



UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA

Diagnóstico de Falhas em Transformadores de Potência
através de Análise de Gases Dissolvidos usando Rede Neural
Artificial

ALEX ROGELIO SOTO ENRIQUEZ

São Luís - MA
2020

ALEX ROGELIO SOTO ENRIQUEZ

Diagnóstico de Falhas em Transformadores de Potência
através de Análise de Gases Dissolvidos usando Rede Neural
Artificial

Dissertação apresentada à Coordenação do
Programa de Pós-Graduação em Engenharia
Elétrica da Universidade Federal do Maranhão
como parte dos requisitos para obtenção do título
de Mestre em Engenharia de Eletricidade.

Orientador: Prof. Dr. Osvaldo Ronald Saavedra
Mendez

Coorientador: Prof. Dr. Shigeaki Leite de Lima

São Luís - MA
2020

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Soto Enriquez, Alex Rogelio.

Diagnóstico de Falhas em Transformadores de Potência através de Análise de Gases Dissolvidos usando Rede Neural Artificial / Alex Rogelio Soto Enriquez. - 2020.

99 f.

Coorientador(a): Shigeaki Leite de Lima.

Orientador(a): Osvaldo Ronald Saavedra Mendez.

Dissertação (Mestrado) - Programa de Pós-graduação em Engenharia de Eletricidade/ccet, Universidade Federal do Maranhão, Auditório de Sistemas de Potência CCET / UFMA, 2020.

1. BPSO. 2. K-NN. 3. Redes Neurais Artificiais. 4. Transformador de potência. I. Leite de Lima, Shigeaki. II. Saavedra Mendez, Osvaldo Ronald. III. Título.

Diagnóstico de Falhas em Transformadores de Potência através de Análise de Gases Dissolvidos usando Rede Neural Artificial

ALEX ROGELIO SOTO ENRIQUEZ

Dissertação aprovada em 28 de fevereiro de 2020.

Prof. Dr. Osvaldo Ronald Saavedra Mendez
Universidade Federal do Maranhão – DEE/UFMA
(Orientador)

Prof. Dr. Shigeaki Leite de Lima
Universidade Federal do Maranhão – CCECP/UFMA
(Co-orientador)

Prof. Dr. André Nunes de Souza
Universidade Estadual Paulista Júlio de Mesquita Filho – DEE/UNESP
(Membro da Banca Examinadora)

Prof. Dr. Vicente Leonardo Paucar Casas
Universidade Federal do Maranhão – DEE/UFMA
(Membro da Banca Examinadora)

AGRADECIMENTOS

Agradeço à Organização dos Estados Americanos (OEA) e à Universidade Federal do Maranhão (UFMA) por ter-me selecionado e aceitado no programa de Pós-Graduação em Engenharia Elétrica. Agradeço especialmente à Companhia Energética do Maranhão (CEMAR) pelo apoio financeiro ao projeto de pesquisa e desenvolvimento denominado “*Diagnóstico de falhas on-line dos transformadores de potência*”, do qual fiz parte.

Ao meu orientador, prof. Osvaldo Saavedra Mendez, pela orientação e o conhecimento transferido durante minha formação acadêmica. Ao meu coorientador, prof. Shigeaki Lima, por me dar confiança no desenvolvimento dos trabalhos de pesquisa e ter oferecido sempre uma solução para minhas dúvidas durante o desenvolvimento desta dissertação. Da mesma forma agradeço aos professores que fizeram parte de minha formação acadêmica: Anselmo Barbosa, João Viana Fonseca Neto, José Gomes de Matos, José Eduardo Onoda Pessanha e Vicente Leonardo Paucar Casas.

Aos meus colegas que me ajudaram na adaptação pessoal e profissional e sempre auxiliaram na solução das minhas dúvidas: Diego Cosme, Leonilson Veras, Iasmim Almeida, Ana Carolina Everton, Thiago Gomes, Lucas Borges, Ítalo Gusmão, Jessica Almeida, Patrícia Santos, Thais Barreto, Luis Felipe, Diogo Ferreira e Suellen Rocha.

Um agradecimento especial a meu pai Samuel Soto e minha mãe Venedicta Enriquez, minhas irmãs Lyz e Salinova Soto, minha sobrinha Maria Aizel e meus familiares que sempre foram minha inspiração para alcançar meus objetivos profissionais e pessoais.

Finalmente quero agradecer a Deus por me dar as oportunidades de viver com plenitude. Sei que onde estiver, estará comigo.

RESUMO

Os transformadores de potência são equipamentos muito importantes na operação de sistemas elétricos, tendo como função insubstituível de transformar níveis de tensão e corrente para transmissão de energia elétrica do centro de geração até o usuário final. Essa importância é ainda maior do ponto de vista econômico, já que uma eventual condição de falha, com a consequente interrupção do serviço elétrico, pode levar a grandes perdas econômicas tanto para a concessionária como para o usuário final. É apresentada na literatura atualizada uma quantidade expressiva de bibliografias orientadas à manutenção de transformadores de potência em perfeitas condições de operação. Nesta dissertação de mestrado é desenvolvida uma metodologia de diagnóstico de falhas em transformadores de potência pela aplicação de Otimização de Enxame de Partículas Binária (em inglês, *Binary Particle Swan Optimization - BPSO*) no ajuste do classificador K-NN (*k-Nearest Neighbor*) para seleção de variáveis de avaliação de melhor agrupamento para um método (configuração cascata). No processo de treinamento e teste do método baseado na Rede Neural Artificial (RNA) é alcançado um desempenho de 100 %, constituindo desta forma uma alternativa competitiva de diagnóstico de falhas em transformadores de potência.

Palavras-chave: Transformador de potência, BPSO, K-NN, Redes Neurais Artificiais.

ABSTRACT

Power transformers are very important equipment in the operation of electrical systems, having the irreplaceable function of transforming voltage and current levels for transmission of electrical energy from generation center to end user. This importance is even greater from the economic point of view, since in the event of a failure condition with the consequent interruption of electrical service can lead to major economic losses for both the utility and the end user. An important amount of bibliographies oriented to the maintenance of power transformers in perfect operating conditions is presented in the updated literature. In this master's dissertation, a methodology for diagnosing power transformers failures is developed by applying Binary Particle Swarm Optimization (BPSO) to adjust the K-NN classifier (k-Nearest Neighbor) selecting best grouping evaluation variables for a method (waterfall configuration). In the training and testing process for a method based on Artificial Neural Network (ANN) a performance of 100% is achieved, thus constituting a competitive alternative for power transformer fault diagnosis.

Keywords: Power Transformer, BPSO, K-NN, Artificial Neural Network.

LISTA DE ILUSTRAÇÕES

Figura 2.1 Primeiro transformador GANZ	21
Figura 2.2 Diagrama Equivalente do Sistema Elétrico.....	21
Figura 2.3 Transformador de potência com isolamento de óleo	23
Figura 2.4 Evolução de conteúdo de gases falha em diferentes temperaturas / condições de falha	25
Figura 2.5 Diagnóstico de falhas em TP por AGD, por método de gases chave (a), (b), (c) e (d)	28
Figura 2.6 Diagnóstico de falhas em TP por AGD, por Triângulo de Duval	31
Figura 3.1 Distribuição de metodologias por ferramenta aplicada em diagnóstico de falhas no transformador de potência, período 2011-2013	40
Figura 3.2 Assertividade de metodologias de diagnóstico de falhas em TP (2011-2013)	41
Figura 3.3 Distribuição de metodologias por ferramenta aplicada no diagnóstico de falhas em transformadores de potência, período 2014-2016.....	44
Figura 3.4 Assertividade de metodologias de diagnóstico de falhas em TP (2014-2016)	45
Figura 3.5 Assertividade de metodologias (Outros) de diagnóstico de falhas em TP (2014-2016)	45
Figura 3.6 Distribuição de metodologias por ferramenta aplicada no diagnóstico de falhas em transformador de potência, período 2017-2019	49
Figura 3.7 Assertividades de metodologias de diagnóstico de falhas em TP (2017- 09/2019).....	50
Figura 3.8 Assertividades de metodologias (Outros) de diagnóstico de falhas em TP (2017-09/2019)	50
Figura 4.1 Diagrama gráfico de diagnóstico de falhas em transformadores de potência	55
Figura 4.2 Diagrama índice-diagnóstico de transformadores de potência.....	55
Figura 4.3 Deslocamento de partículas em PSO	57
Figura 4.4 Esquemas de neurônios biológico e artificial.....	59
Figura 4.5 Máquina de aprendizagem profundo versus rede neural artificial RNA.....	60
Figura 4.6 RNA (MLP) de três camadas	61
Figura 4.7 Ilustração gráfica da distância euclidiana	63

Figura 4.8 Classificação por K-NN no espaço bidimensional, para duas estados de classificação.....	64
Figura 5.1 Esquema de classificação geral proposto em diagnóstico de falhas no TP...	69
Figura 5.2 Curva de convergência de BPSO/ K-NN, para CL1	72
Figura 5.3 Curva de convergência de BPSO/ K-NN, para CL2	73
Figura 5.4 Curva de convergência de BPSO/ K-NN, para CL3	74
Figura 5.5 Estrutura da rede neural proposta.....	76
Figura 5.6 Fluxo de diagnóstico de falhas no TP, utilizando classificador KNN ponderado	77
Figura 5.7 Curvas de desempenho de K-NN ponderado em CL1 (K=1:100).....	78
Figura 5.8 Curvas de desempenho de K-NN ponderado em CL2 (K=1:100).....	78
Figura 5.9 Curvas de desempenho de K-NN ponderado em CL3 (K=1:100).....	79
Figura 5.10 Esquema completa de diagnóstico de falhas em transformadores de potência	80

LISTA DE TABELAS

Tabela 2.1 Concentrações de gases dissolvidos para o método Dornenburg	29
Tabela 2.2 Regras de diagnóstico de falhas para o método Dornenburg	30
Tabela 2.3 Regras de diagnóstico de falhas por método Rogers	30
Tabela 2.4 Regras de diagnóstico de falhas pelo método IEC 60599	33
Tabela 2.5 Codificação CEGB no método Rogers	34
Tabela 2.6 Regras de diagnóstico de falhas pelo método CEGB	34
Tabela 3.1 Quadro resumo de artigos de investigação revisadas, período 2011-2013...	38
Tabela 3.2 Quadro resumo de artigos de investigação revisadas, período 2014-2016...	42
Tabela 3.3 Quadro resumo de artigos de investigação revisadas, período 2017-2019...	47
Tabela 4.1 Regras de aprendizagem, gradiente descendente de RNA	62
Tabela 5.1 Dados de conteúdo de gases no TP.....	68
Tabela 5.2 Dados de conteúdo de gases no TP extraídos da revisão bibliográfica	69
Tabela 5.3 Codificação de conteúdo de gases	71
Tabela 5.4 parâmetros de BPSO/K-NN.....	71
Tabela 5.5 Parâmetros de treinamento da RNA	76
Tabela 5.6 Desempenho de classificadores CL1, CL2 e CL3 (para K-NN ponderado e RNA)	79
Tabela 5.7 Matriz de confusão, validação da metodologia proposta.....	80

LISTA DE SIGLAS E ABREVIATURAS

A3S:	Algoritmo fusão de informação
ABC:	<i>Artificial Bee Colony</i>
ABNT:	Associação Brasileira de Normas Técnicas
AD:	Algoritmo de árvore de decisão
AG:	Algoritmos genéticos
AGD:	Análise de gases dissolvidos
ANEEL:	Agência Nacional de Energia Elétrica
ANFIS:	<i>Adaptive Neural Fuzzy Inference System</i>
ANN:	<i>Artificial Neural Network</i>
AR:	Falha elétrica de arco
ARL:	Análise de regressão linear
BP:	<i>Back Propagation</i>
BPSO:	<i>Binary Particle Swarm Optimization</i>
BQPSO:	<i>Quantum-Behaved Particle Swarm Optimization with Binary Encoding</i>
CEGB:	<i>Central Electricity Generating Board</i>
CF:	Algoritmo colônia de formigas
CP:	Rede neural artificial de contra propagação
CPSO:	<i>Chaos Particle Swarm Optimazation</i>
CS:	Falha de chispa contínua
D1:	Falha descarga de baixa energia
D2:	Falha descarga de alta energia
DBN:	<i>Deep Belief Network</i>
DC1:	Falha de arco com baixa densidade de energia
DC2:	Falha de arco com alta densidade de energia
DOR:	Método Dornenburg
DST:	Teoria de Dempster-Shafer
EDN:	Estimador de densidade de núcleo (kernel)
ELM:	<i>Extreme Learning Machine</i>
FA:	<i>Factor Analysis</i>
FCM:	Algoritmo Fuzzy c-means clustering (Agrupamento fuzzy)
FDNM:	Função de densidade de probabilidade normal multivariada
FIS:	<i>Fuzzy Inference System</i>
FRA:	<i>Frequency Response Analysis</i>
GEP:	<i>Gene Expression Programming</i>
GWO:	<i>Gray Wolf Optimization algorithm</i>
HAE:	Método de diagnóstico de falhas no TP, baseado em teoria de informação
HED:	Falha arco de alta energia
HTH:	Falha térmica de $> 700^{\circ}\text{C}$
IA:	Inteligência Artificial

IAFSA:	<i>Improved Artificial Fish-Swarm Algorithm</i>
IB:	Método de informação de <i>Bottleneck</i>
IEC:	<i>International Electrotechnical Commission</i>
IEEE:	<i>Institute of Electrical and Electronic Engineers</i>
IKH:	<i>Improved krill herd algorithm</i>
INN:	<i>Immune Neural Network</i>
ITR:	Método de três relações (com muita aceitação na china)
JP:	Estimação de janela de PARZEN
KELM:	<i>Kernel extreme learning machine</i>
KMA:	<i>k-means algorithm</i>
K-NN:	<i>k- nearest neighbor algorithm</i>
LTH:	Falha térmica de baixa energia
L:	Litro
MLP:	<i>Multi-Layer Perceptron</i>
MS:	<i>Mean Shift</i>
MTH:	Falha térmica de $< 700^{\circ}C$
MVA:	Mega Volt-Ampere
NF:	Operação normal
OLTC:	<i>On Load Tap Changer</i>
PCA:	<i>Principal component analysis</i>
PCC:	<i>Pearson's Correlation Coefficient</i>
PD:	Falha elétrica de descarga parcial
PDT:	Falha de descarga parcial com rastreio
Ppm:	Partes por milhão
PSO:	<i>Particle Swarm Optimization</i>
PSVM:	<i>Proximal Support Vector Machine</i>
PV:	Parcela Variável
RB:	Redes bayesianas
RBF:	<i>Radial Basis Function</i>
RBM:	<i>Restricted Boltzmann Machine</i>
RF:	Algoritmo de razão de Fisher
RL:	Rede neural artificial linear
RNA:	Redes Neurais Artificiais
ROG:	Método Rogers
RST:	<i>Rough Set Theory</i>
RVM:	<i>Relevance vector machine</i> (extensão bayesiana de SVM)
SE:	Sistema Elétrico
SIN:	Sistema Interligado Nacional
SRM:	<i>Structure Risk Minimization</i>
SVM:	<i>Support vector machine</i>
T1:	Falha térmica de temperatura $< 300^{\circ}C$
T2:	Falha térmica de temperatura $300^{\circ}C < T2 < 700^{\circ}C$
TC1:	Falha térmica $< 150^{\circ}C$
TC2:	Falha térmica $150^{\circ}C < TC2 < 200^{\circ}C$

TC3:	Falha térmica $200^{\circ}\text{C} < TC3 < 300^{\circ}\text{C}$
TC4:	Falha térmica (incremento de temperatura geral em parte condutiva)
TC5:	Falha térmica (corrente circulante em bobina)
TC6:	Falha térmica (corrente circulante em núcleo e bobina, sobreaquecimento conjunto)
TD:	Método Triângulo de Duval
TH:	Falha térmica
TP:	Transformador de potência imerso em óleo
TPr:	Técnica de probabilidades
UD:	Condição de operação de TP não identificada
WEKA:	<i>Waikato Environment for Knowledge Analysis</i>

SUMARIO

1 - INTRODUÇÃO	15
1.1. Marco Contextual e Justificativa da Dissertação.....	15
1.2. Objetivos.....	18
1.2.1. Objetivo Geral.....	18
1.2.2. Objetivos Específicos	18
1.3. Organização da dissertação.....	18
2 - DIAGNÓSTICO DE FALHAS EM TRANSFORMADORES DE POTÊNCIA	20
2.1. Transformador de Potência.....	20
2.2. Análise de Gases Dissolvidos (AGD).....	23
2.2.1. Decomposição de Óleo	24
2.2.2. Decomposição de Celulose	24
2.3. Metodologias de Diagnóstico de Falhas Incipientes no TP.....	26
2.3.1. Metodologias de Diagnóstico Convencional	26
2.3.2. Metodologias de Técnicas de Inteligência Artificial	35
2.4. Conclusão do capítulo.....	36
3 - REVISÃO BIBLIOGRÁFICA.....	37
3.1. Introdução	37
3.2. Estado da arte.....	37
3.2.1. Artigos de 2011-2013	38
3.2.2. Artigos de 2014-2016	42
3.2.3. Artigos de 2017-2019	47
3.3. Conclusão do capítulo.....	52
4 - TÉCNICAS DE IA APLICADAS AO DIAGNÓSTICO DE FALHAS	54
4.1. Introdução	54
4.2. Binary Particle Swarm Optimization (BPSO)	56
4.3. Redes Neurais Artificiais (RNA).....	59

	14
4.3.1. RNA como Máquina de Aprendizado.....	60
4.3.2. Perceptron Multicamada (MLP)	60
4.3.3. Regra de Aprendizado da RNA	61
4.4. K-Nearest Neighbor (K-NN)	62
4.5. Conclusão do capítulo.....	65
5 - METODOLOGIA PROPOSTA E RESULTADOS.....	67
5.1. Introdução	67
5.2. Caracterização dos Dados	68
5.3. Arquitetura Proposta para o Diagnóstico de Falhas	69
5.4. Seleção de Variáveis de Avaliação Ótimas	70
5.4.1. Variáveis de Entrada	70
5.4.2. Seleção de Variáveis por BPSO/K-NN	71
5.5. Diagnóstico de Condições de Falha no TP	75
5.5.1. Classificador RNA	75
5.5.2. Classificador K-NN ponderada.....	76
5.6. Resultados de Avaliação de Classificadores.....	77
5.7. Validação da metodologia proposta.....	80
5.8. Conclusão do capítulo.....	81
6 - CONCLUSÕES	82
REFERENCIAS	85
ANEXOS	97

1 - INTRODUÇÃO

1.1. Marco Contextual e Justificativa da Dissertação

O transformador de potência imerso em óleo (TP) é um equipamento elétrico que foi concebido e manufaturado pela primeira vez em meados do século XIX [1] [2]. No Sistema Interligado Nacional (SIN), constituem o nó de transformação (em Subestações Elétricas) de níveis de tensão e corrente para transmissão, distribuição e controle da energia elétrica, do centro de geração até o usuário final.

Na operação de um Sistema Elétrico (SE), o funcionamento correto e em segurança de um transformador de potência é muito importante, por ser um equipamento insubstituível na operação do SE, que pode causar grandes perdas econômicas tanto para a empresa operadora como para o usuário final em eventual condição de falha, com a consequente interrupção do serviço elétrico [3].

O transformador de potência é usualmente confiável em um intervalo de operação de 20-35 anos [4]. Porém, na atualidade, os transformadores de potência no mundo possuem muitos anos de serviço, ultrapassando o tempo de vida útil projetado pelo fabricante [5]. Além disso na operação real do SE, devido à natureza variável da carga, o nível de exposição de um transformador de potência é alto, já que qualquer variação de tensão e corrente nos enrolamentos primário ou secundário causa uma constante deterioração do equipamento. Esta variação é determinante na projeção do tempo de vida útil. O tempo de vida útil do equipamento está estreitamente relacionado com a ausência ou presença de uma condição de falha no equipamento elétrico [6].

Dentro de uma área de concessão, ter acesso ao serviço elétrico confiável é um serviço básico, previsto inclusive pelas normas brasileiras [7]. Neste contexto os órgãos

nacionais e empresas privadas realizam esforços para expandir e fortalecer o SIN, que levam ao crescimento constante do número de transformadores de potência operando interligados ao SIN.

Monitorar os transformadores de potência em termos de tempo de vida útil sob conceito de variabilidade de carga em um sistema elétrico em constante crescimento é um tema de investigação bastante abordado. Na expansão do SE, a instalação de transformadores envolve investimento significativo, portanto a manutenção do TP para ter um serviço elétrico confiável é uma luta constante das empresas operadoras que operam sob condições de regulação estreita que podem gerar grandes perdas econômicas nos agentes envolvidos (Empresa Operadora -Usuário) [8].

A regulação no serviço elétrico é um aspecto importante no cumprimento dos direitos e deveres tanto da empresa operadora como do usuário beneficiário. No caso do Brasil, a Agência Nacional de Energia Elétrica (ANEEL) é o órgão regulador das normas do setor elétrico. A Resolução Normativa nº 270/2007 da ANEEL, por exemplo, estabelece as disposições relativas e qualidade de serviço público [9].

A indisponibilidade do serviço elétrico no caso de empresas brasileiras é determinada pela Parcela Variável (PV), que é descontada sob conceito de redução do índice de qualidade de serviço elétrico. O cálculo da PV é realizado conforme estabelecido na Resolução nº 270/2007 da ANEEL que está intrinsecamente vinculada com o tempo de indisponibilidade de componentes de transmissão da qual os transformadores de potência fazem parte [9]. O mecanismo de PV, em transformadores de potência, tem levado as empresas concessionárias a investirem em programas de diagnóstico de falhas incipientes com objetivo de monitorar a condição de operação do transformador de potência em tempo real.

Na bibliografia especializada há um número significativo de metodologias de diagnóstico de falhas em transformadores de potência, porém a disponibilidade limitada de dados assim como o uso não otimizado dos dados disponíveis têm sido um obstáculo para obter uma metodologia generalizável e de alta assertividade [10]. O uso da vibração para medir o grau de estresse do transformador de potência e a Análise de Resposta em Frequência (*Frequency Response Analysis - FRA*), como ferramenta para a detecção de falhas em os enrolamentos do TP, são algumas metodologias desenvolvidas para

monitorar os transformadores de potência [11] [12]. Contudo uma metodologia abrangente segue sendo a partir da Análise de Gases Dissolvidos (AGD) [13].

No contexto da AGD, o transformador de potência é considerado como um reator químico, já que os elementos do sistema de isolamento, tanto óleo como papel, se deterioram com a conseqüente quebra da cadeia de hidrocarbonetos e celulose que resultam na formação de gases falha [10]. A presença de gases falha dentro do TP é um indicador vinculado à condição de operação do mesmo [14], portanto foram desenvolvidas metodologias de diagnóstico de falhas incipientes em TP a partir de dados obtidos da AGD.

As primeiras metodologias propostas no diagnóstico de falhas incipientes em TP usaram regras de interpretação direta sobre o conteúdo ou relação de gases. Dentre um grupo importante de metodologias, os mais populares e estabelecidos em normativas internacionais são: método Rogers, método Dornenburg e Triângulo Duval estabelecidos pelo Instituto de Engenheiros Elétricos e Eletrônicos (IEEE), método IEC 60599 estabelecido pela Comissão Eletrotécnica Internacional (IEC) e pelo Centro de Geração Elétrica (CEGB) [15]. Por outro lado, a aplicação da heurística como ferramenta de inteligência artificial (IA) marcou um avanço significativo no desenvolvimento tecnológico da humanidade, assim, no diagnóstico de falhas incipientes em transformadores de potência melhorou tanto a generalização como a assertividade quando comparada com métodos mais populares indicados precedentemente.

Metodologias baseadas em técnicas de inteligência artificial para diagnóstico de falhas incipientes em transformadores de potência foram desenvolvidas com objetivo de mitigar os inconvenientes de baixa assertividade dos métodos mais populares. Dentre o grupo de ferramentas de IA, os de maior aplicabilidade são as técnicas de classificação de dados como: Rede neural artificial (RNA) [16], lógica fuzzy [17], Máquina de suporte vetorial (SVM) [18], árvores de decisão [19], algoritmo de agrupamento [20], entre outros. Das metodologias abordadas na bibliografia é registrado que o nível de assertividade alcançado é superior aos métodos populares. Entretanto, um diagnóstico de falhas em transformadores de potência com uma assertividade de 100 %, robusta e generalizável ainda é um tema de investigação aberta.

Neste contexto, nesta dissertação é realizada uma revisão bibliográfica das metodologias desenvolvidas e publicadas no *IEEE Xplore Digital Library* [21] durante o

período 2011-2019. A partir desta pesquisa é desenvolvida uma metodologia de diagnóstico de falhas incipientes em transformadores de potência a partir da AGD por aplicação de BPSO/K-NN e RNA.

1.2. Objetivos

1.2.1. Objetivo Geral

O objetivo é desenvolver uma metodologia de diagnóstico de falhas em transformadores de potência, generalizável e de alta assertividade, como uma ferramenta de auxílio ao operador do sistema elétrico na tomada de decisão com argumento técnico sustentável.

1.2.2. Objetivos Específicos

O diagnóstico de falhas incipientes em TP é um tópico de investigação bastante abordado nos últimos anos, nesse contexto os objetivos específicos desta dissertação são:

- Revisar o estado de arte das metodologias de diagnóstico de falhas incipientes em transformadores de potência a óleo, abordadas e publicadas durante o período 2011-2019.
- Coletar os dados de interesse para o desenvolvimento de uma metodologia generalizável em pesquisas posteriores.
- Desenvolver uma metodologia generalizável e de alta assertividade para diagnóstico de falhas incipientes em transformadores de potência, por aplicação de técnicas de inteligência artificial (Rede neural artificial (RNA), algoritmos de agrupamento e otimização por enxame de partículas binárias (BPSO)) a partir da análise de gases dissolvidos (AGD).

1.3. Organização da dissertação

A dissertação está organizada por capítulos e estruturada como segue:

Capítulo 2 – Trata do desenvolvimento do marco teórico de diagnóstico de falhas em transformadores de potência, se ressaltam a importância dos transformadores de potência e se descrevem as principais normativas internacionais de diagnóstico de falhas em transformadores de potência, baseada na análise de gases dissolvidos (AGD).

Capítulo 3 – Apresenta a revisão de 88 artigos de investigação, abordados e publicados durante o período 2011-2019 no *IEEE Xplore digital Library*. Para uma

abordagem correta, os artigos foram agrupados em períodos de 3 anos. Dentro dos indicadores ponderados na análise estão o desempenho, número de padrões de treinamento e validação das metodologias propostas. Também se sintetiza uma coluna de comentários por metodologia abordada.

Capítulo 4 – Desenvolve o marco teórico das técnicas de inteligência artificial rede neural artificial (RNA), algoritmo de agrupamento (K-NN) e algoritmo de otimização de enxame de partículas binária (BPSO); as quais são passíveis de implementação no novo esquema de diagnóstico de falhas em transformadores de potência.

Capítulo 5 – Descreve um esquema de diagnóstico de falhas incipientes em transformadores de potência por rede neural artificial e algoritmo de agrupamento (K-NN ponderado), com variáveis de avaliação selecionadas por algoritmo de otimização de enxame de partículas binárias (BPSO). Adicionalmente se apresentam simulações e resultados de estudo de casos. Para o método baseado em rede neural artificial é alcançado um desempenho de 100 % no processo de validação.

Capítulo 6 – As conclusões acerca do trabalho, com o destaque as principais contribuições e os desdobramento que levam ao desenvolvimento de trabalhos futuros.

2 - DIAGNÓSTICO DE FALHAS EM TRANSFORMADORES DE POTÊNCIA

2.1. Transformador de Potência

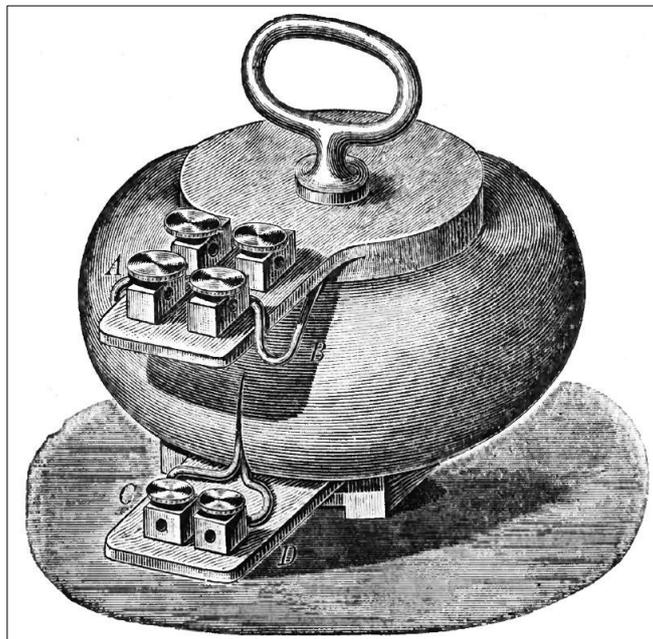
O princípio de funcionamento do transformador de potência é baseado na segunda lei de Faraday, registrada em 1831. A partir desta concepção, em 1836, G. J. Page desenvolveu o equipamento elétrico conhecido atualmente como autotransformador. Acontecimentos precedentes e a necessidade de transmitir energia elétrica permitiram que, em 1884, os engenheiros húngaros M. Dery, O. Blathy e K. Zipernovský promovessem a fabricação do primeiro transformador elétrico (Figura 2.1), que foi desenvolvido dentro da fábrica GANZ, na cidade de Budapeste - Hungria [22].

A inserção do transformador no mercado elétrico foi um passo importante na proximidade de uma fonte de geração de energia elétrica ao usuário final, permitindo que ao longo do tempo fossem desenvolvidos muitos equipamentos elétricos e eletrônicos de uso industrial e residencial que facilitaram o crescimento acelerado da demanda energética. Paralelamente, muitos transformadores elétricos foram desenvolvidos para satisfazer os novos requisitos do sistema elétrico. Estes podem ser classificados de acordo com vários critérios, como:

- ❖ Segundo a função: elevadores e redutores de tensão e corrente.
- ❖ Segundo o número de fases envolvidas: monofásicos e polifásicos.
- ❖ Segundo o lugar de instalação: transformadores de interior e de exterior.
- ❖ Segundo o tipo de refrigeração: transformadores com refrigeração de óleo e seco (ar).

- ❖ Segundo o nível de tensão: transformadores de potência (transmissão de altos níveis de tensão) e transformadores de distribuição (estritamente ligados ao atendimento do usuário residencial e da indústria).

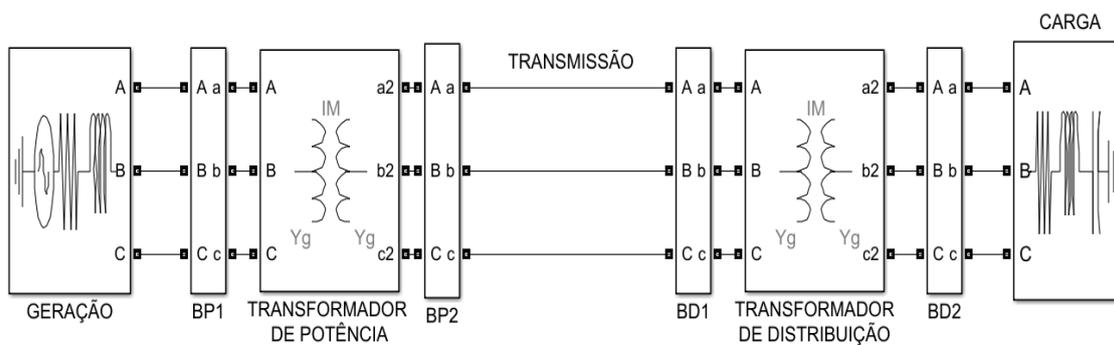
Figura 2.1 Primeiro transformador GANZ



Fonte: Adaptado de [22]

O Sistema Elétrico é constituído por três componentes funcionais (Figura 2.2): geração, transmissão e distribuição. Neste conjunto, o transformador elétrico cumpre a função de condicionamento em interconexão, expansão e controle de energia elétrica; portanto o transformador é um equipamento importante na transmissão e distribuição de energia elétrica do centro de geração até o usuário final [23].

Figura 2.2 Diagrama Equivalente do Sistema Elétrico



Fonte: Elaborado pelo Autor

Quanto ao aspecto econômico, em um estudo efetuado em [8], no qual se envolvem 94 casos de falhas em transformadores de 25 MVA, sobre valores de seguros pagos observados entre 1997 e 2001, foram encontrados prejuízos econômicos de US\$ 123 milhões para o usuário final e de US\$ 163 milhões para a empresa concessionária e particulares. Por outro lado em [3] foi estimado que o custo de fabricação e transporte do transformador de potência varia entre US\$ 8,5 e US\$ 35 mil/MVA, para um prazo de produção e entrega entre 10 e 20 meses. Estes cenários, considerando ambos os agentes envolvidos (empresa-usuário final), permitem demonstrar que o transformador de potência é um ativo valioso do sistema elétrico.

Considerando o aspecto funcional, o transformador é um equipamento elétrico estático de corrente alternada (CA). O princípio de funcionamento é baseado na transferência (elevar e reduzir os níveis de tensão e corrente) de energia elétrica de um circuito a outro por indução eletromagnética, com uma taxa de perda pequena e sem variação da frequência elétrica [23].

Os componentes principais do transformador elétrico podem ser agrupados de duas formas: o primeiro, corresponde à parte operacional, formada por dois circuitos elétricos e um circuito magnético de acoplamento (enrolamento primário, enrolamento secundário e núcleo magnético); o segundo, correspondente ao sistema de isolamento.

Seguindo os propósitos desta dissertação de mestrado, o objetivo está relacionado com o monitoramento de transformadores de potência com sistema de isolamento a óleo (Figura 2.3). O óleo mineral é o meio de isolamento e resfriamento mais comum devido à propriedade de alta resistência dielétrica do sistema de isolamento sólido (papel e cartão prensado) impregnado de óleo, portanto, a variável de avaliação da metodologia desenvolvida deve considerar o comportamento de ambos os isolamentos (líquido e sólido) quando o transformador de potência está em operação, para garantir a confiabilidade do sistema elétrico [24].

Para o monitoramento do estado de operação de transformadores, foram desenvolvidas metodologias de diagnóstico de falhas incipientes. Entre uma ampla possibilidade de metodologias, a vinculação da vibração com a condição mecânica dos enrolamentos e núcleo [11], assim como a análise do circuito [12] são tópicos de investigação bem estudados em diagnóstico de falhas no TP, porém as metodologias abordadas tem muitos inconvenientes, sendo o principal a indisponibilidade de dados,

seguido da análise parcial das condições de operação do transformador de potência (análise para falhas específicas do TP). Neste contexto, uma metodologia mais abrangente e bem estabelecida nas normativas internacionais é baseada na Análise dos Gases Dissolvidos (AGD). Como as demais metodologias existentes, esta apresenta inconvenientes, entretanto a abrangência e disponibilidade de dados, torna um tema de investigação constante.

Figura 2.3 Transformador de potência com isolamento de óleo



Fonte: Adaptado de [24]

2.2. Análise de Gases Dissolvidos (AGD)

Quando o transformador de potência é analisado a partir de indicadores de gases dissolvidos ele é considerado como um reator químico [13], já que na operação real do sistema elétrico, dentro do transformador de potência surgirão novos elementos reativos (conteúdo de gases) que podem indicar a condição de operação do TP. Na literatura especializada são encontrados importantes avanços em metodologias de diagnóstico de falhas incipientes a partir da AGD.

É importante salientar que em transformadores de potência o processo de formação de gases é normal, podendo ser resultado do envelhecimento do óleo isolante, descargas parciais, sobreaquecimento do sistema de isolamento, entre outros. Quando esta geração, entretanto, ultrapassa limites previamente estabelecidos pode se tornar um risco potencial para o equipamento e para o sistema elétrico. Portanto é de interesse

descrever o processo de formação destes gases para compreender de melhor forma o vínculo da AGD e a condição de operação do transformador de potência.

Dentro da estrutura construtiva e funcional do transformador de potência são encontrados papel e óleo, como componentes do sistema de isolamento. Em estudos efetuados por muitos anos, o processo de formação de gases está estreitamente ligado com o processo de decomposição do sistema de isolamento. Segundo a literatura especializada, esta formação de gases é tecnicamente resultado de estresse térmico, elétrico, mecânico e químico do transformador de potência [25].

2.2.1. Decomposição de Óleo

O óleo mineral para transformadores de potência possui estabilidade em temperaturas altas e, portanto, possui elevadas características isolantes. A composição química é resultado de uma mistura de moléculas de hidrogênio e carbono. No processo de decomposição há o rompimento de ligações de hidrogênio-carbono e carbono-carbono, que liberam átomos de hidrogênio, permitindo a formação dos denominados átomos ativos de hidrogênio e fragmentos de hidrocarbonetos. Os radicais livres podem se combinar para a formação dos gases hidrogenados (metano, etano, acetileno, ou mesmo, carbono moderadamente hidrogenado em forma de partícula), este processo de geração de gases também será ponderado significativamente por agentes externos como hidrocarbonetos individuais, distribuição de energia e temperatura na vizinhança da falha, e o tempo durante o qual o óleo é termicamente ou eletricamente estressado [13].

2.2.2. Decomposição de Celulose

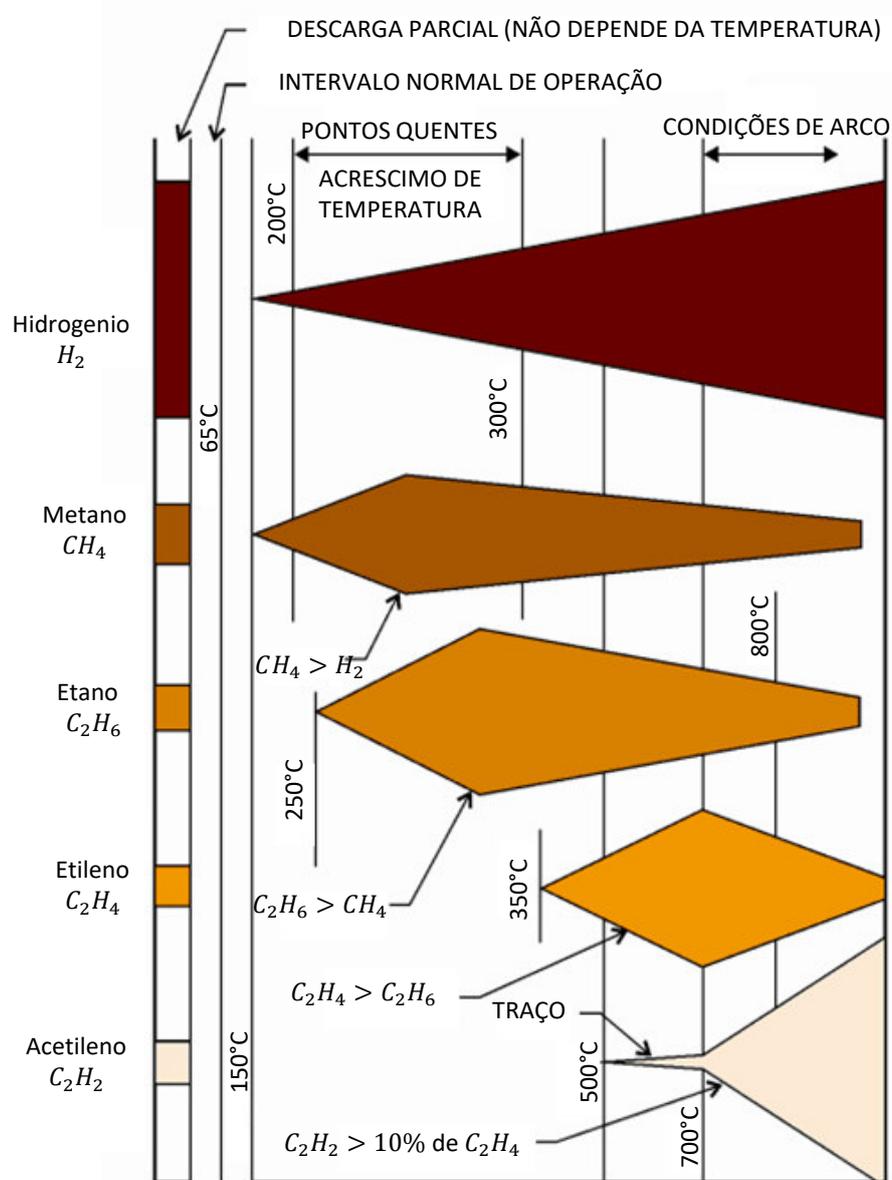
A decomposição térmica do isolamento sólido impregnado em óleo produz óxidos de carbono como monóxido de carbono CO e dióxido de carbono CO₂ (CO₂ não é gás combustível), algo de hidrogênio e metano devido à presença de óleo. Deve ser observado que a taxa de produção destes gases cresce exponencialmente com a temperatura, sendo diretamente proporcional ao volume do material nessa temperatura [26].

Nos parágrafos precedentes foi descrito o processo geral de formação de gases tanto em óleo e celulose (papel), quando é apresentada uma condição de falha dentro do TP. A frequência de geração de gases é influenciada por muitos fatores, que podem ser o ambiente em que opera o equipamento (localização geográfica) até o aspecto técnico operacional. Estes fatores múltiplos e complexos não permitem desenvolver uma

metodologia generalizável em diagnóstico de falhas nos transformadores de potência, porém, na literatura especializada foi usado algumas inferências válidas sobre alguns fatores que servem como indicadores potenciais da condição de operação do TP.

A temperatura e volume de conteúdo de gases foram vinculados diretamente com a condição de operação de um transformador de potência (Figura 2.4), esta vinculação é apenas um passo no desenvolvimento de metodologias estabelecidas em normas internacionais e melhoradas posteriormente na implementação de novas estratégias de diagnóstico mais robustas para falhas no TP.

Figura 2.4 Evolução de conteúdo de gases falha em diferentes temperaturas / condições de falha



Fonte: Adaptado de [14]

2.3. Metodologias de Diagnóstico de Falhas Incipientes no TP

É muito importante enfatizar que no contexto de AGD, a análise e interpretação de gases extraídos não é exata, estando sujeita à variabilidade [13]. Para uma abordagem adequada a partir de AGD é de interesse saber o conteúdo e taxa de geração de gases, estes dois aspectos nos permitem determinar com maior assertividade a vinculação de conteúdo de gases e fonte de isolamento em decomposição, conseqüentemente, a condição de operação do transformador de potência.

Na bibliografia revisada, há um número significativo de metodologias de diagnóstico de falhas incipientes em transformadores de potência baseados na AGD, porém poucas abordagens a partir da taxa de geração de gases são identificadas devido aos sérios inconvenientes de disponibilidade de dados. Nesse contexto, sempre se pretende implementar uma estratégia de diagnóstico de falhas de alta assertividade e generalizável a partir de conteúdo de gases (dados disponíveis). Assim, na literatura atualizada são encontrados dois grupos de metodologias de diagnóstico.

Nesta dissertação a vinculação direta de gases (volume e temperatura) com condição de operação do TP traduzido em simples regras de diagnóstico e algumas interpretações gráficas serão denominadas como metodologias convencionais, enquanto as metodologias que incluem ferramentas de metaheurística - estatística serão denominadas como metodologias de técnicas de inteligência artificial.

2.3.1. Metodologias de Diagnóstico Convencional

Na literatura recente existem um número importante de metodologias de diagnóstico de falhas incipientes em transformadores de potência, baseadas na AGD. Considerando o grau de assertividade e generalização, algumas metodologias foram estabelecidas em normativas internacionais, as quais no processo de desenvolvimento de novas estratégias de diagnóstico são consideradas como caso-base de comparação (caraterísticas de generalização e assertividade).

a. Instituto de Engenheiros Elétricos e Eletrônicos (IEEE)

O IEEE é uma organização de profissionais sem fins lucrativos, fundada em 1963 nos Estados Unidos. Os objetivos desta organização estão baseados em promover o conhecimento no campo de engenharia elétrica, eletrônica e computação [21]. No caso de equipamentos elétricos de sistemas de potência, caso específico do diagnóstico de

falhas incipientes no transformadores de potência imerso em óleo, estão estabelecidos em normativa descrita nos documentos [26] e [27]. As metodologias de diagnóstico de maior destaque são:

a.1. Método do Gás Chave

É uma metodologia de interpretação direta, onde as variáveis de avaliação são o conteúdo de gases típicos ou predominantes em diferentes temperaturas. Dentro da análise são consideradas quatro condições de operação do TP (falha térmica em óleo, falha térmica em celulose, falha elétrica de descarga parcial e falha elétrica de arco).

Do conteúdo de gases extraídos (de gases dissolvidos ou espaço de gás), as relações de interdependência podem ser ilustradas na Figura 2.5. Quando se analisa uma falha térmica originada na celulose (papel), Figura 2.5- b, uma quantidade predominante de monóxido de carbono é apresentada, enquanto os conteúdos para outros gases terão uma proporção pequena.

a.2. Método Dornenburg

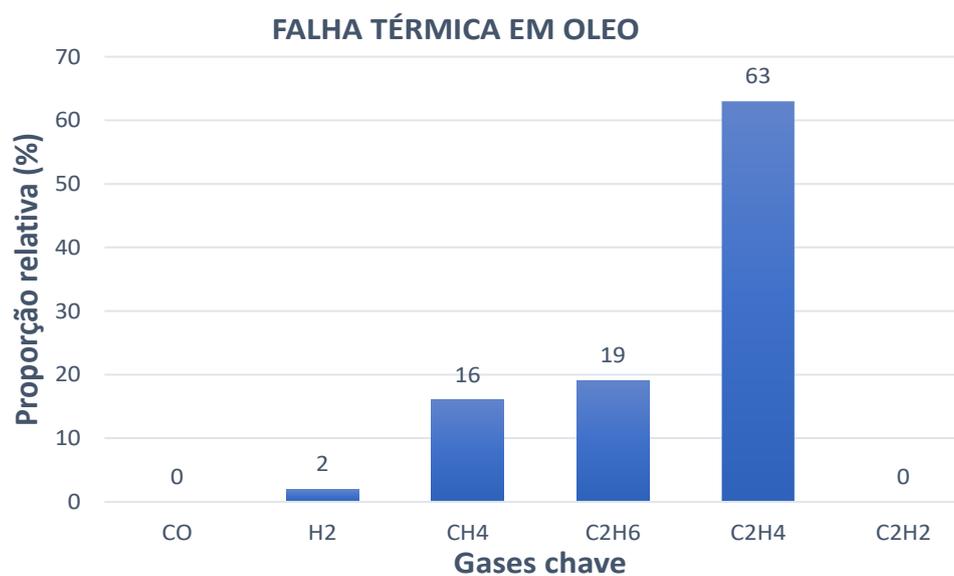
O diagnóstico de falhas incipientes em transformadores de potência por relações de conteúdo de gases foi proposto pela primeira vez por Dornenburg [15] [26], considerando as seguintes relações de gases.

- Relação 1 (R_1) = $\frac{CH_4}{H_2}$
- Relação 2 (R_2) = $\frac{C_2H_2}{C_2H_4}$
- Relação 3 (R_3) = $\frac{C_2H_2}{CH_4}$
- Relação 4 (R_4) = $\frac{C_2H_6}{C_2H_2}$
- Relação 5 (R_5) = $\frac{C_2H_4}{C_2H_6}$

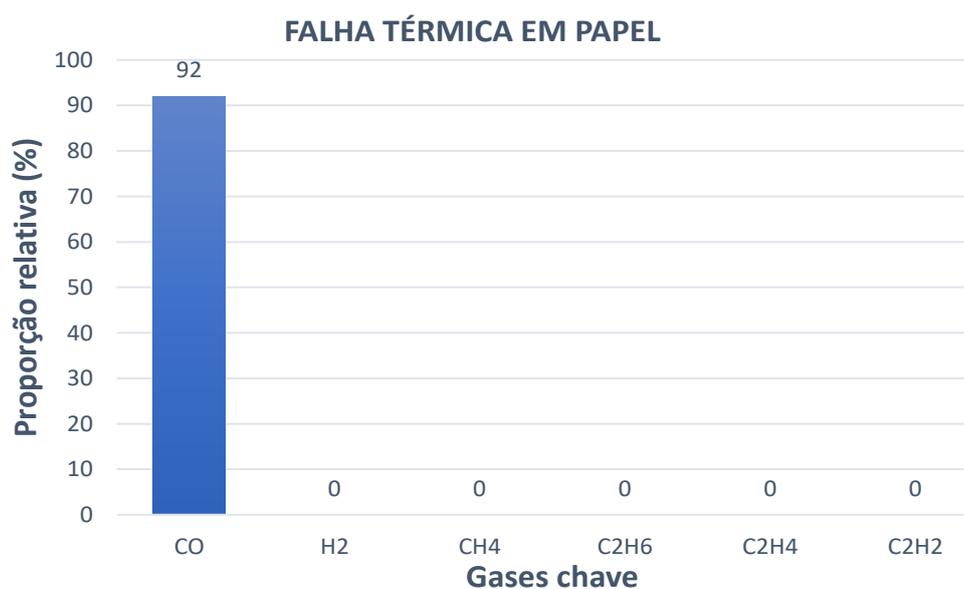
As regras de diagnóstico de falhas em transformadores de potência, estabelecidas por Dornenburg foram a partir de cinco conteúdos de gases ($H_2, CH_4, C_2H_2, C_2H_4, C_2H_6$ e CO) e quatro relações de gases (R_1, R_2, R_3 e R_4); são consideradas uma condição de falha térmica (TH) e duas condições de falha elétrica (descarga parcial e arco).

O processo de diagnóstico pelo método Dornenburg se inicia com a comparação do conteúdo de gases medidos e estabelecidas em normativa (conforme apresentado na Tabela 2.1). Nesta comparação ao menos um conteúdo de gás deve ser o dobro do conteúdo de gás estabelecido na normativa; paralelamente, um segundo conteúdo de gás dentro da mesma amostra deve passar os limites estabelecidos na mesma normativa (Tabela 2.1). Finalmente as relações de gases são comparadas com as regras de diagnóstico de falhas no TP, indicadas na Tabela 2.2.

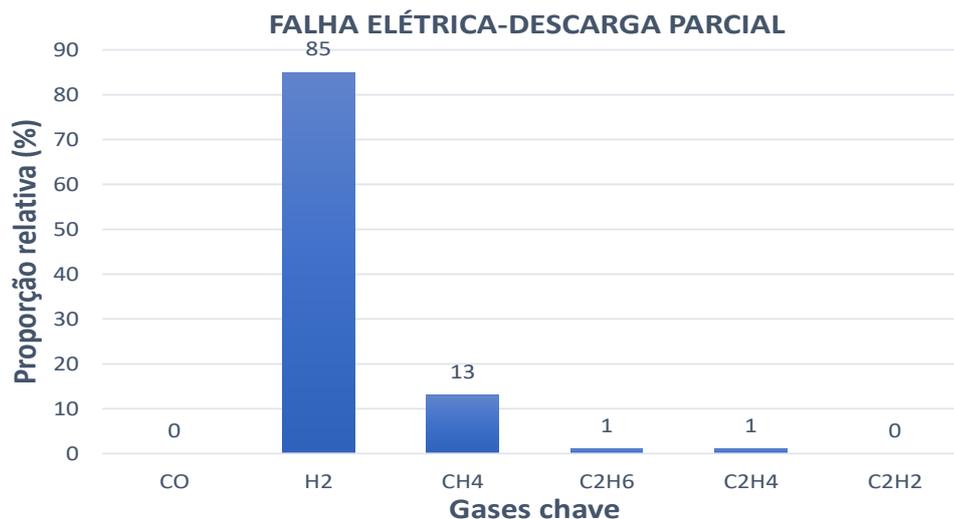
Figura 2.5 Diagnóstico de falhas em TP por AGD, por método de gases chave (a), (b), (c) e (d)



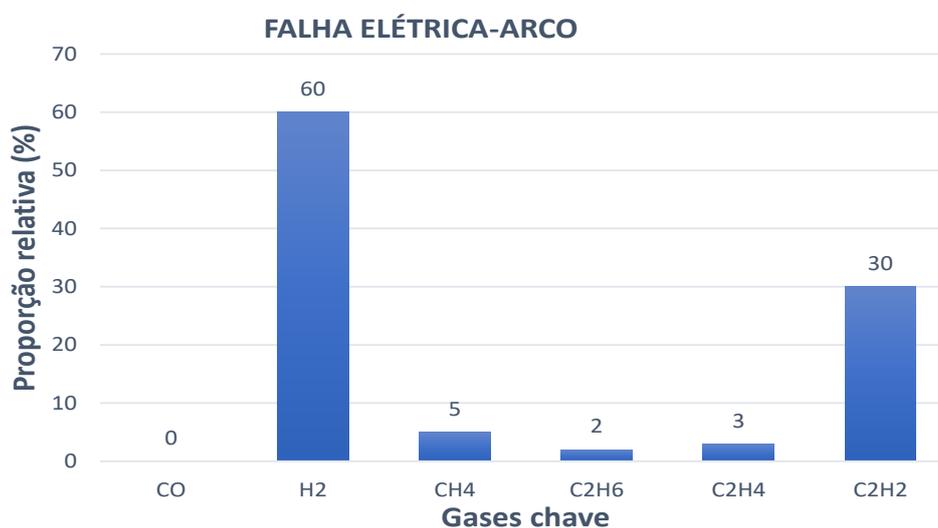
(a) Falha térmica em óleo



(b) Falha térmica em papel



(c) Falha elétrica – Descarga parcial



(d) Falha elétrica – Arco

Fonte: Adaptado de [26]

Tabela 2.1 Concentrações de gases dissolvidos para o método Dornenburg

Gases claves	Concentrações (L /ppm)
Hidrogênio H2	100
Metano CH4	120
Acetileno C2H2	35
Etileno C2H4	50
Etano C2H6	65
Monóxido de carbono CO	350

Fonte: Adaptado de [26]

Tabela 2.2 Regras de diagnóstico de falhas para o método Dornenburg

Condições de operação no TP	REGRAS			
	(R_1)	(R_2)	(R_3)	(R_4)
Falha térmica (TH)	$R_1 > 1$	$R_2 < 0.75$	$R_3 < 0.3$	$R_4 > 0.4$
Falha elétrica – descarga parcial (PD)	$R_1 < 0.1$	-	$R_3 < 0.3$	$R_4 > 0.4$
Falha elétrica – arco (AR)	$0.1 \leq R_1 \leq R_2 > 0.75$		$R_3 > 0.3$	$R_4 < 0.4$

Fonte: Adaptado de [26]

É muito importante indicar que o conteúdo de gases aplicáveis nesta análise pode ser extraído do espaço de gás do transformador de potência por meio de um sensor, assim como de gases extraídos da análise de gases dissolvidos no óleo por cromatografia de gases.

a.3. Método Rogers

O método Rogers é baseado em três relações de gases para diagnosticar seis condições de operação do transformador de potência, apresentado na Tabela 2.3: descarga parcial (PD), arco de alta energia (HED), falha térmica de baixa energia (LTH), falha térmica de $< 700 \text{ }^\circ\text{C}$ (MTH), falha térmica de $> 700 \text{ }^\circ\text{C}$ (HTH) e operação normal (NF).

Tabela 2.3 Regras de diagnóstico de falhas por método Rogers

Condições de operação no TP	REGRAS		
	(R_1)	(R_2)	(R_5)
Operação normal (NF)	$0.1 \leq R_1 \leq 1$	$R_2 < 0.1$	$R_5 < 1$
Descarga parcial (PD)	$R_1 > 1$	$1 \leq R_2 \leq 3$	$R_5 < 1$
Arco de alta energia (HED)	$R_1 > 0.1$	$0.1 \leq R_2 \leq 1$	$R_5 > 3$
Falha térmica de baixa energia (LTH)	$0.1 \leq R_1 \leq 1$	$R_2 < 0.1$	$1 \leq R_5 \leq 3$
Falha térmica $< 700 \text{ }^\circ\text{C}$ (MTH)	$0.1 \leq R_1 \leq 1$	$0.1 \leq R_2 \leq 1$	$1 \leq R_5 \leq 3$
Falha térmica $> 700 \text{ }^\circ\text{C}$ (HTH)	$0.1 \leq R_1 \leq 1$	$0.1 \leq R_2 \leq 1$	$R_5 > 3$

Fonte: Adaptado de [26]

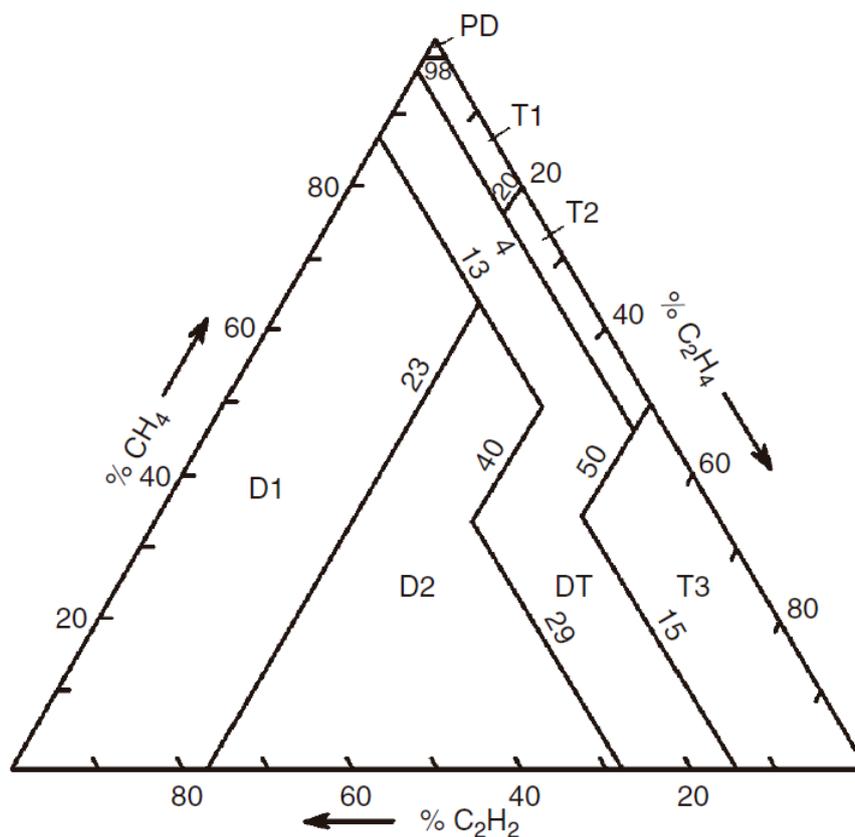
O diagnóstico das condições de operação do transformador de potência pelo método Rogers é aplicado diretamente sobre a regra de classificação estabelecida na Tabela 2.3. Os testes para a validação do método foram realizados sobre um grande número de dados fornecidos por um grupo industrial e testes de laboratório. A normativa é aplicável tanto para conteúdo de gases extraídos da AGD no óleo por cromatografia de

gases, quanto para o conteúdo de gases extraídos do espaço de gás do transformador de potência por meio de um sensor.

a.4. Método de Triângulo de Duval

A metodologia baseada no esquema gráfico denominado como Triângulo de Duval foi desenvolvida e publicada pela primeira vez no informe IEEE C74-476-8 de 1974, por Michael Duval [27] [28]; a estrutura de diagnóstico é realizada sobre uma superfície triangular (Figura 2.6). São considerados três conteúdos de gases como parâmetros de avaliação (metano, etileno e acetileno) e seis condições de operação no transformador de potência: descarga parcial (PD), descarga de baixa energia (D1), descarga de alta energia (D2), falha térmica de temperatura $< 300\text{ }^{\circ}\text{C}$ (T1), falha térmica de temperatura $300\text{ }^{\circ}\text{C} < T2 < 700\text{ }^{\circ}\text{C}$ (T2), falha térmica de temperatura $> 700\text{ }^{\circ}\text{C}$ (HTH).

Figura 2.6 Diagnóstico de falhas em TP por AGD, por Triângulo de Duval



Fonte: Adaptado de [27]

O cálculo numérico dos lados do Triângulo de diagnóstico de falhas incipientes no transformador de potência é realizado da seguinte forma:

$$\%C_2H_2 = \frac{100x}{x + y + z}$$

$$\%C_2H_4 = \frac{100y}{x + y + z}$$

$$\%CH_4 = \frac{100z}{x + y + z}$$

Em que:

$$x = C_2H_2, \quad y = C_2H_4; \quad z = CH_4$$

A metodologia foi testada com mais de 1000 instâncias de teste, sendo importante indicar que a base de dados usada é extraída da IEC TC10 [28]. Por essa razão, a metodologia de Triângulo de Duval é considerada como uma boa comparação gráfica da metodologia desenvolvida pela Comissão Eletrotécnica Internacional (Padrão IEC 60599).

b. Comissão Eletrotécnica Internacional (IEC)

A IEC é uma organização de liderança mundial em preparação e publicação de normativas internacionais em tecnologias de engenharia elétrica e eletrônica. Foi fundada em 1906, e atualmente a sede principal está localizada em Genebra, na Suíça. Para o diagnóstico de falhas incipientes em transformadores de potência foi publicada a normativa IEC 60599 em janeiro de 1978, a qual foi modificada significativamente em 1999 [28-30]

b.1. Método IEC 60599

A publicação da IEC 60599, emitida em 1999, é o resultado da revisão realizada em uma publicação da mesma norma (IEC 60599), emitida em 1978. A atualização do padrão está centrada basicamente na descrição mais profunda das cinco condições de falha (foram alterados os novos limites de regras de diagnóstico), adicionalmente foi sugerido o uso de novas relações de gases para falhas específicas. Outro avanço importante é também a consideração de uma condição de operação normal no transformador de potência. Então as condições de diagnóstico para o padrão atualizada em 1999 são de seis condições de operação do TP (incluindo condição normal).

As falhas indicadas no padrão IEC 60599 são as que confiavelmente podem ser identificadas em um transformador após ocorrência de uma falha em serviço, sendo

descarga parcial (DP), descarga de baixa energia(D1), descarga de alta energia(D2), falhas térmicas (T1, T2 e T3)

As três relações de gases básicas da IEC 60599 (R_x , R_y e R_z) são utilizadas para identificação de seis condições de operação do transformadores de potência (Tabela 2.4), as relações incluídas na análise são: C_2H_2/H_2 para detectar possível contaminação do OLTC (*On Load Tap Changer*), O_2/N_2 para detectar anormalidade no óleo, adicionalmente o CO_2/CO como indicador de que o isolante sólido está envolvido na falha.

Considerando as relações $R_x = \frac{C_2H_2}{C_2H_4}$, $R_y = \frac{CH_4}{H_2}$ e $R_z = \frac{C_2H_4}{C_2H_6}$, as regras de diagnóstico de falhas no TP são feitas segundo a Tabela 2.4.

Tabela 2.4 Regras de diagnóstico de falhas pelo método IEC 60599

Condições de operação no TP	REGRAS		
	(R_x)	(R_y)	(R_z)
Descarga parcial (PD)	NS	$R_y < 0.1$	$R_z < 0.2$
Descarga de baixa energia (D1)	$R_x > 1$	$0.1 \leq R_y \leq 0.5$	$R_z > 1$
Descarga de alta energia (D2)	$0.6 \leq R_x \leq 2.5$	$0.1 \leq R_y \leq 1$	$R_z > 2$
Falha térmica $< 300^\circ C$ (T1)	NS	$R_y > 1 / NS$	$R_z > 1$
Falha térmica $300^\circ C < T < 700^\circ C$ (T2)	$R_x < 0.1$	$R_y > 1$	$1 \leq R_z \leq 4$
Falha térmica $> 700^\circ C$ (HTH)	$R_x < 0.2$	$R_y > 1$	$R_z > 4$

Fonte: Adaptado de [10]

c. Centro de Geração Elétrica (CEGB)

Planta Geradora de Eletricidade Central, conhecida universalmente pela sigla em inglês CEGB (*Central Electricity Generating Board*), é uma empresa de energia elétrica responsável pela energia elétrica da Inglaterra e do país de Gales por mais de 40 anos. Com objetivo de monitorar os ativos dentro da concessão elétrica, desenvolveram uma metodologia de diagnóstico de falhas incipientes no transformador de potência. Os novos parâmetros de avaliação são baseado em relações do método Rogers [15] [31].

c.1. Método CEGB

O método CEGB é uma extensão do método Rogers, em que são considerados quatro relações de gases (três relações são do método Rogers) e as condições de operação do transformador, incluído a operação normal e não identificada (Tabela 2.5 e 2.6).

Tabela 2.5 Codificação CEGB no método Rogers

Relações de gases	Regra	Código
$R_a = \frac{CH_4}{H_2}$	$0.1 < R_a < 1$	0
	$1 \leq R_a < 3$	1
	$R_a \geq 3$	2
	$R_a \leq 1$	3
$R_b = \frac{C_2H_2}{C_2H_4}$	$R_b < 0.5$	0
	$0.5 \leq R_b \leq 3$	1
	$R_b > 3$	2
$R_c = \frac{C_2H_4}{C_2H_6}$	$R_c < 1$	0
	$1 \leq R_c < 3$	1
	$R_c > 3$	2
$R_d = \frac{C_2H_6}{CH_4}$	$R_d < 1$	0
	$R_d \geq 1$	1

Fonte: Adaptado de [15]

Tabela 2.6 Regras de diagnóstico de falhas pelo método CEGB

Condições de operação do TP	REGRAS			
	(R_a)	(R_b)	(R_c)	(R_d)
Operação normal (NF)	0	0	0	0
Condição de operação não definida (UD)	4	4	4	4
Descarga parcial (PD)	3	0	0	0
Falha térmica $< 150^\circ C$ (TC1)	1 ou 2	0	0	0
Falha térmica $150^\circ C < TC2 < 200^\circ C$ (TC2)	1 ou 2	0	0	1
Falha térmica $200^\circ C < TC3 < 300^\circ C$ (TC3)	0	0	0	1
Falha térmica (incremento de temperatura geral em parte condutiva) (TC4)	0	0	1	0
Falha térmica (corrente circulante em bobina) (TC5)	1	0	1	0
Falha térmica (corrente circulante em núcleo e bobina, sobreaquecimento conjunto) (TC6)	1	0	2	0
Arco com baixa densidade de energia (DC1)	0	1	0	1
Arco com alta densidade de energia (DC2)	0	1 ou 2	1 ou 2	0
Chispa contínua (CS)	0	2	2	0
Descarga parcial com rastreou (PDT)	3	1 ou 2	0	0

Fonte: Adaptado de [15]

*Código 4 é indicado na regra de diagnóstico de falhas em TP (indicação de não definida)

Foi desenvolvido um número significativo de metodologias de diagnóstico de falhas incipientes no transformador de potência (desde regras simples de diagnóstico até abordagens gráficas) com objetivo de determinar as fronteiras das condições de operação do transformador de potência, porém na literatura revisada ainda não é alcançada uma metodologia generalizável e de alta assertividade.

Visando a importância dos transformadores de potência e baseados na informação padronizada e atualizada, cada organismo privado ou público adotou uma forma de monitorar ou regular o correto funcionamento dos ativos com algumas variações que não garantem o adequado monitoramento destes equipamentos.

2.3.2. Metodologias de Técnicas de Inteligência Artificial

Ao final do século XIX surgem as primeiras concepções de inteligência artificial como uma máquina capaz de iludir e passar como inteligente aos olhos de um homem [32] [33]. No século XX, o desenvolvimento da inteligência artificial foi estreitamente ligado ao desenvolvimento do computador e reconhecida como ciência a partir de 1956. Na atualidade a tecnologia e/ou trabalhos de otimização de processos são orientados à mineração de dados, que estão estreitamente ligados às ferramentas de tecnologias de inteligência artificial.

Nesta dissertação de mestrado as técnicas de inteligência artificial são referidas como algoritmos que têm a capacidade de emular o processo de conhecimento do ser humano. As principais tarefas desenvolvidas com a tecnologia existente estão demarcadas em exploração e análise para previsão, regressão, classificação, agrupamento e associação de dados. Para cumprir com este propósito as técnicas de inteligência artificial tem dois componentes bem estabelecidos: a) o processo de treinamento em que se pretende aprender as características da amostra de treinamento e, b) uma base de dados de teste no qual se pretende validar a metodologia em desenvolvimento.

Em diagnóstico de falhas incipientes em transformadores de potência, a motivação do uso de técnicas de inteligência artificial está vinculada com a necessidade de realizar tarefas de classificação, agrupamento e otimização, com o objetivo de melhorar a generalização e o desempenho das metodologias existentes. Na revisão da literatura foi observado uma quantidade importante de algoritmos aplicados em tarefas de diagnóstico de falhas no TP, sendo o maior destaque para Rede Neural Artificial (RNA), Máquina Suporte Vetorial (SVM), Lógica fuzzy, algoritmo de vizinhança mais próxima (K-NN),

Algoritmos Genéticos (AG) , Otimização de enxame de partículas (PSO), entre outros [10].

2.4. Conclusão do capítulo

Neste capítulo foi abordado o marco teórico conceitual dos componentes básicos da problemática apresentada nesta dissertação, sendo entendido que o transformador de potência imerso em óleo (TP), pela função desempenhada e os fatores econômicos quando se apresenta uma condição de falha com a consequente interrupção de serviço elétrico, é um ativo valioso do sistema elétrico.

No monitoramento da condição de operação do transformador de potência, uma metodologia generalizável e de maior assertividade é estabelecida a partir do conteúdo de gases extraídos por AGD.

As metodologias de diagnóstico de falhas incipientes em TP com maior aceitação na comunidade industrial e acadêmica, estão baseadas em normativas internacionais como IEEE, IEC, CGEB, entre outros. Porém a taxa de assertividade é baixa e não permite monitorar corretamente a condição de operação do TP. A inserção de técnicas de inteligência artificial abre uma janela de possibilidades de melhorar tanto a assertividade assim como a generalização de metodologias de diagnóstico de falhas incipientes em transformadores de potência.

3 - REVISÃO BIBLIOGRÁFICA

3.1. Introdução

Na literatura especializada é encontrado um número importante de metodologias de diagnóstico de falhas incipientes em transformadores de potência, porém a metodologia mais abrangente e de constante desenvolvimento é baseado na Análise de Gases Dissolvidos (AGD) associada a uma metaheurística (redes neurais, enxame de partículas, máquina de suporte vetorial, entre outros). Para contextualizar esta dissertação, neste capítulo é realizada uma revisão bibliográfica de trabalhos científicos que foram publicados no período de 2011 a 2019.

Para uma análise abrangente e apropriada, os trabalhos foram selecionados e apresentados por períodos de três anos, considerando tanto as metodologias baseadas em técnicas de Inteligência Artificial como as abordagens orientadas a melhorar as metodologias convencionais.

3.2. Estado da arte

Uma plataforma com acesso a artigos de congressos e periódicos, anais de congressos e outros projetos de desenvolvimento, bastante aceita na comunidade científica de Engenharia Elétrica, Eletrônica e Computação é o *IEEE Xplore Digital Library* [21]. Nessa plataforma foi encontrada uma literatura extensa sobre o tema do trabalho (diagnóstico de falhas incipientes em transformadores de potência), o qual permitiu uma revisão adequada, sendo a busca da informação limitada a partir do tema pontual de “diagnóstico de falhas incipientes em transformadores de potência por AGD”, além dos indicadores disponíveis (desempenho da metodologia, padrões de treinamento e teste) que permitiram avaliar quantitativamente as metodologias desenvolvidas. A

amostra de trabalhos selecionados no período 2011 a 2019 foi de oitenta e oito (88) artigos científicos.

3.2.1. Artigos de 2011-2013

A seleção dos artigos foi baseada especificamente pela disponibilidade de dados de treinamento, dados de validação e desempenho da metodologia. Para o período compreendido entre 2011-2013 foram selecionados vinte e nove (29) artigos. Cada artigo contém um aporte significativo em desenvolvimento da metodologia mais robusta e de alta assertividade para o diagnóstico de falhas incipientes em transformadores de potência imerso em óleo, esta informação é ponderada na sexta coluna (*Metodologia aplicada e comentários*) do resumo apresentada na Tabela 3.1.

Tabela 3.1 Quadro resumo de artigos de investigação revisadas, período 2011-2013

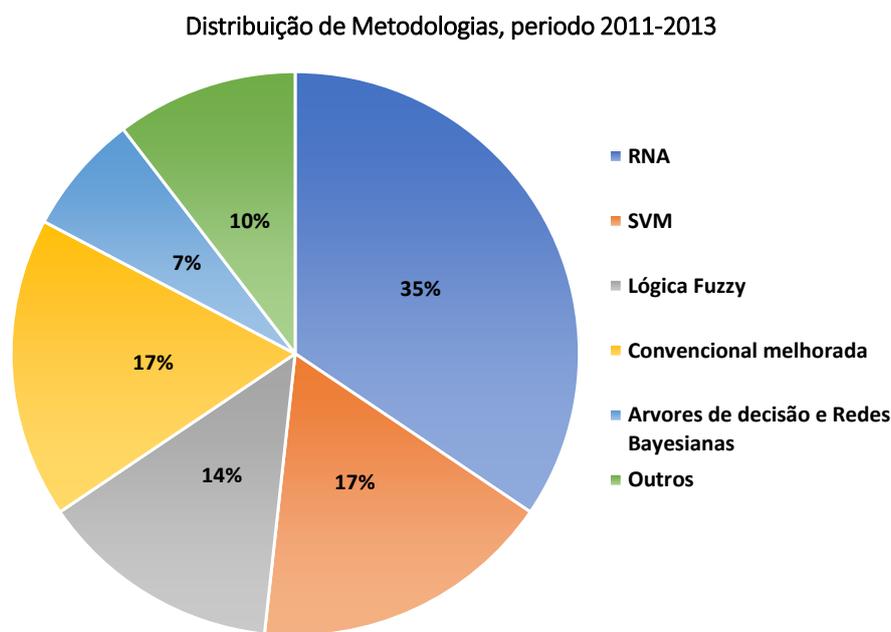
Nº	[Ano-Art.]	Dado Treino	Dado Teste	Desempenho	Metodologia Aplicada e Comentários
1	2011- [34]	130	20	95,00 %	RNA (BP): seleção de grupo ponderação livre para uma estrutura ótima de BP.
2	2011- [35]	51	54	81,48 %	RNA (RBF): a seleção ótima da estrutura da rede RBF (centro RBF) é realizada por CF e RF.
3	2011- [36]		211	93,37 %	Convencional: derivado de um estudo de caso, utiliza relações e proporções de gases.
4	2011- [37]		117	96,67 %	Sistema Inferência FUZZY: é integrado com cinco critérios tradicionais (DOR, ROG, TD e 2 outros) classificadas por fator identificável de falhas.
5	2011- [38]	244	74	95,95 %	SVM: por otimização convexa de dados mediante combinação linear de vários núcleos.
6	2011- [39]	92	101	94,06 %	SVM com parâmetros otimizados a partir de enxame de partículas de caos (CPSO).
7	2011- [40]	170	130	96,15 %	GEP baseado em FA: o FA melhora a correlação do vetor característico.
8	2011- [41]		35	94,28 %	Lógica FUZZY: aplicado na comparação de assertividade de métodos ROG e IEC/ IEC modificado.
9	2012- [42]	600	132	95,45 %	RNA-FUZZY: 6 critérios tradicionais são treinados por RNA - FIS (4 camadas) e o resultado é misturado.
10	2012- [10]	1400	352	100,00 %	RNA (Auto associativa) para cada falha de TP é empregado, e MS é utilizado para gerar data.
11	2012- [43]		162	93,75 %	AD c4.5 é utilizado sobre um espaço de alta dimensão (21 atributos).

12	2012- [44]		101	97,03 %	Convencional, combina quatro métodos (ROG, IEC, TD e gás chave).
13	2012- [45]	200	200	100,00 %	RNA conjunta, é aplicado conjuntos estáticos com método meio de 5 e 6 MLPs (expertos).
14	2012- [46]	160	30	86,70 %	RNA(RBF) em combinação de critérios convencionais (relações, gráficos e gás chave).
15	2012- [47]	56	126	85,92 %	RST é aplicado na classificação de dados em complementariedade com RNA(BP).
16	2012- [48]		159	81,25 %	RST é aplicado em redução de espaço de entrada e classificação por regras, da condição do TP.
17	2012- [49]	175	30	94,00 %	Lógica FUZZY, RNA(BP) e ANFIS é aplicado em standard IEC, melhor assertividade em FUZZY.
18	2012- [50]		35	94,30 %	IAFSA é aplicado na obtenção de regras causa-falha, RST na otimização das regras IAFSA.
19	2013- [51]		232	86,64 %	RB é aplicado em ROG para classificar a condição de deterioração normal, falha térmica e elétrica.
20	2013- [52]		44	95,50 %	Os parâmetros de RNA(CP) são otimizados a partir de relação ótima de treinamento e prova por AG.
21	2013- [53]	244	244	79,76 %	RNAs (RL, MLP e RBF) é estudada, melhor desempenho é registrado em MLP de 4 entradas.
22	2013- [54]	30	14	85,71 %	SVM com seleção ótima de núcleo e parâmetro de penalidade C por SRM, é aplicado, (C=10).
23	2013- [55]		81	61,00 %	FUZZY em critérios tradicionais (ROG, DOR, IEC, TD e gás chave), abordagem-fuzzy é melhor.
24	2013- [56]		117	92,31 %	Crítérios tradicionais (ROG, IEC, TD, gás chave) é combinado em software (Hybrid-AGD).
25	2013- [57]		122	95,90 %	Análise de 15 combinações de relações de gases, são selecionadas 3 combinações ótimas.
26	2013- [58]		122	96,20 %	Análise de combinação de porcentagem relativo de gases, é selecionado uma combinação dupla.
27	2013- [59]		100	89,00 %	Lógica FUZZY: aplicado sobre a combinação de critérios tradicionais (ROG, IEC e TD).
28	2013- [60]	135	40	85,00 %	SVM com núcleo gaussiano: aplicado em ROG e DOR, ROG é de melhor assertividade.
29	2013- [61]	64	24	92,00 %	Três SVM multiclases: é analisado, uma-contra-uma é selecionado de melhor assertividade.

Fonte: Elaborado pelo Autor.

Analisando da perspectiva da ferramenta aplicada em diagnóstico de falhas em transformadores de potência e metodologias orientadas no melhoramento de critérios convencionais (Tabela 3.1) é possível ilustrar um gráfico percentual de distribuição de metodologias (Figura 3.1).

Figura 3.1 Distribuição de metodologias por ferramenta aplicada em diagnóstico de falhas no transformador de potência, período 2011-2013



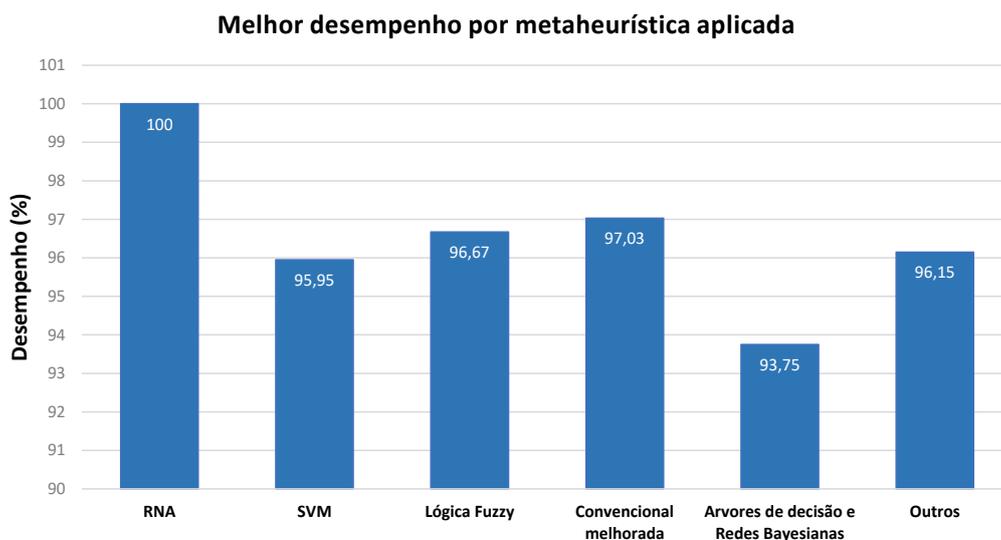
Fonte: Elaborado pelo Autor

Ainda na Figura 3.1 é possível observar que a rede neural artificial (RNA) é uma ferramenta com maior frequência de uso em desenvolvimento de metodologias no diagnóstico de falhas no transformador de potência. Por outro lado, é importante ressaltar que as metodologias desenvolvidas para melhorar os “critérios convencionais” seguem tendo uma importância considerável como solução alternativa (17 % de trabalhos direcionados).

Para uma avaliação quantitativa de metodologias de diagnóstico de falhas foi importante ter a disponibilidade de dados de avaliação (treinamento, teste e desempenhos), apresentado na Tabela 3.1, em que há ausência de alguns dados, o qual não permite avaliar apropriadamente as metodologias desenvolvidas.

Nesta revisão para uma melhor visualização da abrangência dos artigos (revisados no período 2011-2013), foi ilustrado por meio da Figura 3.2 um histograma de melhor desempenho, por metaheurística aplicada.

Figura 3.2 Assertividade de metodologias de diagnóstico de falhas em TP (2011-2013)



Fonte: Elaborado pelo Autor

Ainda na Figura 3.2 é possível observar que a metodologia de diagnóstico de falhas por rede neural artificial tem uma maior assertividade sobre as demais. Um exemplo significativo foi encontrado na metodologia desenvolvida em [10]. Neste artigo foi alcançado um desempenho de 100 %, tanto no processo de treinamento e validação para 1400 (dados gerados) e 352 (dados reais), respectivamente.

A abordagem desse trabalho foi baseada no uso de um conjunto de redes neurais auto associativas por condição de operação do transformador. A estrutura da RNA auto associativa consiste na igualdade dos parâmetros de entrada e saída da rede, a qual segundo os autores é capaz de armazenar nos pesos as informações referentes ao tipo de falha, portanto esta informação pode ser utilizada na classificação quando um novo dado é diagnosticado por critério de semelhança.

A inconveniência da indisponibilidade de dados é resolvida por meio do gerador de dados do algoritmo Mean Shift. Dentro do mesmo grupo de algoritmos é apresentado a aplicação da RNA conjunta [45], em que um número razoável de redes neurais (MLP) são empregadas para tarefas de classificação sob o princípio de “*dividir para conquistar*”. Desta forma são selecionados conjuntos estáticos de métodos meio com 100 sistemas que no processo de treinamento permitem a seleção de 20 sistemas com o melhor desempenho. No processo de treinamento e validação para 200 dados de treinamento e teste foi alcançado um desempenho de 100 % para RNA conjunta com 5 e 6 sistemas especialistas.

Por outro lado, em metodologias orientadas a melhorar os critérios convencionais, um aporte significativo é encontrado em [44], com um desempenho de 97,03 % para uma amostra de 101 dados, no qual o abordagem é baseado na combinação de quatro métodos convencionais (método de Rogers, IEC 60599, gás chave e Triângulo de Duval).

Segundo os autores foi desenvolvido um programa computacional na linguagem C++ na plataforma *Microsoft .NET Framework 3.0*, no qual o fluxo de diagnóstico começa com diagnóstico por cada metodologia empregada, no final da análise é realizada uma classificação de falha por porcentagem de forma a avaliar a condição de operação do transformador de potência. Em [56] foi apresentado um programa computacional semelhante, porém na validação com 117 dados, a metodologia alcançou um desempenho de 92,31 %.

3.2.2. Artigos de 2014-2016

Diagnóstico de falhas incipientes em transformadores de potência é atualmente um tema aberto, portanto a produção de material científico é de constante desenvolvimento. Durante o período 2014-2016 foram desenvolvidas diferentes metodologias de diagnóstico, sendo estas com foco principal em melhorar os critérios convencionais ou baseados em abordagens de técnicas de inteligência artificial. Considerando os critérios de avaliação definidos no subtópico 3.2.1, foram selecionados e revisados trinta (30) artigos (Tabela 3.2).

Tabela 3.2 Quadro resumo de artigos de investigação revisadas, período 2014-2016

Nº	[Ano- Art.]	Dado Treino	Dado Teste	Desempenho	Metodologia Aplicada e Comentários
1	2014- [62]	120	51	98,53 %	Cinco classificadores GEP-binários: aplicado em classificação escalonada sobre metodologia IEC.
2	2014- [63]		30	83,33 %	Lógica FUZZY: aplicado sobre metodologia IEC, implementação é baseado no método Mamdani.
3	2014- [64]	V-C	174	96,50 %	Test K-S: aplicado na extração de características de dados, PSO é utilizado na seleção ótima de parâmetros (C e ζ) de classificador SVM multicamada.
4	2014- [65]	120	51	98,00 %	Metodologia IEC: aplicado 5 PSVMs de classificação.
5	2014- [66]	120	51	98,28 %	RNA (probabilística) com seleção de características por Software RapidMiner (pacote de otimizadores).

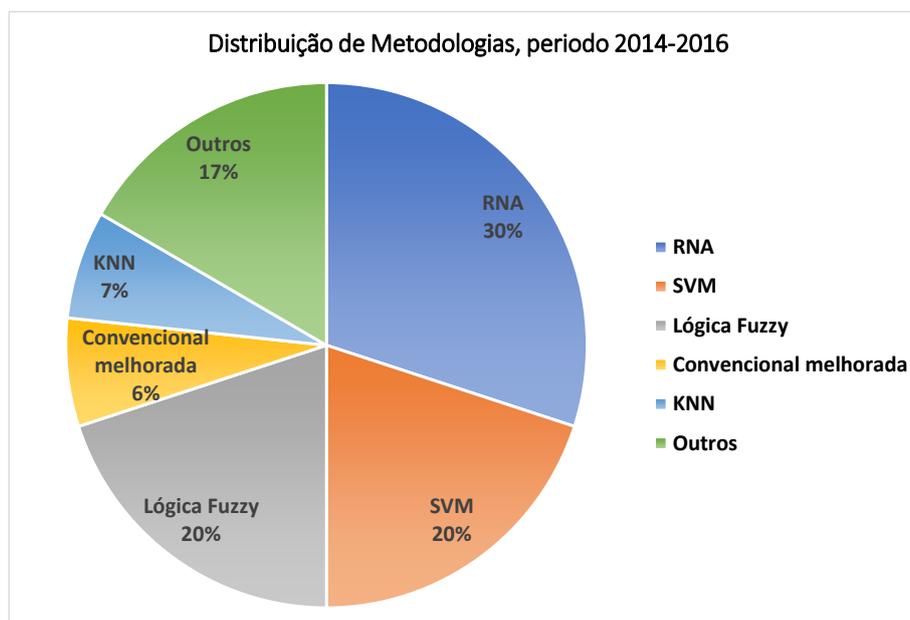
6	2014- [67]	3674	1575	98,00 %	SMOTEBoost e bootstrap: em técnicas de IA(SVM) se registra o melhor desempenho.
7	2014- [68]		77	89,00 %	RNA(BP): aplicado em metodologia IEC 60599.
8	2014- [69]	280	70	81,43 %	RNA (INN) com combinação de 5 conteúdos de gases.
9	2014- [70]		117	98,00 %	4 conteúdos relativos e 6 combinações de relações de gases são usadas na geração de regras de classificação.
10	2015- [71]	150	50	91,57 %	Usa PCC e PCA para selecionar dados relevantes e RNA(BP) na classificação final.
11	2015- [72]	81	36	91,45 %	RNA(BP): aplicado com método de Duval.
12	2015- [73]	92	36	85,31 %	RNA(BP): aplicado em combinação de critérios convencionais (ROG e DOR).
13	2015- [74]		237	93,67 %	RST no pré-processamento de dados, e lógica FUZZY na extração de regras de classificação.
14	2015- [75]	120	51	99,42 %	RapidMiner (PCA): aplicado na seleção ótima de variáveis de entrada e RNA(ELM) no diagnóstico.
15	2015- [76]		320	79,38 %	Regras de ROG (4 relações) e IEC reestruturado: melhor desempenho é registrado em método de ROG.
16	2015- [77]		166	60,00 %	Tomada de decisão multicritério, por relações intuitivas FUZZY, sobre 4 critérios convencionais.
17	2015- [78]		350	60,00 %	IB é aplicado na classificação, e entropia na avaliação dos atributos dos dados.
18	2016- [79]		61	75,00 %	Lógica FUZZY: aplicado em 4 relações de gases (entrada de IEC + C2H6/CH4).
19	2016- [80]		150	84,00 %	FUZZY: aplicado em combinação de critérios convencionais (IEC, ROG, DOR, CO2/CO e CIGRE), melhor desempenho em ROG (84 %).
20	2016- [81]	120	72	98,53 %	5 GEPs em classificação escalonado de 6 tipos de falhas, em 360 dados de lab. A performance foi de 98,05 %.
21	2016- [82]	78	707	93,07 %	Combinação de 4 critérios convencionais (ROG, TD, IEC e GB/T 72525) e 2 técnicas de IA (RBM e RNA(BP)).
22	2016- [83]	95	77	92,21 %	6 SVM: aplicado na classificação escalonada de falhas para 7 condições do TP.
23	2016- [84]	96	25	92,00 %	2 SVM (de núcleo (1) gaussiano e (2) linear): aplicado na classificação escalonada de 4 condições do TP.
24	2016- [85]		444	98,88 %	Lógica FUZZY em combinação de TD, DOR e gás chave é aplicado.

25	2016- [86]	V-C	329	97,87 %	PSO binaria multiobjectivo: aplicado em seleção de classificadores, melhor classificador é combinação de FUZZY-KNN, RNA e SVM.
26	2016- [87]		145	93,10 %	Método relação Grey, com entropia da informação relativa é combinado os pesos objetivos e subjetivos.
27	2016- [88]	318	58	93,10 %	Geração de clusters por KMA, seguido de classificador K-NN no diagnóstico final.
28	2016- [15]	199	466	87,80 %	RNAs em critérios convencionais (DOR, ROG, CEGB, IEC, TD e gás chave) é integrado em pacote inteligente.
29	2016- [89]	118	117	87,18 %	AG é aplicado na seleção de relações de gás - ótimo e parâmetros de SVM, a saída é baseado em IEC 60599.
30	2016- [90]	120	30	96,67 %	CF: aplicado no pré-processamento de dados de treinamento e seleção de parâmetros ótimos de SVM.

Fonte: Elaborado pelo Autor

Para o diagnóstico de falhas baseado na AGD, a tarefa principal está centrada em classificação de dados, portanto implica a utilização de ferramentas que permitam a delimitação correta das condições de operação no transformador de potência. Na Figura 3.3 é ilustrada a distribuição das ferramentas, por metodologia desenvolvida, no período 2014-2016.

Figura 3.3 Distribuição de metodologias por ferramenta aplicada no diagnóstico de falhas em transformadores de potência, período 2014-2016

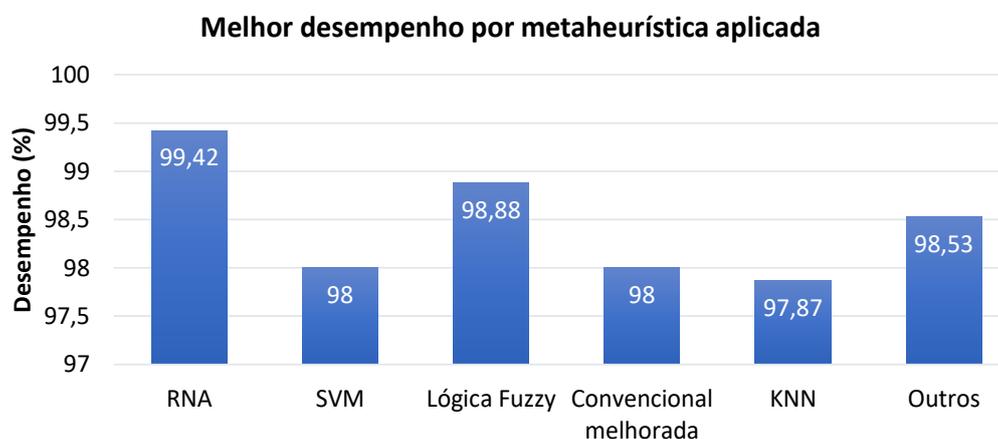


Fonte: Elaborado pelo Autor

Ainda na Figura 3.3 e Tabela 3.2 é possível informar que foram acrescentadas novas metaheurísticas no desenvolvimento de metodologias de diagnóstico de falhas incipientes no TP (cinco metaheurísticas), enquanto para metodologias orientadas a melhorar os critérios convencionais, uma assertividade superior é alcançada pela combinação das metodologias existentes ou pela proposição de novas variáveis de avaliação como adicionais das metodologias existentes.

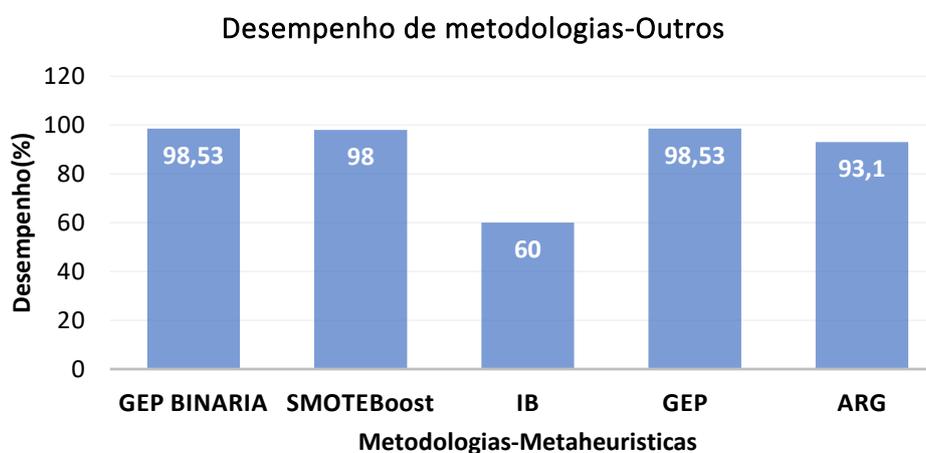
Nos artigos revisados não foram encontradas bases de dados completas (dados de treinamento/teste, desempenho em treinamento/teste), fato que não permite uma avaliação completa das metodologias desenvolvidas, porém na Figura 3.4 é ilustrado por meio de um histograma de melhores desempenhos encontrados.

Figura 3.4 Assertividade de metodologias de diagnóstico de falhas em TP (2014-2016)



Fonte: Elaborado pelo Autor

Figura 3.5 Assertividade de metodologias (Outros) de diagnóstico de falhas em TP (2014-2016)



Fonte: Elaborado pelo Autor

Comparando as Figuras 3.3 e 3.4, é observado que o desempenho para metodologias incluindo novas metaheurísticas tem uma assertividade maior (98,53 %), o qual constitui 17 % das metodologias desenvolvidas no período 2014-2016. Na Figura 3.5 é ilustrado um histograma de desempenho para metodologias agrupadas em “Outros” (novas metaheurística).

Cada artigo revisado tem uma contribuição no avanço de tecnologias em diagnóstico de falhas incipientes em transformador de potência. O histograma ilustrado na Figura 3.4 e Tabela 3.2 apresenta uma metodologia de melhor desempenho em [75]. Uma área de pesquisa muito importante e poucas vezes abordada é a seleção ótima das variáveis de avaliação.

Em [75] uma Análise de Componente Principal (*Principal Component Analysis - PCA*) é implementado no software computacional RapidMiner (versão 5.2). Isso é aplicado na seleção de variáveis de avaliação. O espaço de busca foi baseado em 20 atributos que permitiram a seleção ótima de oito variáveis mais influentes na classificação ($\%C_2H_2$, $\%CH_4$, $\%C_2H_6$, $\%H_2$, C_2H_2 / CH_4 , C_2H_2 / H_2 , C_2H_4 / C_2H_6 e CH_4 / H_2), em conjunto com uma máquina de aprendizagem extrema (em inglês, ELM) aplicada no diagnóstico de falhas.

A ferramenta matemática Máquina de Aprendizado Extremo (*Extreme Learning Machine-ELM*) é baseada em uma rede neural *Feedforward* de camada simples, sendo as condições de operação consideradas no diagnóstico como: uma condição normal e cinco condições de falha. Para 120 dados de treinamento e 51 dados de teste foi registrado um desempenho de 100 % e 99.42 %, respectivamente.

Outro trabalho de investigação com assertividade relativamente alta e com contribuição significativa é encontrado em [85]. A metodologia é baseada na aplicação de lógica fuzzy com a combinação de três critérios convencionais (Dornenburg, Triângulo de Duval e Gases Chaves). O fluxo de diagnóstico começa com a classificação de condição de operação normal por modelo de filtro IEEE fuzzy, em seguida é aplicado um diagnóstico paralelo considerando oito condições de operação aplicada em três métodos convencionais fuzzy, com um esquema de conjuntos (diagrama de Venn) aplicado em um modelo combinado fuzzy para a classificação final. Para os 444 dados de teste (incluindo operação normal e de falha) foi obtido um desempenho médio de 98,88 %.

Para metodologias orientadas a melhorar os critérios convencionais, em [70] se apresenta uma metodologia com uma assertividade alta e com uma informação significativa. O diagnóstico é baseado em regras de classificação gerados a partir de conteúdo relativo e combinação de relações de gases.

Para os 117 dados de teste é alcançado um desempenho de 98 %. O espaço da análise é ajustado em quatro conteúdos de gases (H_2 , CH_4 , C_2H_6 e C_2H_2) e seis combinações de relações de gases, sendo o fluxo de diagnóstico baseado na classificação estratificada de falhas gerais para falhas específicas. Neste caso as saídas consideradas são as condições de operação do transformador de potência para a norma IEC 60599.

3.2.3. Artigos de 2017-2019

Os artigos selecionados do banco de dados de periódicos (período 2017 até 2019) totalizam vinte nove (29). Os indicadores de avaliação e as considerações específicas para as metodologias abordadas estão resumidos na Tabela 3.3.

Tabela 3.3 Quadro resumo de artigos de investigação revisadas, período 2017-2019

Nº	[Ano-Art.]	Dado Treino	Dado Teste	Desempenho	Metodologia Aplicada e Comentários
1	2017- [91]	350	51	90,00 %	Thompson Tau e agrupamento por fuzzy c é utilizado na filtração de dados, decisão por IA (FUZZY) e critérios convencionais usando FATOR DE PONDERAÇÃO.
2	2017- [92]	323	80	81,25 %	Teorema de probabilidade (TPr): aplicado na correlação de 5 gases dissolvidos e 6 condições de operação do TP, FDNM: aplicado na probabilidade condicional.
3	2017- [93]		50	98,00 %	Fator de pontuação e ponderação em combinação de critérios convencionais (ROG, DOR, IEC e TD).
4	2017- [94]	3714	928	89,20 %	RNA(DBN) multicamada: aplicada em 3 relações de gases para diagnóstico de 8 condições de falha.
5	2017- [95]		72	100 %	ARL: aplicado no diagnóstico do TP, o coeficiente é determinado para cada condição geral do TP.
6	2017- [96]		107	98,13 %	PCA: aplicado na extração de características de dados e lógica FUZZY para o diagnóstico.
7	2017- [20]		268	72,50 %	ReliefF, Laplacian Score e Fisher Score: aplicado em seleção de variáveis de entrada e K-NN no diagnóstico.

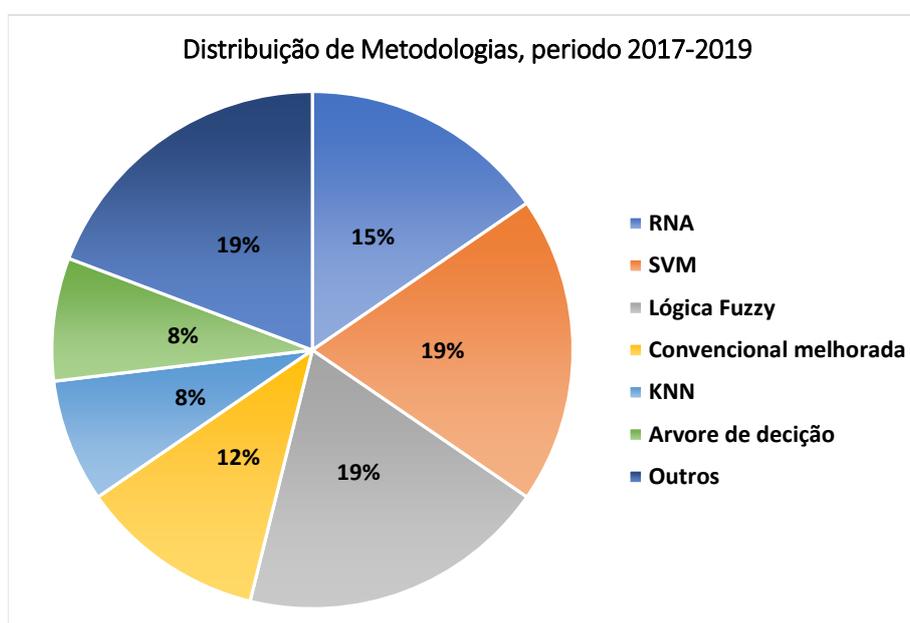
8	2017- [97]	V-C	466	95,00 %	SVM(RVM): aplicado na classificação binária em adição de ANFIS dirigido para análise por tipo de falha.
9	2017- [98]		45	86,70 %	Algoritmo fusão de informação A3S: aplicado no critério convencional (DOR).
10	2018- [99]	400	183	95,22 %	Metaheurística Bat: aplicado na otimização da estrutura da RNA, chamada Bat-BP.
11	2018- [100]		171	89,51 %	Classificador probabilístico baseado em Teorema de Bayes com EDN na difusão é aplicado no diagnóstico de falhas.
12	2018- [101]	V-C	697	84,40 %	Critérios convencionais (TD, DOR, ITR e HAE) são implementados em ANFIS, a saída é integrada por DST.
13	2018- [102]	318	58	94,82 %	Estimação de janela PARZEM: aplicado sobre cinco tipos de gases para sete condições de falha.
14	2018- [103]	105	50	92,00 %	K-NN: aplicado em entradas de TD para uma saída de 6 condições de falha, Naive bayes (baixo desempenho).
15	2018- [104]	105	50	98,00 %	PSO aplicado na otimização de parâmetros de SVM, entradas de TD, 6 saídas, K-NN (baixo desempenho).
16	2018- [105]	1000	50	84,87 %	DBN é gerado de RBMs, é aplicado com sete gases característicos, para 6 condições de falha.
17	2018- [106]	118	112	95,54 %	FUZZY Petri Nets é otimizado por algoritmo Chaotic Bat, sendo considerado 6 condições de falha.
18	2018- [107]		161	94,41 %	GA: aplicado na seleção de parâmetros ótimos de classificador SVM de função de núcleo Gaussiano.
19	2018- [108]	94	23	91,56 %	SVM de vários estágios é aplicado, considerados 6 saídas do padrão IEC 60599
20	2018- [109]	471	15	80,00 %	AD por algoritmo c4.5 de WEKA e Orange é aplicado com 7 variáveis de entrada, 9 condições de falha.
21	2018- [110]		452	89,41 %	Esquema gráfica HEPTAGONAL com 7 variáveis de entrada e 11 condições de falha.
22	2018- [111]		688	99,86 %	3 novas relações de gases é proposto para diagnóstico do TP, com 10 condições de falha.
23	2018- [112]	240	117	89,92 %	GWO é aplicado na otimização de parâmetros de ELM de função de núcleo híbrido (núcleo polinomial e base radial) – KELM, são considerados 6 condições de falha.
24	2018- [113]	95	23	84,35 %	Variáveis de entrada e parâmetros de SVM é otimizado por BQPSO, e ABC-SVM é aplicado no diagnóstico.

25	2018- [114]	162	99,38 %	AD por algoritmo c4.5 com espaço de busca de 21 atributos para 5 condições de falha.	
26	2019- [115]	85	28	85,71 %	As variáveis de entrada e parâmetros de SVM é otimizado por IKH; GA, PSO-SVM (baixo desempenho).
27	2019- [116]	383	85,42 %	Triângulo (esquema gráfica) com novas relações de gases (combinação de 5 gases), dados da norma TC10.	
28	2019- [117]	201	89,00 %	FCM é aplicado na medida de similaridade de dados por classe, para realizar a classificação.	
29	2019- [118]	496	100	83,00 %	Pentágono (esquema gráfica) em zonas de superposição é aplicado MLP-FUZZY, método de combinação de relações de gases. Diagnostico por FUZZY.

Fonte: Elaboração próprio

A distribuição de metodologias por ferramenta aplicada no período 2017-2019 é ilustrada na Figura 3.6.

Figura 3.6 Distribuição de metodologias por ferramenta aplicada no diagnóstico de falhas em transformador de potência, período 2017-2019



Fonte: Elaborado pelo Autor

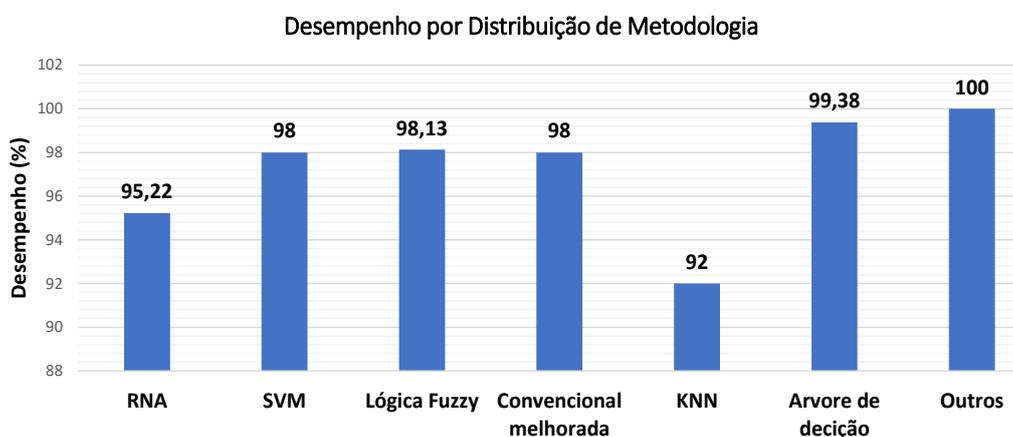
Aplicação de técnicas inteligentes para o diagnóstico de falhas em transformadores, no período 2017-2019, tem uma distribuição marcada pela aplicação de novas metaheurísticas de inteligência artificial (consideradas como *outros* na Figura 3.6). Entretanto as metodologias voltadas em melhorar os critérios convencionais tentam

fundir os critérios existentes ou incorporar novas variáveis de avaliação, de forma a ponderar com mais eficiência as relações entre gases específicos.

Por outro lado, na Tabela 3.3 é observado que as abordagens tradicionais de inteligência artificial (classificadores) como RNA, K-NN e SVM foram incorporando novos grupos de metaheurística (otimizadores) como IKH, CF, BQPSO, GWO, entre outros que permitiram a seleção ótima dos parâmetros do próprio classificador ou otimizar os dados disponíveis na tarefa do diagnóstico.

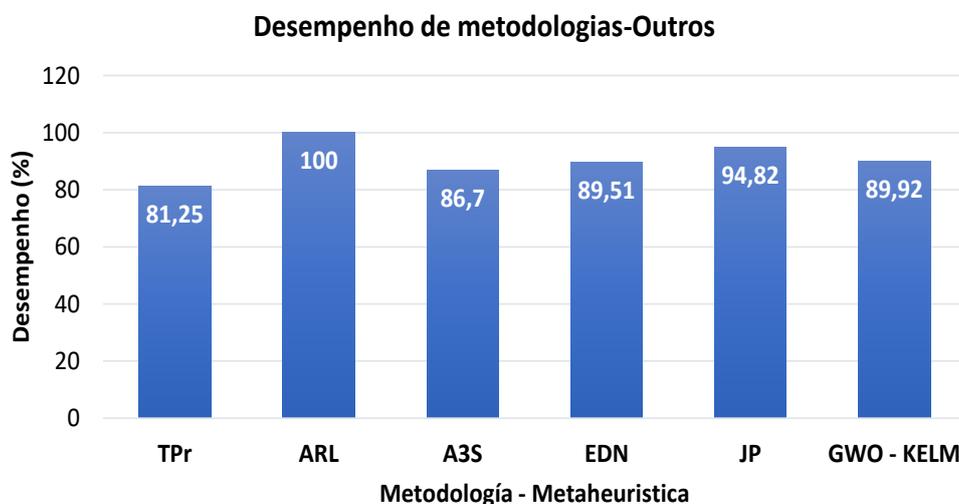
Na Figura 3.7 é ilustrado um histograma dos melhores desempenhos para metodologias baseadas em técnicas de inteligência artificial (classificadores) e metodologias orientadas a melhorar critérios convencionais no período 2017-2019.

Figura 3.7 Assertividades de metodologias de diagnóstico de falhas em TP (2017-09/2019)



Fonte: Elaborado pelo Autor

Figura 3.8 Assertividades de metodologias (Outros) de diagnóstico de falhas em TP (2017-09/2019)



Fonte: Elaborado pelo Autor

Ainda na Figura 3.7 são ilustradas as estratégias de diagnóstico de falhas que obtiveram maior assertividade, pertencentes ao grupo de metodologias no qual é incluído novas metaheurísticas de inteligência artificial (*Outros*, na Figura 3.7). De forma a facilitar a visualização dos indicadores quantitativos dos classificadores desenvolvidos, o histograma de desempenho no processo de teste por metaheurística agrupado em *Outros* é ilustrado na Figura 3.8.

Entre as metodologias analisadas no período 2017-2019 é possível encontrar em [95] uma técnica estatística para resolver problemas de superposição de condições de falha no transformador, com a aplicação de uma análise de regressão para exploração da relação linear de gases falha e tipo de falha, de forma a obter um coeficiente de correlação que é usado no diagnóstico.

O modelo de regressão é desenvolvido individualmente para cada condição de falha (falhas térmicas, elétricas e casos não identificados). A validação da metodologia é proposta para 72 dados de teste, no qual 12 casos contêm superposição de falhas. O desempenho registrado é de 100 %.

Já em [114] é aplicado uma máquina de aprendizagem baseada em árvore de decisão. Uma vantagem na metodologia de árvore de decisão é no processo de validação, em que os parâmetros finais do processo de treinamento podem ser interpretados como regras de diagnóstico de fácil entendimento. Já os critérios de seleção para melhorar a divisão de dados de entrada (21 atributos) é baseado na entropia, ganho de informação e razão de ganho que são implementados no algoritmo c4.5 do software computacional *SIPINA*, que permitiu a extração máxima das informações disponíveis por classe (cinco condições de operação do transformador de potência), para 162 dados de teste é registrado um desempenho de 99,38 %.

Por outro lado, dentro de metodologias orientadas a melhorar os critérios convencionais, em [93] é encontrado uma proposta significativa: com 50 dados de teste é alcançado um desempenho de 98 %. A metodologia é baseada em quatro critérios convencionais (método de Rogers, Dornenburg, IEC e Triângulo Duval) que permitem obter um índice de pontuação e/ou ponderação para cada tipo de falha. No processo de avaliação do método proposto, cada metodologia é ponderada com um fator específico, logo o fluxo de classificação começa com a avaliação por critérios convencionais e

quando apresenta conflito de classificação são aplicados tanto a pontuação quanto a ponderação proposta.

Em [111] é abordada uma metodologia de diagnóstico, o qual considera três novas relações da combinação de cinco conteúdo de gases (etano, etileno, hidrogênio, acetileno e metano) como variáveis de avaliação, enquanto a saída é limitada em 10 condições de falha. No processo de validação para 688 dados de teste foi registrado um desempenho de 99,86 %, enquanto para dados obtido da norma TC10 foi registrado um desempenho de 91,3 %.

3.3. Conclusão do capítulo

Como forma de concluir e fornecer uma análise dos assuntos discutidos no capítulo é possível resumir que foram encontradas duas metodologias de técnicas de inteligência artificial no diagnóstico de falhas com um desempenho de 100 %, tanto no processo de treinamento como de teste [10] [95]. Todavia, o número limitado de dados reais e independentes no processo de validação não permite a generalização das metodologias desenvolvidas.

Não obstante, em abordagens orientadas a melhorar os critérios convencionais de diagnóstico de falhas foi encontrado um desempenho de 98 % [70] [93], porém devido ao limitado número de dados de teste, não é possível generalizar esta alta assertividade. Contudo, a melhoria no diagnóstico com critérios convencionais é encontrada na inserção de novas variáveis de entrada que permitiram melhorar a caracterização de um conjunto de dados representativos de uma determinada condição de falha.

Durante o período 2017-2019 foi encontrado em alguns artigos a inserção de um número considerável de algoritmos de otimização (IKH, BQPSO, GWO, AG entre outros), como uma alternativa para melhorar a seleção ótima dos parâmetros de classificação para as metodologias baseadas em técnicas de inteligência artificial tradicional como RNA, SVM, K-NN e outros.

Nos artigos [66] [75], foi abordado o uso de software computacional *RapidMiner* como uma plataforma de seleção de melhores variáveis de entrada para tarefas de diagnóstico de falhas (desempenho acima de 98 % para 51 dados de teste). O número limitado de dados de teste não permite generalizar a metodologia, porém abre uma nova

linha de investigação para melhorar a assertividade e generalização no diagnóstico de falhas por seleção ótima de variáveis de entrada.

Segundo a literatura revisada, o critério de classificação das condições de falha mais abordado no período de investigação (2011-2019) é baseado na norma IEC 60599, logo os dados disponíveis são relativos a essa norma.

4 - TÉCNICAS DE IA APLICADAS AO DIAGNÓSTICO DE FALHAS

4.1. Introdução

Em decorrência das considerações referidas à revisão bibliográfica de artigos no período 2011-2019, é importante enfatizar alguns aspectos que podem permitir o desenvolvimento de uma metodologia de alta assertividade e generalizável para o diagnóstico de falhas incipientes em transformadores de potência.

No caso de metodologias orientadas a melhorar os critérios convencionais foram realizadas por reformulação parcial ou total de variáveis de avaliação ou por operação conjunta dos critérios convencionais, em termos de desempenho os indicadores quantitativos reportadas são superiores aos critérios convencionais padronizados em normativas internacionais. Todavia, os dados usados na avaliação (na maioria) são pequenas amostras que não permitem generalizar a metodologia desenvolvida, este inconveniente pode ser visto claramente em [111], em que a assertividade registrada é alta para um conjunto de dados específico (688), porém para dados extraídos de TC10 o nível de assertividade é menor (de 99.86 % a 91.3 %, respectivamente).

Já em metodologias desenvolvidas a partir de técnicas de inteligência artificial, foi observado que uma boa seleção de variáveis de entrada, associado a uma adequada ferramenta de classificação permite desenvolver uma metodologia de diagnóstico de falhas incipientes em transformadores de potência de alta assertividade e generalizável.

Um aspecto importante da revisão bibliográfica (tanto em metodologias baseadas em técnicas de inteligência artificial como nas direcionadas a melhorar os critérios

convencionais) é o uso quase universal das variáveis de saída estabelecidos na norma IEC 60599.

Sob estas considerações, uma metodologia de diagnóstico de falhas incipientes em transformadores de potência de alta assertividade e generalizável tem que ser implementada segundo o diagrama gráfico ilustrado na Figura 4.1.

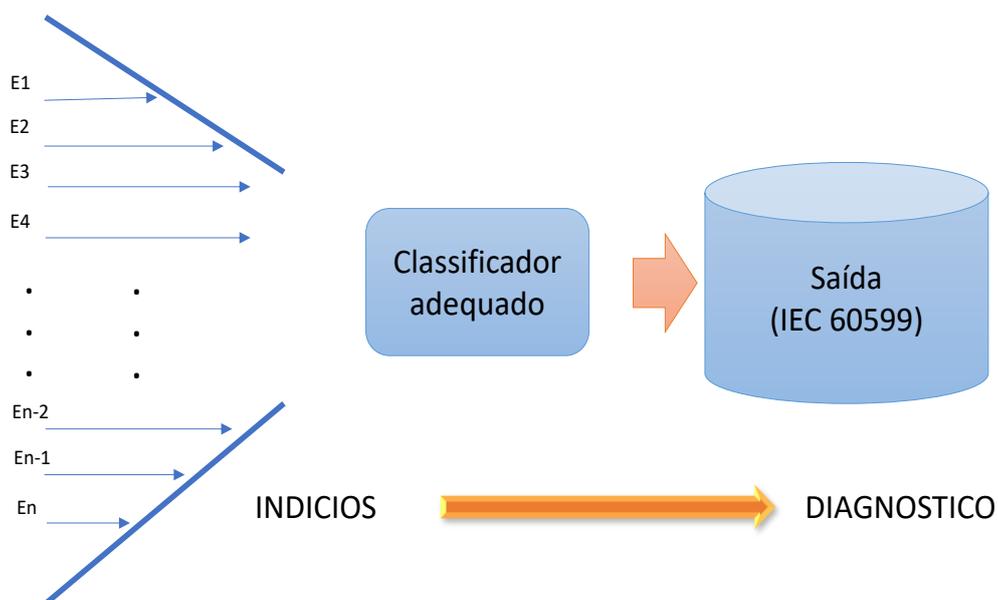
Figura 4.1 Diagrama gráfico de diagnóstico de falhas em transformadores de potência



Fonte: Elaborado pelo Autor

Na literatura revisada foi encontrada uma importante quantidade de variáveis de avaliação que foram surgindo como resultado de reformulação das metodologias de diagnóstico de falhas (tanto para metodologias orientadas a melhorar critérios convencionais como para metodologias baseadas em técnicas de IA), quando analisadas da perspectiva de falha/diagnóstico, todas as variáveis de avaliação são direta ou indiretamente indício de uma condição de falha no transformador (Figura 4.2).

Figura 4.2 Diagrama indício-diagnóstico de transformadores de potência



Fonte: Elaborado pelo Autor

Nesse contexto se pretende encontrar as melhores variáveis de avaliação para garantir a melhor caracterização dos dados, a qual permita uma classificação com uma alta assertividade e generalizável. Esta tarefa já foi realizada por inserção das metaheurísticas como algoritmos genéticos, colônia de formigas, cardume de peixes entre outros, que permitiram uma classificação superior das abordagens tradicionais [66]. Com objetivo de encontrar as variáveis de avaliação com melhores características de agrupamento, nesta dissertação será implementado o algoritmo Otimização de Enxame de Partículas Binária (BPSO) na classificação do classificador da vizinhança mais próxima (*k- nearest neighbor*).

Na tarefa de classificação foi encontrada uma quantidade importante de classificadores (na literatura revisada). A metodologia baseada em redes neurais artificiais RNA segue sendo uma abordagem bastante comum e aceita na comunidade científica, sendo desenvolvidas uma diversidade de arquiteturas com objetivo de alcançar desempenhos altos. Porém uma metodologia de alta assertividade e generalizável segue sendo um problema aberto, logo com o objetivo de aproveitar as variáveis de melhor agrupamento que serão extraídas do algoritmo BPSO/K-NN.

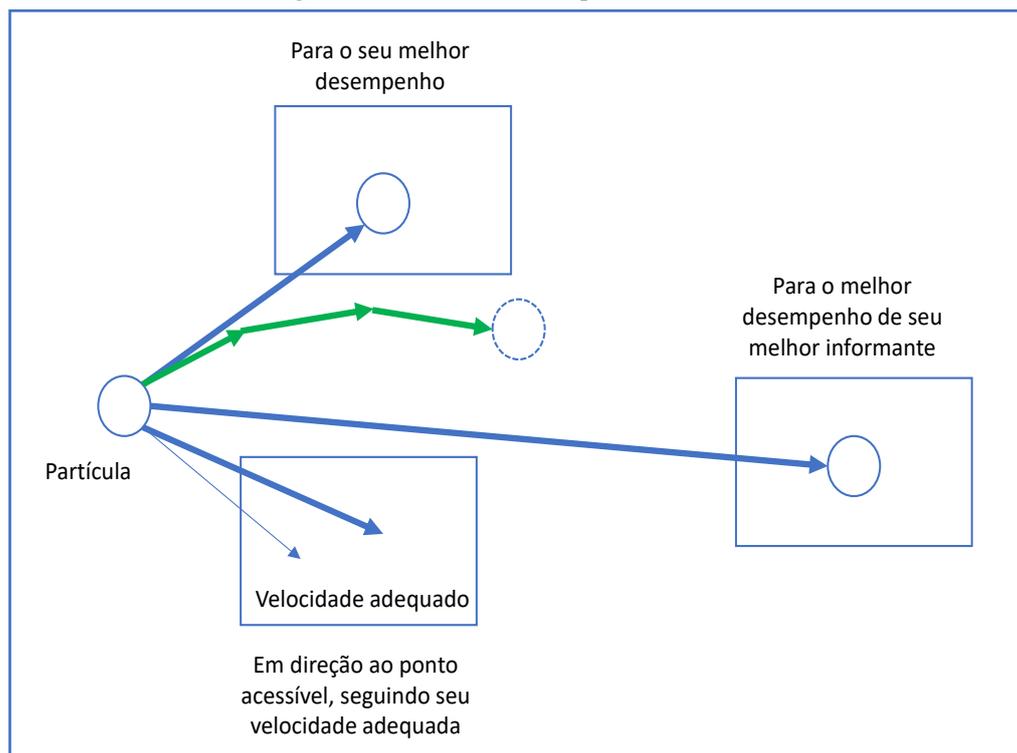
Neste trabalho é implementado um algoritmo para o diagnóstico de falhas em transformadores de potência, com configuração em cascata usando redes neurais artificiais (RNA). Adicionalmente, o classificador K-NN com distância de classificação ponderada é implementado e simulado para fins de comparação.

Por outro lado, as condições de operação no transformador de potência são ajustadas conforme estabelecido na norma IEC 60599. Esta decisão é baseada pela ampla aplicação em artigos (disponibilidade de dados) e uma adequada classificação das condições de operação no transformador de potência.

4.2. Binary Particle Swarm Optimization (BPSO)

O algoritmo de Otimização de Enxame de Partícula (*Particle Swarm Optimization* - PSO) é uma metaheurística de inteligência artificial baseada no conceito de que “*uma população de partículas se movimenta de ponto A para o ponto B, o melhor caminho adotado por uma partícula x é alcançado sobre a informação precedente da mesma partícula e o melhor desempenho das partículas da vizinhança*” [119], cujo comportamento do deslocamento das partículas pode ser ilustrado por meio da Figura 4.3.

Figura 4.3 Deslocamento de partículas em PSO



Fonte: Adaptado de [120]

Ainda na Figura 4.3, os três elementos fundamentais para o cálculo do próximo deslocamento de uma partícula são, a própria velocidade, a direção e o melhor desempenho e/ou melhor desempenho do melhor informante. A interpretação deste comportamento de partículas é estabelecida em relações matemáticas iterativas, que ao longo do tempo permitiram otimizar muitas tarefas complexas na engenharia.

O PSO foi proposto por Eberhard e Kennedy em 1995 [121] [122], contudo ao longo do tempo o algoritmo foi utilizado em diversas aplicações especiais que permitiram obter resultados ótimos em tarefas específicas. Um abordagem de maior aplicabilidade é a versão binária de PSO que foi proposta pela primeira vez em 1997 [123], sendo apresentado da seguinte forma: assumindo que existem um grupo de partículas em um espaço d -dimensional, cada partícula é uma solução potencial do problema de otimização. Já no PSO clássico, o grupo de partículas localizado em $x_i = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{id})$, $i = 1, 2, 3, \dots, m$ se desloca considerando o histórico de melhor desempenho individual $P_{besti} = (p_{i1}, p_{i2}, p_{i3}, \dots, p_{id})$ e o melhor desempenho global $g_{best} = (g_1, g_2, g_3, \dots, g_d)$ ajustado desde a função de otimização, logo a taxa de atualização do grupo de partículas $v_i = (v_{i1}, v_{i2}, v_{i3}, \dots, v_{id})$ é estabelecido como:

$$v_i^d(t+1) = wv_i^d(t) + c_1r_1(P_{best_i}^d(t) - x_i^d(t)) + \dots \quad (4.1)$$

$$\dots + c_2r_2(g_{best}^d(t) - x_i^d(t))$$

Em que:

- w : peso de inércia
- c_1, c_2 : fatores de aceleração
- r_1, r_2 : número aleatório independente entre 0-1
- t : número de iterações

Na equação 4.1, é possível notar que a velocidade tem limites v_{max} e v_{min} . No contexto do BPSO esta velocidade se torna uma probabilidade de selecionar a variável ideal para limitar uma saída binária (0, 1). Em [124] é sugerida a atualização do deslocamento de um grupo de partículas baseados na função sigmoide. A atualização do algoritmo BPSO é realizada como segue:

$$s(v_i^d(t+1)) = \frac{1}{1 + e^{-v_i^d(t+1)}} \quad (4.2)$$

$$x_i^d(t+1) = \begin{cases} 1, & \text{sim aleatório (rand) } < s(v_i^d(t+1)) \\ 0, & \text{caso contrário} \end{cases} \quad (4.3)$$

Em que:

- $rand$: número aleatório eventualmente distribuído entre 0 e 1.

Considerando F , p_{best} e g_{best} como função de minimização, como melhor posição individual e como melhor posição global respectivamente, o processo iterativo do algoritmo BPSO é atualizado como:

$$P_{best_i}(t+1) = \begin{cases} x_i(t+1), & \text{if } F(x_i(t+1)) < F(P_{best_i}(t+1)) \\ P_{best_i}(t), & \text{caso contrário} \end{cases} \quad (4.4)$$

$$g_{best}(t+1) = \begin{cases} P_{best_i}(t+1), & \text{if } F(P_{best_i}(t+1)) < F(g_{best}(t)) \\ g_{best}(t), & \text{caso contrário} \end{cases}$$

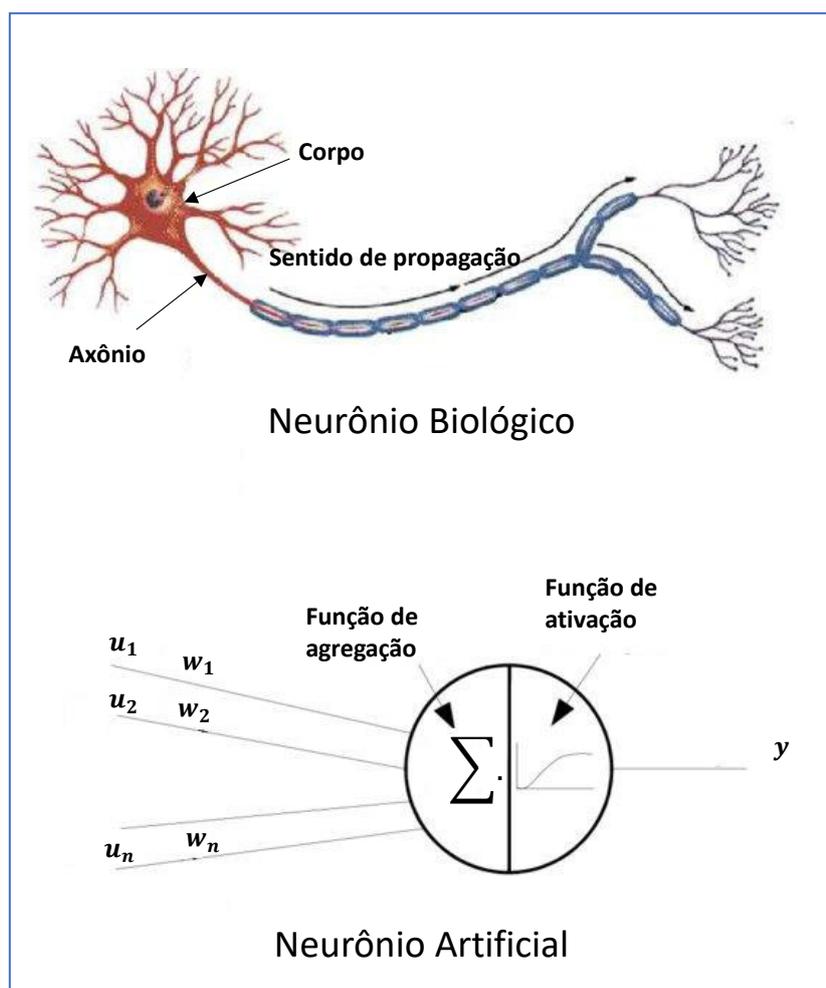
O critério de parada ou de convergência para o algoritmo BPSO é estabelecido de acordo com a aplicação específica.

O algoritmo de otimização de enxame de partículas binária BPSO, desde a descrição funcional tem grandes potencialidades na exploração de resultados ótimos em processos complexos e é de fácil implementação.

4.3. Redes Neurais Artificiais (RNA)

Rede neural artificial (RNA) é uma técnica de inteligência artificial utilizada como um modelo de máquina de aprendizado para classificação, reconhecimento, regressão, otimização, entre outras tarefas específicas de mineração de dados. O desenvolvimento da RNA foi baseado no funcionamento dos neurônios no cérebro humano, logo para uma melhor visualização, uma comparação da rede neural biológica do cérebro humano e a formulação da rede neural artificial é ilustrada na Figura 4.4.

Figura 4.4 Esquemas de neurônios biológico e artificial



Fonte: Adaptado de [125]

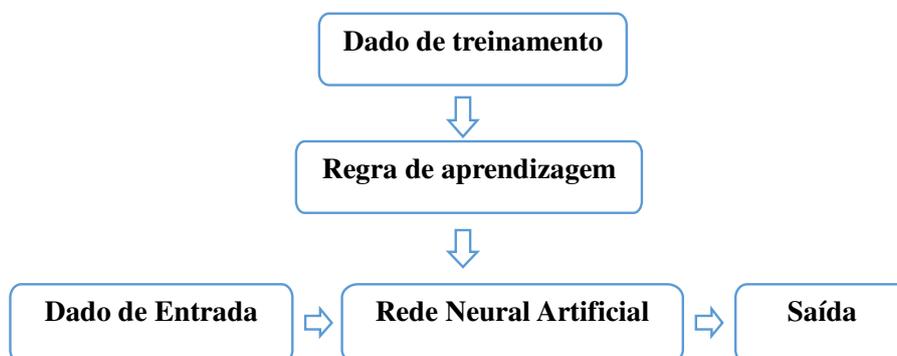
O desenvolvimento das RNAs foram marcados por três acontecimentos importantes, o primeiro foi marcado pelo desenvolvimento do trabalho que iniciou o uso das redes neurais artificiais efetuado por McCulloch e Pitts em 1940, a seguinte etapa foi a discussão do teorema de convergência do Perceptron de Roseblatt, assim como das limitações de Perceptron simples realizada por Minsky e Papert em 1960. Finalmente nos

anos 1980 foram desenvolvidas as principais partes funcionais da rede neural artificial (abordagem de energia Hopfield, algoritmo de aprendizagem *back-propagation*, entre outros) [126]

4.3.1. RNA como Máquina de Aprendizado

Rede neural artificial é a composição de funções não lineares de dois ou mais neurônios conectados entre si [127]. As principais aplicações da RNA foram desenvolvidas para tarefas de mineração de dados para reconhecimento e classificação de padrões complexos sem muito conhecimento do processo, todavia para entender o desempenho da RNA em interação com máquina de aprendizado é necessário considerar a configuração ilustrada na Figura 4.5 [128].

Figura 4.5 Máquina de aprendizagem profundo versus rede neural artificial RNA



Fonte: Adaptado de [128]

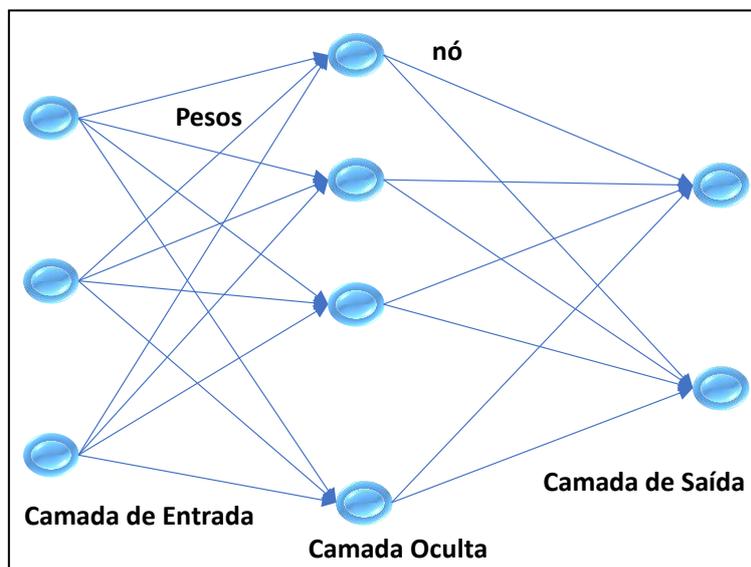
O desempenho da RNA (Figura 4.5) é determinado pelo número dados de treinamento, regra de aprendizado, seleção de dados de avaliação (entrada) e a consideração das condições de classificação (saída). Na comunidade científica o desenvolvimento de metodologias a partir de mineração de dados para aplicação industrial é realizado baseado principalmente usando uma rede neural artificial, chamada de Perceptron Multicamada (*Multi Layer Perceptron - MLP*). Na literatura revisada sobre diagnóstico de falhas incipientes em transformadores de potência, a MLP é amplamente utilizada devido a capacidade de precisão e desempenho em problemas de modelagem numérica [68].

4.3.2. Perceptron Multicamada (MLP)

Relembrando, o MLP é uma rede básica da RNA e amplamente utilizada em tarefas de classificação, sendo definida como multicamadas devido a arquitetura da rede

conter um número sucessivo de camadas, em que cada uma tem um número finito de unidades de processamento chamadas de neurônios (Figura 4.6).

Figura 4.6 RNA (MLP) de três camadas



Fonte: Elaborado pelo Autor

Pode ser observado que o número de neurônios nas camadas de entrada e saída é determinado pelo número de variáveis de entrada e a condição de classificação proposta para uma tarefa específica, enquanto o número de neurônios para a camada oculta é determinado de forma aleatória ou usando alguma ferramenta de otimização que permita atingir os objetivos procurados [132].

4.3.3. Regra de Aprendizado da RNA

Seguindo a análise sob perspectiva da interação da RNA como máquina de aprendizado, a eficiência da RNA é também determinada pela regra de aprendizado, ou seja, a abrangência e velocidade de convergência do erro médio quadrático (*Mean Square Error - MSE*), dado por:

$$MSE(x) = (a - y(k))^t (a - y(k)) \quad (4.5)$$

Em que:

- x : Vetor de peso sináptico (variável incógnita)
- a : Saída desejada
- y : Saída na iteração k

No processo de treinamento, o MSE da RNA é ajustado para uma precisão de erro definida pelo usuário. Esse ajuste é possível atualizando a variável desconhecida (pesos sinápticos e bias) que garante a classificação correta dos dados. Em termos matemáticos, a regra de aprendizado da RNA pode ser vista como um problema de otimização [126].

As principais regras de aprendizagem utilizadas no desenvolvimento de novas metodologias a partir de mineração de dados são: Gradiente Descendente, Gradiente Conjugado, Método Newton e Levenbert-Marquadt.

Em diagnóstico de falhas incipientes em transformadores de potência, no contexto atual, a prioridade é desenvolver uma metodologia de alta assertividade, portanto a regra de aprendizagem deve ser de alta abrangência. Desta forma, neste trabalho foi implementado as regras de atualização por gradiente descende (*Back Propagation* (BP) com taxa de aprendizado variável), conforme pode ser observado na Tabela 4.1.

Tabela 4.1 Regras de aprendizagem, gradiente descendente de RNA

Nome do algoritmo	Regra de aprendizagem
BP standard	$x_{k+1} = x_k - \alpha_k g_k$
BP momento	$x_{k+1} = x_k + \gamma \Delta x_k - (1 - \gamma) \alpha s(y)^t$
BP taxa de aprendizado variável VLBP	$MSE(\alpha, \gamma, \zeta, \rho, \eta)$ $\alpha, \gamma = \text{var iavel}$ $\zeta, \rho, \eta = \text{fixo}$

Fonte: Adaptado de [126]

Da Tabela 4.1, x representa peso sináptico ou bias, α taxa de aprendizagem, g gradiente de MSE, γ coeficiente de momento, Δx variação de x na iteração prévia, s sensibilidade de BP, y dado de entrada em neurônio, ζ, ρ, η parâmetros fixos de ajuste de VLBP [126].

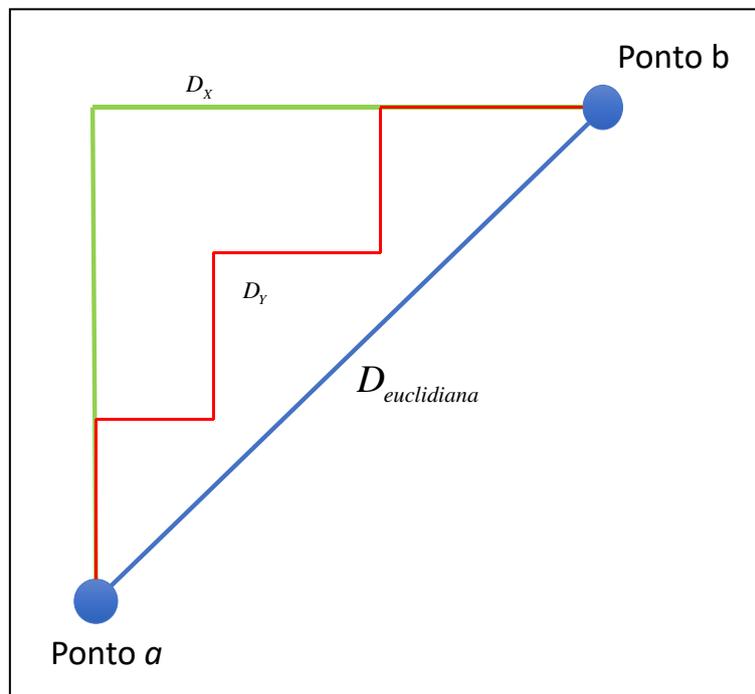
4.4. K-Nearest Neighbor (K-NN)

O K-NN é um algoritmo de mineração de dados baseado em aprendizagem supervisionada, o qual foi proposto por Fukunaga e Narendra em 1975 [129]. Este algoritmo apresenta vantagem de fácil compreensão e implementação em plataformas computacionais, podendo ser utilizado em aplicações industriais, pois pode gerar bons resultados em tarefas de classificação com dados bem caracterizados.

Especificamente, o K-NN aplicado em tarefas de classificação é baseado em critério de semelhança, portanto a distância de proximidade dos dados no espaço d -dimensional é de vital importância para a consideração dos vizinhos mais próximos. Nas metodologias desenvolvidas na comunidade científica, segundo as especificações de classificação, as semelhanças podem ser baseadas em distância euclidiana, Manhattan, Minkowski, Chebyshev e outras [130].

Das medidas de distâncias utilizadas em tarefas de classificação de dados, a distância euclidiana é geralmente a mais usada, pois tem como principal característica encontrar a distância mais curta entre dois pontos [131], como ilustrado na Figura 4.7.

Figura 4.7 Ilustração gráfica da distância euclidiana



Fonte: Elaborado pelo Autor

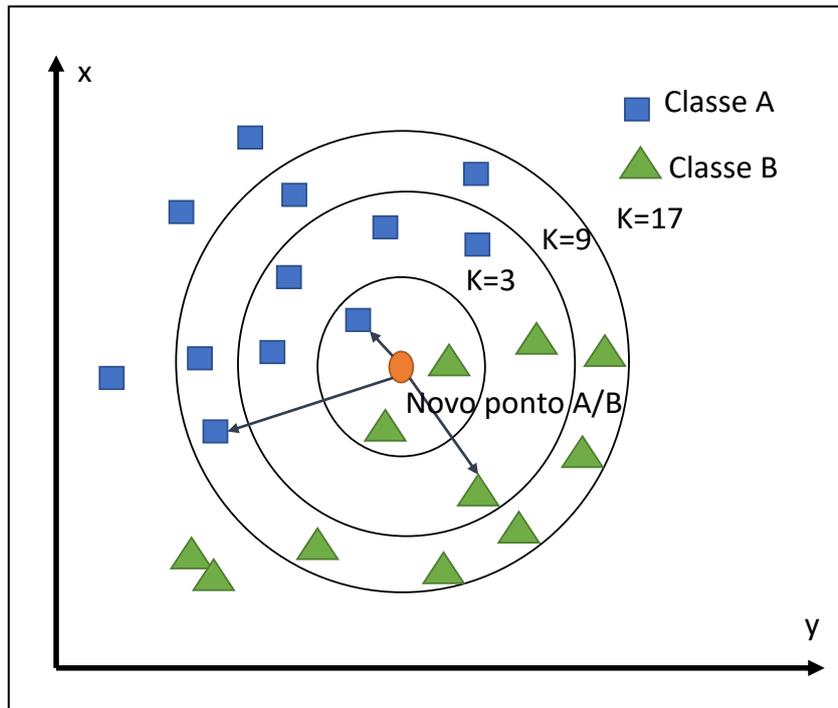
Em termos matemáticos a distância euclidiana entre dois pontos a e b no espaço d -dimensional é definida como:

$$D_d(a, b) = \sqrt{\sum_{i=1}^d (a^i - b^i)^2} \quad (4.6)$$

Portanto o classificador K-NN é um algoritmo que depende da medida de proximidade de uma instância (dados a classificar) a um conjunto de dados previamente

rotulados de uma determinada classe e o número de vizinhos mais próximos (k), conforme a Figura 4.8.

Figura 4.8 Classificação por K-NN no espaço bidimensional, para duas estados de classificação



Fonte: Elaborado pelo Autor

Ainda na Figura 4.8, o dado que se pretende classificar (círculo laranja) em um espaço bidimensional (x e y) para dois estados de classificação (A e B), os resultados para os vizinhos mais próximos $k=3$, 9 e 17 tem resultados de classificação diferentes. Generalizando, há um conjunto de dados classificados e rotulados no vetor $R = [r_1 \ r_2 \ r_3 \ \dots \ r_s]$ e considerando x uma nova instância para ser classificada em relação a k vizinhos mais próximos. Formalmente, a função de classificação discreta para x é:

$$f(x) \leftarrow \arg \max_{r \in R} \sum_{i=1}^k \delta(r, f(x_i)) \quad \begin{cases} (a=b) \Rightarrow \delta(a,b)=1 \\ (a \neq b) \Rightarrow \delta(a,b)=0 \end{cases} \quad (4.7)$$

A partir da equação 4.7, se visualiza que o critério de classificação no K-NN é determinado pelo número de vizinhos mais próximos ao subconjunto de classificação rotulado no vetor R [132]. Uma vez que a distância de proximidade dos dados é importante, uma série de modificações foram introduzidas na ponderação desta variável no classificador K-NN, de modo que:

$$f(x) \leftarrow \arg \max_{r \in R} \sum_{i=1}^k w_i \delta(r, f(x_i)) \quad \begin{cases} (a=b) \Rightarrow \delta(a,b)=1 \\ (a \neq b) \Rightarrow \delta(a,b)=0 \end{cases} \quad (4.8)$$

Em que:

w_i : variável de ponderação

A partir de (4.8) foi possível acrescentar os critérios de ponderação da distância de classificação. Em [133] foi encontrada uma ponderação clássica da distância de proximidade dada por:

$$D_{cw} = \sum_{i=k}^K \frac{1}{D_{Eu-k}^2} \quad (4.9)$$

No qual:

D_{Eu-k} : distância euclidiana

No caso em particular do classificador K-NN é importante informar que os critérios de seleção da distância de classificação e a respectiva ponderação são estabelecidos de acordo com as características da amostra e as condições de classificação.

4.5. Conclusão do capítulo

Neste capítulo foi abordado o estudo sobre o BPSO, logo de forma resumida é possível concluir que o BPSO é a versão binária do algoritmo PSO, na qual o potencial de otimização e adequação voltados a diferentes problemas de otimização, somado a simples implementação computacional são as principais características que são aproveitadas na seleção de variáveis de avaliação com melhores características de agrupamento, para o desenvolvimento de uma metodologia robusta no diagnóstico de falhas em transformadores de potência.

Já a RNA é uma máquina de aprendizado de aplicação múltipla (classificação, regressão, reconhecimento, otimização entre outras tarefas específicas de mineração de dados). A generalização e alta assertividade é determinada pelos dados de treinamento, regra de aprendizado, dados de entrada (variáveis de avaliação) e as condições de classificação. Nesta dissertação foi pretendido implementar uma metodologia de diagnóstico de falhas incipientes em transformadores de potência, sob esquema de diagnóstico em configuração cascata, usando redes neurais artificiais.

Uma vez que se pretende ter as variáveis de avaliação com boas características de agrupamento (que serão obtidas pelo algoritmo BPSO) será necessário, todavia, desenvolver um classificador K-NN com distância de classificação ponderada, com o objetivo de realizar uma comparação com proposta desta dissertação baseada em redes neurais artificiais.

5 - METODOLOGIA PROPOSTA E RESULTADOS

5.1. Introdução

O diagnóstico de falhas incipientes em transformadores de potência foi bastante abordado tanto por metodologias orientadas a melhorar os critérios convencionais como por técnicas de inteligência artificial, como indicado nos capítulos precedentes, todavia o nível de desempenho é baixo ou tem restrições na generalização devido ao número limitado de dados reais, para validação das metodologias propostas.

Especificamente, em metodologias baseadas em técnicas de inteligência artificial, é utilizado um grande número de algoritmos de classificação, porém poucas vezes é abordada a seleção de variáveis de avaliação ótimas, que segundo a literatura especializada [75] pode vir a melhorar consideravelmente em tarefas de classificação.

No desenvolvimento deste trabalho é usada a Otimização por Enxame de Partículas Binária (BPSO) aplicada no ajuste do classificador K-NN, na seleção de variáveis de avaliação com características de melhor agrupamento. Também é desenvolvida uma metodologia de diagnóstico de falhas em transformadores de potência por meio de uma Rede Neural Artificial e K-NN ($k=nearest\ neighbor$) com distância de classificação ponderada.

Nesta dissertação é proposto:

- a) Diagnóstico de falhas, sob configuração em cascata, desenhada a partir das áreas de falhas do transformador de potência (ilustrada na Figura 2.4). Usando

três redes neurais artificiais, com entradas otimizadas pelo algoritmo BPSO / K-NN

- b) Utilização do algoritmo de classificação K-NN Ponderado, que pode aproveitar perfeitamente as características de agrupamento das variáveis de entrada (selecionadas pelo algoritmo BPSO/K-NN); o qual na mesma configuração proposta é simulado para fins de comparação.

As saídas dos classificadores são estabelecidas segundo a norma IEC 60599.

5.2. Caracterização dos Dados

Os quantitativos de padrões e características de distribuição do banco de dados são importantes nas tarefas de classificação, portanto para ter uma abordagem adequada é preciso conhecer as limitações do problema que se pretende solucionar. Em diagnóstico de falhas em transformadores de potência, segundo a literatura revisada, foi identificado que os inconvenientes de baixa assertividade e generalização decorrem da limitada disponibilidade de dados.

Para atender os propósitos estabelecidos nesta dissertação, foi utilizada um banco de dados resultante da inspeção de 311 transformadores de potência, para desenvolver uma metodologia de diagnóstico de falhas. Estes dados foram coletados baseado no padrão de falhas expresso na norma IEC 60599, logo são considerados cinco conteúdos de gases relacionados diretamente com cinco condições de falha do transformador. A distribuição dos dados por tipo de falha é relacionada na Tabela 5.1.

Tabela 5.1 Dados de conteúdo de gases no TP

Tipo de falha	N° de casos inspecionados
Descarga parcial (PD)	29
Descarga de baixa energia (DL)	37
Descarga de alta energia (DH)	101
Falha térmica $T < 300^{\circ}\text{C}$ (T1)	77
Falha térmica $300^{\circ}\text{C} < T < 700^{\circ}\text{C}$ (T2)	67

Fonte: Adaptado de [10]

Uma vez desenvolvida a metodologia, se pretende efetuar o processo de validação por meio dos dados coletados a partir da revisão dos artigos de investigação durante o período 2011-2019, em que se obtiveram 130 casos inspecionados pela norma IEC 60599. Na Tabela 5.2 é ordenado a distribuição de dados por falhas.

Tabela 5.2 Dados de conteúdo de gases no TP extraídos da revisão bibliográfica

Tipo de falha	Nº de casos inspecionados
Descarga parcial (PD)	18
Descarga de baixa energia (DL)	27
Descarga de alta energia (DH)	36
Falha térmica $T < 300^{\circ}\text{C}$ (T1)	22
Falha térmica $300^{\circ}\text{C} < T < 700^{\circ}\text{C}$ (T2)	27

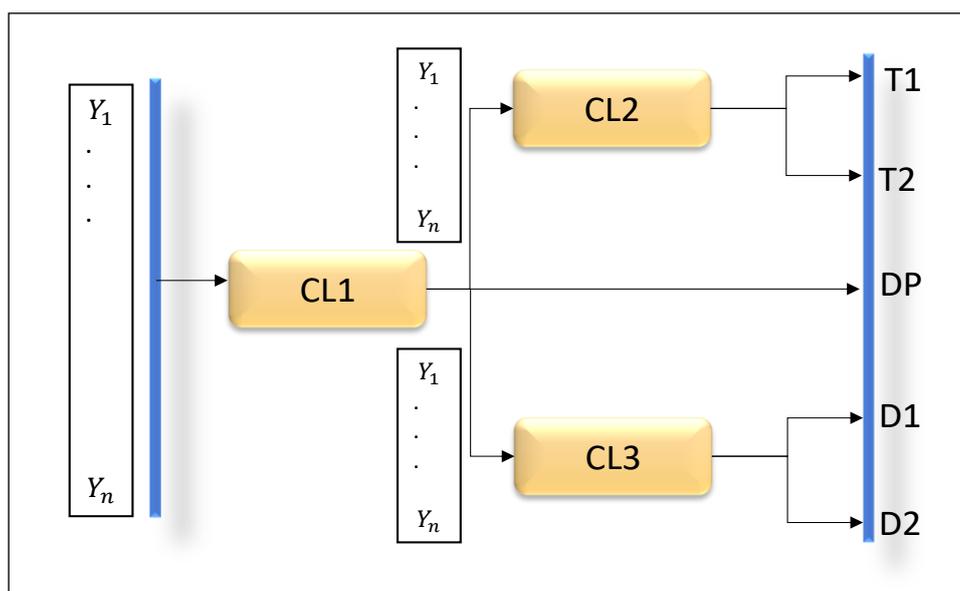
Fonte: Elaborado pelo Autor

Da base de dados disponível (Tabelas 5.1 e 5.2), as condições de falha do transformador (cinco condições) são claramente limitadas, enquanto as variáveis de entrada foram limitadas em cinco conteúdos de gases e as múltiplas combinações que se pode obter.

5.3. Arquitetura Proposta para o Diagnóstico de Falhas

Considerando o que foi estabelecido na Seção 2 do Capítulo 2 (*Análise de Gases Dissolvidos*) e especificamente na ilustração contida na Figura 2.4, é possível observar que as áreas de operação para o transformador de potência são bem diferenciadas para falhas térmicas, falhas de descarga de energia (alta e baixa intensidade) e falha de descarga parcial; portanto é proposta uma classificação em cascata, conforme a arquitetura da Figura 5.1.

Figura 5.1 Esquema de classificação geral proposto em diagnóstico de falhas no TP



Fonte: Elaborado pelo Autor

Nessa proposta, a arquitetura de diagnóstico de falha contém três (3) classificadores que permitem o diagnóstico adequado, sendo as funções definidas da seguinte forma:

O classificador CL1 é proposto como o principal, logo a função é classificar em três condições de falha do transformador de potência, sendo estas condições a falha térmica (T1 e T2), descarga de energia (D1 e D2) e descarga parcial. Já os classificadores CL2 e CL3 são propostos para trabalhos de classificação em uma área de falhas do transformador de potência quando há superposição dos dados.

Em tarefas de classificação por meio de técnicas de inteligência artificial um fator importante é a seleção ótima das variáveis de avaliação. Esta etapa também foi desenvolvida para ser aplicada para se estabelecer uma metodologia de alta assertividade e com altas possibilidades de generalização.

5.4. Seleção de Variáveis de Avaliação Ótimas

5.4.1. Variáveis de Entrada

Na literatura revisada no período 2011-2019, foi observado que as variáveis de entrada aplicadas tanto para metodologias baseadas em técnicas de inteligência artificial quanto em metodologias orientadas a melhorar critérios convencionais, ambas estão estreitamente orientadas por normas internacionais como IEC, IEEE, CGBT entre outras. Porém na investigação realizada foram agregadas algumas relações de gases com objetivo de melhorar metodologias propostas. Nesse contexto foram coletadas 59 variáveis, as quais estão relacionadas às condições de falhas, observadas nos transformadores de potência (Anexo 1).

As variáveis de entrada obtidas, foram classificadas em três grupos: o primeiro grupo é denominado de variáveis percentuais (VP) que é caracterizado pela natureza percentual de conteúdo em relação aos gases. O segundo grupo é denominado como variáveis altamente distribuídas (VAD) devido à distribuição dos dados e finalmente o terceiro grupo, formado pelas variáveis normalizadas entre 0 e 1, e denominadas de variáveis (VN01).

Em mineração de dados, uma tarefa importante é o pré-processamento de dados. Nessa etapa é realizada a normalização dos dados, sendo eliminados alguns ruídos e pontos atípicos [128]. Seguindo esta premissa, o grupo de dados prioritário é focado nas

variáveis de avaliação agrupadas em VN01. Caso o propósito não seja atingido, a tarefa de classificação também pode ser trabalhada com os dados agrupados em VAD e VP.

Sendo extensa a descrição da formulação química das combinações de gases (símbolos químicos), em análises posteriores o conteúdo de gases será codificado conforme a tabela 5.3.

Tabela 5.3 Codificação de conteúdo de gases

item	Conteúdo de gás	Símbolo químico	Codificação
1	Hidrogênio	H_2	a
2	Metano	CH_4	b
3	Acetileno	C_2H_2	c
4	Etileno	C_2H_4	d
5	eteno	C_2H_6	e
6	Mistura de gases	$CH_4 + C_2H_2 + C_2H_4$	f
7	Mistura de gases	$H_2 + CH_4 + C_2H_2 + C_2H_4 + C_2H_6$	g
8	Mistura de gases	$H_2 + CH_4 + C_2H_2 + C_2H_4$	h
9	Mistura de gases	$H_2 + C_2H_2 + C_2H_4$	j

Fonte: Elaborado pelo Autor

Na Tabela 5.3, o conteúdo de gases é codificado por letras do alfabeto, por exemplo, Hidrogênio (H_2) - “a”. Portanto, em análises posteriores, o conteúdo de gases será indicado pelo código alfabético.

5.4.2. Seleção de Variáveis por BPSO/K-NN

O algoritmo BPSO aplicado na seleção de variáveis de entrada ótimas é ajustado pelo algoritmo de classificação K-NN. Os parâmetros de ajuste do algoritmo de seleção BPSO/K-NN são dados na Tabela 5.4.

Tabela 5.4 parâmetros de BPSO/K-NN

Algoritmo	Variáveis de implementação
BPSO	$V_{max}=6, V_{min}=6$ $W_{max}=0.9, W_{min}=0.4$ $C_1 = 2; C_2 = 2$ Partículas(N)=10; Número de iterações (T)=100
K-NN	Vizinhos mais próximos (k)=5 Validação cruzada (vc)=10

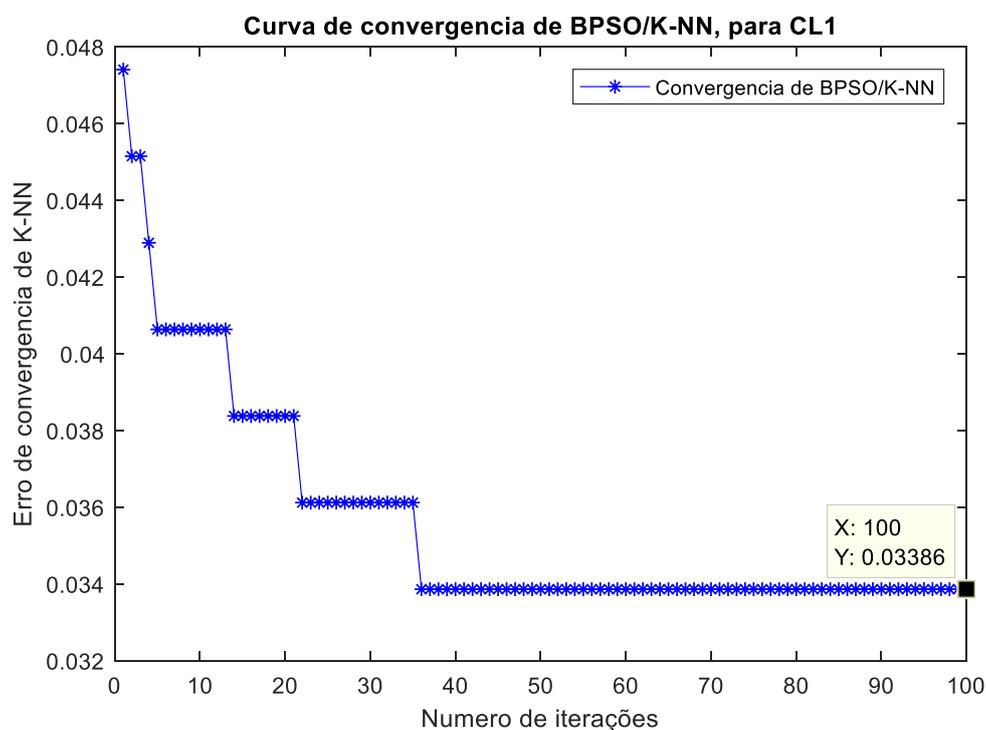
Fonte: Elaborado pelo Autor

Relembrando, o grupo de variáveis de avaliação prioritizada neste processo de seleção foi o grupo de variáveis cujo intervalo de normalização está entre 0 e 1, portanto um total de 13 entradas agrupadas em VN01. Nos tópicos seguintes são selecionadas as variáveis de avaliação ótimas.

a. Classificador CL1

O processo de seleção de variáveis de avaliação para o classificador principal CL1 (encarregada da classificação de três condições de falha) foi executado em 10 repetições e os resultados foram armazenados em uma base de dados adicional, sendo na etapa final selecionadas as variáveis de melhor agrupamento que resultam do menor erro da curva de convergência do algoritmo BPSO/K-NN (Figura 5.2).

Figura 5.2 Curva de convergência de BPSO/ K-NN, para CL1



Fonte: Elaborado pelo Autor

Ainda na Figura 5.2 é ilustrado o erro de classificação para o algoritmo de seleção BPSO/K-NN, em validação cruzada de 10 instancias e $k=5$ vizinhos mais próximos, com um valor de 3.386 %. Este erro em tarefas de diagnóstico de falhas em transformador de potência pode ser considerado alto, porém o algoritmo proporciona os dados de avaliação com melhores características de agrupamento que podem ser aproveitadas perfeitamente em tarefas de classificação.

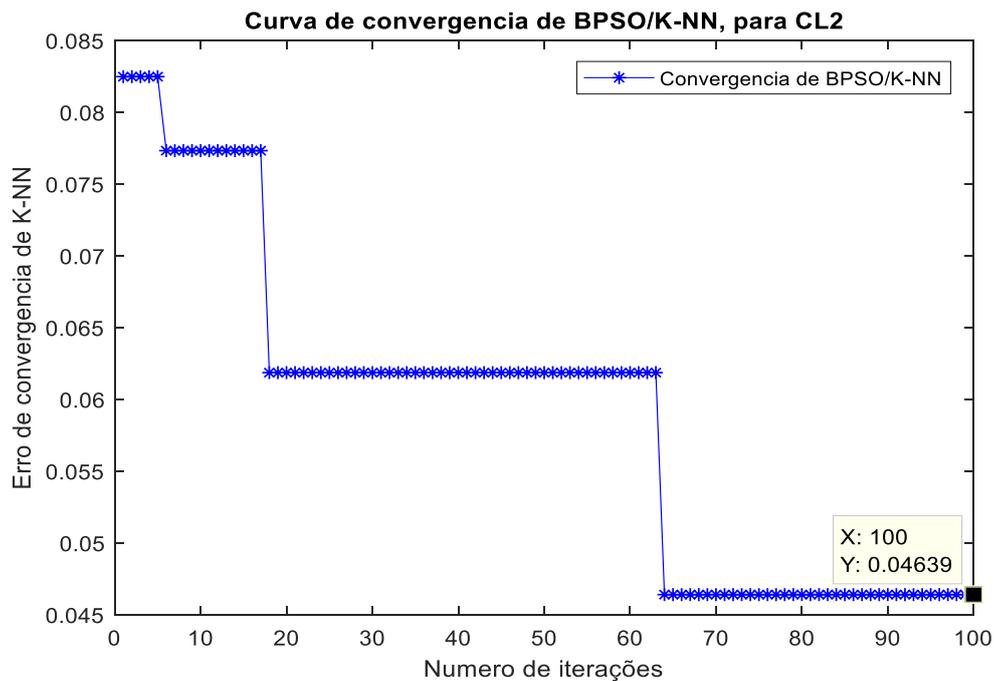
As variáveis de entrada selecionadas para CL1 são:

- $R_{CL1_1} = R_{VN01_5} = \frac{e}{j}$
- $R_{CL1_2} = R_{VN01_3} = \frac{e}{f}$
- $R_{CL1_3} = R_{VN01_1} = \frac{b}{f}$
- $R_{CL1_4} = R_{VN01_12} = \frac{b}{g-a}$
- $R_{CL1_5} = R_{VN01_8} = \frac{b}{g}$

b. Classificador CL2

Para a metodologia proposta, o classificador CL2 implica em classificar as condições de falha térmica, sendo este tipo de falhas codificadas como T1, T2, T3 segundo estabelecido na norma IEC 60599, pela disponibilidade de dados. Nesta metodologia proposta, apenas se consideram duas condições de operação: T1 e T2. Depois de executar 10 vezes o algoritmo BPSO/K-NN, foram selecionadas as variáveis de melhor agrupamento (Figura 5.2).

Figura 5.3 Curva de convergência de BPSO/ K-NN, para CL2



Fonte: Elaborado pelo Autor

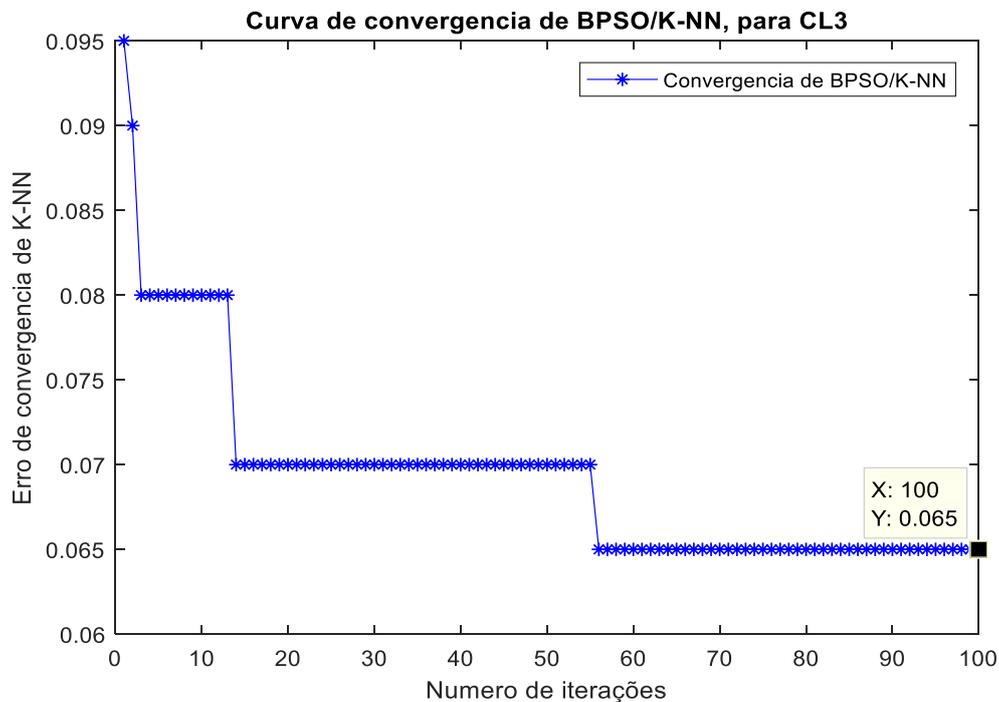
Por meio da ilustração gráfica (Figura 5.3), é possível observar que o erro de classificação de BPSO/K-NN, sob condições de validação cruzada de 10 instâncias e de $k=5$ vizinhos mais próximos é de 4.639 %, além do algoritmo proporcionar cinco entradas de avaliação com o melhor agrupamento:

- $R_{CL2_1} = R_{VN01_13} = \frac{e}{g-c}$
- $R_{CL2_2} = R_{VN01_5} = \frac{e}{j}$
- $R_{CL2_3} = R_{VN01_10} = \frac{d}{g}$
- $R_{CL2_4} = R_{VN01_11} = \frac{c}{g}$
- $R_{CL2_5} = R_{VN01_7} = \frac{a}{g}$

c. Classificador CL3

A seguir é apresentada a curva de convergência do algoritmo BPSO/K-NN, para o classificador CL3 (Figura 5.4):

Figura 5.4 Curva de convergência de BPSO/ K-NN, para CL3



Fonte: Elaborado pelo Autor

O procedimento de seleção de variáveis de avaliação para o classificador CL3 foi implementado para classificar as falhas de descarga de energia (D1 e D2). Após 10 simulações para dados de avaliação agrupados em VN01, foi selecionado o menor erro de convergência do algoritmo BPSO/K-NN (Figura 5.4).

Ainda na Figura 5.4 é possível observar que o erro da curva de convergência do algoritmo BPSO/K-NN é de 6.50 %, além de treze (13) dados de avaliação agrupados em VN01, foram selecionados 4 dados de avaliação com melhores características de agrupamento.

- $R_{CL3_1} = R_{VN01_2} = \frac{b}{f}$
- $R_{CL2_2} = R_{VN01_6} = \frac{d}{j}$
- $R_{CL3_3} = R_{VN01_11} = \frac{c}{g}$
- $R_{CL3_4} = R_{VN01_12} = \frac{b}{g-a}$

5.5. Diagnóstico de Condições de Falha no TP

No processo de seleção de classificadores é proposto avaliar dois classificadores que podem aproveitar perfeitamente as características de agrupamento dos dados de avaliação, efetuado pelo algoritmo de seleção BPSO/K-NN. Estes classificadores são redes neurais artificiais e K-NN com distância de classificação ponderada (*K-NN ponderada*).

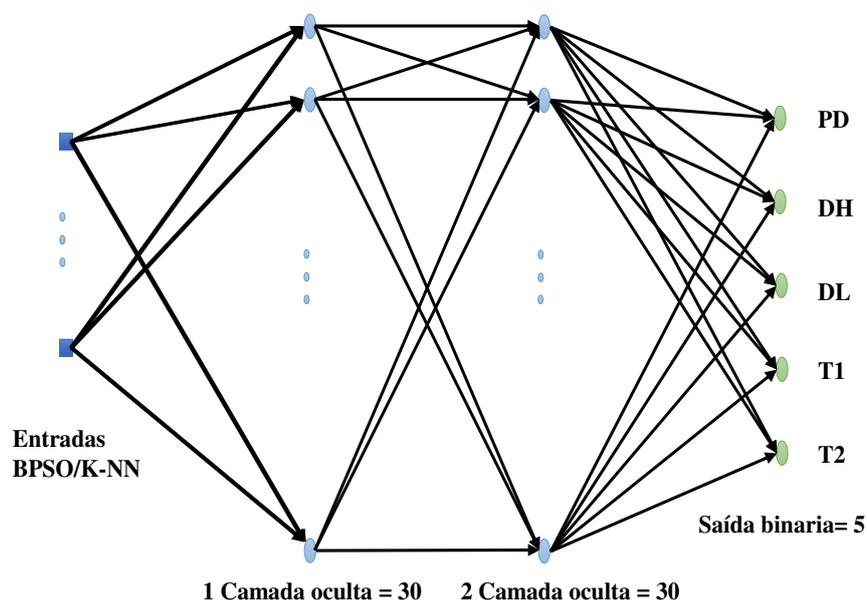
5.5.1. Classificador RNA

Para o método proposto nesta dissertação são utilizadas três redes neurais artificiais com arquitetura da rede com pequenas diferenças que se destacam nas variáveis de avaliação (entrada) e nas condições de falha no TP consideradas para cada classificador (saída), conforme pode ser observado na Figura 5.5.

Baseado nos dados indicados na Tabela 5.1, as RNAs são treinadas com 70 % de dados, enquanto os demais 30 % são usados no processo de teste de cada rede neural. Além disso é importante indicar que os algoritmos de treinamento para as três redes neurais artificiais foram executados em 100000 iterações (10 vezes), em seguida foram

selecionados os ciclos de treinamento de melhor desempenho, sendo armazenado os pesos sinápticos e bias.

Figura 5.5 Estrutura da rede neural proposta



Fonte: Elaborado pelo Autor

Os parâmetros de treinamento para as RNAs correspondente aos classificadores (CL1, CL2 e CL3) são estabelecidos segundo a Tabela 5.5.

Tabela 5.5 Parâmetros de treinamento da RNA

Algoritmo Classificador	RNA
Parâmetros de treinamento de ANN	$\alpha = 0.022$ (taxa de aprendizado) $\gamma = 0.9$ (momento) $\rho = 0.7$ $\eta = 1.05$ $\zeta = 0.05$ ρ, η, ζ variáveis de ajuste de VLPB
Entradas CL1(ANN1)	$R_{CL1_1}, R_{CL1_2}, R_{CL1_3}, R_{CL1_4}, e R_{CL1_5}$
Entradas CL2(ANN2)	$R_{CL2_1}, R_{CL2_2}, R_{CL2_3}, R_{CL2_4}, e R_{CL2_5}$
Entradas CL3(ANN3)	$R_{CL3_1}, R_{CL3_2}, R_{CL3_3}, e R_{CL1_4}$

Fonte: Elaborada pelo Autor

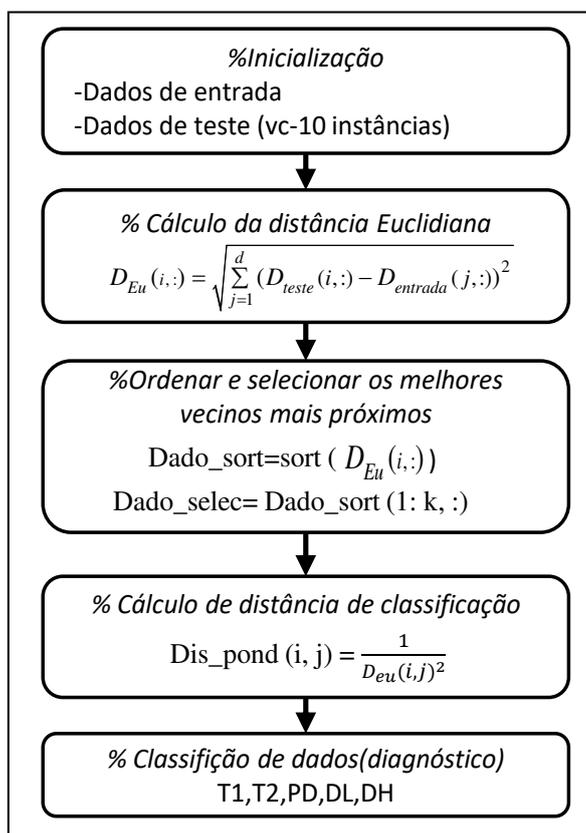
5.5.2. Classificador K-NN ponderada

Os classificadores são implementados considerando o critério de ponderação clássica indicado em (4.9). Na Figura 5.5 é ilustrado o fluxograma de implementação do algoritmo K-NN com distância de classificação ponderada.

Ainda no fluxograma ilustrado na Figura 5.5, é possível ver que o processo de diagnóstico de falhas por classificador K-NN ponderado é realizado com a inicialização do classificador (estabelecer o número de vizinhos mais próximos e instâncias de treinamento) e a eleição de instâncias de teste (validação cruzada “vc” – 10 instâncias de teste), seguidamente é calculado a distância mais curta (distância euclidiana) entre a instância à classificar e os vizinhos mais próximos considerados na análise.

Finalmente a classificação da instância teste começa ordenando e selecionando os melhores vizinhos, para calcular a distância de classificação ponderada no diagnóstico de falha final, no qual a menor distância a uma condição de falha (T1, T2, D1, D2 e DP) implica em uma classificação.

Figura 5.6 Fluxo de diagnóstico de falhas no TP, utilizando classificador KNN ponderado



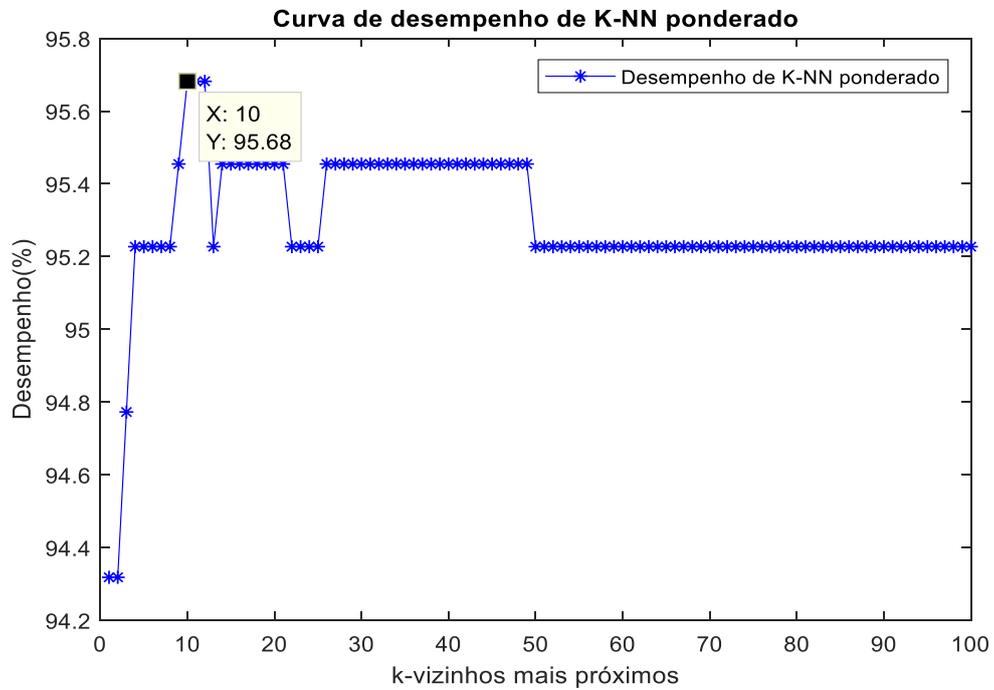
Fonte: Elaborado pelo Autor

5.6. Resultados de Avaliação de Classificadores

Para o método baseado em RNAs, com dados disponibilizados em Tabela 5.1, foi alcançado um desempenho de 100 %, tanto no processo de treinamento, quanto no teste, para os três classificadores (CL1, CL2 e CL3) propostos nesta dissertação.

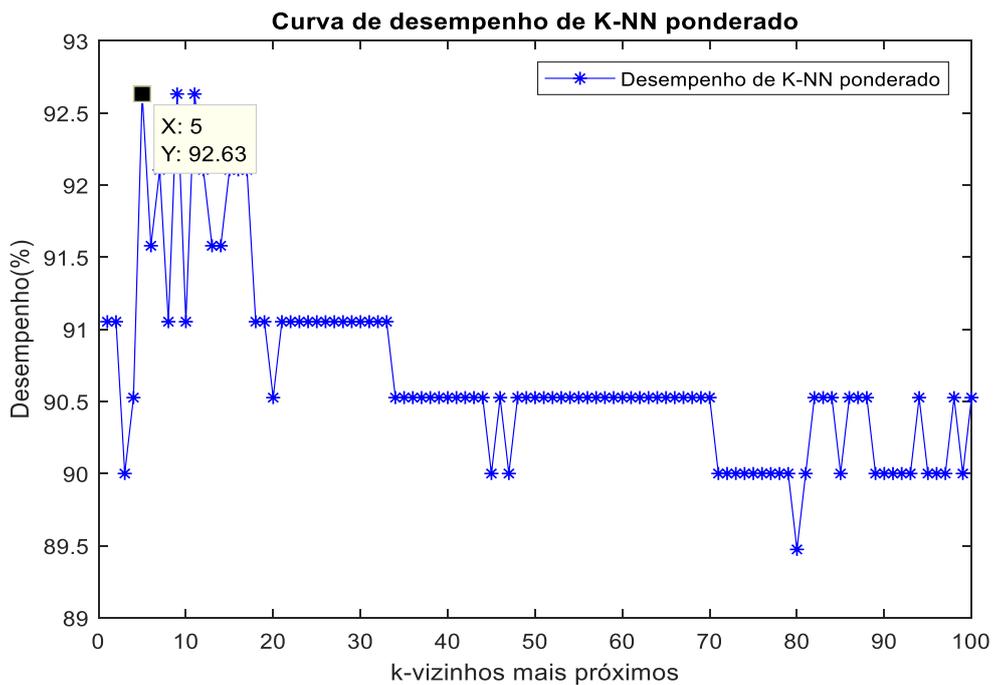
Por outro lado, para o classificador K-NN ponderado, é ajustado para uma validação cruzada de 10 instâncias. Nas Figuras 5.7 a 5.9 são ilustradas as curvas de desempenho, considerando de 1 até 100 vizinhos mais próximos.

Figura 5.7 Curvas de desempenho de K-NN ponderado em CL1 (K=1:100)



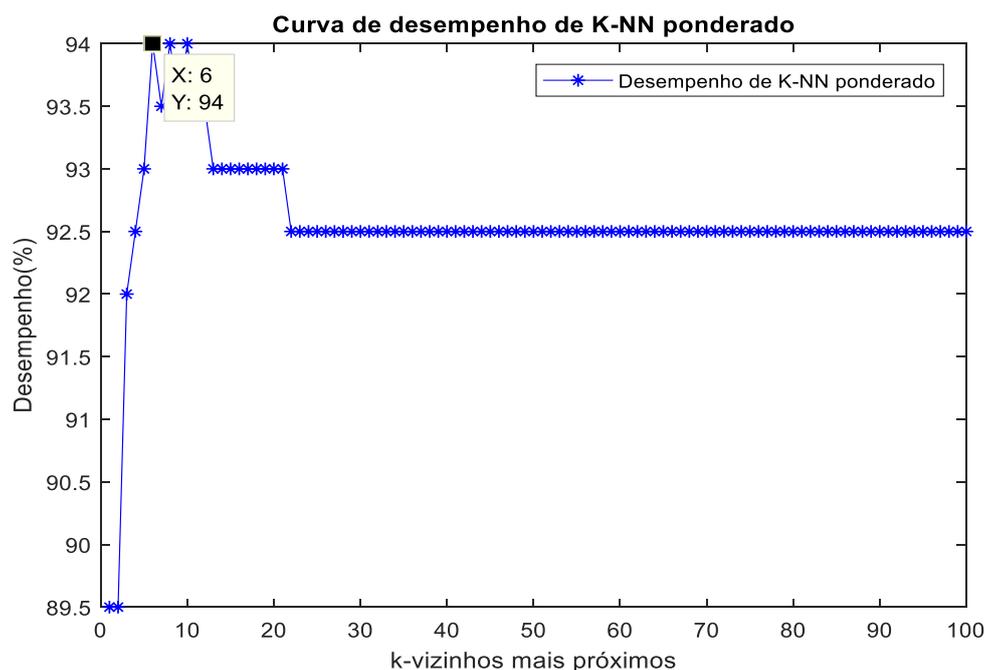
Fonte: Elaborado pelo Autor

Figura 5.8 Curvas de desempenho de K-NN ponderado em CL2 (K=1:100)



Fonte: Elaborado pelo Autor

Figura 5.9 Curvas de desempenho de K-NN ponderado em CL3 (K=1:100)



Fonte: Elaborado pelo Autor

Por meio da Figura 5.7 é possível indicar que o diagnóstico de falhas térmicas, falhas de descarga de energia e falha de descarga parcial, efetuado pelo classificador CL1 baseado em K-NN ponderada, apresenta um resultado de 95.68 % (considerando validação cruzada de 10 instâncias e k=10-12 vizinhos mais próximos). Para o classificador CL2 o desempenho no processo de teste foi de 92.63 %, considerando k= 5, 9 e 11 vizinhos mais próximos (Figura 5.8). Para o classificador CL3 foi registrado um desempenho de 94% considerando k= 6, 8 e 10 vizinhos mais próximos (Figura 5.9).

Para os classificadores baseados na RNA, tanto no processo de treinamento, quanto no teste, foram obtidos resultados superiores à abordagem baseada em K-NN ponderado (Tabela 5.6).

Tabela 5.6 Desempenho de classificadores CL1, CL2 e CL3 (para K-NN ponderado e RNA)

Classificador	Treino (%)	Teste (%)
K-NN ponderado em CL1	VC-10	95.68%
K-NN ponderado em CL2	VC-10	92.63%
K-NN ponderado em CL3	VC-10	94.00%
ANN em CL1 (ANN1)	100%	100%
ANN em CL2 (ANN2)	100%	100%
ANN em CL3 (ANN3)	100%	100%

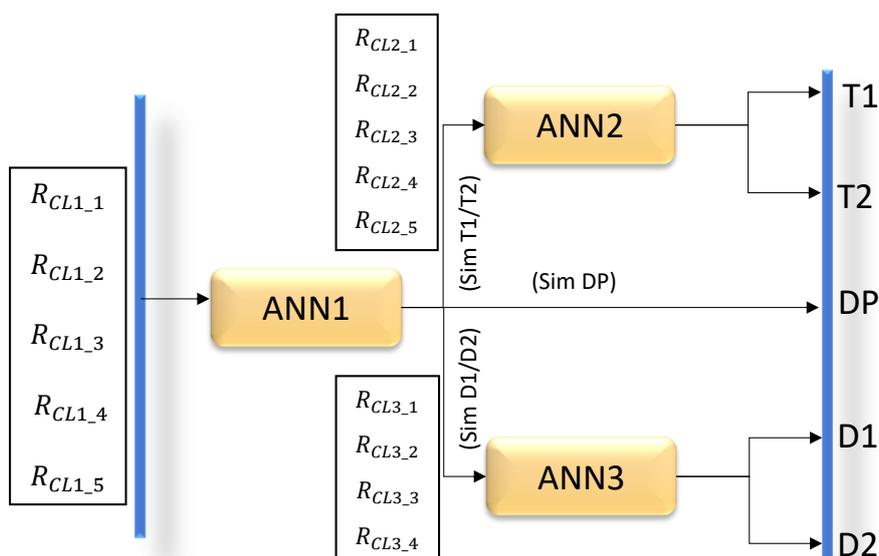
Fonte: Elaborado pelo Autor

Ainda na Tabela 5.6 é observado que o desempenho de classificadores baseados em redes neurais artificiais é superior a abordagem baseada em K-NN com distância de classificação ponderada, portanto em função da assertividade foi constatado que a melhor metodologia é baseada em redes neurais artificiais.

5.7. Validação da metodologia proposta

Em decorrência da avaliação dos classificadores (K-NN ponderado e RNA) realizado no item precedente (avaliação de classificadores) e baseado no esquema de diagnóstico de falhas proposto na Figura 5.1, um esquema completo com variáveis de entrada, variáveis de saída e três classificadores baseados em redes neurais artificiais é ilustrado na Figura 5.10:

Figura 5.10 Esquema completa de diagnóstico de falhas em transformadores de potência



Fonte: Elaborado pelo Autor

Tabela 5.7 Matriz de confusão, validação da metodologia proposta

	T1	T2	D1	D2	PD
T1	22	0	0	0	0
T2	0	27	0	0	0
D1	0	0	27	0	0
D2	0	0	0	36	0
PD	0	0	0	0	18

Fonte: Elaborado pelo Autor

Com a finalidade de validar o grau de generalização da metodologia proposta, os dados coletados no período 2017-2019 (130 instâncias) foram testados, sendo elaborado uma matriz de confusão dos resultados como indicado na Tabela 5.7.

O inconveniente de metodologias de diagnóstico de falhas em transformadores de potência é o problema de generalização devido ao número limitado de dados reais no processo de validação. Neste trabalho, 130 dados reais (coletados da bibliografia revisada) são usados no processo de validação. Como indicado na matriz de confusão, relacionada na Tabela 5.7, se obteve uma assertividade de 100 %.

5.8. Conclusão do capítulo

Esse capítulo foi dedicado às metodologias de classificação propostas para o diagnóstico de falhas em transformadores de potência. De forma sucinta é possível informar que o algoritmo BPSO/K-NN além de selecionar as melhores variáveis de avaliação, pode alcançar um desempenho alto em diagnóstico de falhas incipientes em transformadores de potência, como pode ser evidenciado nas curvas de convergência dos classificadores CL1, CL2 e CL3, nas quais se obteve o erro médio de classificação de 4.842 % (Figura 5.2, 5.3 e 5.4).

Já em metodologia de diagnóstico de falhas em transformadores de potência baseados em K-NN com distância de classificação ponderada, foi encontrado um desempenho médio de 94.1 %. Esse desempenho pode também confirmar a melhor caracterização de agrupamento de algoritmo BPSO/K-NN.

Por fim, as três redes neurais artificiais da metodologia de diagnóstico de falhas incipientes propostas nesta dissertação, foram treinadas e testadas com um desempenho de 100 %, além disso no processo de validação com 130 dados independentes coletadas na revisão bibliográfica, foi possível alcançar um desempenho de 100 %.

6 - CONCLUSÕES

As metodologias de diagnóstico de falhas incipientes em transformadores de potência orientadas a melhorar os critérios convencionais alcançaram desempenho alto comparadas com as metodologias padronizadas. Este desempenho é influenciado diretamente pela reformulação das variáveis de avaliação ou operação conjunta das metodologias existentes. É importante indicar que o desempenho destas metodologias (baseadas em normas), ainda é baixa comparada com metodologias baseadas em técnicas de inteligência artificial.

As condições de operação do transformador de potência mais abrangentes e de melhor aceitação na comunidade acadêmica são baseadas na classificação de falhas estabelecida na norma IEC 60599 (seis condições de falhas e uma condição de operação normal no transformador de potência).

No diagnóstico de falhas em transformadores de potência foi aplicado um número importante de técnicas de inteligência artificial, porém uma metodologia de desempenho alto e com grandes possibilidades de generalização ainda é um tema de pesquisa aberta. Nos trabalhos revisados se observa que as possibilidades de encontrar uma metodologia de assertividade alta e generalizável podem ser ainda melhoradas quando se pretende otimizar o uso de dados disponíveis.

Nesta dissertação de mestrado foi desenvolvida uma metodologia de diagnóstico de falhas em transformadores de potência por aplicação de algoritmo de seleção BPSO/K-NN e redes neurais artificiais, é alcançado um desempenho de 100 % para dados reais coletados da revisão bibliográfica (130 instâncias) e dados disponíveis em TC10 (311 instâncias).

Como trabalho preliminar foi elaborada uma revisão bibliográfica de metodologias de diagnóstico de falhas incipientes em transformadores de potência desenvolvidas e publicadas em anais de congressos e periódicos no período 2011-2019 e finalmente desenvolvida uma metodologia de diagnóstico de falhas incipientes em transformadores de potência por aplicação de BPSO/K-NN e RNA. Logo as conclusões derivadas da presente dissertação são:

- ❖ O algoritmo BPSO/K-NN, sob a configuração proposta nesta dissertação, além de selecionar as melhores variáveis de agrupamento, pode classificar com alto grau de desempenho o diagnóstico de falhas em transformadores de potência (erro de classificação inferior a 7 %, conforme apresentado nas Figuras 5.2 a 5.4).
- ❖ O diagnóstico de falhas incipientes em transformadores usando Redes Neurais Artificiais, sob a configuração proposta, tem um desempenho alto e com grandes possibilidades de generalização, como é evidenciado no desempenho de 100% no processo de validação.
- ❖ Segundo a literatura, o classificador K-NN ponderado pode aproveitar perfeitamente as variáveis de melhor agrupamento em tarefas de classificação, entretanto no diagnóstico de falhas em transformadores de potência, esta metodologia pode ter algumas limitações no desempenho (desempenho inferior a 96 %, conforme apresentado nas Figuras 5.7 a 5.9).

Nesse contexto as principais contribuições desta dissertação são:

- ❖ O desenvolvimento de um material bibliográfico importante, como: quadro resumo de metodologias de diagnóstico de falhas em transformadores de potência desenvolvidas e publicadas em *IEEE Xplore Digital Library*, durante o período 2011-2019; levantamento de dados do conteúdo de gases obtidos a partir da inspeção de 130 transformadores de potência e de 59 variáveis de avaliação relacionados diretamente com as condições de falha no TP.
- ❖ A proposição do uso de variáveis de avaliação com características de melhor agrupamento (obtida pelo algoritmo de seleção BPSO/K-NN), em diagnóstico de falhas em transformadores de potência.
- ❖ Proposição de uma metodologia de diagnóstico de falhas incipientes no TP em configuração em cascata, usando redes neurais artificiais, em casos em que há superposição de dados por condição de falha no transformador de potência.

Em decorrência da presente dissertação de mestrado sugere-se que possa ser estudado temas relacionados como:

- ❖ Desenvolver uma metodologia de diagnóstico de falhas incipientes no transformador de potência considerando conteúdo de gases e histórico de geração de gases dissolvidos no óleo.
- ❖ Considerando o histórico de geração de gases estabelecer a inter-relação de condições de operação no transformador de potência.
- ❖ Desenvolver uma metodologia de monitoramento de transformador de potência dentro da operação real de um sistema elétrico de potência.

Durante o desenvolvimento da dissertação de mestrado foram desenvolvidos trabalhos de pesquisa que foram publicadas e apresentadas em anais de congressos. A seguir são listadas as publicações.

- ❖ **Alex Rogelio Soto Enriquez**, Shigeaki Leite Lima e Osvaldo Saavedra Mendez, “*Análise Comparativa de Técnicas de Inteligência Artificial no Diagnóstico de Falhas em Transformadores de Potência*”, **APRESENTADO** em 14º Simpósio Brasileiro de Automação Inteligente (SBAI 2019). Ouro Preto -Brasil.
- ❖ **Alex Rogelio Soto Enriquez**, Shigeaki Leite Lima e Osvaldo Saavedra Mendez, “*Incipient Fault Diagnosis in Power Transformers by DGA using a Machine Learning ANN - Mean Shift Approach*”, **APRESENTADO** em 2019 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC 2019). Ixtapa, México.
- ❖ **Alex Rogelio Soto Enriquez**, Shigeaki Leite Lima e Osvaldo Saavedra Mendez, “*Optimal Selection of Input Variables by BPSO for Diagnosis of Incipient Failures in Power Transformers (by DGA)*”, **APRESENTADO** em 20th International Conference on Intelligent Systems Applications to Power Systems (ISAP 2019). New Delhi, Índia
- ❖ **Alex Rogelio Soto Enriquez**, Shigeaki Leite Lima e Osvaldo Saavedra Mendez, “*K-NN and Mean-Shift Algorithm Applied in Fault Diagnosis in Power Transformers by DGA*”, **APRESENTADO** em 20th International Conference on Intelligent Systems Applications to Power Systems (ISAP 2019). New Delhi, Índia.

REFERENCIAS

- [1] M. Arschad e S. M. Islam, “Significance of cellulose power transformer condition assessment,” *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 18, p. 1591–1598, 2011.
- [2] “IEEE Guide for the Evaluation and Reconditioning of Liquid Immersed Power Transformers,” *IEEE Std C57.140-2006*, p. c1–67, 2007.
- [3] US-DOE, “Infrastructure security and energy restoration office of electricity delivery and energy reliability U.S. Department of Energy,” In Large Power Transformers and the U. S. Electric Grid, 2014.
- [4] M. Wang e A. J. Vandermaar, “Review of condition assessment of power transformers in service,” *IEEE Electrical Insulation Magazine*, vol. 18, pp. 12-25, 2002.
- [5] N. Dominelli, A. Rao e P. Kundur, “Life extension and condition assessment: techniques for an aging utility infrastructure,” *IEEE Power and Energy Magazine*, vol. 4, pp. 24-35, 2006.
- [6] Y. Benmahamed, T. M e A. Boubakeur, “Application of SVM and KNN to Duval Pentagon 1 for transformer oil diagnosis,” *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 24, pp. 3443-3451, 2017.
- [7] ANEEL, “Resolução Normativa N° 414,” AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, Brasília, 2010.
- [8] W. Bartley, “An analysis of international transformer failures, part 1. In The locomotive: Helping customers manage risk and solve operational problems,” Hartford Steam Boiler, 2013.
- [9] A. (2007b), “Resolução normativa no 270 de 26 de junho de 2007,” Agência Nacional de Energia Eletrica.
- [10] V. Miranda, A. R. G. Castro e S. Lima, “Diagnosing Faults in Power Transformers With Autoassociative Neural Networks and Mean Shift,” *IEEE Transactions on Power Delivery*, vol. 27, pp. 1350-1357, 2012.
- [11] M. Beitle e S. Tembohein, “Usability of vibration measurement for power transformer diagnosis and monitoring,” *2012 IEEE International Conference on Condition Monitoring and Diagnosis*, pp. 281-284, 2012.
- [12] Y. Liu, “A study of the sweep frequency impedance method and its application in the detection of internal winding short circuit faults in power transformers,” *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 22, pp. 2046-2056, 2015.

- [13] A. Abu-Siada, *Power Transformer Condition Monitoring and Diagnosis*, United Kingdom: Stevenage, 2018.
- [14] COMPANY GLOBECORE, “TRANSFORMADOR OIL,” <https://globecore.com/6-transformer-oils.html>. Acesso em 05/05/2019, 2019.
- [15] S. S. M. Ghoneim, I. B. M. Taha e N. I. Elkalashy, “Integrated ANN-based proactive fault diagnostic scheme for power transformers using dissolved gas analysis,” *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 23, pp. 1838-1845, 2016.
- [16] H. Tian, K. Li e B. Meng, “Multiple ANNs combined scheme for fault diagnosis of power transformers,” *2011 Chinese Control and Decision Conference (CCDC)*, pp. 2557-2560, 2011.
- [17] S. Apte, R. Somalwar e A. Wajirabadkar, “Incipient Fault Diagnosis of Transformer by DGA Using Fuzzy Logic,” *2018 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*, pp. 1-5, 2018.
- [18] Y. Lu, C. Wei, T. Kong, T. Shi e J. Zheng, “An improved DAG-SVM algorithm based on KFCM in Power Transformer Fault Diagnosis,” *2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*, pp. 1297-1302, 2019.
- [19] J. Guo, “Fault diagnosis system based on Dynamic Fault Tree Analysis of power transformer,” *2012 9th International Conference on Fuzzy Systems and Knowledge Discovery*, pp. 2679-2682, 2012.
- [20] W. Mo, T. Kari, H. Wang, L. Luan e W. Gao, “Fault diagnosis of power transformer using feature selection techniques and KNN,” *2017 3rd IEEE International Conference on Computer and Communications (ICCC)*, pp. 2827-2831, 2017.
- [21] “IEEE Xplore Digital Library,” <https://ieeexplore.ieee.org/Xplore/home.jsp>, 2019.
- [22] K. Karsai, D. Kerényi e L. Kiss, *Large Power Transformers*, Budapest- Hungria: Elsevier Science Ltd, 1987.
- [23] Dasgupta e Indrajit, *Power Transformers Quality Assurance*, New Age International (P) Ltd, 2009.
- [24] Alstom, *Power Transformers - Fundamentals*, La Defence-Paris: Areva T&D, 2008.
- [25] N. A. Mahamad, B. T. Phung e T. R. Blackburn, “Dissolved gas analysis for common transformer faults in soy seed-based oil,” *IET Electric Power Applications*, vol. 5, pp. 133-142, 2011.

- [26] "IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers," IEEE Standard C57.104-2008, 2009.
- [27] M. Duval, "A review of faults detectable by gas-in-oil analysis in transformers," *IEEE Electrical Insulation Magazine*, vol. 18, pp. 8-17, 2002.
- [28] M. Duval e A. de Pabla, "Interpretation of gas-in-oil analysis using new IEC publication 60599 and IEC TC 10 databases," *IEEE Electrical Insulation Magazine*, vol. 17, pp. 31-41, 2001.
- [29] "Mineral oil-impregnated electrical equipment in service-guide to the interpretation of dissolved and free gases analysis," IEC Publication 60599, 1999.
- [30] V. Miranda e A. Castro, "Improving the IEC table for transformer failure diagnosis with knowledge extraction from neural networks, Power Delivery," *IEEE Transactions*, pp. 2509-2516, 2005.
- [31] I. B. M. Taha, S. S. M. Ghoneim e A. S. A. Duaywah, "Refining DGA methods of IEC Code and Rogers four ratios for transformer fault diagnosis," *2016 IEEE Power and Energy Society General Meeting (PESGM)*, pp. 1-5, 2016.
- [32] E. Pozzebon, L. B. Frigo e G. Bittencourt, "inteligência artificial na educação universitária: quais as," Universidade Federal de Santa Catarina - Departamento de Automação e Sistemas Pós-graduação em Engenharia, Santa Catarina - Brazil.
- [33] A. M. Turing, "Computing machinery and intelligence," *Oxford University Press on behalf of the Mind Association*, vol. 59, pp. 433-460, 1950.
- [34] L. Zheng, W. Liu e L. Lu, "Application of BP network based on free-weighting on transformer fault diagnosis," *2011 6th IEEE Joint International Information Technology and Artificial Intelligence Conference*, pp. 229-232, 2011.
- [35] A. Li, X. Sun e D. Liu, "Application of RBF network with ant colony and fisher ratio to fault diagnosis of oil -immersed," *2011 Seventh International Conference on Natural Computation*, pp. 549-551, 2011.
- [36] X. Li, H. Wu e D. Wu, "DGA Interpretation Scheme Derived From Case Study," *IEEE Transactions on Power Delivery*, vol. 26, pp. 1292-1293, 2011.
- [37] C. Liu, L. Yao, T. Chen, T. Lin e S. Wang, "Fault diagnosis for power transformers based on Hybrid Fuzzy Dissolved Gas Analysis," *2011 Eighth International Conference on Fuzzy Systems and Knowledge Discovery (FSKD)*, pp. 824-828, 2011.
- [38] Y. J. Yin, J. P. Zhan, C. X. Gou, Q. H. Wu e J. M. Zhang, "Multi-kernel support vector classifier for fault diagnosis of transformers," *2011 IEEE Power and Energy Society General Meeting*, pp. 1-7, 2011.

- [39] H. Han e W. Houjun, "Study on power transformer protection based on chaos particle swarm optimization," *IEEE 2011 10th International Conference on Electronic Measurement & Instruments*, pp. 247-250, 2011.
- [40] Z. Dong, Y. Zhu, Z. Hu e Y. Shao, "Transformer fault diagnosis based on factor analysis and gene expression programming," *2011 International Conference on Advanced Power System Automation and Protection*, pp. 402-406, 2011.
- [41] D. Bhalla, R. K. Bansal e H. O. Gupta, "Transformer incipient fault diagnosis based on DGA using fuzzy logic," *India International Conference on Power Electronics 2010 (IICPE2010)*, pp. 1-5, 2011.
- [42] M. Rajabimendi e E. P. Dadios, "hybrid algorithm based on neural-fuzzy system for interpretation of dissolved gas analysis in power transformers," *TENCON 2012 IEEE Region 10 Conference*, pp. 1-6, 2012.
- [43] M. A. B. Amora, O. M. Almeida, A. P. S. Braga, F. R. Barbosa, L. A. C. Lisboa e R. S. T. Pontes, "Improved DGA method based on rules extracted from high-dimension input space," *Electronics Letters*, vol. 48, pp. 1048-1049, 2012.
- [44] A. A. Suleiman, N. A. Mohamad, N. Bashir, A. S. Alghamdi e M. Aizam, "Improving accuracy of DGA interpretation of oilfilled power transformers needed for effective condition monitoring," *2012 IEEE International Conference on Condition Monitoring and Diagnosis*, pp. 374-378, 2012.
- [45] D. Furundzic, Z. Djurovic, V. Celebic e I. Salom, "Neural network ensemble for power transformers fault detection," *11th Symposium on Neural Network Applications in Electrical Engineering*, pp. 247-251, 2012.
- [46] S. Seifeddine, B. Khmais e C. Abdelkader, "Power transformer fault diagnosis based on dissolved gas analysis by artificial neural network," *2012 First International Conference on Renewable Energies and Vehicular Technology*, pp. 230-236, 2012.
- [47] A. Zhou, H. Song, H. Xiao e X. Zeng, "Power Transformer Fault Diagnosis Based on Integrated of Rough Set Theory and Neural Network," *2012 Second International Conference on Intelligent System Design and Engineering Application*, pp. 463-465, 2012.
- [48] N. A. Setiawan, Sarjiya e Z. Adhiarga, "Power transformer incipient faults diagnosis using Dissolved Gas Analysis and Rough Set," *2012 IEEE International Conference on Condition Monitoring and Diagnosis*, pp. 950-953, 2012.
- [49] H. Ahuja, G. Bhuvaneswari, R. Balasubramanian e A. Singh, "Soft Computing -- Applied to Transformer Incipient Fault Diagnosis," *2012 Fourth International Conference on Computational Intelligence and Communication Networks*, pp. 809-814, 2012.

- [50] C. Xiaoqing, L. Juemin, H. Yingwei e F. Bu, "Transformer fault diagnosis based on IAFSA and rough set," *26th International Conference on Electrical Contacts (ICEC 2012)*, pp. 296-300, 2012.
- [51] A. J. Q. Carita, L. C. Leite, A. P. P. Medeiros, R. Barros e I. Sauer, "Bayesian Networks applied to Failure Diagnosis in Power Transformer," *IEEE Latin America Transactions*, vol. 11, pp. 1075-1082, 2013.
- [52] A. Zhao e C. Zhang, "DGA fault diagnosis based on the counter propagation neural network optimized by parallel genetic algorithm," *2013 IEEE International Conference of IEEE Region 10 (TENCON 2013)*, pp. 1-5, 2013.
- [53] A. J. R. Reis, L. G. Castanheira e R. C. Barbosa, "Enhancing Neural Networks-Based Classification of Incipient Faults in Power Transformers via Preprocessing," *2013 BRICS Congress on Computational Intelligence and 11th Brazilian Congress on Computational Intelligence*, pp. 622-627, 2013.
- [54] L. Chao e M. Lin, "Health assessment model of power transformer based on dissolved gas analysis by support vector machine," *2013 6th International Conference on Information Management, Innovation Management and Industrial Engineering*, pp. 280-283, 2013.
- [55] M. SuganyaBharathi, M. W. Iruthayarajan, S. S. Shunmugam e L. Kalavani, "Interpretation of dissolved gas analysis in transformer oil using fuzzy logic system," *2013 International Conference on Power, Energy and Control (ICPEC)*, pp. 245-249, 2013.
- [56] A. A. Suleiman, N. A. Muhamad, N. Bashir e A. S. Alghamdi, "Introducing the Hybrid-DGA Interpretation software as an effective power transformer management tool," *4th International Conference on Power Engineering, Energy and Electrical Drives*, pp. 1410-1414, 2013.
- [57] S. Kim, H. Seo, J. Jung, H. Yang e M. Duval, "New methods of DGA diagnosis using IEC TC 10 and related databases Part 1: application of gas-ratio combinations," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 20, pp. 685-690, 2013.
- [58] S. Lee, Y. Kim, H. Seo, J. Jung, H. Yang e M. Duval, "New methods of DGA diagnosis using IEC TC 10 and related databases Part 2: application of relative content of fault gases," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 20, pp. 691-696, 2013.
- [59] M. R. Ahmed, M. A. Geliel e A. Khalil, "Power transformer fault diagnosis using fuzzy logic technique based on dissolved gas analysis," *21st Mediterranean Conference on Control and Automation*, pp. 584-589, 2013.

- [60] S. Souahlia, K. Bacha e A. Chaari, "SVM-based decision for power transformers fault diagnosis using Rogers and Doernenburg ratios DGA," *10th International Multi-Conferences on Systems, Signals & Devices 2013 (SSD13)*, pp. 1-6, 2013.
- [61] A. K. Mehta, R. N. Sharma, S. Chauhan e S. Saho, "Transformer diagnostics under dissolved gas analysis using Support Vector Machine," *2013 International Conference on Power, Energy and Control (ICPEC)*, pp. 181-186, 2013.
- [62] H. Malik e S. Mishra, "Application of gene expression programming (GEP) in power transformers fault diagnosis using DGA," *2014 6th IEEE Power India International Conference (PIICON)*, pp. 1-5, 2014.
- [63] M. M. Ibrahim, M. M. Sayed e E. E. Abu El-Zahab, "Diagnosis of power transformer incipient faults using Fuzzy Logic-IEC Based Approach," *2014 IEEE International Energy Conference (ENERGYCON)*, pp. 242-245, 2014.
- [64] C. Wei, W. Tang e Q. Wu, "Dissolved gas analysis method based on novel feature prioritisation and support vector machine," *IET Electric Power Applications*, vol. 8, pp. 320-328, 2014.
- [65] H. Malik e S. Mishra, "Fault identification of power transformers using Proximal Support Vector Machine (PSVM)," *2014 IEEE 6th India International Conference on Power Electronics (IICPE)*, pp. 1-5, 2014.
- [66] H. Malik e S. Mishra, "Feature selection using RapidMiner and classification through probabilistic neural network for fault diagnostics of power transformer," *2014 Annual IEEE India Conference (INDICON)*, pp. 1-6, 2014.
- [67] Y. Cui, H. Ma e T. Saha, "Improvement of power transformer insulation diagnosis using oil characteristics data preprocessed by SMOTEBoost technique," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 21, pp. 2363-2373, 2014.
- [68] T. Nagpal e Y. S. Brar, "Neural network based transformer incipient fault detection," *2014 International Conference on Advances in Electrical Engineering (ICAEE)*, pp. 1-5, 2014.
- [69] D. R. Malabanan e A. C. Nerves, "Power transformer condition assessment using an immune neural network approach to Dissolved Gas Analysis," *TENCON 2014 - 2014 IEEE Region 10 Conference*, pp. 1-6, 2014.
- [70] A.-x. Zhao, X.-j. Tang, Z.-h. Zhang e J.-h. Liu, "The DGA interpretation method using relative content of characteristic gases and gas-ratio combinations for fault diagnosis of oil-immersed power transformers," *Proceedings of 2014 International Symposium on Electrical Insulating Materials, Niigata*, pp. 124-127., 2014.
- [71] J. Zhang, Y. Zhu, W. Shi, G. Sheng e Y. Chen, "An Improved Machine Learning Scheme for Data-Driven Fault Diagnosis of Power Grid Equipment," *2015 IEEE*

- 17th International Conference on High Performance Computing and Communications, 2015 IEEE 7th International Symposium on Cyberspace Safety and Security, and 2015 IEEE 12th International Conference on Embedded Software and Systems*, pp. 1737-1742, 2015.
- [72] M. U. Farooque, S. A. Wani e S. A. Khan, "Artificial neural network (ANN) based implementation of Duval pentagon," *2015 International Conference on Condition Assessment Techniques in Electrical Systems (CATCON)*, pp. 46-50, 2015.
- [73] M. A. A. Siddique e S. Mehfuz, "Artificial neural networks based incipient fault diagnosis for power transformers," *2015 Annual IEEE India Conference (INDICON)*, pp. 1-6, 2015.
- [74] E. J. Kadim, C. F. Hee, N. Azis, J. Jasni, S. A. Ahmad e M. Z. A. A. Kadir, "Dissolved gas analysis of transformers based on rough set and fuzzy logic methods," *2015 IEEE Conference on Energy Conversion (CENCON)*, pp. 268-271, 2015.
- [75] H. Malik e S. Mishra, "Extreme learning machine based fault diagnosis of power transformer using IEC TC10 and its related data," *2015 Annual IEEE India Conference (INDICON)*, pp. 1-5, 2015.
- [76] I. B. M. Taha, S. S. M. Ghoneim e H. G. Zaini, "Improvement of Rogers four ratios and IEC Code methods for transformer fault diagnosis based on Dissolved Gas Analysis," *2015 North American Power Symposium (NAPS)*, pp. 1-5, 2015.
- [77] C. H. R. Martins, M. A. A. Araujo e R. A. Flauzino, "Power transformer fault diagnosis using DGA and group decision making with intuitionistic fuzzy preference relations," *2015 IEEE PES Innovative Smart Grid Technologies Latin America (ISGT LATAM)*, pp. 344-348, 2015.
- [78] H. Lu, Y. Ye e G. Chen, "Transformer Fault Diagnosis Algorithm Based on Entropy-Weighting Information Bottleneck Method," *2015 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery*, pp. 127-130, 2015.
- [79] C. Q. Su, "A new fuzzy logic method for transformer incipient fault diagnosis," *2016 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, pp. 324-327, 2016.
- [80] R. Soni e K. Chaudhari, "An approach to diagnose incipient faults of power transformer using dissolved gas analysis of mineral oil by ratio methods using fuzzy logic," *2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPEs)*, pp. 1894-1899, 2016.
- [81] H. Malik e S. Mishra, "Application of Gene Expression Programming (GEP) in Power Transformers Fault Diagnosis Using DGA," *IEEE Transactions on Industry Applications*, vol. 52, pp. 4556-4565, 2016.

- [82] Trianto, Suwarno, Y. Li e G. Zhang, "Combining conventional and artificial intelligence DGA interpretation methods using optimized weighting factor," *2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, pp. 37-42, 2016.
- [83] J. Singh, P. Kumari, K. Kaur e A. K. Swami, "Condition assessment of power transformer using SVM based on DGA," *2016 Al-Sadeq International Conference on Multidisciplinary in IT and Communication Science and Applications (AIC-MITCSA)*, pp. 1-5, 2016.
- [84] F. R. Souza e B. Ramachandran, "Dissolved gas analysis to identify faults and improve reliability in transformers using support vector machines," *2016 Clemson University Power Systems Conference (PSC)*, pp. 1-4, 2016.
- [85] E. Aburaghiega, M. E. Farrag, D. M. Hepburn e B. Garcia, "Enhanced condition monitoring of power transformers through improvement in accuracy of DGA interpretation," *2016 51st International Universities Power Engineering Conference (UPEC)*, pp. 1-6, 2016.
- [86] A. Peimankar, S. J. Weddell, T. Jalal e A. C. Laphorn, "Ensemble classifier selection using multi-objective PSO for fault diagnosis of power transformers," *2016 IEEE Congress on Evolutionary Computation (CEC)*, pp. 3622-3629, 2016.
- [87] T. Kari, "Fault diagnosis model of power transformer based on improved grey relation method with combined weight," *12th IET International Conference on AC and DC Power Transmission (ACDC 2016)*, pp. 1-6, 2016.
- [88] M. M. Islam, G. Lee e S. N. Hettiwatte, "Incipient fault diagnosis in power transformers by clustering and adapted KNN," *2016 Australasian Universities Power Engineering Conference (AUPEC)*, pp. 1-5, 2016.
- [89] J. Li, Q. Zhang, J. Wang, T. Zhou e Y. Zhang, "Optimal dissolved gas ratios selected by genetic algorithm for power transformer fault diagnosis based on support vector machine," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 23, pp. 1198-1206, 2016.
- [90] Q. Liu, G. Huang, C. Mao, Y. Shang e F. Wang, "Recognition of dissolved gas in transformer oil by ant colony optimization support vector machine," *2016 IEEE International Conference on High Voltage Engineering and Application (ICHVE)*, pp. 1-4, 2016.
- [91] C. Subroto, Suwarno, Trianto e G. Zhang, "Artificial intelligence for DGA interpretation methods using weighting factor," *2017 1st International Conference on Electrical Materials and Power Equipment (ICEMPE)*, pp. 85-88, 2017.
- [92] I. B. M. Taha, D. A. Mansour, S. S. M. Ghoneim e N. I. Elkalashy, "Conditional probability-based interpretation of dissolved gas analysis for transformer incipient faults," *IET Generation, Transmission & Distribution*, vol. 11, pp. 943-951, 2017.

- [93] N. A. Bakar, A. Abu-Siada, H. Cui e S. Li, "Improvement of DGA interpretation using scoring index method," *2017 1st International Conference on Electrical Materials and Power Equipment (ICEMPE)*, pp. 502-506, 2017.
- [94] J. Dai, H. Song, G. Sheng e X. Jiang, "Dissolved gas analysis of insulating oil for power transformer fault diagnosis with deep belief network," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 24, pp. 2828-2835, 2017.
- [95] S. A. Wani, S. A. Khan, Y. Vikram, C. Bhasker, S. Perneen e D. Gupta, "An improved dissolved gas analysis technique for incipient fault detection," *2017 3rd International Conference on Condition Assessment Techniques in Electrical Systems (CATCON)*, pp. 88-92, 2017.
- [96] R. M. A. Velásquez e J. V. M. Lara, "Expert system for power transformer diagnosis," *2017 IEEE XXIV International Conference on Electronics, Electrical Engineering and Computing (INTERCON)*, pp. 1-4, 2017.
- [97] J. Fan, F. Wang, Q. Sun, F. Bin, F. Liang e X. Xiao, "Hybrid RVM-ANFIS algorithm for transformer fault diagnosis," *IET Generation, Transmission & Distribution*, vol. 11, pp. 3637-3643, 2017.
- [98] K. O. Bachri, A. D. W. Sumari, B. A. Soedjarno e A. S. Ahmad, "The implementation of A3S information fusion algorithm for interpreting Dissolved Gas Analysis (DGA) based on Doernenburg Ratio," *2017 International Symposium on Electronics and Smart Devices (ISESD)*, pp. 335-340, 2017.
- [99] H. Dong, X. Yang e A. Li, "A Novel Method for Power Transformer Fault Diagnosis Based on Bat-BP Algorithm," *2018 International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC)*, pp. 566-569, 2018.
- [100] M. Chen, N. Xiao, M. J. Zuo e C. Zhou, "A Probabilistic Classifier for Transformer Dissolved Gas Analysis Using Various Input Variables," *2018 Prognostics and System Health Management Conference (PHM-Chongqing)*, pp. 506-510, 2018.
- [101] T. Kari, "An integrated method of ANFIS and Dempster-Shafer theory for fault diagnosis of power transformer," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 25, pp. 360-371, 2018.
- [102] M. M. Islam, G. Lee e S. N. Hettiwatte, "Application of Parzen Window estimation for incipient fault diagnosis in power transformers," *High Voltage*, vol. 3, pp. 303-309, 2018.
- [103] Y. Benmahamed, Y. Kemari, M. Teguar e A. Boubakeur, "Diagnosis of Power Transformer Oil Using KNN and Nave Bayes Classifiers," *2018 IEEE 2nd International Conference on Dielectrics (ICD)*, pp. 1-4, 2018.

- [104] Y. Benmahamed, M. Tegar e A. Boubakeur, "Diagnosis of Power Transformer Oil Using PSO-SVM and KNN Classifiers," *2018 International Conference on Electrical Sciences and Technologies in Maghreb (CISTEM)*, pp. 1-4, 2018.
- [105] Y. Liang, Y. Xu, X. Wan, Y. Li, N. Liu e G. Zhang, "Dissolved gas analysis of transformer oil based on Deep Belief Networks," *2018 12th International Conference on the Properties and Applications of Dielectric Materials (ICPADM)*, pp. 825-828, 2018.
- [106] M. Li, X. Liu, R. Li, R. Zheng e W. Zhao, "Fault Diagnosis of Transformer Based on Chaotic Bats Algorithm Optimizing Fuzzy Petri Net," *2018 2nd IEEE Advanced Information Management, Electronic and Automation Control Conference (IMCEC)*, pp. 885-889, 2018.
- [107] T. Kari, "Hybrid feature selection approach for power transformer fault diagnosis based on support vector machine and genetic algorithm," *IET Generation, Transmission & Distribution*, vol. 12, pp. 5672-5680, 2018.
- [108] A. Dhini, I. Surjandari, A. Faqih e B. Kusumoputro, "Intelligent Fault Diagnosis for Power Transformer Based on DGA Data Using Support Vector Machine (SVM)," *2018 3rd International Conference on System Reliability and Safety (ICSRS)*, pp. 294-298, 2018.
- [109] A. Basuki e Suwarno, "Online Dissolved Gas Analysis of Power Transformers Based on Decision Tree Model," *2018 Conference on Power Engineering and Renewable Energy (ICPERE)*, pp. 1-6, 2018.
- [110] O. E. Gouda, S. H. El-Hoshy e H. H. El-Tamaly, "Proposed heptagon graph for DGA interpretation of oil transformers," *IET Generation, Transmission & Distribution*, vol. 12, pp. 490-498, 2018.
- [111] O. E. Gouda, S. H. El-Hoshy e H. H. El-Tamaly, "Proposed three ratios technique for the interpretation of mineral oil transformers based dissolved gas analysis," *IET Generation, Transmission & Distribution*, vol. 12, pp. 2650-2661, 2018.
- [112] X. Huang, X. Wang e Y. Tian, "Research on Transformer Fault Diagnosis Method based on GWO Optimized Hybrid Kernel Extreme Learning Machine," *2018 Condition Monitoring and Diagnosis (CMD)*, pp. 1-5, 2018.
- [113] Y. Zhang, H. Peng, J. Fang, L. Zhao, X. Li e C. Liao, "Transformer fault diagnosis based on new features selection and artificial bee colony optimization SVM," *2018 International Conference on Power System Technology (POWERCON)*, pp. 3607-3613, 2018.
- [114] A. G. C. Menezes, O. M. Almeida e F. R. Barbosa, "Use of decision tree algorithms to diagnose incipient faults in power transformers," *2018 Simposio Brasileiro de Sistemas Eletricos (SBSE)*, pp. 1-6, 2018.

- [115] Y. Zhang, "A Fault Diagnosis Model of Power Transformers Based on Dissolved Gas Analysis Features Selection and Improved Krill Herd Algorithm Optimized Support Vector Machine," *IEEE Access*, vol. 7, pp. 102803-102811, 2019.
- [116] O. E. Gouda, S. H. El-Hoshy e H. H. El-Tamaly, "Condition assessment of power transformers based on dissolved gas analysis," *IET Generation, Transmission & Distribution*, vol. 13, pp. 2299-2310, 2019.
- [117] E. Li, L. Wang e B. Song, "Fault Diagnosis of Power Transformers With Membership Degree," *IEEE Access*, vol. 7, pp. 28791-28798, 2019.
- [118] K. Chatherjee, S. Dawn, V. K. Jadoun e R. K. Jarial, "Novel prediction-reliability based graphical DGA technique using multi-layer perceptron network & gas ratio combination algorithm," *IET Science, Measurement & Technology*, vol. 13, pp. 836-842, 2019.
- [119] P. J. Angeline, "Using selection to improve particle swarm optimization," *1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No.98TH8360)*, pp. 84-89, 1998.
- [120] M. Clerc, Particle Swarm Optimization, Great Britain and the United States: LAVOISIER, 2006.
- [121] J. Kennedy e R. Eberhart, "Particle swarm optimization," *Proceedings of ICNN'95 - International Conference on Neural Networks*, vol. 4, pp. 1942-1948, 1995.
- [122] M. R. Bonyadi e Z. Michalewicz, "Particle Swarm Optimization for Single Objective Continuous Space Problems: A Review," *Evolutionary Computation*, vol. 25, pp. 1-54, 2017.
- [123] J. Kennedy e R. C. Eberhart, "A discrete binary version of the particle swarm algorithm," *1997 IEEE International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation*, vol. 5, pp. 4104-4108, 1997.
- [124] J. Liu e X. Fan, "The Analysis and Improvement of Binary Particle Swarm Optimization," *2009 International Conference on Computational Intelligence and Security*, pp. 254-258, 2009.
- [125] J. A. Fabro, "Uma abordagem neuro-nebulosa para controle preditivo de processos multi-estágios," 2003.
- [126] M. T. Hagan, Neural Network Design (2da Ed), 2014.
- [127] G. Dreyfus, Neural Networks: Methodology and Applications, (1ra Ed), Springer, 2005.

- [128] P. Kim, *MATLAB Deep Learning: With Machine Learning, Neural Networks and Artificial Intelligence*, (1ra ed.), Apress, 2017.
- [129] K. Fukunaga e P. M. Narendra, "A branch and bound algorithm for computing k-nearest neighbors," *IEEE Transactions on Computers*, vol. 100, p. 750–753, 1975.
- [130] I. Balabanova, G. Georgiev, S. Kostadinova e R. Dimova, "Classification of teletraffic service devices by κ -NN, ANFIS and ANN classifiers," *2016 IEEE International Black Sea Conference on Communications and Networking (BlackSeaCom)*, pp. 1-5, 2016.
- [131] H. Li e L. Yang, "Analysis of Local-LDtree classifier based on K-nearest Neighbor algorithm," *2012 2nd International Conference on Consumer Electronics, Communications and Networks (CECNet)*, pp. 2392-2394, 2012.
- [132] T. M. Mitchell, *Machine learning*, McGraw-Hill Boston, MA: McGraw-Hill Science/Engineering/Math, 1997.
- [133] H. Yigit, "A weighting approach for KNN classifier," *2013 International Conference on Electronics, Computer and Computation (ICECCO)*, pp. 228-231, 2013.

ANEXOS

Anexo 1.1. variáveis de avaliação VP, registradas em artigos revisados 2011- 2019

Item	Relação de gás
1	$100 * C_2H_2 / (CH_4 + C_2H_2 + C_2H_4)$
2	$100 * C_2H_4 / (CH_4 + C_2H_2 + C_2H_4)$
3	$100 * CH_4 / (CH_4 + C_2H_2 + C_2H_4)$
4	$100 * H_2 / (CH_4 + C_2H_2 + C_2H_4 + H_2)$
5	$100 * C_2H_6 / (CH_4 + C_2H_2 + C_2H_4 + C_2H_6)$
6	$100 * H_2 / (H_2 + CH_4 + C_2H_2 + C_2H_4)$
7	$100 * CH_4 / (H_2 + CH_4 + C_2H_2 + C_2H_4)$
8	$100 * C_2H_2 / (H_2 + CH_4 + C_2H_2 + C_2H_4)$
9	$100 * C_2H_4 / (H_2 + CH_4 + C_2H_2 + C_2H_4)$
10	$100 * H_2 / (H_2 + C_2H_6)$
11	$100 * H_2 / (H_2 + CH_4 + C_2H_2 + C_2H_4 + C_2H_6)$
12	$100 * CH_4 / (H_2 + CH_4 + C_2H_2 + C_2H_4 + C_2H_6)$
13	$100 * C_2H_2 / (H_2 + CH_4 + C_2H_2 + C_2H_4 + C_2H_6)$
14	$100 * C_2H_4 / (H_2 + CH_4 + C_2H_2 + C_2H_4 + C_2H_6)$
15	$100 * C_2H_6 / (H_2 + CH_4 + C_2H_2 + C_2H_4 + C_2H_6)$
16	$100 * CH_4 / (CH_4 + C_2H_6 + C_2H_4 + C_2H_2) / (H_4 / (CH_4 + C_2H_6 + C_2H_4 + C_2H_2) + C_2H_2 / (H_2 + CH_4 + C_2H_6 + C_2H_4) + C_2H_4 / (H_2 + CH_4 + C_2H_6 + C_2H_2))$
17	$100 * C_2H_2 / (H_2 + CH_4 + C_2H_6 + C_2H_4) / (H_4 / (CH_4 + C_2H_6 + C_2H_4 + C_2H_2) + C_2H_2 / (H_2 + CH_4 + C_2H_6 + C_2H_4) + C_2H_4 / (H_2 + CH_4 + C_2H_6 + C_2H_2))$
18	$100 * C_2H_4 / (H_2 + CH_4 + C_2H_6 + C_2H_2) / (H_4 / (CH_4 + C_2H_6 + C_2H_4 + C_2H_2) + C_2H_2 / (H_2 + CH_4 + C_2H_6 + C_2H_4) + C_2H_4 / (H_2 + CH_4 + C_2H_6 + C_2H_2))$

Anexo 1.2. variáveis de avaliação VAD, registradas em artigos revisados 2011-2019

Item	Relação de gás
1	CH_4 / H_2
2	C_2H_2 / C_2H_4
3	C_2H_2 / CH_4
4	C_2H_6 / C_2H_2
5	C_2H_4 / C_2H_6
6	C_2H_2 / C_2H_6
7	C_2H_6 / CH_4
8	C_2H_4 / CH_4
9	C_2H_2 / H_2
10	CH_4 / C_2H_4
11	C_2H_6 / H_2
12	C_2H_4 / H_2
13	$C_2H_6 / (CH_4 + C_2H_2 + C_2H_4)$
14	$H_2 / (CH_4 + C_2H_2 + C_2H_4)$
15	C_2H_6

16	$\text{CH}_4 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4 + \text{C}_2\text{H}_6$
17	$\text{C}_2\text{H}_4 / \text{C}_2\text{H}_2$
18	$\text{C}_2\text{H}_6 / \text{C}_2\text{H}_4$
19	$(\text{C}_2\text{H}_6 + \text{C}_2\text{H}_4) / (\text{H}_2 + \text{C}_2\text{H}_2)$
20	$(\text{C}_2\text{H}_2 + \text{CH}_4) / \text{C}_2\text{H}_4$
21	H_2 / CH_4
22	$\text{H}_2 / \text{C}_2\text{H}_2$
23	$\text{H}_2 / \text{C}_2\text{H}_4$
24	$\text{H}_2 / \text{C}_2\text{H}_6$
25	$\text{CH}_4 / \text{C}_2\text{H}_2$
26	$\text{CH}_4 / \text{C}_2\text{H}_6$
27	$\text{C}_2\text{H}_4 / (\text{H}_2 + \text{CH}_4 + \text{C}_2\text{H}_6 + \text{C}_2\text{H}_2)$
28	$\text{CH}_4 / (\text{CH}_4 + \text{C}_2\text{H}_6 + \text{C}_2\text{H}_4 + \text{C}_2\text{H}_2) + \text{C}_2\text{H}_2 / (\text{H}_2 + \text{CH}_4 + \text{C}_2\text{H}_6 + \text{C}_2\text{H}_4) + \text{C}_2\text{H}_4 / (\text{H}_2 + \text{CH}_4 + \text{C}_2\text{H}_6 + \text{C}_2\text{H}_2)$

Anexo 1.3. variáveis de avaliação VNO1, registradas em artigos revisados 2011-2019

Item	Relação de gás
1	$\text{CH}_4 / (\text{CH}_4 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4)$
2	$\text{C}_2\text{H}_4 / (\text{CH}_4 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4)$
3	$\text{C}_2\text{H}_2 / (\text{CH}_4 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4)$
4	$\text{H}_2 / (\text{H}_2 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4)$
5	$\text{C}_2\text{H}_2 / (\text{H}_2 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4)$
6	$\text{C}_2\text{H}_4 / (\text{H}_2 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4)$
7	$\text{H}_2 / (\text{H}_2 + \text{CH}_4 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4 + \text{C}_2\text{H}_6)$
8	$\text{CH}_4 / (\text{H}_2 + \text{CH}_4 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4 + \text{C}_2\text{H}_6)$
9	$\text{C}_2\text{H}_2 / (\text{H}_2 + \text{CH}_4 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4 + \text{C}_2\text{H}_6)$
10	$\text{C}_2\text{H}_4 / (\text{H}_2 + \text{CH}_4 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4 + \text{C}_2\text{H}_6)$
11	$\text{C}_2\text{H}_6 / (\text{H}_2 + \text{CH}_4 + \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4 + \text{C}_2\text{H}_6)$
12	$\text{CH}_4 / (\text{CH}_4 + \text{C}_2\text{H}_6 + \text{C}_2\text{H}_4 + \text{C}_2\text{H}_2)$
13	$\text{C}_2\text{H}_2 / (\text{H}_2 + \text{CH}_4 + \text{C}_2\text{H}_6 + \text{C}_2\text{H}_4)$