matriz de comparação, w_k são os pesos calculados para cada critério, e $\lambda_{\max}$ é o maior autovalor da matriz de comparação.

Para avaliar a média do erro relativo dos pesos calculados, considera-se o *Mean Relative Error (MRE)* expresso matematicamente pela Equação 4.11.

$$MRE = \sqrt{\frac{1}{n} \sum_{j=1}^n \left(\frac{\Delta w_i}{w_i} \right)^2} \quad (4.11)$$

Além do *CR* e do *GCI*, GOEPEL (2013) enfatiza que o consenso entre os participantes também deve ser analisado como uma medida de consistência.

O consenso no método AHP é uma métrica que avalia a concordância entre os participantes no processo de decisão. Esse consenso é calculado a partir dos resultados da teoria da entropia de *Shannon* α , β e γ .

No método de Análise Hierárquica (AHP), a concordância entre os participantes é avaliada a partir de um indicador de consenso conhecido como S^* . Este indicador é derivado utilizando-se as entropias de *Shannon*, especificamente as entropias α , β , e γ , calculadas a partir das prioridades normalizadas p_{ij} (4.9).

A entropia de *Shannon* α (H_α) é calculada para refletir a diversidade de opiniões entre os participantes em relação a cada critério, a partir da Equação 4.12.

$$H_\alpha = \frac{1}{K} \sum_{j=1}^K \sum_{i=1}^N -p_{ij} \ln p_{ij}, \quad (4.12)$$

A entropia de *Shannon* γ (H_γ), que mede a entropia das médias das prioridades agregadas, é calculada a partir da Equação 4.13.

$$H_\gamma = \sum_{j=1}^K -\bar{p}_j \ln \bar{p}_j, \quad (4.13)$$

A entropia de *Shannon* β (H_β), que indica a variação entre as prioridades agregadas e individuais, é expressa pela Equação 4.14.

$$H_\beta = H_\gamma - H_\alpha. \quad (4.14)$$

O indicador de consenso S^* é então definido pela Equação 4.15.

$$S^* = \frac{\frac{1}{\exp(H_\beta)} - \exp(H_{\alpha \min}) / \exp(H_{\gamma \min})}{1 - \exp(H_{\alpha \max}) / \exp(H_{\gamma \max})} \quad (4.15)$$

Em que: os valores $H_{\alpha \min}$ e $H_{\gamma \max}$ são calculados pelas Equações 4.16 e 4.17.

$$H_{\alpha \min} = -\frac{M}{N+M-1} \ln \left(\frac{c_{\max}}{N+M-1} \right) - (N-1) \frac{1}{N+M-1} \ln \left(\frac{1}{N+M-1} \right) \quad (4.16)$$

$$H_{\gamma \max} = \ln(n) \quad (4.17)$$

Onde: M é a relação entre $\exp(H_\alpha)$ e $\exp(H_\gamma)$.

O valor de S^* pode variar de 0% a 100%, com interpretações que variam de muito baixo a muito alto consenso. Um valor mais alto de S^* indica um maior grau de concordância entre os participantes, refletindo uma coesão significativa no grupo durante o processo decisório.

Estas métricas fornecem uma análise detalhada e consistente dos julgamentos no AHP, assegurando que as decisões tomadas se baseiam em avaliações coesas e fundamentadas.

4.3 Análise Multivariada e Aprendizado Supervisionado

A análise multivariada compreende um conjunto de métodos estatísticos desenvolvidos para quantificar inter-relações e associações entre múltiplas variáveis quantitativas simultaneamente, proporcionando uma compreensão aprimorada dos dados. As técnicas variam amplamente em função e aplicabilidade, abrangendo desde a Análise de Componentes Principais (*Principal Component Analysis - PCA*), regressão múltipla, correlação múltipla, análise discriminante múltipla, análise de correlação canônica, análise conjunta, análise de agrupamentos, análise de correspondência, entre outros HAIR et al. (2009).

Para o propósito desta tese, focado na análise não supervisionada dos dados sobre a criticidade dos transformadores, enfatizando a redução de dimensionalidade, agrupamento de dados e investigação das dependências entre variáveis, optou-se por técnicas específicas de análise multivariada não supervisionada, tais como: *Principal Component Analysis - PCA* (método de análise dos fatores comuns) e o *KNN* (algoritmo de aprendizado não supervisionado). A seleção dessas técnicas foi motivada pela necessidade de uma abordagem objetiva e imparcial, ao contrário da AHP, que depende de julgamentos comparativos entre pares e pode levar a análises tendenciosas.

Dentro deste contexto, o método *PCA* foi selecionado por sua capacidade de reduzir a dimensionalidade dos dados, transformando um conjunto de variáveis correlacionadas em um número reduzido de componentes principais. Esta transformação facilita a identificação das direções de máxima variação nos dados, proporcionando uma visão clara das características mais relevantes. Já o método *KNN* foi utilizado para classificar os transformadores com base em critérios técnicos, econômicos e operacionais.

4.3.1 Análise Exploratória dos Dados

Durante a análise exploratória e antes da implementação de técnicas de análise multivariada, a normalização dos dados se torna uma etapa importante. Esse processo é realizado, pois as variáveis exibem escalas variadas ou não atendem às premissas de normalidade.

Nessa tese, optou-se pela normalização *Min-Max* (Equação 4.18), pois essa técnica preserva a estrutura relativa dos dados, mantendo as proporções entre os valores mesmo quando transformados para um intervalo de 0 a 1. Diferentemente da normalização *Z-Score*, que transforma os dados para uma distribuição com média 0 e desvio padrão 1, este método não pressupõe que os dados sigam uma distribuição normal. Portanto, a escolha do *Min-Max* considerou a natureza da distribuição dos dados.

$$x_{\text{norm}_i} = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (4.18)$$

Em que: x_i é um valor original da variável, $\min(x)$ e $\max(x)$ são, respectivamente, os valores mínimo e máximo observados na variável.

Embora os métodos *PCA* não exijam a suposição de normalidade na distribuição dos dados, a avaliação das correlações entre variáveis e da conformidade com a distribuição normal é essencial em análises multivariadas. Essa análise é particularmente relevante para garantir a adequação e a validade estatística de testes como o *Kaiser-Meyer-Olkin* (*KMO*), que depende das propriedades correlacionais dos dados.

O teste de *Kaiser-Meyer-Olkin* (*KMO*) BARTLETT (1951) é um método estatístico que mede a proporção de variância compartilhada entre as variáveis em um conjunto de dados, avaliando sua adequação para análise fatorial, como o *PCA*. O índice *KMO* é calculado a partir da Equação 4.19.

$$KMO = \frac{\sum_i \sum_{j \neq i} r_{x_{\text{norm}_i}, x_{\text{norm}_j}}^2}{\sum_i \sum_{j \neq i} r_{x_{\text{norm}_i}, x_{\text{norm}_j}}^2 + \sum_i \sum_{j \neq i} s_{x_{\text{norm}_i}, x_{\text{norm}_j}}^2} \quad (4.19)$$

onde: r_{ij} é o coeficiente de correlação entre as variáveis i e j , s_{ij} é o coeficiente de correlação parcial entre as variáveis i e j .

Valores de *KMO* próximos de 1 indicam uma forte correlação entre as variáveis, sugerindo que o *PCA* é apropriado. Já valores abaixo de 0,5 indicam correlações fracas, o que pode inviabilizar a análise.

A aplicação do teste pode ser estruturada da seguinte maneira:

1. Calcule-se os coeficientes de correlação de *Pearson* para cada par de variáveis. O coeficiente de correlação é dado por 4.20.

$$r_{ij} = \frac{\sum (x_i - \bar{x}_i)(x_j - \bar{x}_j)}{\sqrt{\sum (x_i - \bar{x}_i)^2 \sum (x_j - \bar{x}_j)^2}} \quad (4.20)$$

onde: x_i e x_j são as variáveis analisadas e $\bar{x}_i$ e $\bar{x}_j$ são as médias das variáveis x_i e x_j .

2. Calcule-se os coeficientes de correlação parcial $s_{ij,k}$ para o par de variáveis x_i e x_j , ajustando pela variável x_k . O coeficiente de correlação parcial é dado por 4.21.

$$s_{ij.k} = \frac{r_{ij} - r_{ik}r_{jk}}{\sqrt{(1 - r_{ik}^2)(1 - r_{jk}^2)}} \quad (4.21)$$

onde: r_{ij} é o coeficiente de correlação entre x_i e x_j , r_{ik} é o coeficiente de correlação entre x_i e x_k , r_{jk} é o coeficiente de correlação entre x_j e x_k , $s_{ij.k}$ é o coeficiente de correlação parcial entre x_i e x_j , ajustando pela influência de x_k .

3. Determina-se o valor de *KMO* a partir da matriz de correlação (r_{ij}) e matriz de correlação parcial (s_{ij}) na Equação 4.19; e
4. Por fim, interpreta-se os resultados do teste *KMO*. Para o *KMO*, valores acima de 0,5 indicam que as variáveis possuem correlações suficientes para análise *PCA*; valores inferiores a 0,5 sugerem que as variáveis são inadequadas para este tipo de análise.

O teste *KMO* é amplamente utilizado para avaliar a correlação dos dados para análise fatorial ou *PCA*, verificando a proporção de variância comum entre as variáveis. No entanto, como o cálculo do *KMO* tradicionalmente utiliza o coeficiente de correlação de *Pearson*, ele é mais apropriado para dados que seguem, pelo menos parcialmente, uma distribuição normal.

Quando os dados apresentam desvios significativos de normalidade, é recomendável recorrer a abordagens alternativas que utilizam testes não paramétricos. O coeficiente de correlação de *Spearman* é uma medida não paramétrica que avalia a força e a direção da associação entre duas variáveis ranqueadas. Este coeficiente é particularmente útil quando os dados não atendem à suposição de normalidade requerida pelo coeficiente de correlação de *Pearson* AL-HAMEED (2022). O coeficiente de *Spearman*, r_s , é calculado a partir da Equação 4.22.


$$r_s = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (4.22)$$

onde: d_i é a diferença entre os postos das duas variáveis ($d_i = R_A - R_B$), e n é o número de observações.

Essa equação quantifica quão bem a relação entre as duas variáveis pode ser descrita usando uma função monotônica. O resultado varia de -1 a +1, onde +1 indica uma associação perfeitamente positiva, -1 indica uma associação perfeitamente negativa, e valores próximos a 0 sugerem uma relação linear fraca ou inexistente.

Para uma avaliação visual da distribuição de normalidade e das relações entre variáveis, pode-se utilizar gráficos como o histograma e o *Q-Q Plot* (*Quantile-Quantile Plot*), ambos úteis para análises exploratórias.

O *Q-Q Plot* é uma representação gráfica utilizada para avaliar se os dados amostrais seguem uma distribuição teórica específica, como a distribuição normal. Na Figura 4.2, os *quantis* amostrais (eixo y) são comparados com os *quantis* teóricos (eixo x). Quando os dados estão alinhados à distribuição teórica, os pontos se dispõem aproximadamente ao longo de uma linha reta. Desvios dessa linha indicam discrepâncias, como assimetrias ou caudas extremas na distribuição HUANG (2023). Além disso, desvios da linha de referência podem revelar variabilidade amostral.

Figura 4.2: Representação de Diferentes Padrões de Distribuição em um Q-Q Plot.

Fonte: Elaborado pelo autor a partir de HUANG (2023).

Na Figura 4.2, são apresentados cinco cenários distintos:

1. Assimetria à Esquerda: Os pontos se afastam para baixo no lado esquerdo e para cima no lado direito, indicando que a cauda esquerda da distribuição é mais longa;
2. Normal: Os pontos seguem uma linha reta, indicando que os dados são aproximadamente normais;
3. Assimetria à Direita: Os pontos se afastam para cima no lado esquerdo e para baixo no lado direito, sugerindo uma cauda direita mais longa.
4. Cauda "Pesada": Desvios extremos nos dois lados indicam que as caudas da distribuição são mais longas do que as da distribuição normal; e
5. Cauda "Leve": Os pontos ficam mais próximos ao centro e menos dispersos, indicando que as caudas são mais curtas que as da distribuição normal.

4.3.2 Análise de Componentes Principais

A Análise de Componentes Principais (*Principal Component Analysis*, PCA) é uma técnica matemática e estatística usada para reduzir a dimensionalidade de conjuntos de dados enquanto preserva o máximo possível da variância dos dados originais. Formalizada por Harold Hotelling em 1933 HOTELLING (1933), o PCA utiliza transformações lineares para mapear p variáveis correlacionadas em k variáveis ortogonais ($k \leq p$), chamadas componentes principais. O objetivo principal da PCA é encontrar componentes principais, ou combinações lineares das variáveis originais, que expliquem a maior parte da variância nos dados Jolliffe (2002).

Dado um conjunto de dados $X \in \mathbb{R}^{n \times p}$, onde n é o número de observações e p o número de variáveis, o PCA baseia-se na decomposição da matriz de covariância $\Sigma \in \mathbb{R}^{p \times p}$, definida como 4.23.

$$\Sigma = \frac{1}{n-1} X^\top X, \quad (4.23)$$

Em que: Σ é simétrica e positiva semi-definida. Essa matriz captura as correlações entre as variáveis e serve como base para a identificação das direções principais de variabilidade nos dados.

A primeira componente principal u_1 é a combinação linear das variáveis originais X que maximiza a variância explicada, dada por 4.24:

$$u_1 = X w_1, \quad (4.24)$$

sujeito à restrição de normalização (4.25):

$$w_1^\top w_1 = 1. \quad (4.25)$$

Matematicamente, isso equivale a resolver o problema de autovalores e autovetores da matriz de covariância S (4.26):

$$\Sigma w_1 = \lambda_1 w_1, \quad (4.26)$$

Em que: w_1 é o autovetor correspondente ao maior autovalor λ_1 , λ_1 representa a variância explicada pela primeira componente principal.

As componentes principais subsequentes ($u_2, u_3, \dots$) são determinadas de forma a maximizar a variância explicada, sob a condição de ortogonalidade com as componentes anteriores, calculadas a partir de 4.27.

$$\Sigma w_j = \lambda_j w_j, \quad j = 1, 2, \dots, p, \quad (4.27)$$

com os autovalores ordenados de forma decrescente ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$).

A proporção da variância explicada por cada componente é calculada a partir da Equação 4.28.

$$\text{Variância explicada} = \frac{\lambda_j}{\sum_{k=1}^p \lambda_k}. \quad (4.28)$$

A variância acumulada, por sua vez, é calculada a partir da Equação 4.29.

$$\text{Variância acumulada} = \frac{\sum_{j=1}^r \lambda_j}{\sum_{k=1}^p \lambda_k}. \quad (4.29)$$

Um critério comum para selecionar o número de componentes principais r é garantir que a variância acumulada seja maior que um limite predefinido, por exemplo 80%.

Após determinar os autovetores w_j , os dados originais X são projetados no novo espaço (4.30) de variáveis

principais.

$$Z = XW_r \quad (4.30)$$

onde: $Z \in \mathbb{R}^{n \times r}$ contém as r primeiras componentes principais, e $W_r \in \mathbb{R}^{p \times r}$ é a matriz cujas colunas são os r autovetores (componentes principais) associados.

Esses resultados são utilizados para construir o *Scree Plot* e para interpretar as contribuições de cada variável em relação às componentes principais.

4.3.3 *K-Nearest Neighbors (KNN)*

O algoritmo clássico *K-Nearest Neighbors* (KNN) é um método de aprendizado supervisionado utilizado, principalmente para fins de classificação. Ele é baseado em um parâmetro variável, conhecido como k , que determina o número de “vizinhos mais próximos” a serem considerados UDDIN et al. (2022).


O funcionamento do KNN consiste em localizar os pontos de dados mais próximos (ou vizinhos) em um conjunto de treinamento, com base em uma métrica de distância, para uma dada consulta. A métrica mais comumente utilizada é a distância Euclidiana, que mede a proximidade entre dois pontos no espaço das características. A equação da distância Euclidiana é dada por 4.31.

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.31)$$

onde: x e y são vetores que representam os pontos no espaço de características, n é o número de características, e x_i e y_i são os valores correspondentes às i -ésimas características de x e y , respectivamente.

Após calcular as distâncias entre o ponto de consulta e todas as amostras do conjunto de treinamento, o algoritmo seleciona os k vizinhos mais próximos com base nas menores distâncias. Em seguida, aplica uma regra de *votação por maioria* para determinar a classe final da amostra de consulta. A classe mais frequente entre os vizinhos selecionados é atribuída como a classificação final.

A Figura 4.3 ilustra um exemplo desse processo. Suponha que $k = 3$ para a consulta B . O algoritmo localiza os 3 vizinhos mais próximos e verifica que, desses vizinhos, dois pertencem à Classe 1 e um à Classe 0. Nesse caso, pela regra de votação por maioria, a consulta B é classificada como Classe 1. De forma semelhante, para a consulta A , se $k = 5$, e a maioria dos vizinhos pertence à Classe 0, a consulta é classificada como Classe 0.

Figura 4.3: Exemplo do Método KNN.

Fonte: Retirado de UDDIN et al. (2022).

O valor de k é um hiperparâmetro do algoritmo e precisa ser ajustado de forma empírica, balanceando a precisão e a capacidade de generalização do modelo. Valores muito baixos de k podem tornar o algoritmo sensível a ruídos, enquanto valores muito altos podem diluir a influência dos vizinhos mais próximos.

Em problemas de classificação, especialmente quando as classes estão desbalanceadas, o *KNN* pode apresentar desempenho insatisfatório ao favorecer as classes majoritárias. Para reduzir esse problema, técnicas de reamostragem, como o *Synthetic Minority Oversampling Technique (SMOTE)*, podem ser utilizadas.

4.3.4 Synthetic Minority Oversampling Technique (SMOTE)

Proposto por CHAWLA et al. (2002), o algoritmo *Synthetic Minority Oversampling Technique SMOTE* é amplamente reconhecido como uma solução eficaz para lidar com conjuntos de dados desbalanceados, criando novas amostras sintéticas da classe minoritária. Diferentemente da replicação direta de amostras, o *SMOTE* gera amostras sintéticas utilizando uma interpolação linear entre um ponto de classe minoritária e um de seus K vizinhos mais próximos, reduzindo a disparidade de proporção entre as classes e ampliando as regiões de decisão dos classificadores. O método segue os seguintes passos WANG et al. (2021):

1. **Seleção de vizinhos mais próximos:** Para cada amostra da classe minoritária x_i ($i = 1, 2, \dots, n$), calcula-se a distância para as demais amostras da mesma classe, identificando os k vizinhos mais próximos.
2. **Escolha de vizinhos para interpolação:** De acordo com o grau de ampliação desejado, seleciona-se aleatoriamente m vizinhos ($m \leq k$) para cada amostra x_i . Os vizinhos selecionados são denotados como x_{ij} ($j = 1, 2, \dots, m$).
3. **Geração de amostras sintéticas:** Novas amostras sintéticas p_{ij} são criadas a partir da Equação 4.32.

$$p_{ij} = x_i + \text{rand}(0, 1) \times (x_{ij} - x_i) \quad (4.32)$$

onde: $\text{rand}(0, 1)$ representa um número aleatório uniformemente distribuído no intervalo $[0, 1]$.

Esse processo é repetido até que o conjunto de dados alcance a proporção de balanceamento desejada. Além de aumentar a quantidade de amostras minoritárias, o *SMOTE* preserva a diversidade dos dados ao posicionar as novas amostras no espaço n -dimensional de forma distribuída, promovendo maior generalização dos modelos de classificação. Assim, o método contribui para a melhoria do desempenho em problemas de classificação com dados desbalanceados.

Para avaliação de desempenho dos algoritmos de aprendizado supervisionado, três métricas principais são comumente utilizadas: acurácia, precisão, sensibilidade e índice F_1 HICKS et al. (2022).

A acurácia (Equação 4.33) é uma métrica utilizada para avaliar o desempenho do modelo de aprendizado supervisionado a partir da proporção de previsões corretas em relação ao total de exemplos analisados.

$$\text{Acurácia} = \frac{\text{Positivos Verdadeiros} + \text{Negativos Verdadeiros}}{\text{Positivos Verdadeiros} + \text{Negativos Verdadeiros} + \text{Falsos Positivos} + \text{Falsos Negativos}} \quad (4.33)$$

A precisão (Equação 4.34) mede a confiabilidade de um modelo ao prever que um exemplo pertence a uma determinada classe. Em problemas de classificação, a precisão é definida como a razão entre os verdadeiros positivos e o total de previsões positivas feitas pelo modelo.

$$\text{Precisão} = \frac{\text{Positivos Verdadeiros}}{\text{Positivos Verdadeiros} + \text{Falsos Positivos}}. \quad (4.34)$$

A sensibilidade (Equação 4.35) mede a capacidade do modelo de identificar corretamente todos os exemplos positivos, sendo definido como a razão entre os verdadeiros positivos e o total de exemplos positivos reais.

$$\text{Sensibilidade} = \frac{\text{Positivos Verdadeiros}}{\text{Positivos Verdadeiros} + \text{Falsos Negativos}}. \quad (4.35)$$

O índice F_1 (Equação 4.36) é uma métrica definida como a média harmônica entre a precisão e o *recall*.

$$\text{Índice } F_1 = 2 \cdot \frac{\text{Precisão} \cdot \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}}. \quad (4.36)$$

A média harmônica é utilizada porque atribui mais peso aos valores baixos, refletindo melhor situações em que o equilíbrio entre precisão e recall é particularmente importante.

Adicionalmente, a matriz de confusão é uma ferramenta visual para avaliar o desempenho de modelos de classificação. Essa matriz apresenta os resultados em quatro categorias principais: Verdadeiros Positivos (VP), Falsos Positivos (FP), Verdadeiros Negativos (VN) e Falsos Negativos (FN). Uma representação de uma matriz para duas classes é dada por 4.37.

$$\begin{bmatrix} \text{VP} & \text{FP} \\ \text{FN} & \text{VN} \end{bmatrix} \quad (4.37)$$

Cada elemento da matriz representa:

- **Verdadeiros Positivos (VP):** Casos corretamente classificados como positivos;
- **Falsos Positivos (FP):** Casos incorretamente classificados como positivos;
- **Verdadeiros Negativos (VN):** Casos corretamente classificados como negativos; e
- **Falsos Negativos (FN):** Casos incorretamente classificados como negativos.

4.4 Considerações Finais

Neste capítulo, foram apresentadas as fundamentações teóricas para a aplicação de técnicas de análise multicritério e multivariada no contexto da avaliação da criticidade de transformadores de potência. A utilização do método AHP, com sua estrutura hierárquica e comparações paritárias, permitiu o estabelecimento de pesos relativos consistentes para os critérios analisados. Métricas como a Razão de Consistência (*CR*) e o Índice de Consistência Geométrica (*GCI*) garantiram a análise da consistência dos julgamentos, conferindo maior confiabilidade ao processo decisório.

Além disso, foram exploradas técnicas de análise multivariada e de aprendizado supervisionado, como o PCA e o *KNN*, para construção de um algoritmo classificador do tipo supervisionado. Além disso, considerando o desbalanceamento das classes nos dados analisados, a técnica *SMOTE* foi incorporada como parte da metodologia, sendo fundamental para equilibrar as amostras e melhorar o desempenho do modelo. A aplicação integrada dessas abordagens será discutida em maior profundidade nas diretrizes metodológicas, apresentando a construção do modelo proposto nesta pesquisa.

Por fim, foram apresentados conceitos sobre matriz de confusão e métricas de desempenho: acurácia, precisão, sensibilidade e índice F_1 .

Capítulo 5

DIRETRIZES METODOLÓGICAS

5.1 Considerações Iniciais

Neste capítulo será apresentada a metodologia dessa tese que foi desenvolvida para caracterizar o nível de criticidade dos 355 transformadores de potência. As seguintes etapas compõem essa metodologia:


- **Etapa 1:** Definição dos critérios para a composição da base de dados dos transformadores de potência da concessionária, alinhando critérios específicos (técnicos, operacionais e econômicos);
- **Etapa 2:** Realização de uma análise exploratória e processamento dos dados, abrangendo normalização segundo o método *Min-Max* e a segregação de conjuntos de interesse utilizando o método de *Sturges* (Equação 5.1);
- **Etapa 3:** Implementação do método AHP a partir da ferramenta desenvolvida por GOEPEL (2018), com a contribuição interdisciplinar de 19 colaboradores dos departamentos de manutenção, engenharia e gestão de transformadores;
- **Etapa 4:** Interpretação dos resultados obtidos pelo método AHP e desenvolvimento de um algoritmo para classificar e priorizar a criticidade dos transformadores. Esta etapa considera a integração das variáveis utilizadas para o cálculo do índice de impacto (I_{IMP}) e índice de saúde do transformador (I_{SAT}); e
- **Etapa 5:** Desenvolvimento e implementação de um algoritmo classificador que combina *PCA* e *KNN* para determinar o nível de criticidade.

5.2 Análise Hierárquica dos Processos (AHP)

5.2.1 Método do Cálculo do Índice de Impacto - (I_{IMP})

A Figura 5.1 apresenta o fluxograma da metodologia desenvolvida para a implementação do método multicritério, no qual foi utilizado para o cálculo do Índice de Impacto (I_{IMP}).

Figura 5.1: Fluxograma da Metodologia do Método Multicritério.



Fonte: Elaborado pelo autor.

A primeira etapa envolveu a definição dos critérios e a construção da base de dados necessária para o novo cálculo do índice de impacto (I_{IMP}) de cada equipamento. A aplicação do método AHP tem como objetivo estabelecer os pesos relativos de cada critério. Os critérios para os 355 transformadores nas classes de tensão 34,5, 69 e 138 kV são:

- **Número de Clientes (Mil.):** Este critério reflete a importância do ativo em relação número de unidades consumidoras. Quanto maior o valor mais crítico é o ativo. Contudo, é importante ressaltar que um maior

número de clientes não implica necessariamente em uma demanda mais elevada ou maior faturamento. Tais variáveis dependem significativamente do perfil de consumo dos clientes atendidos;

- **Distância da Base (km):** Este critério avalia a logística necessária para manutenção ou reparos emergenciais. A distância da base de controle até o ativo influencia diretamente o tempo de resposta para intervenções, sendo relevante em emergência para grandes distâncias;
- **Potência Nominal (MW):** Representa a capacidade do ativo em atender à demanda de energia. Ativos com maior potência nominal são capazes de suportar uma carga maior e consequentemente são mais críticos;
- **Valor do Ativo Societário (Mil.):** Indica o valor patrimonial do ativo em relação aos acionistas. Basicamente, em caso de falha os acionistas são impactados financeiramente pelo sucateamento antecipado deste equipamento. Este valor é reduzido com a depreciação do ativo e, portanto, altos valores representam alta criticidade;
- **FEC e DEC:** Estes indicadores de qualidade são relevantes na análise da continuidade do serviço de fornecimento de energia. Eles possuem um impacto financeiro direto na empresa, uma vez que ultrapassagem de valores limites resultam em compensações financeiras aos consumidores. Especificamente, a relação entre o valor anual máximo registrado e o valor contratado é utilizada no banco de dados, coletados em ANEEL (2024). Assim, quanto maior essa relação, mais crítico é o transformador;
- **Idade (Anos):** A idade do ativo é um indicador relacionado ao ciclo de vida, sendo que no Brasil a vida útil regulatória deste equipamento é de 35 anos definida no Manual de Controle Patrimonial do Setor Elétrico (MCPSE). Deste modo, ativos mais antigos são mais críticos, pois podem requerer intervenções mais frequentes e planejamento cuidadoso para sua substituição ou reforma;
- **Subestação (SE) de Transmissão:** Ativos instalados em SE de transmissão são considerados críticos, pois estão em locais com equipamentos que compõem a rede básica. Uma falha deste equipamento pode impactar outros ativos próximos e resultar em penalizações financeiras significativas;
- **Risco Regulatório:** Este critério enfatiza se o ativo é parte integrante de conjunto elétrico crítico de infraestruturas; e
- **Cargas Críticas:** Considera a importância das unidades consumidoras atendidas pelo ativo. Cargas críticas incluem aquelas que, por qualquer interrupção ou degradação do serviço, podem causar impactos severos, como em hospitais, centros de dados, e outras infraestruturas essenciais.

Conforme apresentado, em todos os critérios avaliados, existe uma correlação direta entre o valor da variável e seu nível de criticidade: quanto maior o valor, maior é considerada a criticidade do critério.

Para a maioria dos critérios, houve uma dificuldade significativa em desagregar as variáveis associadas a cada ativo individualmente. Consequentemente, optou-se por adotar uma abordagem que considera uma variável global representativa da subestação como um todo. As exceções a essa abordagem foram a potência nominal, o valor do ativo societário e a idade. Portanto, o índice deste critério está relacionado ao impacto que o ativo pode causar com uma saída de operação não programada.

As variáveis quantitativas, tanto discretas quanto contínuas, foram organizadas em grupos utilizando o método estatístico de *Sturges*. Neste contexto, com N' (355 neste caso) sendo o número total de observações, resultou em 9 grupos distintos. A Equação 5.1 expressa o cálculo para determinar o número ideal de grupos. Já as variáveis qualitativas foram separadas em dois grupos.

$$G = 1 + 3,322 \cdot \log(N') \quad (5.1)$$

Nas Tabelas 5.1 e 5.2 estão representados os valores das faixas de cada grupo, bem como as respectivas notas (W').

Tabela 5.1: Valores e Notas (w') dos Grupos Para Cada Critério: Número de Clientes, Distância da Base, Potência Nominal, Valor Ativo Societário e FEC.

Número de Clientes	Distância da Base (km)	Potência Nominal (MW)	Valor Ativo Societário	FEC	Nota (W')
> 65721	> 79,06	> 49	> 4057	> 0,9972	10,00
[57505, 65720]	[69, 17, 79, 05]	[42, 48]	[3549, 4056]	[0, 8876, 0, 9972]	20,00
[49290, 57505]	[59, 29, 69, 17]	[36, 42]	[3042, 3549]	[0, 7780, 0, 8876]	30,00
[41075, 49290]	[49, 41, 59, 29]	[30, 36]	[2535, 3042]	[0, 6684, 0, 7780]	40,00
[32860, 41075]	[39, 53, 49, 41]	[24, 30]	[2028, 2535]	[0, 5589, 0, 6684]	50,00
[24645, 32860]	[29, 65, 39, 53]	[18, 24]	[1521, 2028]	[0, 4493, 0, 5589]	60,00
[16430, 24645]	[19, 77, 29, 65]	[12, 18]	[1014, 1521]	[0, 3397, 0, 4493]	70,00
[8215, 16430]	[9, 88, 19, 77]	[6, 12]	[507, 1014]	[0, 2302, 0, 3397]	85,00
≤ 8215	≤ 9,88	≤ 6	≤ 507	≤ 0,2302	100,00

Fonte: Elaborado pelo autor.

Tabela 5.2: Valores e Notas (w') dos Grupos Para Cada Critério: DEC, Idade, Subestação (SE) Transmissão Risco Regulatório e Cargas Críticas.

DEC	Idade	SE Transmissão	Risco Regulatório	Cargas Críticas	Nota (W')
> 1,13	> 63	1	1	1	10,00
[1,02, 1,13]	[49,63]				20,00
[0,91, 1,02]	[42,49]				30,00
[0,79,0,91]	[35,42]				40,00
[0,68,0,79]	[28,35]				50,00
[0,57,0,68]	[21,28]				60,00
[0,46,0,57]	[14,21]				70,00
[8215,16430]	[7,14]				85,00
≤ 0,35	≤ 7	0	0	0	100,00

Fonte: Elaborado pelo autor.

A distribuição das notas dos grupos varia entre 10 e 100. Para os elementos com os maiores valores em cada grupo é atribuído uma nota igual a 10, enquanto aqueles mais próximos aos valores mínimos recebem o máximo de 100.

Após a definição dos critérios, 19 engenheiros(as) da empresa realizaram o preenchimento da planilha GOE-PEL (2018) com o grau de importância de cada critério em relação ao impacto (I_{IMP}). Com o grau de importância atribuído, foi possível construir a matriz de comparação paritária e a matriz consolidada, a partir da média geométrica ponderada dos elementos de julgamentos de paridade.

A consistência dos julgamentos e o consenso foram analisados para calcular o peso relativo de cada critério a partir da normalização dos autovetores principais de cada critério.

Por fim, o cálculo do I_{IMP} é realizado a partir da Equação 5.2. Para cada transformador R dentro de um conjunto de 355 transformadores, este índice é determinado pela soma ponderada das notas atribuídas a cada critério para cada transformador, onde p representa o número total de critérios avaliados. Para cada transformador R , $W'_{i,R}$ indica a nota atribuída ao grupo do critério i e w_i é o peso associado a esse critério, derivado do autovetor normalizado obtido pelo método de AHP.


$$I_{IMP_R} = \sum_{t=1}^p (W'_{t,R} \cdot w_t) \quad \text{para } R = 1, 2, \dots, 355 \quad (5.2)$$

Este cálculo permite avaliar a importância relativa de cada transformador com base no impacto que eventuais falhas podem causar, englobando aspectos técnicos e econômicos.

Para determinar o ranqueamento dos transformadores com base no índice de impacto, decidiu-se distribuir os 355 transformadores em cinco níveis distintos, conforme ilustrado na Figura 5.2, que apresenta a quantidade de equipamentos em cada classe.

Essa separação foi realizada para destacar os ativos com maiores valores no índice de impacto, permitindo uma análise focada nos transformadores mais representativos para este critério. Aproximadamente os 10% dos maiores valores foram categorizados como "impacto muito alto", priorizando os ativos que demandam atenção especial devido ao seu potencial de impacto significativo no sistema.

Figura 5.2: Distribuição dos Índices de Impacto para os 355 Transformadores.




Fonte: Elaborado pelo autor.

5.3 Método do Cálculo do Índice de Saúde - (I_{SAT})

Conforme discutido na fundamentação teórica, o índice de saúde do transformador é uma métrica importante na GA, usada para quantificar o estado de degradação do equipamento. Apesar de ser um tema amplamente investigado na literatura científica, a inclusão desse índice na avaliação da criticidade do transformador representa uma contribuição desta pesquisa. Essa abordagem é particularmente relevante, pois integra simultaneamente critérios técnicos, operacionais e econômicos relacionados à saúde do ativo (I_{SAT}) e ao seu impacto (I_{IMP}).

As falhas na parte ativa (núcleo e enrolamento) representam uma proporção significativa (37%) das falhas graves em transformadores, independentemente da classe de tensão CIGRE (2024). Em função dessa constatação, a metodologia para calcular o índice de saúde foi adaptada de SILVA (2020) e CHITNAVIS e BHASME (2017), incorporando o Fator de Carregamento (FC), Análise de Gases Dissolvidos (AGD) e Análise Físico-química (AFQ) conforme detalhado no fluxograma 5.3.

Figura 5.3: Fluxograma da Metodologia do Cálculo do Índice de Saúde do Transformador.

Fonte: Elaborado pelo autor.

Elenca-se a seguir as etapas para o cálculo do (I_{SAT}):

- **Fator de Carregamento (FC):** A metodologia de CHITNAVIS e BHASME (2017) foi adaptada para considerar uma única medição de carregamento médio mensal por transformador. A Tabela 5.3 apresenta os valores para o cálculo de F_{HC} , considerando como parâmetro a razão entre o carregamento médio mensal (S) e a potência nominal (S_n).

Tabela 5.3: Relações para Cálculo do FC .

FC	S/S_n
0	$S/S_n < 0.6$
1	$0.6 \leq S/S_n < 1$
2	$1 \leq S/S_n < 1.3$
3	$1.3 \leq S/S_n < 1.5$
4	$S/S_n > 1.5$

Fonte: Adaptado de CHITNAVIS e BHASME (2017).

- **Análises de Gases Dissolvidos (AGD) e Análise Físico-química (AFQ):** Os parâmetros, as pontuações e os pesos para o cálculo destes fatores são definidos nas Tabelas 5.4 e 5.5.

Tabela 5.4: Pontuações (S_i) e Pesos (W_i) para o Cálculo do AGD.

Gás	1	2	3	S_i	4	5	6	W_i
H_2	≤ 100	100 – 200	200 – 300	300 – 500	500 – 700	≤ 700		2
CH_4	≤ 75	75 – 125	120 – 200	200 – 400	400 – 600	≤ 600		3
C_2H_6	≤ 65	65 – 80	80 – 100	100 – 120	120 – 150	≤ 150		3
C_2H_4	≤ 50	50 – 80	80 – 100	100 – 150	150 – 200	≤ 200		3
C_2H_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	≤ 5500	≤ 7000	≤ 7000		1

Fonte: Adaptado de CHITNAVIS e BHASME (2017).

Tabela 5.5: Pontuações (S_i') e Pesos (W_i') para o Cálculo do AFQ.

Parâmetros	$U \leq 69 \text{ kV}$	$69 \text{ kV} < U \leq 230 \text{ kV}$	$230 \text{ kV} \leq U$	S_i'	W_i'
Rigidez Dielétrica (kV)	≥ 45	≥ 52	≥ 60	4	3
	35-45	45-52	50-60	3	
	30-35	35-45	40-50	2	
	≤ 30	≤ 35	≤ 40	1	
Tensão Interfacial (dyn/cm)	≥ 25	≥ 45	≥ 45	4	2
	20-25	35-45	35-45	3	
	15-20	30-35	30-35	2	
	≤ 15	≤ 30	≤ 30	1	
Acidez (mg KOH/g óleo)	≤ 0.05	≤ 0.04	≤ 0.03	1	1
	0.05-0.1	0.04-0.1	0.03-0.07	2	
	0.1-0.2	0.1-0.15	0.07-0.10	3	
	≥ 0.2	≥ 0.15	≥ 0.10	4	
Teor de Água (ppm)		≤ 20		1	4
		20-30		2	
		30-40		3	
		≥ 40		4	
Coloração		≤ 1.5		1	2
		1.5-2.0		2	
		2.0-2.5		3	
		> 2.5		4	

Fonte: Adaptado de CHITNAVIS e BHASME (2017).

- **Condição dos Fatores:** Após a atribuição das pontuações e pesos de cada fator, eles são classificados em uma escala de 0 a 4, variando de Muito Ruim a Bom, conforme descrito na Tabela 5.6.

Tabela 5.6: Notas para as Condições dos Fatores FC , AGD e AFQ .

Fatores						
FC	Nota	AFQ	Nota	AGD	Nota	Condição
$FC \leq 0$	0	$AFQ \leq 1,5$	0	$AGD < 1,2$	0	Bom
$FC \leq 1$	1	$1,5 < AFQ \leq 2$	1	$1,2 \leq AGD < 1,5$	1	Aceitável
$FC \leq 2$	2	$2 < AFQ \leq 3$	2	$1,5 \leq AGD < 2,0$	2	Atenção
$FC \leq 3$	3	$3 < AFQ \leq 3,5$	3	$2,0 \leq AGD < 3,0$	3	Ruim
$FC \leq 4$	4	$3,5 < AFQ \leq 4$	4	$AGD \geq 3,0$	4	Muito Ruim

Fonte: Adaptado de CHITNAVIS e BHASME (2017).

- **Cálculo do Índice de Saúde:** O índice I_{SAT} é determinado para cada transformador R , representando sua condição geral de saúde. Esse índice classifica o ativo de acordo com os critérios apresentados no Quadro 5.1. O cálculo é realizado com base na Equação 5.3, que agrega informações relevantes para uma avaliação precisa da condição do equipamento.

$$I_{SAT_R} = 10 \cdot (FC_R + AGD_R + AFQ_R) \quad (5.3)$$

Quadro 5.1: Índice de Saúde e Expectativa de Vida de Transformadores de Potência.

Índice de Saúde	Condição	Expectativa de Vida	Requisitos de Manutenção
0-30	Muito Bom	Mais de 15 anos	Manutenção Normal
30-50	Bom	Mais de 10 anos	Manutenção Normal
50-70	Razoável	Entre 3 e 10 anos	Acompanhamentos periódicos
70-85	Ruim	Menos de 3 anos	Iniciar plano de substituição
85-120	Muito Ruim	Final da vida útil	Substituição imediata


Fonte: Adaptado de CHITNAVIS e BHASME (2017).

5.4 Criticidade

A metodologia utilizada para determinar o nível de criticidade dos transformadores considera dois índices calculados anteriormente, pois ambas as variáveis são relevantes.

Para atribuir o rótulo de criticidade, foi adotado o conceito da matriz de risco, que associa a posição do transformador em uma matriz de acordo com a probabilidade de falha (representada pelo índice de saúde) e o impacto.

A Figura 5.4 apresenta um exemplo hipotético no qual o transformador possui um (I_{SAT}) igual a 70 e (I_{IMP}) igual a 33,21. Nesse caso, conforme ilustrado, o ponto correspondente na matriz está localizado na região amarela, indicando um nível de criticidade médio.

Figura 5.4: Matriz de Risco para um Transformador com (I_{SAT}) igual a 70 e (I_{IMP}) igual a 33.

Fonte: Elaborado pelo autor.

Ressalta-se que os eixos de probabilidade e impacto na matriz de risco são expressos em percentuais, variando de 0% a 100%. No entanto, os valores resultantes dos cálculos do índice de saúde (I_{SAT}) e do impacto (I_{IMP}) possuem limites mínimos e máximos que não se encontram necessariamente dentro dessa faixa. Isso ocorre porque, durante o cálculo desses índices, a escala de 0% a 100% não é considerada diretamente.


Para adequar esses valores à matriz de risco e garantir que ela reflita de forma consistente os níveis de criticidade, foi necessário normalizar os resultados dos índices a partir da Equação 4.18 multiplicado por 100. Essa normalização ajusta os valores para que se enquadrem na escala padrão de 0% a 100%, proporcionando uma melhor proporção e correspondência entre as faixas de probabilidade e impacto na matriz de risco, além de facilitar a interpretação dos níveis de criticidade atribuídos.

5.5 Análise de Componentes Principais e Algoritmo KNN

A Figura 5.5 apresenta o fluxograma da metodologia do algoritmo de classificação da criticidade, que combina os métodos *PCA* e *KNN*. Essa combinação foi escolhida devido à complexidade envolvida no processo de atribuição da criticidade dos ativos, que é influenciada por múltiplos critérios técnicos, operacionais e econômicos.

O *KNN* foi utilizado especificamente por ser um algoritmo de aprendizado supervisionado que classifica as amostras com base na distância entre elas no espaço das variáveis. Esse algoritmo foi utilizado neste caso porque a criticidade dos ativos, determinada por uma matriz de risco que combina os (I_{SAT}) e (I_{IMP}), apresenta uma estrutura onde as distâncias entre pontos refletem a similaridade entre as condições dos ativos. Assim, o *KNN* consegue identificar padrões e agrupar amostras com características semelhantes.

Figura 5.5: Fluxograma da Metodologia para Classificação da Criticidade Utilizando os Métodos PCA e KNN.



Fonte: Elaborado pelo autor.

Para uma melhor compreensão desta metodologia, são apresentadas as seguintes etapas:

1. Normalização dos Dados:

- As variáveis de D_{Rq} são normalizadas para o intervalo $[0, 1]$ utilizando o método *Min-Max*.

2. Análise de Componentes Principais:

- A matriz normalizada $D_{Rq,norm}$ é utilizada para calcular a matriz de covariância, que captura as cor-

relações entre as variáveis normalizadas, conforme a Equação 5.4.

$$\Sigma = \frac{1}{n-1} D_{Rq, \text{norm}}^T D_{Rq, \text{norm}} \quad (5.4)$$

- A partir da matriz de covariância Σ , são calculados os autovalores (λ) e os autovetores (w). Os autovalores indicam a variância explicada por cada componente principal, enquanto os autovetores definem as direções principais no espaço das variáveis originais.
- As r primeiras componentes principais são projetadas no espaço reduzido por meio da multiplicação dos autovetores com os valores normalizados dos dados, conforme a Equação 5.5.

$$Z = D_{Rq, \text{norm}} W_r \quad (5.5)$$

3. Divisão do Conjunto de Dados:

- O conjunto de dados é dividido em treinamento (80%) e teste (20%) com os rótulos da criticidade definidos na metodologia da matriz de risco.

4. Treinamento do Modelo KNN:

- O algoritmo KNN é ajustado utilizando o conjunto de treinamento no espaço reduzido Z .
- A predição da criticidade é realizada para cada ponto de teste z_i , o valor predito de criticidade ($\hat{y}_i$) é calculado com a média das criticidades dos k vizinhos mais próximos, arredondado para o inteiro mais próximo.

5. Teste para n hiperparâmetros:

- O algoritmo realiza uma iteração variando: número de componentes principais (r) no PCA e número de vizinhos (k) no KNN. Para cada combinação de r e k , o modelo é avaliado no conjunto de teste, e a combinação que maximiza a acurácia é selecionada.

6. Avaliação do Modelo:

- O desempenho do modelo é avaliado utilizando o conceito da matriz de confusão, a partir das comparações entre as predições e os valores reais (matriz de risco). A avaliação do modelo ainda inclui a análise da precisão e acurácia.

7. Classificação da Criticidade do Transformador:

- Os resultados finais são exportados para um arquivo *Excel*, contendo: coordenadas no espaço PCA e a criticidade real e predita para cada ponto do conjunto de teste.

Ressalta-se que, devido ao desbalanceamento das classes de criticidade na base de dados, foi utilizado o algoritmo *SMOTE* para gerar amostras sintéticas das classes minoritárias. Esse processo foi realizado com base nas componentes principais obtidas pelo PCA, garantindo que as amostras sintéticas preservassem as características estruturais do conjunto de dados original. Após essa etapa de balanceamento, os mesmos processos descritos na metodologia apresentada no fluxograma 5.5 foram aplicados, incluindo a normalização, redução de dimensionalidade, treinamento do modelo KNN e validação.

5.6 Considerações Finais

Neste capítulo, foram apresentadas as diretrizes metodológicas para o cálculo dos índices de saúde (I_{SAT}) e Impacto (I_{IMP}), utilizados na atribuição do nível de criticidade em uma matriz de risco. Cada etapa foi detalhadamente descrita, desde a definição das variáveis de entrada até a integração dos índices na matriz, permitindo uma avaliação da criticidade baseada na probabilidade de falha e no impacto sistêmico.

Adicionalmente, foi abordada a metodologia para o desenvolvimento do algoritmo de classificação, utilizando análise multivariada por análise de componentes principais e o método de *KNN*. Essa abordagem combina a redução da dimensionalidade proporcionada pelo *PCA* com a capacidade do *KNN* na classificação de padrões.

Capítulo 6

RESULTADOS

6.1 Considerações Iniciais

Neste capítulo, são apresentados e discutidos os resultados alcançados com a metodologia proposta neste trabalho. A primeira etapa consiste na realização de uma análise exploratória dos dados, com o objetivo de avaliar os padrões e as características dos dados para a realização dos cálculos do índice de saúde, índice de impacto e criticidade dos transformadores.

Em seguida, desenvolveu-se um algoritmo de aprendizado supervisionado para atribuir a criticidade de maneira automática, sem a necessidade de ponderações dos pesos que pode ser subjetiva e tendenciosa.

6.2 Análise Exploratória dos Dados

Para realizar uma análise exploratória, foi necessário obter conhecimento dos tipos de variáveis (observações) que foram manipuladas, pois o tratamento (normalização e separação das classes) destes dados foi baseado neste conhecimento.

A maior parte das variáveis utilizadas são do tipo quantitativa, com exceção de três variáveis qualitativas ordinais. Para viabilizar o cálculo do índice de criticidade, essas variáveis qualitativas foram codificadas em valores binários (0 e 1). No Quadro 6.1, são apresentados os tipos de variáveis correspondentes aos critérios selecionados na metodologia.

Quadro 6.1: Tipos de Variáveis Utilizadas na Metodologia.

Qualitativa Ordinal	Quantitativa Discreta	Quantitativa Contínua
Subestação (SE) de Transmissão	Número de Clientes (Mil.)	Valor do Ativo Societário (Mil. de Reais)
Risco Regulatório	Potência do Transformador (MVA)	Idade (Anos)
Cargas Críticas	-	Distancia da Base de Apoio (Km)
-	-	Relação DEC
-	-	Relação DEC
-	-	Fator de Carregamento (FC)
-	-	Concentração em ppm dos gases: Hidrogênio (H ₂), Metano (CH ₄), Acetileno (C ₂ H ₂), Etileno (C ₂ H ₄), Etano (C ₂ H ₆), Monóxido de Carbono (CO) e Dióxido de Carbono (CO ₂)
-	-	Rigidez Dielétrica (kV)
-	-	Tensão Interfacial (dyn/cm)
-	-	Acidez (mg KOH/g óleo)
-	-	Fator de Dissipação (%)
-	-	Coloração


Fonte: Elaborado pelo autor.

O primeiro passo para a análise exploratória consiste em normalizar os dados, a partir da Equação 4.18. Em seguida, analisam-se se os dados tem uma distribuição de normalidade, como já discutido na fundamentação optou-se por escolher o método de análise visual a partir do Gráfico *Q-Q Plot*.

Como foram consideradas 23 variáveis para a classificação da criticidade dos transformadores, torna-se desnecessário a apresentação de todos os gráficos (*Q-Q Plot*) e por isso serão apresentados os gráficos das distribuições dos dados que possuem maiores características de distribuição de normalidade.

A Figura 6.1 apresenta os histogramas e gráficos *Q-Q Plot* das variáveis concentração de CO₂, relação DEC, relação FEC e número de clientes. Observa-se que todas as variáveis possuem boa aderência aos quantis teóricos da distribuição normal, conforme indicado pelos *Q-Q Plots*, embora pequenos desvios sejam visíveis nas caudas. O histograma da concentração de CO₂ e das relações DEC e FEC apresentam formas aproximadamente simétricas, reforçando a proximidade com característica de distribuições normais. Já o número de clientes apresenta maior dispersão, mas ainda mantém alinhamento geral com a normalidade. Essas características indicam que as variáveis analisadas podem ser consideradas aproximadamente normais para fins estatísticos.


Figura 6.1: Histogramas e *Q-Q Plots* das Variáveis CO₂, Relação DEC, Relação FEC e Número de Clientes.



Fonte: Elaborado pelo autor.

A Figura 6.2 apresenta os histogramas e gráficos *Q-Q Plot* das variáveis C₂H₆, CO, tensão interfacial e valor do ativo societário. Observa-se que as variáveis C₂H₆ e CO apresentam aderência aos quantis teóricos da distribuição normal, com poucos desvios nas caudas. A variável tensão interfacial apresenta maior assimetria no histograma, com concentração nos valores mais altos, o que se reflete em desvios mais acentuados no *Q-Q Plot*.

Figura 6.2: Histogramas e Q-Q Plots das variáveis C₂ H₆, CO, Tensão Interfacial e Valor do Ativo Societário.



Fonte: Elaborado pelo autor.

Constata-se, portanto, que apenas 7 variáveis apresentam características de uma distribuição normal, em relação às 23 variáveis da base de dados. Dessas, quatro estão relacionadas ao índice de saúde dos ativos e três ao índice de impacto. Portanto, embora o teste *KMO*, que pressupõe a normalidade devido à utilização dos coeficientes de correlação de *Pearson*, tenha sido realizado, optou-se, por complementar a análise com testes de correlação baseados nos coeficientes não paramétricos de *Spearman*, proporcionando uma avaliação da correlação entre os dados com essa característica predominante de não normalidade.

Os coeficientes de correlação de *Spearman* variam entre -1 e 1, sendo que valores positivos indicam correlação direta entre as variáveis, enquanto valores negativos sugerem correlação inversa. Coeficientes próximos de zero indicam ausência de correlação significativa. Nesse contexto, as correlações positivas foram predominantes em relação às negativas. Identificou-se, ainda, que os tipos de variáveis influenciam diretamente nas correlações, reforçando a importância da normalização do conjunto de dados. Além disso, a realização de uma análise exploratória é essencial para identificar possíveis causas de resultados inesperados ou insatisfatórios, garantindo maior precisão nas interpretações.

Após a realização do teste de *KMO*, que indica a proporção da variância dos dados que pode ser atribuída

a fatores comuns entre as variáveis, constatou-se que métodos de análise multivariada podem ser utilizados nesta base de dados, uma vez que o valor obtido foi de 0,72.

Vale destacar que quando o valor do *KMO* é próximo de 1, há um elevado nível de correlação entre as variáveis, tornando-as adequadas para a aplicação de métodos como o *PCA*. Por outro lado, se o valor for inferior a 0,5, a correlação é considerada baixa, e o uso do *PCA* não seria indicado.

A Figura 6.3 ilustra a matriz de correlação das variáveis relacionadas ao índice de impacto.

Figura 6.3: Matriz de Correlação dos Critérios Relacionados ao Índice de Impacto.



Fonte: Elaborado pelo autor.

Observa-se na Figura 6.3 que poucas variáveis apresentam correlação positiva elevada, destacando-se a relação entre potência do transformador e número de clientes, bem como entre relação DEC e relação FEC, que evidenciam interdependência significativa. Por outro lado, nota-se uma forte correlação negativa entre o valor do ativo societário e a idade, refletindo a depreciação natural dos ativos ao longo do tempo. Correlações mais fracas incluem aquelas entre distância da base e risco regulatório, bem como entre idade e número de clientes, indicando associações menos significativas.

Em complemento, variáveis como cargas críticas e SE transmissora demonstram correlações fracas com as demais, sugerindo um comportamento relativamente independente em relação às outras variáveis analisadas.

A Figura 6.4 ilustra a matriz de correlação das variáveis relacionadas ao índice de saúde.

Figura 6.4: Matriz de Correlação dos Critérios Relacionados ao Índice de Saúde.



Fonte: Elaborado pelo autor.

Observa-se na Figura 6.4 uma forte relação negativa entre a tensão interfacial e o índice de neutralização, indicando que a degradação química do óleo, refletida no aumento do índice de neutralização, está associada à redução da tensão interfacial.

Destaca-se também a correlação negativa entre a tensão interfacial e a coloração, evidenciando que a perda das propriedades isolantes do óleo está diretamente relacionada ao aumento de sua coloração, característica típica de processos de oxidação e contaminação.

Por outro lado, variáveis como teor de água e rigidez dielétrica apresentam correlações relevantes, refletindo a influência da umidade na redução da capacidade isolante do óleo. A coloração demonstra correlação moderada com o índice de neutralização e os gases dissolvidos, como CO e CO₂, sugerindo uma relação com os processos de degradação termo-química do papel isolante. Além disso, os gases dissolvidos, como metano (CH₄) e etano (C₂H₄) apresentam maiores correlações positivas.


Após a análise das características e padrões dos dados, constatou-se que a maioria das variáveis apresentam uma distribuição não normal, com correlações positivas e negativas maiores entre as variáveis relacionadas ao

cálculo do índice de saúde, evidenciando a interdependência entre fatores críticos que influenciam a saúde dos ativos.

Essas observações podem impactar diretamente os resultados da aplicação do método *PCA* nos dados para o cálculo do índice de impacto, considerando que o *PCA* pressupõe um certo grau de correlação entre as variáveis.


Após a análise dessas características, conforme descrito na metodologia (Tabelas 5.1 e 5.2), as variáveis utilizadas no cálculo do índice de impacto foram agrupadas. Para as variáveis quantitativas, as classes foram definidas com base na regra de *Sturges*. As Figuras 6.5 e 6.6 (A, B, C e D) apresentam as distribuições dessas variáveis quantitativas, acompanhadas dos percentuais relativos a cada classe.

Figura 6.5: Representação Percentual das Separações por Classe: Número de Clientes Atendidos, Distância da Base e Potência Nominal do Transformador.



Fonte: Elaborado pelo autor.

Figura 6.6: Representação Percentual das Separações por Classe: Valor do Ativo Societário, Idade, Relação DEC e FEC.



Fonte: Elaborado pelo autor.

A partir da análise das figuras, constata-se:

- **Número de Clientes:** A distribuição mostra que a maior concentração de ativos está nas classes com valores entre 16.430 e 24.645 (22,8%) e até 8.215 (20,8%). As classes com valores maiores apresentam percentuais menores, refletindo que poucos ativos atendem uma quantidade elevada de unidades consumidoras;
- **Distância da Base:** A maior parte dos ativos está localizada a distâncias de até 9,88 km (32,7%), seguida pelas faixas entre 9,88 e 19,77 km (19,7%). As demais faixas têm percentuais progressivamente menores, indicando que a maioria dos ativos está relativamente próxima das bases operacionais, com poucas exceções em grandes distâncias;
- **Potência Nominal:** A distribuição é caracterizada pela classe entre 24 e 30 MVA (51%). As Classes com até 6 MVA e maiores que 49 MVA apresentam percentuais baixos, indicando uma menor representatividade de transformadores de potência muito baixa e muito alta;
- **Valor do Ativo Societário:** Os valores financeiros societários são mais frequentes na classe até 507 mil reais (24,5%), seguidos pela classe entre 507 e 1.014 milhões (17,9%). Isso demonstra que a maioria dos ativos possui valores baixos a moderados, com uma distribuição decrescente em faixas de valores mais altos;
- **Idade:** A maioria dos ativos concentra-se nas faixas mais novos, com 29% entre 1 e 14 anos e 14,9% com até 7 anos. As classes de maiores idades têm percentuais menores, ou seja, existem poucos ativos mais antigos no sistema;

- **Relação DEC:** A maior parte dos ativos encontra-se na faixa entre 0,79 e 0,91 (25,6%), seguida por valores entre 0,68 e 0,79 (16,3%). A distribuição demonstra uma concentração em faixas intermediárias, com poucos ativos apresentando valores extremos; e
- **Relação FEC:** A relação FEC apresenta uma distribuição equilibrada, com maior frequência nas faixas entre 0,6684 e 0,7780 (20,3%) e 0,5589 e 0,6684 (20%). As classes extremas, tanto inferiores quanto superiores, apresentam percentuais menores.

Com base na análise das variáveis, observa-se que os ativos apresentam características predominantemente associadas a sistemas com bons indicadores de qualidade de energia e ativos relativamente novos. As faixas de relação DEC e FEC, que representam importantes critérios de qualidade de energia, concentram-se em valores intermediários, evidenciando que a maioria dos ativos opera dentro de padrões aceitáveis de desempenho. Além disso, a maior parte dos ativos está em faixas etárias mais recentes, com uma concentração significativa de ativos entre 1 e 14 anos, refletindo um parque operacional relativamente jovem.

6.3 Análise Multicritério

Como apresentado no fluxograma da Figura 5.1, a metodologia multicritério AHP foi utilizada pra definição dos pesos w_i dos critérios.

6.3.1 Matriz de Comparação Paritária, Pesos Relativos e Indicadores de Consistência

Na Figura 6.7 é apresentada a matriz de comparação consolidada dos julgamentos paritários entre os dez critérios considerados para o cálculo do (I_{IMP}), realizada pelos 19 especialistas da concessionária com o preenchimento da planilha desenvolvida por GOPEL (2018).

Figura 6.7: Matriz de Comparação Paritária Consolidada.


Matriz Consolidada		Cargas críticas	N° clientes	DEC alto	FEC alto	Risco regulatório	Idade	Distância base	Potência instalada	SE Transmissora	Valor Societário
		1	2	3	4	5	6	7	8	9	10
Cargas críticas	1	1,00	0,51	0,35	0,58	0,77	1,40	1,23	2,01	1,17	1,44
N° clientes	2	1,96	1,00	0,51	0,95	1,08	2,17	2,96	2,50	1,26	2,54
DEC alto	3	2,82	1,96	1,00	2,08	2,08	3,74	3,59	3,63	2,21	4,10
FEC alto	4	1,71	1,05	0,48	1,00	1,13	2,34	2,30	2,60	1,90	2,42
Risco regulatório	5	1,31	0,93	0,48	0,89	1,00	1,75	2,62	1,87	1,39	1,96
Idade	6	0,71	0,46	0,27	0,43	0,57	1,00	1,37	1,15	0,84	1,18
Distância base	7	0,81	0,34	0,28	0,43	0,38	0,73	1,00	0,80	0,60	0,70
Potência instalada	8	0,50	0,40	0,28	0,38	0,53	0,87	1,25	1,00	0,89	1,00
SE Transmissora	9	0,86	0,79	0,45	0,53	0,72	1,19	1,68	1,12	1,00	1,27
Valor Societário	10	0,70	0,39	0,24	0,41	0,51	0,85	1,42	1,00	0,79	1,00

Fonte: Elaborado pelo autor.

Observa-se que os critérios: número de clientes, DEC e FEC apresentam coeficientes significativamente mais elevados em comparação aos demais, com o critério DEC destacando-se como o mais relevante na comparação paritária. Por outro lado, alguns critérios possuem menor relevância relativa, como a distância base, a potência instalada e o valor societário, indicando que esses fatores têm um impacto menos expressivo para o índice, na opinião dos especialistas.

A Figura 6.8 apresenta os pesos relativos obtidos a partir dos autovetores normalizados da matriz consolidada. Adicionalmente, a figura demonstra os desvios-padrão associados ao (*EVM*).

Figura 6.8: Pesos Consolidados de Cada Critério com os Desvios Padrões do *EVM*.



Fonte: Elaborado pelo autor.

Esses pesos representam a importância relativa de cada critério, sendo o critério DEC o mais relevante, com um peso de 22,6%, seguido por FEC (13,5%) e número de clientes (13,3%). Por outro lado, critérios como distância base (5%) e potência instalada (5,7%) representam menor relevância relativa. Os desvios padrão indicam o consenso e a confiabilidade dos pesos atribuídos. O critério DEC possui o maior desvio padrão (3,2%), refletindo maiores variações relativas nas comparações associadas a esse critério. No entanto, critérios como distância da base (0,4%) e idade (0,8%) apresentam menores desvios, indicando maior consenso nos pesos atribuídos entre os participantes.

A Tabela 6.1 contém os valores das métricas para avaliação da consistência nos julgamentos paritários (CR, GCI e MRE). Além disso, apresenta-se também o autovalor associado a matriz e o resultado do consenso em percentual.

Tabela 6.1: Resultados dos Indicadores de Consistência dos Julgamentos Paritários.

Indicador	Valor
<i>CR</i>	0,6%
<i>MRE</i>	1,5%
<i>GCI</i>	0,02
$\lambda_{\max}$ (Maior autovalor)	10,078
Consenso	48,4%

Fonte: Elaborado pelo autor.

A razão de consistência (*CR*) de 0,6 evidencia que os julgamentos realizados estão de acordo com os critérios

de consistência recomendados pelo método GOPEL (2018), uma vez que o valor está significativamente abaixo do limite aceitável de 10%. O erro médio relativo (MRE) de 1,5% e o índice de consistência geral (GCI) de 0,02, por sua vez, reforçam a confiabilidade do processo, considerando que o GCI é menor que o limite de 0,35. Contudo, o consenso de 48,4% sugere um nível moderado de concordância entre os participantes, refletindo a complexidade e a subjetividade inerentes ao processo de definição dos critérios com maior peso na atribuição do índice de importância (I_{IMP}).


Outro aspecto relevante diz respeito à tendência na comparação paritária, já que mais de 60% do peso total está concentrado em apenas 4 dos 10 critérios avaliados. Isso evidencia uma priorização desproporcional, onde poucos critérios exercem maior influência na tomada de decisão, enquanto os demais têm menor relevância relativa.

6.3.2 Índices de Impacto - (I_{IMP})

Conforme apresentado na metodologia, a soma ponderada das notas atribuídas para cada critério para cada transformador (Equação 5.2) resultou no índice de impacto de cada ativo. Além disso, a distribuição para ranqueamento foi realizada conforme descrito na (Figura 5.4).

Para visualizar o resultado do índice (I_{IMP}), foi elaborado o gráfico do tipo *Boxplot* para cada uma das classes de impacto (Muito Baixo, Baixo, Moderado, Alto e Muito Alto), considerando todos os ativos. Esse gráfico (Figura 6.9) permite uma análise detalhada da variabilidade dos dados, pois apresenta, para cada categoria, os valores: máximo, mínimo, média e desvio padrão.

Figura 6.9: Gráfico *Boxplot* do Índice de Impacto dos Transformadores.



Fonte: Elaborado pelo autor.

O gráfico *boxplot* é uma ferramenta estatística que resume a distribuição de um conjunto de dados com base nos quartis, fornecendo uma visão clara da dispersão e simetria. Este, divide os dados em quatro partes iguais: o 1º quartil (Q1) representa o ponto abaixo do qual estão 25% dos valores, o 2º quartil (Q2 ou mediana) indica o valor central, onde 50% dos dados estão abaixo e acima, e o 3º quartil (Q3) é o ponto abaixo do qual estão 75% dos


dados. A diferença entre Q3 e Q1, chamada de amplitude interquartil (IQR), revela a dispersão dos dados centrais, enquanto os valores extremos são visualizados pelos limites (*whiskers*).

Observa-se na Figura 6.9, que a categoria Muito Baixo possui a maior dispersão, com um desvio padrão de 5,09, indicando maior variabilidade entre os índices. Por outro lado, a categoria Baixo apresenta a menor dispersão, com um desvio padrão de 1,66, ou seja, menor variação nos valores dessa faixa. As categorias intermediárias (Baixo e Moderado) possuem médias próximas, com os dados mais concentrados, enquanto as extremidades (Muito Baixo e Muito Alto) revelam maior variabilidade.

A categoria Muito Alto apresenta a maior média (65,34) e um desvio padrão relativamente elevado (3,18), o que evidencia maior variabilidade em transformadores com índices de impacto mais altos. Já as categorias intermediárias (Moderado e Alto) revelam variabilidades moderadas.


Para explorar um pouco mais os resultados, optou-se por apresentar nas Figuras 6.10 e 6.11 os gráficos *boxplot* dos valores dos critérios quantitativos, para as faixas de (I_{IMP}) extremos (Muito Baixo e Muito Alto).

Figura 6.10: 1º Gráfico *Boxplot* dos Critérios de Impacto para os Índices: Muito Baixo e Muito Alto



Fonte: Elaborado pelo autor.

Figura 6.11: 2º Gráfico *Boxplot* dos Critérios de Impacto para os Índices: Muito Baixo e Muito Alto



Fonte: Elaborado pelo autor.

A análise das Figuras 6.10 e 6.11 evidencia que as variáveis DEC, FEC e número de clientes são os principais determinantes. A diferença significativa nos valores de média e quartis entre as classes Muito Alto e Muito Baixo reflete o impacto direto dessas variáveis no (*IMP*). Ativos classificados como Muito Alto possuem um maior número de clientes atendidos, além de apresentarem elevados índices de DEC e FEC.

Por outro lado, variáveis como distância da base, idade e valor do ativo societário apresentam menor variação entre os extremos. Embora desempenhem um papel relevante na análise geral, sua influência direta no (I_{IMP}) é menos expressiva em comparação com os principais determinantes. Essas variáveis funcionam como critérios complementares, auxiliando na análise de cenários específicos.

Adicionalmente, variáveis como potência do transformador indicam uma diferença ainda mais reduzida entre as classes Muito Alto e Muito Baixo, indicando um impacto limitado no índice de criticidade. Essas características serão fundamentais para a compreensão e interpretação dos resultados obtidos pelo método de análise multivariada PCA na próxima seção.

6.4 Índices de Saúde - (I_{SAT})

A soma ponderada dos fatores de carregamento, análise de gases dissolvidos e análise físico-química de cada transformador, conforme descrito na Equação 5.3, determina o índice de saúde de cada equipamento. Adicionalmente, a classificação dos índices foi realizada seguindo os critérios estabelecidos no Quadro 5.1.

Os resultados dos índices de saúde para cada condição (Tabela 5.6) estão apresentados em detalhes nas Tabelas 6.2, 6.3, 6.4 juntamente com os valores médios obtidos para cada um dos critérios utilizados no cálculo dos fatores: fator de carregamento (FC), análise físico-química (AFQ) e análise de gases dissolvidos (AGD).

Tabela 6.2: Valores Médios do Parâmetro (S/S_n) e Quantidades das Condições - (FC).

Classificação	Média (S/S_n)	Quantidade
Bom	0,56	65
Aceitável	0,72	70
Atenção	0,88	157
Ruim	1,08	63
Muito Ruim	-	-

Fonte: Elaborado pelo autor.

Tabela 6.3: Valores Médios dos Parâmetros e Quantidades das Condições - (AFQ).

Classificação	Valores Médios						Quantidade
	Teor de Água	Rigidez Dielétrica	Tensão Interfacial	Acidez	Coloração	AFQ	
Bom	7,37	76,66	40,73	0,02	0,97	1,17	268,00
Aceitável	14,71	70,67	29,70	0,04	2,52	1,81	49,00
Atenção	23,03	56,87	25,02	0,06	2,95	2,32	31,00
Ruim	39,60	32,80	22,10	0,10	3,20	3,33	5,00
Muito Ruim	51,00	27,50	27,20	0,04	2,50	3,63	2,00

Fonte: Elaborado pelo autor.

Tabela 6.4: Média dos Critérios do Fator (AGD) e Quantificação das Condições.

Classificação	Valores Médios							Quant.
	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	
Bom	12,17	4,25	0,01	7,03	3,86	331,47	1986,69	139
Aceitável	20,32	14,70	0,04	14,98	11,79	666,85	3799,08	98
Atenção	19,44	44,95	0,46	20,63	89,69	862,63	4469,88	84
Ruim	22,14	137,86	0,00	38,43	235,90	597,24	5460,00	21
Muito Ruim	225,50	268,00	73,50	751,00	183,00	327,00	4130,00	2


Fonte: Elaborado pelo autor.

Observa-se na análise das tabelas que a qualidade do óleo isolante dos transformadores analisados é predominantemente classificada como Bom e Aceitável para os fatores AFQ e AGD , com uma maior quantidade da condição Atenção no fator AGD . Isso indica uma tendência de aumento nos níveis de alerta em relação à análise de gases dissolvidos. Além disso, a relação média entre S/SB demonstra que, na maioria dos ativos, o critério é classificado como Atenção, sendo identificado que, em média, 157 transformadores operam com um carregamento médio de 88%.

Para o critério AFQ em condições de Ruim e Muito Ruim, nota-se uma degradação acentuada, particularmente em teor de água e a rigidez dielétrica que estão relacionados com a resistência de isolamento. Já para a o critério AFQ , os parâmetros como H₂, CH₄, C₂H₂, C₂H₄, e C₂H₆ apresentaram aumentos significativos em transformadores classificados como Atenção, Ruim, e Muito Ruim, especialmente C₂H₂, que é um indicador-chave de falhas de descargas baixa e alta energia (arco elétrico). Gases como CO e CO₂, associados à degradação de papel isolante, também se mostraram elevados, sendo necessário atenção aos ativos que operam nessas condições.

Salienta-se que uma das limitações para o cálculo do índice de saúde foi a ausência de informações sobre as temperaturas do óleo isolante no momento da coleta e os tratamentos realizados, como regeneração, secagem, entre outros

A Figura 6.12 apresenta a classificação do índice de saúde dos 355 ativos, conforme parâmetros estabelecidos no Quadro 5.1.


Figura 6.12: Distribuição dos Índices de Saúde para os 355 Transformadores.

Fonte: Elaborado pelo autor.

6.5 Criticidades dos Transformadores

Para avaliar o nível de criticidade dos transformadores, foi desenvolvida uma matriz de risco que integra a probabilidade de falha, representada pelo índice de saúde, e o impacto associado. O nível de criticidade de cada transformador é determinado com base em sua posição relativa nessa matriz. Assim, a Figura 6.13 apresenta a matriz de risco, destacando a distribuição dos 355 transformadores analisados e sua classificação nos diferentes níveis de criticidade.

Figura 6.13: Matriz de Risco dos 355 Transformadores.




Fonte: Elaborado pelo autor.

6.6 Análise Multivariada e Aprendizado Supervisionado

Como apresentado na fundamentação teórica, o método de análise de *PCA* é um método de redução de dimensionalidade, sendo que as componentes principais representam a variabilidade dos dados e transformam linearmente o conjunto dessas variáveis originais correlacionadas em um conjunto de variáveis não correlacionadas.

Deste modo, apresenta-se na Figura 6.14 o gráfico *Scree plot* com as componentes principais no eixo das abscissas e o percentual de representação das variabilidades no eixo das ordenadas (autovalores). Esse gráfico permite a avaliação de quantas componentes principais são suficientes para representarem uma parcela significativa da variabilidade dos dados.

Figura 6.14: Gráfico Scree Plot das Componentes Principais.

Fonte: Elaborado pelo autor.

Analisando a Figura 6.14, observa-se que são necessárias seis componentes principais para representar mais de 80% da variância do conjunto de amostras. Essa informação é relevante, pois, na etapa de treinamento do algoritmo *KNN*, as componentes principais servem como base para a classificação. Utilizar um número inferior a seis componentes pode levar à perda significativa de informação relevante, reduzindo a acurácia do modelo e comprometendo sua capacidade de identificar padrões de forma eficiente.

Posteriormente, foram analisados os coeficientes de cada componente principal, os quais foram projetados em um plano de duas dimensões por meio da multiplicação dos valores normalizados dos dados correspondentes aos critérios considerados com os respectivos autovetores. Esses coeficientes das componentes principais podem assumir valores positivos ou negativos, sendo os positivos os que possuem maior contribuição representativa para a variabilidade explicada. Apresenta-se na Tabela 6.5 os resultados dos coeficientes das dez primeiras componentes principais com os maiores valores destacados de cada critério.

Tabela 6.5: Coeficientes das Componentes Principais (Autovetores).

Crítérios	1	2	3	4	5	6	7	8	9	10
Núm. Clientes	-0,1575	0,0810	0,2177	0,2141	-0,0741	0,3092	-0,1597	0,3433	-0,3039	-0,1879
Dist. Base	0,2062	0,0365	-0,1088	-0,3352	0,0811	-0,1223	0,6096	0,5566	-0,2355	-0,2491
Potê. Transformador	-0,1837	0,1728	0,1898	0,2993	-0,2040	0,2697	-0,1703	0,2982	-0,2105	-0,1279
Valor do ativo Societário	-0,1661	0,5937	0,0648	-0,0255	-0,0794	0,0544	0,0662	0,0763	0,3588	-0,2432
Idade	0,1706	-0,5298	-0,1191	0,1794	0,0666	-0,0730	-0,2551	0,0919	-0,2453	-0,3747
Cargas Críticas	-0,0221	0,0872	0,0829	-0,0202	-0,0020	0,1067	0,1263	0,0665	-0,4744	0,7364
Relação DEC	0,1767	-0,0150	-0,0385	-0,3185	0,2503	0,5418	-0,0893	0,0374	0,1506	-0,0191
Relação FEC	0,1273	-0,0389	0,0071	-0,3013	0,3334	0,4831	-0,2010	-0,0139	0,0176	0,0125
Risco regulatório	0,8735	0,2576	0,3047	0,2127	-0,1374	-0,0403	-0,0634	-0,0786	-0,0122	0,0013
SE Transmissora	-0,0606	0,0048	0,1836	0,5492	0,7312	0,0182	0,3374	-0,0483	0,0909	-0,0029
FC	-0,1464	-0,1486	0,8267	-0,3894	0,1283	-0,2841	-0,1098	0,0008	-0,0085	-0,0644
FQA	0,0765	-0,2566	0,0259	0,1303	-0,0443	-0,0801	-0,1593	0,6423	0,5672	0,3724
AGD	-0,0215	-0,4067	0,2595	0,1063	-0,4357	0,4255	0,5336	-0,2051	0,2018	-0,0343

Fonte: Elaborado pelo autor.


Os maiores valores (destacados em vermelho) não estão associados a critérios com maiores pesos atribuídos pelo método AHP, como Risco Regulatório (11,4%), Valor do Ativo Societário (5,8%) e FC, que possui peso igual aos critérios AGD e FQA no cálculo do índice de saúde. Isso evidencia que alguns critérios de menor relevância na hierarquia definida pelo AHP apresentam maior contribuição nos coeficientes principais das análises de componentes principais.

Por outro lado, os critérios com maiores pesos atribuídos pelo AHP, como DEC e FEC, apresentam coeficientes baixos na CP1 e valores negativos nas CP2 e CP3. Essa discrepância entre os pesos do AHP e os coeficientes das componentes principais sugere que, embora esses critérios sejam considerados altamente relevantes no modelo AHP, sua contribuição para a variância explicada pela PCA é menor. No entanto, isso não significa que a atribuição de pesos pelos especialistas esteja incorreta, mas sim que, do ponto de vista estatístico, as variáveis com menor peso no método AHP são as que mais contribuem para a variância explicada pela PCA.

Essa análise sugere que, no plano bidimensional formado pelas duas primeiras componentes principais, as classes de criticidade estarão distribuídas de forma relativamente dispersa. Essa dispersão pode impactar negativamente a acurácia do algoritmo classificador, caso poucas componentes principais sejam utilizadas, uma vez que este se baseia na média das distâncias dos vizinhos mais próximos.

Para ilustrar essa conclusão, a Figura 6.15 apresenta a distribuição das amostras no espaço das duas primeiras componentes principais (CP1 e CP2), com os respectivos rótulos da criticidade. A separação das criticidades é destacada pelas cores, onde criticidade 0 (Condição Normal) está em verde, criticidade 1 (Acompanhamento 1) em amarelo, criticidade 2 (Acompanhamento 3) em laranja e criticidade 3 (Acompanhamento 3) em vermelho. Além disso, é ilustrado o gráfico do tipo *Biplot* dos vetores dos coeficientes (autovetores). Essa representação facilita a compreensão de quais critérios influenciam a posição relativa da amostra no plano bidimensional das componentes.

Figura 6.15: Projeção dos Coeficientes das Componentes Principais e Gráfico (*Biplot*).



Fonte: Elaborado pelo autor.


As figuras evidenciam que algumas amostras rotuladas como Criticidade (Acompanhamento 3) estão significativamente distantes das demais amostras com o mesmo rótulo. Devido à limitação dimensional para a plotagem, não é possível avaliar visualmente, com precisão, se o algoritmo de classificação é capaz de ter uma alta acurácia para essa classe. Nota-se também que essas amostras distantes possuem um valor elevado de FC, o que pode

indicar uma relação direta entre esse critério e a dispersão observada para a classe Criticidade (Acompanhamento 3).

6.6.1 Algoritmo de Classificação KNN

A Figura 6.16 apresenta, no gráfico da esquerda, os pontos que representam as criticidades reais das amostras, enquanto no gráfico da direita estão representadas as criticidades previstas pelo classificador, ambos referentes ao conjunto de teste (20% dos dados). O modelo foi treinado com 80% do conjunto de dados utilizando a quantidade ideal de componentes principais (10), identificada por meio de iterações para definição dos hiperparâmetros e da análise de variância explicada pelo PCA. Além disso, foi definido $k=4$ como o número ideal de vizinhos mais próximos. Esse resultado reflete o melhor desempenho do modelo, considerando a configuração desses parâmetros.

Figura 6.16: Projeção dos Coeficientes das Componentes Principais Classificados Incorretamente.



Fonte: Elaborado pelo autor.

Os círculos vermelhos sobrepostos em ambos os gráficos destacam as amostras classificadas incorretamente pelo modelo. Esses erros de classificação ocorreram ao considerar a média arredondada das criticidades dos quatro vizinhos mais próximos, calculada no espaço das dez componentes principais. Essa análise gráfica visa permitir a identificação clara das regiões onde o modelo falhou, facilitando a compreensão dos padrões de erro.

A distribuição das amostras revela que algumas classes de criticidade possuem uma sobreposição significativa, especialmente entre as classes próximas, como criticidade 1 (amarelo) e criticidade 2 (laranja). Essa sobreposição dificulta a correta separação entre essas classes e influencia diretamente nos erros de classificação, como evidenciado pelos círculos vermelhos. Além disso, a dispersão dos pontos dentro de cada classe indica uma variabilidade significativa, o que contribui para as dificuldades do modelo em distinguir corretamente as diferentes criticidades.

De modo complementar a essa análise gráfica, são apresentadas as matrizes de confusão das etapas de treinamento e de teste (Figuras 6.17 e 6.18). As matrizes contêm a proporção de predições corretas e incorretas para cada classe de criticidade, permitindo avaliar a precisão do modelo e identificar padrões específicos de erro entre as classes.

Figura 6.17: Matriz de Confusão da Etapa de Treinamento - KNN.

Classe Real	Normal	74 76.3%	23 23.7%	0 0.0%	0 0.0%	23.7%	76.3%
	Acomp. 1	23 16.8%	100 73.0%	13 9.5%	1 0.7%	27.0%	73.0%
	Acomp. 2	0 0.0%	16 42.1%	18 47.4%	4 10.5%	52.6%	47.4%
	Acomp. 3	0 0.0%	1 8.3%	8 66.7%	3 25.0%	75.0%	25.0%
		Normal	Acomp. 1	Acomp. 2	Acomp. 3	Classe Predita	
		76.3%	71.4%	46.2%	37.5%		
		23.7%	28.6%	53.8%	62.5%		
							Acurácia Total 68.7%

Fonte: Elaborado pelo autor.

Figura 6.18: Matriz de Confusão da Etapa de Teste - KNN.

Classe Real	Normal	19 79.2%	5 20.8%	0 0.0%	0 0.0%	20.8%	79.2%
	Acomp. 1	3 8.8%	29 85.3%	2 5.9%	0 0.0%	14.7%	85.3%
	Acomp. 2	0 0.0%	5 50.0%	4 40.0%	1 10.0%	60.0%	40.0%
	Acomp. 3	0 0.0%	0 0.0%	1 33.3%	2 66.7%	33.3%	66.7%
		Normal	Acomp. 1	Acomp. 2	Acomp. 3	Classe Predita	
		86.4%	74.4%	57.1%	66.7%		
		13.6%	25.6%	42.9%	33.3%		
							Acurácia Total 76.1%

Fonte: Elaborado pelo autor.

Analisando os resultados, verifica-se que o modelo apresentou uma acurácia superior na etapa de teste (76,1%) em comparação ao treinamento (68,7%). Esse resultado pode ser atribuído à distribuição não uniforme das classes rotuladas e à forma como o método *KNN* utiliza a distância entre os vizinhos mais próximos como principal critério de decisão. No espaço bidimensional reduzido pela *PCA*, as classes mostraram-se dispersas, o que aumenta a probabilidade de o vizinho mais próximo pertencer a uma classe incorreta. Esse efeito se intensifica no conjunto de treinamento, que contém uma amostra maior (80% dos dados). Com um número maior de amostras, a probabilidade de um ponto ser influenciado por uma classe vizinha que não reflete corretamente seu rótulo original também cresce, contribuindo para a diferença de desempenho observada.

Em relação às classes Acompanhamento 1 e Acompanhamento 2, ambas apresentaram taxas de acerto mais elevadas na etapa de teste, indicando que o modelo foi capaz de identificar padrões consistentes associados a essas

classes. Esse desempenho sugere que os dados dessas classes possuem características bem definidas e distinguíveis, mesmo em um espaço reduzido.

Por outro lado, a classe Acompanhamento 2 e 3 possuem os piores resultados em ambos os conjuntos avaliados. Na etapa de teste, apenas 57,1% e 66,7% das amostras foram classificadas corretamente, enquanto no treinamento esse valor foi de 46,2% e 37,5%. O desempenho insatisfatório do modelo para essa classe pode ser explicado pela sobreposição de características com outras classes, especialmente com Acompanhamento 3.

Esses resultados evidenciam os desafios em lidar com classes menos representadas e com características que se sobrepõem, impactando negativamente a sua capacidade de generalização.

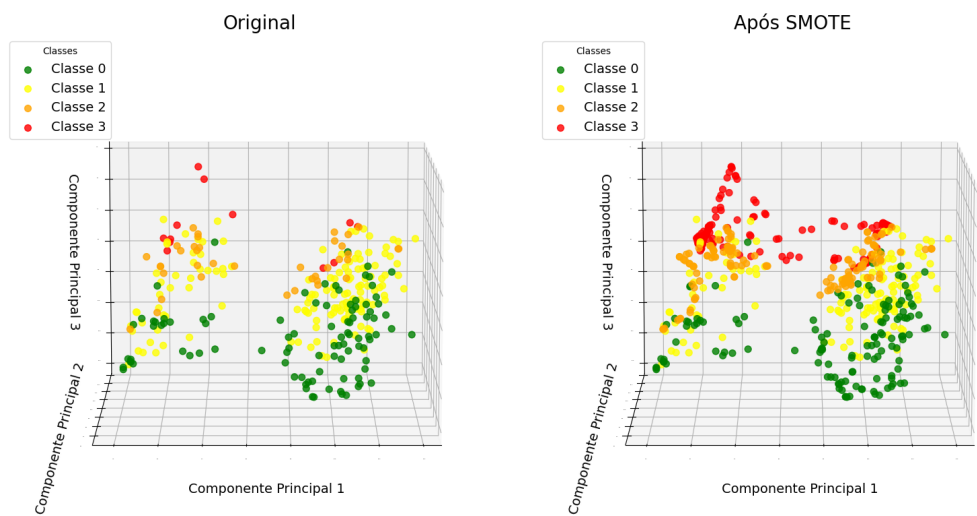
6.6.2 Algoritmo de Classificação *KNN* e *SMOTE*

Conforme descrito na metodologia, visando aprimorar o desempenho do algoritmo classificador, foi implementado o método *SMOTE*. Essa técnica foi empregada para gerar dados sintéticos e corrigir o desbalanceamento das classes, buscando garantir uma distribuição mais uniforme entre as categorias e, consequentemente, melhorar a capacidade do modelo em identificar padrões associados a classes menos representadas.

Para a implementação desse método há a necessidade de definição do hiperparâmetro relacionado a aleatoriedade associada ao processo de geração de amostras sintéticas. O método *SMOTE*, considera a criação de novas amostras por meio da interpolação entre exemplos de classes minoritárias no espaço de atributos. A escolha desse hiperparâmetro pode impactar tanto a qualidade das amostras geradas quanto o desempenho final do classificador. Neste caso, foi realizado testes com diferentes valores, avaliando o impacto dessa variação no balanceamento dos dados e, consequentemente, no desempenho do modelo classificador.

O balanceamento dos dados foi realizado de forma a igualar o número de amostras das classes minoritárias ao número de amostras da classe majoritária na etapa de treinamento, que compreende 80% do total de amostras. Como a classe Acompanhamento 1 possui 171 amostras, todas as demais classes foram ajustadas para conter 171 amostras. A Figura 6.19 apresenta a distribuição das amostras no plano tridimensional formado pelas componentes principais CP1, CP2 e CP3 para compreender se os padrões e uniformidade foram mantidos após o balanceamento.

Figura 6.19: Distribuição das Amostras Originais e Amostras Sintéticas Criadas pelo Método SMOTE no Espaço de 3 Dimensões (CP1, CP2 e CP3).




Fonte: Elaborado pelo autor.


A comparação entre os gráficos da Figura 6.19 evidencia a grande disparidade entre as classes 3 (vermelha) e 0 (verde), por exemplo. Após a aplicação do método *SMOTE*, verifica-se uma distribuição mais equilibrada, alcançada por meio da geração de amostras sintéticas posicionadas entre os pontos da classe minoritária e seus vizinhos mais próximos no espaço multidimensional. Esse balanceamento permite que o classificador identifique padrões e seja capaz de generalizar, reduzindo o viés em relação às classes majoritárias e aumentando o desempenho na predição das classes minoritárias.

As Figuras 6.20 e 6.21 as matrizes de confusão das etapas de treinamento e de teste após a criação dos dados sintéticos. Neste caso, os hiperparâmetros foram: componentes principais igual a 10, aleatoriedade (*SMOTE*) igual a 15 e *K* igual a 2.

Figura 6.20: Matriz de Confusão da Etapa de Treinamento - *KNN-SMOTE*.



Fonte: Elaborado pelo autor.

Figura 6.21: Matriz de Confusão da Etapa de Teste - KNN-SMOTE.


Fonte: Elaborado pelo autor.

Analisando as matrizes de confusão obtidas após o balanceamento das classes pelo método *SMOTE*, observa-se uma melhoria significativa na acurácia geral do modelo, passando de 68,7% para 88,5% na etapa de treinamento e 76,1% para 78,9% na etapa de teste.

Na matriz de confusão (Figura 6.21), destaca-se o desempenho das classes Normal e Acompanhamento 1, com taxas de acerto de 87,5% e 81,2%, respectivamente. No entanto, a classe Acompanhamento 2 ainda apresenta baixa precisão, com apenas 54,5% das amostras corretamente classificadas, mesmo na etapa de treinamento dos valores terem sido melhores (89,3%). Para a classe Acompanhamento 3 a taxa de acerto foi de 100% na etapa de teste, significativamente superior aos resultados anteriores à criação dos dados sintéticos.

Esses resultados demonstram que o uso do *SMOTE* contribuiu para uma melhor representação das classes no espaço de decisão do modelo, reduzindo os efeitos negativos do desbalanceamento. No entanto, as amostras da classe Acompanhamento 3 ainda apresentam desafios devido à sobreposição de características com outras classes.

O modelo de classificação apresentou uma acurácia total de 79,2%, o que demonstra um desempenho razoável, analisando somente a acurácia e considerando o problema abordado. A matriz de confusão para todas as amostras, exibida na Figura 6.22, ilustra a distribuição dos acertos e erros do modelo em cada classe. Observa-se que a classe Normal (Classe 0) possui uma alta taxa de acerto, com 86,8% de sensibilidade, ou seja, dos exemplos reais pertencentes a essa classe, a grande maioria foi corretamente identificada. No entanto, 13,2% dos exemplos reais dessa classe foram erroneamente classificados como Acompanhamento 1.

Figura 6.22: Matriz de Confusão do Algoritmo Classificador para os 355 Transformadores.

Fonte: Elaborado pelo autor.

Para a classe Acompanhamento 1, que apresentou o maior número de exemplos, a sensibilidade foi de 69%, indicando que quase um terço dos exemplos dessa classe foram confundidos com outras, especialmente com a classe Normal. Apesar disso, a precisão de 86% demonstra que o modelo é confiável ao identificar instâncias dessa classe.

A classe Acompanhamento 2 apresentou uma sensibilidade impressionante de 89,6%, o que significa que a maioria dos exemplos reais dessa classe foi corretamente classificada. Contudo, a precisão mais baixa, de 67,2%, indica que o modelo confundiu alguns exemplos de outras classes como pertencentes a Acompanhamento 2.

Por fim, a classe Acompanhamento 3 possui um desempenho melhor em termos de sensibilidade, com 100% de acerto, pois todos os exemplos reais foram corretamente classificados. A precisão de 75% demonstra que houve algumas confusões com outras classes, mas dada a menor representatividade dessa classe este resultado pode ser considerado satisfatório.

As métricas globais, apresentadas na Tabela 6.6, destacam um índice F_1 médio ponderado de 79%, equilibrando a precisão e a sensibilidade para todas as classes.

Tabela 6.6: Métricas de Desempenho do Classificador da Criticidade dos Transformadores.

Classe	Precisão (%)	Sensibilidade (%)	Índice F_1 (%)	Classes
Normal (0)	79,0	86,8	83,0	121
Acomp, 1 (1)	86,0	69,0	76,0	171
Acomp, 2 (2)	67,0	89,6	77,0	48
Acomp, 3 (3)	75,0	100,0	86,0	15
Acurácia Total (%)		79,2		
Média Aritmética (%)	77,0	86,4	80,0	355
Média Aritmética Ponderada (%)	80,0	79,2	79,0	355

Fonte: Elaborado pelo autor.

Em resumo, o modelo é eficiente na classificação da criticidade dos transformadores, com desempenho em sensibilidade satisfatória para a maioria das classes. No entanto, há espaço para melhorias, especialmente na precisão da classe Acompanhamento 2 e na redução das confusões entre Normal e Acompanhamento 1.

6.7 Aplicação Prática da Metodologia

A metodologia de criticidade para transformadores de potência apresentada nesta tese, propõem um modelo sistemático para o acompanhamento e a gestão de ativos, fundamentado nos pilares: risco, custo e desempenho. Por meio da integração do método multicritério AHP, foram atribuídos pesos relativos às variáveis de impacto sistêmico, possibilitando a hierarquização com base na relevância técnica e operacional. Ademais, foi implementada uma metodologia para atribuição do índice de saúde dos ativos, embasada nos trabalhos de CHITNAVIS e BHASME (2017) e SILVA (2020), os quais fornecem a estrutura teórica para uma condição da vida útil.

A definição da criticidade foi estabelecida utilizando uma matriz de risco, considerando a posição relativa à probabilidade de falha (índice de saúde) e impacto. Essa abordagem baseia-se em dados obtidos por comparações paritárias realizadas por 19 especialistas, além de pesos derivados de limites normativos referentes à análise de gases dissolvidos em óleo isolante, carregamento e propriedades físico-químicas.

Embora a metodologia inicial tenha demonstrado viabilidade para aplicação na classificação da criticidade, identificou-se um caráter empírico na atribuição dos pesos de cada variável, bem como uma falta de uniformidade no consenso entre os especialistas. Sendo assim, desenvolveu-se um algoritmo classificador supervisionado que utiliza técnicas de análise multivariada e algoritmo de *Machine Learning* no processo. Essa metodologia permite uma escalabilidade da ferramenta, relacionada à capacidade de processar grande volume de dados operacionais, técnicos e econômicos reduzindo a subjetividade na análise.


Em termos de aplicação prática, a concessionária tem investido em pesquisas, tecnologias avançadas e capacitações técnico-científicas para melhorar a gestão de seus ativos. Atualmente, sistemas especialistas concentram-se predominantemente no cálculo do índice de saúde, baseado em critérios que demandam elevada complexidade e esforço na coleta e tratamento de dados. A necessidade de maximizar a confiabilidade e a disponibilidade dos transformadores, aliada à minimização de custos associados à gastos operacionais e de capital, destaca a relevância de uma metodologia quantitativa e baseada em dados para a atribuição da criticidade e gestão dos transformadores.

Essa nova metodologia, apresenta-se como uma solução integrada que abrange desde a coleta e tratamento de dados até a tomada de decisões pautadas em análises de dados.

Historicamente, a MCC tem evoluído significativamente com a introdução de indicadores como o *Health Index*. Essa evolução reflete a transição de manutenções baseadas em tempo para estratégias orientadas pela condição dos ativos e, mais recentemente, para a gestão de riscos. A integração de tecnologias avançadas de informação e sistemas computacionais permitem análises mais robustas, considerando históricos de operação, condições climáticas e manutenções realizadas.

No âmbito desta tese, durante a parceria público-privada foi desenvolvido um sistema em *Power BI*, que integra funcionalidades específicas para análise de dados. Este sistema incorpora um *dashboard* específico (Figura 6.23) para ponderação da criticidade, utilizando a sistemática do método AHP e algumas variáveis da metodologia proposta nesta tese, com o objetivo de fornecer suporte à tomada de decisões de forma visual e interativa. Neste *dashboard* optou-se por apresentar o índice de criticidade do transformador e os pesos (gráfico de radar) para cada uma das variáveis.

Figura 6.23: *Dashboard* do Sistema Relacionado à Criticidade dos Transformadores.



Fonte: Elaborado pelo autor.

A implementação inicial da metodologia demonstrou potencial relevante, e, como continuidade da pesquisa, pretende-se aprimorar o sistema desenvolvido, integrando todas as etapas propostas nesta tese, tais como: vida útil, matriz de risco e classificador.

6.8 Considerações Finais

As análises realizadas neste capítulo evidenciam a eficiência da metodologia proposta para atribuição de criticidade em transformadores de potência. A abordagem apresentada integra análises exploratórias, métodos multicritério (AHP), algoritmos de classificação supervisionada (*KNN*) e técnicas avançadas, como *PCA* e *SMOTE*, para lidar com o desbalanceamento de classes e maximizar a precisão dos resultados.

Os resultados obtidos destacam a importância de integrar dados técnicos, operacionais e econômicos para a gestão eficaz de ativos, reduzindo subjetividades e otimizando a tomada de decisão. O desenvolvimento de índices de saúde (I_{SAT}) e impacto (I_{IMP}), bem como sua combinação em uma matriz de risco, permitiu classificar transformadores em diferentes níveis de criticidade, considerando fatores técnicos e regulatórios.

Adicionalmente, a implementação prática do modelo por meio de um *dashboard* demonstrou viabilidade e potencial para aprimorar a gestão de ativos da concessionária, pois integra dados em um painel interativo, facilitando a priorização de ações de manutenção.

Apesar dos resultados promissores, limitações relacionadas à dispersão das classes e à sobreposição de características entre criticidades indicam oportunidades para refinamento do modelo de classificação. Trabalhos futuros poderão focar na melhoria do algoritmo de classificação, integração de novos critérios e desenvolvimento de sistemas mais robustos para aplicação em larga escala. A metodologia proposta possui contribuições relevantes para a eficiência operacional e a sustentabilidade no setor elétrico.

Capítulo 7

CONCLUSÕES

O constante crescimento de demanda por energia elétrica, somado ao envelhecimento crescente de ativos críticos como os transformadores de potência, tornam evidente a necessidade de soluções mais avançadas e integradas para o eficiente gerenciamento de ativos do setor elétrico. Sob essa perspectiva, o presente trabalho buscou propor uma metodologia inovadora para a classificação da criticidade de 355 transformadores de uma distribuidora, através de métodos multicritério AHP, análise multivariada PCA e aprendizado supervisionado KNN. A proposta se difere por contemplar critérios sobre impactos físicos, técnicos e econômicos, incorporando a experiência de especialistas acerca de quais seriam os critérios relevantes na análise dos impactos sistêmicos decorrentes da ocorrência de falhas.

Os resultados obtidos evidenciaram a complexidade da atribuição do nível de criticidade, dada a interação simultânea de inúmeras variáveis técnicas, econômicas e operacionais. Enquanto a aplicação exclusiva do método AHP revelou limitações significativas, incluindo a maior concentração de relevância em poucos critérios e a introdução de viés analítico devido à subjetividade na atribuição de pesos, o baixo consenso entre os 19 especialistas que participaram do processo de definição das variáveis mais relevantes mostrou a necessidade de utilização de algoritmo de reconhecimento de padrões.

Estas limitações foram parcialmente mitigadas pela integração com métodos de análise multivariada e de aprendizagem supervisionada, como PCA e KNN, respectivamente. O PCA reduziu a dimensionalidade e, assim, facilitou a identificação de padrões nas regiões do espaço de atributos, permitindo uma classificação adequada da criticidade dos ativos e, ao mesmo tempo, melhorou a sensibilidade do método de KNN à tendência da variável resposta. O espaço transformado por PCA tem uma tendência óbvia, mas existe uma grande quantidade de dispersões dentro de todas as classes, o que resulta em várias misturas das instâncias de diferentes classes. Para considerar as tendências mostradas e ao mesmo tempo gerar mais instâncias diferentes em cada classe para melhorar a acurácia da classificação KNN, foi aplicada a técnica da geração de dados sintéticos. A abordagem demonstrou ser eficaz na medida em que resultou no aumento da precisão do modelo após a adaptação. A acurácia do modelo quase alcançou 80% – 79,2%, de acordo com o teste.

O modelo de classificação apresentou uma acurácia geral de 79,2%, o que demonstra um desempenho satisfatório, considerando a complexidade do problema abordado. Em termos de sensibilidade, o modelo apresentou resultados consistentes para a maioria das classes, destacando sua capacidade de identificar corretamente os exemplos reais, especialmente nas classes mais críticas.

Na análise detalhada por classe, a categoria mais crítica (Acompanhamento 3) apresentou uma sensibilidade de 100%, indicando que todos os exemplos reais dessa classe foram corretamente classificados, sem ocorrência de falsos positivos. Essa característica é particularmente importante, pois garante que ativos críticos não sejam subestimados em sua avaliação. A precisão de 75% para essa classe demonstra que, embora tenha havido algumas confusões com outras categorias, a ausência de falsos positivos confirma a eficácia do modelo em evitar erros que poderiam comprometer a segurança e a confiabilidade do sistema.

No entanto, identificou-se a necessidade de melhorias na precisão das classes intermediárias, como Acompanhamento 2, que apresentou maior índice de confusões com outras classes, como Normal e Acompanhamento 1. Esse comportamento sugere a necessidade de refinamento nos critérios de classificação ou na inclusão de novos atributos que melhor representem as nuances desses ativos.

Em resumo, o modelo desenvolvido se mostrou eficiente para a classificação da criticidade de transformadores, especialmente na identificação de ativos mais críticos. No entanto, há oportunidades para aprimorar a precisão em classes específicas e reduzir a sobreposição entre categorias, consolidando ainda mais a metodologia como uma ferramenta estratégica para a gestão de ativos no setor elétrico.

A implementação de um sistema de apoio à decisão, materializado no *dashboard* (Figura 6.23), consolidou-se como um elemento estratégico. Este sistema possibilitou a apresentação dos índices de criticidade de maneira visual, interativa e intuitiva, facilitando a priorização de ações corretivas e preventivas.

A metodologia proposta foi bem-sucedida ao abordar os desafios relacionados à subjetividade e à integração de variáveis multidisciplinares. Sua aplicação permitiu identificar transformadores críticos de maneira estruturada, otimizando os planos de manutenção e promovendo o aumento da confiabilidade, da eficiência operacional e a sustentabilidade do sistema elétrico. Além disso, ao equilibrar aspectos técnicos, operacionais e econômicos, o estudo destacou-se como uma base sólida para a tomada de decisões baseadas em dados.

7.1 Sugestões para Continuidade do Trabalho

Como proposta de continuidade deste trabalho, podem ser realizadas as etapas:

- **Aumento da base de dados:** Incorporar variáveis adicionais, como impacto ambiental, condições climáticas e valor contábil regulatório, bem como ampliar a análise para outros tipos de ativos, como disjuntores e reatores, ajustando os critérios conforme necessário;
- **Aprimoramento do método AHP:** Realizar a pesquisa com maior número de especialistas de diferentes áreas, visando reduzir a subjetividade na atribuição de pesos e alcançar maior concordância nos critérios; e
- **Exploração de Novos Métodos:** Implementar e testar outros algoritmos de classificação supervisionado ou não supervisionado, como *Random Forest* e *Support Vector Machines (SVM)*, *Optimum-path Forest (OPF)*, *K-Means Clustering* e entre outros para investigar se é possível aumentar a precisão da classificação.

REFERÊNCIAS

- ABNT. ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - NBR 7274: *Interpretação da análise dos gases em transformadores em serviço*. Rio de Janeiro: [s.n.], 2012.
- ABNT. Nbr iso 55000 - gestão de ativos - visão geral, princípios e terminologia. Associação Brasileira de Normas Técnicas, p. 29, 2014. Disponível em: <<https://www.target.com.br/produtos/normas-tecnicas/43334/nbriso55000-gestao-de-ativos-visao-geral-principios-e-terminologia>>.
- ABNT. *Óleo mineral isolante de equipamentos elétricos — Diretrizes para supervisão e manutenção*. Rio de Janeiro: Associação Brasileira de Normas Técnicas, 2017. 38 p. Quarta edição, publicada em 11.10.2017. ISBN 978-85-07-XXXXX.
- ABNT. ISO 31000: *Gestão de riscos - Diretrizes*. [S.l.]: Associação Brasileira de Normas Técnicas, 2018. 23 p.
- ABU-ELANIEN, A.; SALAMA, M.; IBRAHIM, M. Determination of transformer health condition using artificial neural networks. In: *Proceedings of the 2011 International Symposium on Innovations in Intelligent Systems and Applications*. Istanbul, Turkey: [s.n.], 2011. p. 1–5.
- ABU-ELANIEN, A. E. B.; SALAMA, M. M. A. Asset management techniques for transformers. v. 80, p. 456–464, 2010.
- AL-HAMEED, K. A. Spearman's correlation coefficient in statistical analysis. *International Journal of Nonlinear Analysis and Applications*, AL-Qasim Green University, Babil, Hilla, Iraq, v. 13, n. 1, p. 3249–3255, 2022. ISSN 2008-6822. Communicated by Madjid Eshaghi Gordji.
- ALONSO, J. A.; LAMATA, M. T. Consistency in the analytic hierarchy process: a new approach. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, v. 14, n. 4, p. 445–459, 2006.
- AMADI-ECHENDU, J.; MAFUTSANA, J. M. A bibliographic review of trends in design and management of electrical power transmission transformers. 2016.
- ANEEL. RESOLUÇÃO NORMATIVA Nº 906, DE 08 DE DEZEMBRO DE 2020. A, 2020. Disponível em: <www.aneel.gov.br>.
- ANEEL. Módulo 8 – qualidade do fornecimento de energia elétrica. *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST*, p. 69, 2021. Disponível em: <<https://www2.aneel.gov.br/cedoc/aren202195627.pdf>>.
- ANEEL. *Indicadores de Continuidade - DEC e FEC*. 2024. Accessed: January 6, 2024. Disponível em: <<https://portalrelatorios.aneel.gov.br/indicadoresDistribuicao/indicadoresContinuidadeDEC/FEC>>.
- AZMI, A. et al. Evolution of transformer health index in the form of mathematical equation. *Renewable and Sustainable Energy Reviews*, v. 76, p. 687–700, 2017. ISSN 1364-0321. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364032117304306>>.
- AZMI, A. et al. Evolution of transformer health index in the form of mathematical equation. *Renewable and Sustainable Energy Reviews*, v. 76, p. 687–700, 2017. ISSN 1364-0321.
- BARTLETT, M. S. The effect of standardization on a χ^2 approximation in factor analysis. *Biometrika*, Oxford University Press, v. 38, n. 3/4, p. 337–344, 1951.
- BIRLIK, K.; OZGONENEL, O.; KARAGÜL, S. Transformer health index estimation using artificial neural network. In: *Proceedings of the 2016 National Conference on Electrical*. Bursa, Turkey: [s.n.], 2016. p. 1–5.

- CALDAS, A. N. *Desenvolvimento de um Sistema de Apoio à Decisão para a manutenção preditiva dos ativos de uma subestação elétrica*. Dissertação (Mestrado Integrado em Engenharia Informática e Computação) — Faculdade de Engenharia da Universidade do Porto, Porto, Portugal, July 2015.
- CGEE. *Prospecção tecnológica no setor elétrico brasileiro: Eevolução tecnológica nacional no segmento de transmissão de energia elétrica*. [s.n.], 2017. v. 4. 24-26 p. ISSN 978-85-5569-135. Disponível em: <<http://www.cgee.org.br>>.
- CHAWLA, N. V. et al. Smote: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, v. 16, n. 1, p. 321–357, 2002.
- CHITNAVIS, K.; BHASME, D. N. R. Review of critical analysis for life estimation of power transformer. In: *4th International Conference on Power Control & Embedded Systems (ICPCES)*. [S.l.: s.n.], 2017. p. 1–6.
- CIGRE. *Guide for Transformer Maintenance A2.34*. 2011. Disponível em: <<https://e-cigre.org/>>.
- CIGRE. *Guia de Manutenção para Transformadores de Potência Grupo de Trabalho CIGRÉ A2.05*. 2013. Disponível em: <<https://e-cigre.org/>>.
- CIGRE. *Condition Assessment of Power Transformers*. [S.l.], 2019. Study Committees: Power Transformers and Reactors (A2); Working Groups: WG A2.49; Pages: 163. Disponível em: <<https://www.e-cigre.org/publications/detail/761-condition-assessment-of-power-transformers.html>>.
- CIGRE. *Asset Health Indices for Equipment in Existing Substations*. [S.l.], 2021.
- CIGRE. *Analysis of AC Transformer Reliability*. Paris, France, 2024. 109 p. Members: Stefan Tenbohlen (Convenor, DE), Dan Martin (Secretary, AU & NZ), Roberto Asano Jr. (BR), Zeenat Hanif (DE), Pablo Pacheco Ramos (ES), Ed Tenyenhuus (CA), Simone Sacco (IT), Andrew Collier (DE), Shin Yamada (JP), ShengJi Tee (UK), Keneilwe Seleme (ZA), Piotr Manski (PL), Gobi K. Supramaniam (MY), Martin Buellesbach (DE), Jack Herring (IE), Cornelius Plath (DE). Disponível em: <<https://e-cigre.org/publication/939-analysis-of-ac-transformer-reliability>>.
- COBO, M. et al. Scimat: A new science mapping analysis software tool. *Journal of the American Society for Information Science and Technology*, v. 63, p. 1609–1630, 08 2012.
- DONG, M.; LI, W.; NASSIF, A. Long-term health index prediction for power asset classes based on sequence learning. *IEEE Transactions on Power Delivery*, v. 37, p. 197–207, 2020.
- DUVAL, M. The duval triangle for load tap changers, non-mineral oils and low temperature faults in transformers. *IEEE Electrical Insulation Magazine*, v. 24, n. 6, p. 22–29, 2008. ISSN 08837554.
- EECKHOUDT, S.; AUTRU, S.; LERAT, L. Stray gassing of transformer insulating oils: Impact of materials, oxygen content, additives, incubation time and temperature, and its relationship to oxidation stability. *IEEE Electrical Insulation Magazine*, Institute of Electrical and Electronics Engineers Inc., v. 33, n. 6, p. 27–32, nov 2017. ISSN 08837554.
- EPE. *Informe Técnico – Atualização de Preços de Referência para Estudos de Planejamento: Data-Base Março de 2022*. [S.l.], 2022. Acessado em: [Data de Acesso]. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/informe-tecnico-atualizacao-de-precos-de-referencia-para-estudos-de-planejamento-data-base-marco-de-2022>>.
- ESCOBAR, M.; AGUARÓN, J.; MORENO-JIMÉNEZ, J. A note on ahp group consistency for the row geometric mean prioritization procedure. *European Journal of Operational Research*, v. 153, n. 2, p. 318–322, 2004. ISSN 0377-2217. Management of the Future MCDA: Dynamic and Ethical Contributions. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0377221703001541>>.
- FERREIRA, L. G. M. Governança corporativa e contabilidade regulatória nas concessionárias do serviço público de energia elétrica. 2020.
- FREITAG, S. C. et al. Power transformer risk management: Predictive methodology based on reliability centered maintenance. In: *Proceedings of the 2018 Simpósio Brasileiro de Sistemas Elétricos (SBSE)*. Niterói, Brazil: [s.n.], 2018. p. 1–6.
- GFMAM. *The Asset Management Landscape*. 2. ed. Canadá: GFMAM, 2014.
- GLYCON, G.; ZAMPOLL, M. *Guia básico para implantação da gestão de ativos em empresas de energia*. International Copper Association, 2012. Disponível em: <www.procobre.org>.

- GOEPEL. *New AHP Excel template with multiple inputs*. [s.n.], 2018. Disponível em: <<https://bpmsg.com/new-ahp-excel-template-with-multiple-inputs/>>.
- GOEPEL, K. D. Implementing the analytic hierarchy process as a standard method for multi-criteria decision making in corporate enterprises—a new ahp excel template with multiple inputs. In: CREATIVE DECISIONS FOUNDATION KUALA LUMPUR KUALA LUMPUR, MALAYSIA. *Proceedings of the international symposium on the analytic hierarchy process*. [S.l.], 2013. v. 2, n. 10, p. 1–10.
- GOEPEL, K. D. Comparison of judgment scales of the analytical hierarchy process - a new approach. *International Journal of Information Technology and Decision Making*, World Scientific Publishing Company, 2017. Disponível em: <<http://www.worldscientific.com/worldscinet/ijitdm>>.
- HAIR, J. F. J. et al. *Análise multivariada de dados [recurso eletrônico]*. 6. ed. Porto Alegre: Bookman, 2009. Editado também como livro impresso em 2009. ISBN 978-85-7780-534-1.
- HICKS, S. A. et al. On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports*, v. 12, n. 1, p. 5979, Apr 2022.
- HOTELLING, H. Analysis of a complex of statistical variables into principal components. *Journal of educational psychology*, Warwick & York, v. 24, n. 6, p. 417, 1933.
- HU, W.-P. et al. Risk assessment of power transformer life cycle cost based on analytical hierarchy process. *Applied Mechanics and Materials*, v. 291-294, p. 2334 – 2339, 2013. Cited by: 4. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84876909517doi=10.4028>>
- HUANG, Y. *Normal Probability Plot*. 2023. Accessed: 2025-01-06. Disponível em: <<https://www.stat.uchicago.edu/yibi/teaching/stat224/qnorm.pdf>>.
- IEC 60599. *Mineral oil-filled electrical equipment in service – Guidance on the interpretation of dissolved and free gases analysis*. 3. ed. [S.l.: s.n.], 2015.
- IEEE. *IEEE-C57.104 Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers*. New York: IEEE, 2008.
- IEEE. *IEEE-C57.104 Guide for the Interpretation of Gases Generated in Mineral Oil Immersed Transformers*. 2. ed. [S.l.: s.n.], 2019.
- ILGEVICIUS, A.; BABIZKI, A. Integrated transformer fleet management (itfm) system. In: MASCHINEN-FABRIK REINHAUSEN GMBH. *23rd International Conference on Electricity Distribution (CIRED)*. [S.l.]: CIRED, 2015. p. 1–5.
- ISLAM, M.; LEE, G.; HETTIWATTE, S. Application of a general regression neural network for health index calculation of power transformers. *Int. J. Electr. Power Energy Syst.*, v. 93, p. 308–315, 2017.
- IUDÍCIBUS, S. *Manual de Contabilidade Societária*. [S.l.: s.n.], 2010.
- JIANG, G.; CHEN, H.; WANG, C. Transformer network intelligent flight situation awareness assessment based on pilot visual gaze and operation behavior data. *International Journal of Pattern Recognition and Artificial Intelligence*, v. 36, p. 2259015, 2022.
- JOLLIFFE, I. T. *Principal Component Analysis*. 2. ed. New York: Springer, 2002.
- KARDEC, A. et al. Gestão de ativos. p. 376, 2014.
- LEANGKRUA, K. Power transformer risk-based maintenance by optimization of transformer condition and transformer importance. *World Academy of Science, Engineering and Technology, International Journal of Electrical, Computer, Energetic, Electronic and Communication Engineering*, v. 12, p. 191–195, 2018.
- LI, S. et al. Review of transformer health index from the perspective of survivability and condition assessment. *Electronics (Switzerland)*, v. 12, n. 11, 2023. Cited by: 12; All Open Access, Gold Open Access. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85161477430doi=10.3390>>
- LI, S. et al. Bayesian information fusion for probabilistic health index of power transformer. *IET Gener. Transm. Dis.*, v. 12, p. 279–287, 2018.
- LIMA, S. L.; SAAVEDRA, O. R.; MIRANDA, V. A two-level framework to fault diagnosis and decision making for power transformers. *IEEE Transactions on Power Delivery*, v. 30, n. 1, p. 497–504, 2015. Cited By :21. Disponível em: <www.scopus.com>.

- MARQUES, A. P. Diagnóstico otimizado de transformadores de potência: Integração de técnicas preditivas. p. 236, 2019.
- NURCAHYANTO, H. et al. Analysis of power transformer's lifetime using health index transformer method based on artificial neural network modeling. In: *Proceedings of the 2019 International Conference on Electrical Engineering and Informatics (ICEEI)*. Bandung, Indonesia: [s.n.], 2019. p. 574–579.
- PANWAR, R. et al. Ranking of power transformers on the basis of their health index and fault detection on the basis of dga results using support vector machine (svm). *Int. J. Eng. Technol. Manag. Appl. Sci.*, v. 5, p. 393–397, 2017.
- QUEIROZ, R. D. S. M.; GOULART, V. D. G. Ativo imobilizado, classificação e contabilização conforme o manual de contabilidade da aneel. *Revista Eletrônica Gestão e Negócios*, 2014.
- RIGATOS, G.; SIANO, P. Power transformers' condition monitoring using neural modelling and the local statistical approach to fault diagnosis. *Int. J. Electr. Power Energy Syst.*, v. 80, p. 150–159, 2016.
- SAATY, T. L. *Método de Análise Hierárquica*. [S.l.: s.n.], 1991.
- SAATY, T. L. Decision making with the analytic hierarchy process. *International journal of services sciences*, v. 1, n. 1, p. 83–98, 2008.
- SCATIGGIO, F.; POMPILI, M. Health index: The terna's practical approach for transformers fleet management. In: *Proceedings of the 2013 IEEE Electrical Insulation Conference (EIC)*. Ottawa, ON, Canada: IEEE, 2013. p. 178–182.
- SILVA, D. G. T. D. *Índice de saúde aprimorado para diagnóstico de transformadores de potência*. Tese (Tese de doutorado) — Unesp, Bauru, SP, 2020.
- SIRAJ, S. *Preference elicitation from pairwise comparisons in multi-criteria decision making*. Tese (Doutorado) — The University of Manchester, December 2011.
- SOUZA, J. C. S.; SAAVEDRA, O. R.; LIMA, S. L. Decision making in emergency operation for power transformers with regard to risks and interruptible load contracts. *IEEE Transactions on Power Delivery*, v. 33, n. 4, p. 1556–1564, 2018.
- SPARLING, B.; AUBIN, J. Determination of health index for aging transformers in view of substation asset optimization. *GE Energy*, v. 6, p. 274–288, 2018.
- SUWANASRI, T.; KUMPALAVALEE, S.; SUWANASRI, C. Risk assessment of power transformer in thailand's distribution grid. *Lecture Notes in Electrical Engineering*, v. 598 LNEE, p. 184 – 196, 2020. Cited by: 1. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85076847570doi=10.1007>>
- TANG, S.; HALE, C.; THAKER, H. Reliability modeling of power transformers with maintenance outage. *Systems Science Control Engineering: An Open Access Journal*, v. 2, p. 316–324, 12 2014.
- TOMASHEVSKII, I. L. Geometric mean method for judgement matrices: formulas for errors. *arXiv*, v. 1410.0823v1, 2014.
- TOMASHEVSKII, I. L. Eigenvector ranking method as a measuring tool: formulas for errors. *European Journal of Operational Research*, v. 240, n. 3, p. 774–780, February 2015.
- TRAPPEY, A. et al. Integrating real-time monitoring and asset health prediction for power transformer intelligent maintenance and decision support. In: *Engineering Asset Management-Systems*. Berlin/Heidelberg, Germany: Springer, 2015. p. 533–543.
- UDDIN, S. et al. Análise comparativa do desempenho do algoritmo k-nearest neighbor (knn) e suas diferentes variantes para a previsão de doenças. *Scientific Reports*, v. 12, p. 6256, 2022. Disponível em: <<https://doi.org/10.1038/s41598-022-10358-x>>.
- VAIDYA, O. S.; KUMAR, S. Analytic hierarchy process: An overview of applications. *European Journal of operational research*, Elsevier, v. 169, n. 1, p. 1–29, 2006.
- WANG, M.; VANDERMAAR, A. J.; SRIVASTAVA, K. D. Review of condition assessment of power transformers in service. *IEEE Electrical Insulation Magazine*, v. 18, n. 6, p. 12–25, 2002. Cited By :675. Disponível em: <www.scopus.com>.
- WANG, S. et al. Pesquisa sobre expansão e classificação de dados desequilibrados com base no algoritmo smote. *Scientific Reports*, v. 1111, p. 24039, 2021. Disponível em: <<https://doi.org/10.1038/s41598-021-03430-5>>.

ZAMPOLLI, M. et al. *Gerenciamento de Ativos no Setor Elétrico da América Latina: Resultados da Pesquisa, Melhores Práticas e Tendências*. Av. Vitacura 2909, Oficina 303, Las Condes, Santiago, Chile, 2011. Disponível em: https://www.leonardo-energy.org.br/wp-content/uploads/2018/02/Doc-146-ga-Gerenciamento_ativos_setor_eletrico_America_Latina.pdf.

ZAMPOLLI, M. et al. *Gestão de Ativos no Setor Elétrico da América Latina: Melhores Práticas e Tendências — Resultados da pesquisa 2014 com comparativos da pesquisa 2011*. Av. Vitacura 2909, Oficina 303, Las Condes, Santiago, Chile, 2014. Contribuições de: Duam S.A. Innovación al Sur del Mundo, Procobre Peru. Disponível em: <<https://www.procobre.org>>.

ZHONG, Q. Power transformer end-of-life modelling: Linking statistics with physical ageing. In: . [S.l.]: The University of Manchester, 2011. ISBN The University of Manchester. ISSN Faculty of Engineering and Physical Sciences.