



Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciências

Faculdade de Engenharia


Ramon Alves dos Santos

**Avaliação da Condição Operacional de  
Transformadores de Potência com *Health Index*  
utilizando Inteligência Computacional**

Rio de Janeiro  
2019

Ramon Alves dos Santos

**Avaliação da Condição Operacional de  
Transformadores de Potência com *Health Index*  
utilizando Inteligência Computacional**



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Orientadora: Prof.<sup>a</sup> Dr.<sup>a</sup> Nadia Nedjah

Orientadora: Prof.<sup>a</sup> Dr.<sup>a</sup> Luiza de Macedo Mourelle

Rio de Janeiro  
2019

CATALOGAÇÃO NA FONTE  
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

S237 Santos, Ramon Alves dos.  
Avaliação da condição operacional de transformadores de potência com health index utilizando inteligência computacional / Ramon Alves dos Santos. – 2019.  
93f.

Orientadoras: Nadia Nedjah, Luiza de Macedo Mourelle.  
Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.

1. Engenharia eletrônica - Teses. 2. Transformadores elétricos - Teses. 3. Inteligência computacional - Teses. 4. Inteligência coletiva - Teses. 5. Sistemas de controle inteligente - Teses. I. Nedjah, Nadia. II. Mourelle, Luiza de Macedo. III. Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia. IV. Título.

CDU 004.89:621.314

Bibliotecária: Júlia Vieira – CRB7/6022

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta tese, desde que citada a fonte.

---

Assinatura

---

Data

Ramon Alves dos Santos

# Avaliação da Condição Operacional de Transformadores de Potência com *Health Index* utilizando Inteligência Computacional

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Aprovado em: 28 de Agosto de 2019.

Banca Examinadora:

---

Prof.<sup>a</sup> Dr.<sup>a</sup> Nadia Nedjah (Orientadora)  
Faculdade de Engenharia, UERJ

---

Prof.<sup>a</sup> Dr.<sup>a</sup> Luiza de Macedo Mourelle (Orientadora)  
Faculdade de Engenharia, UERJ

---

Prof. Dr. Vitor Hugo Ferreira  
Escola de Engenharia, UFF

---

Prof. Dr. João Roberto de Toledo Quadros  
Escola de Informática e Computação, CEFET/RJ

Rio de Janeiro  
2019

## DEDICATÓRIA

Dedico este trabalho a mulher da minha vida, minha melhor amiga, meu amor, minha esposa Matuza de Souza Alves dos Santos, a qual, foi a maior incentivadora, para que eu realizasse e concluísse o mestrado, mesmo em meio a tantas dificuldades e problemas. A minha mãe, Rosana Alves dos Santos, e meu pai, Marcelo Francisco dos Santos, por serem mais que pais, verdadeiros amigos e estarem ao meu lado em todos os momentos, me dando todo suporte e me assistindo em tudo que fugisse às minhas capacidades. Aos meus avós e exemplos de vida, Marlene de Lima Alves e Manoel Geraldo Alves, os quais, mesmo sem instrução acadêmica alguma são verdadeiros mestres da vida, acreditando desde minha infância na educação como fator de transformação e obtenção de meus sonhos. A minha irmã Raquel Alves dos Santos, por hoje, mesmo distante, estar sempre orando pela minha vida e torcendo pelo meu sucesso. Amo muito todos vocês e não teria conseguido chegar até aqui, sem tê-los em minha vida!

## AGRADECIMENTOS

Agradeço a Jesus Cristo por até aqui ter me sustentado, tendo um plano em cada passo desta caminhada e colocando pessoas maravilhosas em minha vida.

Agradeço a minha esposa e minha família por serem o meu esteio, estando do meu lado nos momentos mais difíceis da minha caminhada, trazendo alegria, esperança, inspiração, amor e me incentivando a cada passo para não desistir de meu objetivo.

Às professoras Nadia Nedjah e Luiza de Macedo Mourelle, pela orientação, parceria no desenvolvimento desta dissertação de mestrado e ensinamentos que levarei por toda vida.

Agradeço aos pesquisadores Carlos Magno Rodrigues Vasquez, Helvio Jailson Azevedo Martins pela oportunidade de participar da equipe do Laboratório de Diagnóstico de Equipamentos de Alta Tensão (LABDIG) no Centro de Pesquisa de Energia Elétrica (CEPEL) da Eletrobras. Ao pesquisador Leonardo Bispo Torres pela co-orientação, conselhos e parceria na busca por uma solução para o problema de priorização de ativos de alta potência. A equipe do LABDIG pela amizade e ensinamentos.

Agradeço aos meus colegas de mestrado Alexandre Cardoso, Cesar Affonso, Joelmir Ramos, Luneque Del Rio, Pedro Albuquerque, Luigi Ribeiro, Reinaldo Gomes, Igor Santos e Tarso Mesquita, pela troca de conhecimentos, suporte técnico em diversos momentos, companheirismo e momentos de descontração.

Agradeço ao grande mestre e amigo, Arlei Fonseca Barcelos, pelas orientações, incentivos e conselhos, antes e durante esta caminhada, torcendo sempre pelo meu crescimento e sucesso.

Agradeço a Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ), ao Programa de Pós-Graduação em Engenharia Eletrônica (PEL) da Universidade do Estado do Rio de Janeiro (UERJ) e ao CEPEL, pelos recursos investidos e estrutura fornecida para desenvolvimento dessa pesquisa.

O temor do Senhor é o princípio da sabedoria; têm bom entendimento todos os que  
cumprem seus preceitos; o seu louvor subsiste para sempre.

*Salmos 111:10*

## RESUMO

SANTOS, Ramon Alves dos. *Avaliação da Condição Operacional de Transformadores de Potência com Health Index utilizando Inteligência Computacional*. 2019. 93f. Dissertação (Mestrado em Engenharia Eletrônica) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2019.

O gerenciamento, técnico e financeiro, de subestações de potência passa pela avaliação da condição operacional de transformadores. A avaliação é um estágio essencial para a manutenção do fornecimento de energia elétrica e eficiência na aplicação dos recursos, por guiar o processo de manutenção ou atualização de um parque de transformadores. Este processo visa identificar os ativos com condição operacional crítica em uma subestação, os quais podem oferecer riscos para os operadores, equipamentos instalados e clientes. A utilização de técnicas de inteligência computacional tem por objetivo auxiliar o processo de avaliação, que não é simples por necessitar compor ensaios, os quais avaliam distintos sistemas de um transformador de potência. Associa-se, aos ensaios de avaliação, um conhecimento técnico profundo sobre ensaios químicos, elétricos e físicos para inferir um diagnóstico. Dessa forma, técnicas de inteligência computacional reduzem a necessidade do fator humano, uma vez que são capazes de extrair padrões de informações conhecidas ou otimizar processos para identificação de ativos críticos. Nesta dissertação, são aplicadas técnicas de inteligência computacional objetivando compor um índice numérico, *Health Index* ou índice de saúde, para priorização de ativos. A priorização pode apresentar o estado operacional de um ativo com a classificação por níveis de criticidade ou por meio de uma ordenação, em um conjunto de ativos. As informações referentes aos ensaios utilizados para composição do índice estão dispostas em periódicos, sendo fruto de medições em transformadores reais. Nesta dissertação, são exploradas especialmente técnicas de inteligência coletiva para a composição do índice de saúde, visto que, até o início desta dissertação, não havia publicações com a aplicação destas técnicas na resolução do problema. Com o desenvolvimento desta dissertação, busca-se o conjunto de métodos mais adequados para apoiar a tomada de decisão na priorização de ativos. A eficácia dos métodos propostos é avaliada, buscando-se estratégias que agreguem a maior flexibilidade, simplicidade e alta taxa de acurácia na priorização dos ativos.

Palavras-chave: Transformadores; diagnóstico; estado operacional; inteligência computacional; inteligência coletiva; ensaios; *health index*; níveis de criticidade; ordenação.



## ABSTRACT

SANTOS, Ramon Alves dos. *Evaluation of the Operational Condition of Power Transformers with Health Index using Computational Intelligence*. 2019. 93f. Dissertação (Mestrado em Engenharia Eletrônica) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2019.

The technical and financial management of power substations involves the evaluation of the operational condition of power transformers. Evaluation is an essential stage for maintaining electricity supply and resource efficiency by guiding the process of maintaining or upgrading a transformers park. This process aims at identifying assets with critical operational condition in a substation that may pose risks to operators, installed equipments and customers. The use of computational intelligence techniques aims at assisting the evaluation process, which is not simple because it requires composing measurements, that evaluate different systems of a power transformer. A deep technical knowledge of chemical, electrical and physical measurements is necessary to infer a diagnosis. Thus, computational intelligence techniques reduce the need for the human factor, since they are able to extract patterns of known information or optimize processes for identifying critical assets. In this dissertation, computational intelligence techniques are applied aiming at composing a numerical index, designated Health Index, for asset prioritization. Prioritization can present the operating state of one asset through the classification based on criticality levels or through an ordination in a set of assets. Information regarding the measurements used to compose the index is available in periodicals, based on measurements in real transformers. In this dissertation, techniques of swarm intelligence are specially explored for the composition of the health index, since, until the beginning of this dissertation, there were no publications with the application of these techniques to solve the prioritization problem. With the development of this dissertation, we seek the most appropriate set of methods to support decision making in prioritizing assets. The effectiveness of the proposed methods is evaluated, seeking strategies that add greater flexibility, simplicity and high accuracy rate in the prioritization of assets.

Keywords: Power transformers; diagnosis; operational condition; computational intelligence; swarm intelligence; measurements; health index; criticality levels; ordination.

## LISTA DE FIGURAS

1	Modelo de neurônio artificial . . . . .	28
2	Arquitetura de rede neural Perceptron de múltiplas camadas . . . . .	29
3	Ciclo de evolução usado em algoritmo genético. . . . .	33
4	Exemplo de sistema de controle de velocidade, utilizando sistema <i>fuzzy</i> . .	36
5	Análise estatística para a base de dados preliminar utilizada . . . . .	37
6	Processo otimização RNK com PSO . . . . .	42
7	Representação Regra 1 para RNK . . . . .	43
8	Representação Regra 2 para RNK . . . . .	43
9	Análise estatística realizada para a base de dados sem tratamento . . . . .	44
10	Análise estatística realizada para a base de dados filtrada . . . . .	45
11	Análise estatística realizada para a base de dados filtrada e normalizada .	45
12	Metodologia de aproximação com priorização do especialista . . . . .	46
13	Modelo de neurônio artificial . . . . .	47
14	Acurácia média (%) utilizando PSO com base de dados sem filtragem . . .	50
15	Acurácia média (%) utilizando PSO com base de dados filtrada . . . . .	50
16	Acurácia com base de dados filtrada utilizando algoritmo PSO . . . . .	51
17	Fronteira de Pareto obtida com a aplicação do algoritmo MOPSO . . . . .	51
18	Aplicação de clusterização evolucionária em base de dados sem filtragem .	52
19	Divisão de classes com clusterização evolucionária após filtragem dos dados	52
20	Aproximação alcançada para HI com a aplicação de AG . . . . .	54
21	Acurácia média (%) alcançada para classificação de ativos . . . . .	56
22	Tempo de convergência médio ( <i>s</i> ) alcançado na etapa de classificação de ativos . . . . .	57
23	Acurácia média (%) alcançada com aumento de dados . . . . .	58
24	Tempo de convergência médio ( <i>s</i> ) alcançado na classificação de ativos . . .	59
25	Ativação dos neurônios por cada classe de ativos no treinamento . . . . .	61
26	Ativação dos neurônios por cada classe de ativos no teste. . . . .	61
27	Fluxo de tratamento de dados para ordenação de ativos críticos. . . . .	62
28	Melhor resultado para ordenação de transformadores . . . . .	63
29	Acurácia utilizando algoritmo PSO canônico e com VNL . . . . .	64
30	Estratégia para composição do <i>Health Index</i> com valoração não linear . . .	64
31	Acurácia alcançada utilizando o algoritmo PSO com função de ativação. .	65
32	Aproximação HI com composição de erros, utilizando PSO . . . . .	67
33	Aproximação do HI com MSE, utilizando PSO . . . . .	67

## LISTA DE TABELAS

1	Valores médios estimados para HI, utilizando AG . . . . .	54
2	Acurácia média (%) . . . . .	55
3	Desvio padrão ( $\sigma$ ) dos valores encontrados para acurácia média (%) . . . . .	55
4	Tempo de convergência médio ( $s$ ) . . . . .	56
5	Desvio padrão ( $\sigma$ ) do tempo de convergência médio ( $s$ ) . . . . .	56
6	Acurácia média (%) . . . . .	57
7	Desvio padrão ( $\sigma$ ) da acurácia média (%) . . . . .	57
8	Tempo de convergência médio ( $s$ ) . . . . .	58
9	Desvio padrão ( $\sigma$ ) do tempo de convergência médio ( $s$ ) . . . . .	58
10	Parâmetros utilizados e resultados alcançados com rede neural MLP . . . . .	66

## LISTA DE ALGORITMOS

1	Pseudocódigo do algoritmo PSO . . . . .	23
2	Pseudocódigo do algoritmo MOPSO . . . . .	25
3	Pseudocódigo algoritmo EHO . . . . .	27
4	Função de Custo para CE . . . . .	34
5	Algoritmo principal CE, utilizando AG . . . . .	34

## LISTA DE SIGLAS

2-FAL	Análise de 2-Furfuraldeído
ACO	<i>Ant Colony Optimization</i>
AG	Algoritmo Genético
AGD	Análise de Gases Dissolvidos
AHP	<i>Analytic Hierarchy Process</i>
ASTM	<i>American Society for Testing and Materials</i>
BCO	<i>Bee Colony Optimization</i>
BFO	<i>Bacterial Foraging Optimization</i>
CE	Clusterização Evolucionária
CEGB	<i>Central Electricity Generating Board</i>
DE	<i>Differential Evolution</i>
DS	Distância de Superlotação
EHO	<i>Elephant Herding Optimization</i>
FA	<i>Firefly Algorithm</i>
FIS	<i>Fuzzy Inference System</i>
FSVM	<i>Fuzzy Support Vector Machine</i>
HI	<i>Health Index</i>
IEC	<i>International Electrotechnical Commission</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
K-NN	<i>K-Nearest Neighbor Classifier Method</i>
LDA	<i>Linear Discriminant Analysis</i>
LTC	<i>Load Tap Changer</i>
LVI	<i>Low Voltage Impulse</i>
MLP	<i>Multilayer Perceptron</i>

## Lista de Siglas

---

MOPSO *Multi-Objective Particle Swarm Optimization*

MR Melhor Resultado

MSE *Mean Square Error*

NI Número de Indivíduos

NP-Hard *Non Deterministic Polynomial Time-Hard*

ONS Operador Nacional do Sistema

PCA *Principal Component Analysis*

PDC *Polarization and Depolarization Current*

PSHI *Power System Health Index*

PSO *Particle Swarm Optimization*

RNK Rede Neural de Kohonen

RVM *Recovery Voltage Measurements*

SGLDM *Spatial Gray Level Dependence Matrix*

SIN Sistema Interligado Nacional

SMOTE *Synthetic Minority Over-sampling Technique*

SOM *Self Organizing Map*

TAP *Tap changer*

TVE *Total Vector Error*

VNL Valoração Não Linear

## SUMÁRIO

INTRODUÇÃO . . . . .	1
<b>1</b> <b>ENSAIOS DE AVALIAÇÃO PARA TRANSFORMADORES . .</b>	<b>4</b>
<b>1.1</b> <b>Ensaio Preliminares . . . . .</b>	<b>4</b>
1.1.1 <u>Análise da concentração de umidade . . . . .</u>	5
1.1.2 <u>Análise da concentração de acidez . . . . .</u>	5
1.1.3 <u>Tensão de ruptura . . . . .</u>	5
1.1.4 <u>Tensão interfacial . . . . .</u>	6
1.1.5 <u>Análise de gases dissolvidos . . . . .</u>	6
1.1.6 <u>Análise de concentração de 2-furfuraldeído . . . . .</u>	6
<b>1.2</b> <b>Ensaio Complementares . . . . .</b>	<b>7</b>
1.2.1 <u>Fator de dissipação e fator de potência . . . . .</u>	7
1.2.2 <u>Corrente de excitação . . . . .</u>	7
1.2.3 <u>Impedância de curto-circuito . . . . .</u>	7
1.2.4 <u>Relação de transformação. . . . .</u>	8
1.2.5 <u>Resistência dos enrolamentos . . . . .</u>	8
1.2.6 <u>Resistência entre núcleo e terra. . . . .</u>	8
<b>1.3</b> <b>Ensaio Especiais . . . . .</b>	<b>9</b>
1.3.1 <u>Análise de resposta em frequência . . . . .</u>	9
1.3.2 <u>Análise de descargas parciais . . . . .</u>	9
1.3.3 <u>Ensaio de tensão de retorno. . . . .</u>	10
1.3.4 <u>Ensaio de corrente de polarização e despolarização . . . . .</u>	10
<b>1.4</b> <b>Considerações Finais. . . . .</b>	<b>10</b>
<b>2</b> <b>TRABALHOS RELACIONADOS. . . . .</b>	<b>11</b>
<b>2.1</b> <b>Métodos Analíticos . . . . .</b>	<b>11</b>
2.1.1 <u>Técnicas determinísticas . . . . .</u>	11
2.1.2 <u>Técnicas probabilísticas . . . . .</u>	14
<b>2.2</b> <b>Métodos de Inteligência Computacional . . . . .</b>	<b>16</b>
2.2.1 <u>Técnicas baseadas em aprendizagem. . . . .</u>	16
2.2.2 <u>Técnicas baseadas em lógica nebulosa. . . . .</u>	17
2.2.3 <u>Técnicas baseadas em otimização. . . . .</u>	18
2.2.4 <u>Métodos híbridos . . . . .</u>	19
<b>2.3</b> <b>Considerações Finais. . . . .</b>	<b>21</b>
<b>3</b> <b>TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL UTILI-</b>	
<b>ZADAS. . . . .</b>	<b>22</b>
<b>3.1</b> <b>Otimização por Enxame de Partículas. . . . .</b>	<b>22</b>
3.1.1 <u>PSO mono-objetivo. . . . .</u>	22

## SUMÁRIO

3.1.2	PSO multi-objetivo. . . . .	24
<b>3.2</b>	<b>Otimização por Manada de Elefantes . . . . .</b>	<b>26</b>
<b>3.3</b>	<b>Redes Neurais Artificiais. . . . .</b>	<b>27</b>
3.3.1	Rede neural Perceptron de múltiplas camadas . . . . .	28
3.3.2	Rede neural de Kohonen . . . . .	30
<b>3.4</b>	<b>Algoritmo Genético. . . . .</b>	<b>31</b>
<b>3.5</b>	<b>Clusterização Evolucionária. . . . .</b>	<b>33</b>
<b>3.6</b>	<b>Lógica Nebulosa . . . . .</b>	<b>35</b>
<b>3.7</b>	<b>Considerações Finais. . . . .</b>	<b>36</b>
<b>4</b>	<b>MÉTODO PROPOSTO . . . . .</b>	<b>37</b>
4.1	Análise Preliminar . . . . .	37
4.2	Priorização por Níveis de Criticidade . . . . .	40
4.3	Ordenação de Ativos de Alta Potência . . . . .	44
4.4	Considerações Finais. . . . .	48
<b>5</b>	<b>EXPERIMENTOS E RESULTADOS . . . . .</b>	<b>49</b>
5.1	Resultado Preliminar . . . . .	49
5.2	Resultado da Classificação de Ativos. . . . .	54
5.3	Resultados de Ordenação de Ativos. . . . .	62
5.4	Considerações Finais. . . . .	67
<b>6</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS . . . . .</b>	<b>68</b>
6.1	Conclusões . . . . .	68
6.2	Trabalhos Futuros. . . . .	70
	<b>REFERÊNCIAS . . . . .</b>	<b>71</b>
	<b>APÊNDICE - BASE DE DADOS . . . . .</b>	<b>78</b>



# INTRODUÇÃO

**P**OR vezes, aportes financeiros são injetados em subestações para manutenções preventivas, corretivas ou mesmo para a atualização de parte dos transformadores, visando aumento da capacidade de fornecimento. A aplicação desse investimento deve ter máxima eficiência. O passo fundamental, para realizar uma escolha acertiva, é obter o pleno conhecimento quanto à condição operacional dos ativos.

O conhecimento acerca dos equipamentos instalados, em muitas situações, está vinculado ao conhecimento tácito de responsáveis técnicos e a ensaios de avaliação da condição operacional. As informações passam pelo fator humano para avaliação. Na avaliação, é demandado do profissional um conhecimento profundo sobre todos os ensaios químicos, elétricos e físicos, bem como suas relações para concluir um diagnóstico. O profissional responsável deve possuir a capacidade de julgar o comportamento de componentes chave, podendo indicar uma falha, falta, ou mesmo, a condição de operação normal do ativo. A avaliação e composição entre os ensaios, aliada à experiência dos responsáveis, é essencial. Por vezes, não existe um consenso na composição de informações técnicas no processo de avaliação, não sendo trivial a priorização de ativos.

A avaliação do estado operacional de transformadores de potência é um fator relevante, porque estes são os equipamentos instalados com maior importância em uma subestação, correspondendo a cerca de 60% do capital investido (JAHROMI et al., 2009). Realizou-se uma estimativa entre as empresas do grupo Eletrobras e, em uma subestação, o custo de um transformador de potência, com níveis de tensão de 500kV/138kV/13,8kV com potência de 200MVA, pode chegar a mais de R\$5.000.000,00.

A falha de ativos de alta potência pode ser desastrosa e resultar em custos diretos e indiretos para os setores industrial, comercial e residencial, superando em muitos casos o valor do ativo (WANG; VANDERMAAR; SRIVASTAVA, 2002). A interrupção no fornecimento de energia elétrica pode ainda ter efeito negativo sobre a vida social dos usuários (ABU-ELANIEN; SALAMA, 2010).

Os relatórios de desempenho do SIN (Sistema Interligado Nacional) disponibilizados pelo ONS (Operador Nacional do Sistema), nos anos de 2012 a 2015, apontaram um aumento ascendente no indicador de perturbações da rede básica. Uma redução em 1,57% no ano de 2016 foi detectada, todavia, manteve-se um número total de 3201 perturbações (ONS, 2017). Os indicativos apontam um sinal de alerta, podendo, com a utilização de metodologias alternativas, realizar a mitigação e controle dos níveis de perturbação.

Dessa forma, fatores, como a importância dos ativos, a dificuldade de estabelecer uma relação entre os ensaios e a carência de ferramentas para apoio a tomada de decisão, motivaram o estudo. Nesta dissertação, verifica-se como oportunidade a aplicação de técnicas de inteligência computacional na composição de um índice numérico, que represente a condição do ativo. Este índice é definido como *Health Index* (HI). O HI é composto com ensaios de avaliação para cada transformador. Com o valor obtido com o HI otimizado espera-se ser possível determinar a priorização por condição operacional, para cada ativo, e realizar a ordenação do conjunto de ativos avaliados.

A utilização de técnicas baseadas em inteligência computacional visa aumentar a capacidade de extrair relações entre os ensaios na composição do HI. As técnicas de otimização realizarão a exploração de um espaço de busca multi-dimensional. Cada possível solução contará com um vetor ótimo de pesos para a composição no HI. Comparativamente, diferentes técnicas de inteligência computacional serão aplicadas, verificando o desempenho apresentado em cada um dos processos. Como parâmetro para avaliação da qualidade das soluções, será utilizado um conjunto controle. Este conjunto conterá informações de cada ensaio, a condição operacional do ativo e uma ordenação fornecida por especialistas, baseada na condição real dos equipamentos. Com a extração de informações é possível realizar o processo de composição do HI. Com o método de priorização composto, novas informações poderão ser inseridas, estimando através do índice de saúde a condição operacional do ativo.

O objetivo deste trabalho é facilitar o processo de priorização de ativos por níveis de criticidade ou ordenação, com a utilização de técnicas de inteligência computacional. Busca-se ainda a verificação de resultados para composição do HI, com técnicas baseadas em inteligência coletiva. Esta verificação permite trazer uma contribuição à comunidade acadêmica, já que, a literatura apresentava somente a aplicação de redes neurais (ABU-ELANIEN; SALAMA; IBRAHIM, 2011), lógica nebulosa (ABU-ELANIEN; SALAMA; IBRAHIM,

2012) e algoritmo genético (MARTINS et al., 2016) na composição do HI, antes desta dissertação. Ao fim, espera-se alcançar uma solução simples com modelo aberto, por meio da estratégia mais adequada à otimização dos pesos do HI. Esta estratégia deverá ser comparada a outras técnicas e, tornando-se necessária a combinação com modelos de complexidade mais elevada, poderão ser propostos métodos híbridos.

O restante desta dissertação está organizado em seis capítulos. No Capítulo 1, são introduzidos os principais ensaios de avaliação de transformadores de potência. Dividindo-os, para melhor compreensão, em ensaios preliminares, complementares e especiais, de acordo com o nível de complexidade para a sua consecução.

O Capítulo 2 discorre sobre o estado da arte dos principais métodos de priorização encontrados na literatura. As seções são divididas em soluções baseadas em técnicas: determinísticas, probabilísticas, baseadas em aprendizagem, lógica nebulosa, métodos de otimização e métodos híbridos.

O Capítulo 3 aborda as principais técnicas de inteligência computacional empregadas neste projeto. Em cada seção abordada, um breve panorama teórico, quanto ao seu funcionamento, é descrito. Nas seções, apresentam-se técnicas de inteligência computacional baseadas em: otimização meta-heurística, aprendizagem, agrupamento e lógica nebulosa.

O Capítulo 4 apresenta o método proposto para priorização de ativos de alta potência. Inicialmente, uma análise preliminar é executada. Em seguida, os métodos para priorização por níveis de criticidade são experimentados e a metodologia para ordenação de ativos é descrita.

O Capítulo 5 apresenta os resultados obtidos no processo de experimentação. Os resultados são, então, contextualizados e discutidos. Os parâmetros dos principais algoritmos são apresentados, bem como os caminhos necessários para alcançar resultados promissores.

Por fim, o Capítulo 6 apresenta as conclusões obtidas com a consecução desta dissertação. Neste capítulo, são analisados e comentados os principais resultados, acertos e possíveis melhorias, descritas na seção de trabalhos futuros.

# Capítulo 1

## ENSAIOS DE AVALIAÇÃO PARA TRANSFORMADORES

**A**VALIAR a condição operacional de transformadores de potência é uma etapa essencial para a manutenção do fornecimento de energia elétrica. Neste cenário surgem diversas formas de mensurar o envelhecimento dos sistemas constituintes de transformadores de potência. A Seção 1.1 aborda os ensaios preliminares de avaliação para transformadores de potência. A Seção 1.2 trata dos ensaios complementares, possuindo maior exatidão nos diagnósticos porém necessitando de desconexão dos equipamentos da rede. A Seção 1.3 aborda os principais ensaios especiais utilizados para localização de falhas e verificação de sua gravidade. Na Seção 1.4 são apresentadas as considerações finais deste capítulo.

### 1.1 Ensaios Preliminares

A verificação da qualidade do óleo isolante é uma etapa fundamental para a determinação da condição do isolamento líquido e sólido do transformador. Os ensaios responsáveis pela verificação da qualidade de óleo isolante constituem os ensaios preliminares. Os principais ensaios preliminares são: análise da concentração de umidade, acidez, tensão de ruptura, tensão interfacial, fator de dissipação, análise de gases dissolvidos em óleo e análise de concentração de 2-furfuraldeído. Esses ensaios são rotineiramente utilizados pelas equipes de manutenção, por não necessitarem do desligamento do transformador. Para realização destes ensaios uma amostra de óleo pode ser coletada com o equipamento energizado, realizando os respectivos ensaios em laboratório ou em campo com equipamento portátil.

### 1.1.1 Análise da concentração de umidade

Durante o processo de fabricação, transformadores de potência tem como padrão a variação da concentração de umidade no isolamento de 0,5% a 1%. Com a entrada ou aumento da concentração de umidade da atmosfera ocorre a degradação do equipamento (HIRST et al., 2013). As normas IEC (*International Electrotechnical Commission*) 60814 e ASTM (*American Society for Testing and Materials*) D1533, com o Método de Titulação Karl Fisher, determinam as metodologias de avaliação da concentração de umidade. A unidade de concentração de umidade em óleo isolante é comumente apresentada em ppm (partes por milhão) ou  $\mu\text{l/l}$  (LEWAND, 2002). A determinação deste ensaio tem alta importância por ser um dos principais fatores de aceleração do processo de envelhecimento do isolamento sólido e líquido, reduzindo a capacidade dielétrica.

### 1.1.2 Análise da concentração de acidez

A produção de ácidos no isolamento de transformadores de potência advém do processo de oxidação. Neste processo, hidrocarbonetos presentes no óleo reagem com o ar dissolvido, gerando ácidos carboxílicos (ERDMAN, 1988). A concentração de ácidos no ativo é mensurada por titulação química normatizada pela IEC 62021-1, IEC 62021-2 e ASTM D1534. A medida é apresentada em mg de KOH/g (FENWICK et al., 2012). O aumento da concentração de acidez no óleo isolante ocorre devido a períodos extensos em sobrecarga. Este ensaio é um indicativo do processo de deterioração do papel isolante (WAHAB et al., 1999).

### 1.1.3 Tensão de ruptura

A tensão de ruptura é uma medida que visa verificar a suportabilidade dielétrica do óleo isolante. Esse ensaio apresenta valores significativamente altos quando o óleo está sem a presença de contaminantes como água e partículas sólidas (HIRST et al., 2013). O procedimento é normatizado segundo a IEC 60156 e ASTM D1816. No ensaio é verificada a tensão de ruptura da amostra de óleo em ambientes com temperatura controlada normatizada em faixas que variam de 20°C a 30°C, com abertura entre os eletrodos de 1 mm (HIRST et al., 2013). A baixa suportabilidade dielétrica pode ocasionar o aumento de descargas parciais, acelerando o processo de envelhecimento do transformador (ABU-ELANIEN; SALAMA; IBRAHIM, 2012).

### 1.1.4 Tensão interfacial

Na interface de separação de dois líquidos imiscíveis ou entre um líquido e um gás, forma-se uma força de atração entre as moléculas, denominada tensão interfacial. A verificação da tensão interfacial visa fornecer um meio sensível para detectar pequenas quantidades de contaminantes polares solúveis no óleo isolante, bem como produtos oriundos do processo de oxidação. Quanto mais baixo o valor de tensão interfacial obtido no ensaio, maior a oxidação, contaminação e diminuição da capacidade dielétrica do óleo isolante. Os ensaios podem ser conduzidos em laboratório de acordo com a norma ASTM D-971 ou em campo seguindo os procedimentos da norma ASTM 2285-85 (TRAIN et al., 1995).

### 1.1.5 Análise de gases dissolvidos

A análise de gases dissolvidos (AGD) em óleo isolante ou cromatografia gasosa é um dos ensaios mais importantes, responsável por indicar a evolução de gases combustíveis. A presença destes gases no processo de operação normal de um transformador é comum, todavia com o aumento de sua concentração, pode se tornar um indicativo de falha ou envelhecimento (KACHLER; HOHLEIN, 2005). As avaliações podem ser realizadas através de metodologias, como as relações gasosas de Rogers, Dornenburg, Triângulo de Duval, Critério da CEGB (*Central Electricity Generating Board*), Método de Laborelec, entre outros. Estes métodos caracterizam tipos de falhas dentro de transformadores pela concentração de gases chaves (ABU-ELANIEN; SALAMA; IBRAHIM, 2012). Nesta dissertação é utilizada a concentração total dos gases:  $H_2$ ,  $CH_4$ ,  $C_2H_4$ ,  $C_2H_2$  e  $C_2H_6$ , para a determinação da condição operacional.

### 1.1.6 Análise de concentração de 2-furfuraldeído

A análise de 2-furfuraldeído (2-FAL) é uma análise extremamente importante na avaliação da condição do isolamento sólido do equipamento (PRADHAN; RAMU, 2004). Essa técnica é responsável por mensurar a concentração de cadeias de aldeídos no óleo isolante. Por sua vez, a quebra das cadeias de aldeídos são fruto do envelhecimento do papel isolante. O aumento da concentração de aldeídos no óleo isolante, indica a perda de propriedades mecânicas do papel, gerando uma situação favorável ao aumento de descargas parciais e aceleração do processo de envelhecimento (BOLHUIS; GULSKI; SMIT, 2002).

## 1.2 Ensaio Complementares

Os ensaios complementares são ensaios que demandam o desligamento do ativo por um período de tempo para ocorrerem. Todavia, por ser necessária a interrupção do fornecimento de energia pelo ativo, são realizados apenas quando os ensaios preliminares não são suficientes ou conclusivos para determinação da falha.

### 1.2.1 Fator de dissipação e fator de potência

A verificação do fator de dissipação, visa quantificar o nível de energia perdido no óleo do transformador durante sua operação (ABU-ELANIEN; SALAMA; IBRAHIM, 2012). O ensaio é conduzido segundo a norma IEC 60247 e ASTM D-924. A verificação da dissipação de energia no óleo isolante é importante, por esta ocorrer em forma de dissipação térmica, o que acelera o processo de envelhecimento do ativo.

A verificação do fator de potência tem metodologia semelhante, todavia, esta analisa a energia que efetivamente é entregue. Com o ensaio é possível ter parâmetros quanto a integridade do isolamento dos enrolamentos, buchas, para-raios, tanque e óleo isolante (ZHANG; GOCKENBACH, 2008).

### 1.2.2 Corrente de excitação

Esse ensaio tem o objetivo de diagnosticar curtos-circuitos nos enrolamentos, conexões elétrica danificadas, delaminações, curtos no núcleo e problemas nos dispositivos de comutação do TAP (*Tap changer*). Essas condições influem na relutância efetiva do circuito magnético, o que por sua vez alterará a corrente necessária para forçar um determinado fluxo através do núcleo (TRAIN et al., 1995). O ensaio compreende a medida de corrente em cada uma das fases do transformador. A determinação da corrente de excitação é tipicamente realizada no lado de alta tensão, com o lado de baixa em aberto e o neutro aterrado. Deve ser utilizada a máxima tensão de teste possível sem exceder a tensão nominal do enrolamento excitado. Os ensaios são sempre repetidos com os mesmos valores de tensão e utilizando as mesmas conexões, para fins de comparação. Sempre que possível são excluídas das medições correntes capacitivas, existentes entre o enrolamento excitado e o núcleo, tanque ou outro enrolamento do transformador.

### 1.2.3 Impedância de curto-circuito

A determinação da impedância de curto-circuito é normatizado pelo padrão IEEE (*Institute of Electrical and Electronics Engineers*) C57.12.90 (ANTOSZ et al., 2017). Esse ensaio

determina possíveis movimentos nos enrolamentos, que podem ter ocorrido desde os testes realizados na fábrica. O resultado desse ensaio pode ser comparado com os dados encontrados na placa de identificação do transformador ou valores de fábrica. A movimentação dos enrolamentos pode indicar danos ocasionados devido a uma intensa corrente em alguma falha, ou mesmo danos mecânicos ocasionados durante o transporte ou instalação do ativo. As medidas são realizadas uma fase por vez, não devendo a impedância de curto-circuito ultrapassar  $\pm 3\%$  dos valores nominais.

#### 1.2.4 Relação de transformação

O ensaio de determinação da relação de transformação de ativos visa indicar a presença de enrolamentos em curto ou em aberto. A medida da relação de espiras deve ser realizada em todos os enrolamentos, e caso o transformador seja dotado de LTC (*Load Tap Changer*), todas as suas derivações devem ter o número de espiras determinado (ZHANG; GOCKENBACH, 2008). As relações de espiras podem ser comparadas com dados do fabricante, devendo estar dentro de  $0,5\%$  dos valores nominais para todos os enrolamentos.

#### 1.2.5 Resistência dos enrolamentos

A medição da resistência dos enrolamentos é utilizada para verificação de anormalidades devido a conexões soltas, enrolamentos danificados, alta resistência nos contatos e verificação das condições das derivações do TAP (WANG; VANDERMAAR; SRIVASTAVA, 2002). Para realização do ensaio são utilizados ohmímetros capazes de medir em faixas de 20 ohms a algumas frações de ohms. O ensaio pode ter a resistência do enrolamento determinada de forma indireta pela relação de tensão e corrente, com a utilização de voltmímetros, amperímetros e uma fonte de tensão externa controlada. Os valores obtidos no ensaio variam de acordo com a temperatura do óleo isolante, sendo necessário a medição para respectivas conversões e comparações. Podendo estas comparações serem realizadas com dados de fábrica tendo uma tolerância de  $\pm 5\%$  (ZHANG; GOCKENBACH, 2008).

#### 1.2.6 Resistência entre núcleo e terra

O ensaio de resistência entre núcleo e terra é complementar à análise de gases dissolvidos em óleo isolante. Quando uma evolução de gases chave ocorre, este ensaio pode localizar a origem do problema (ZHANG; GOCKENBACH, 2008). A determinação da resistência entre núcleo e terra visa detectar, se o aterramento pode estar solto ou mesmo em falso. No



desenvolvimento do ensaio deve-se desconectar o aterramento do tanque do transformador, e em seguida medir a resistência entre núcleo e terra. Caso o transformador estiver com o aterramento do núcleo em bom estado a medida de resistência apresentará um valor muito baixo.

## 1.3 Ensaios Especiais

A etapa final de diagnóstico não destrutiva para transformadores de potência faz utilização de ensaios especiais. Estes ensaios podem diagnosticar, localizar e obter a gravidade de uma falha. Assim, após a aplicação desses ensaios novas estratégias de correção podem ser empregadas.

### 1.3.1 Análise de resposta em frequência

O primeiro trabalho a propor a análise de resposta em frequência aplicado a transformadores de potência ocorreu em (DICK; ERVEN, 1978). Esta técnica visa a caracterização do transformador no espectro de frequência, obtendo uma assinatura do comportamento dos seus enrolamentos. Com esse ensaio é possível verificar, em quais frequências ocorrem ressonâncias, e quais as suas amplitudes. São empregados para a realização desse ensaio dois métodos distintos de avaliação. O primeiro método compreende a medição das impedâncias terminais em função da frequência (DICK; ERVEN, 1978). O segundo método compreende a resposta em frequência obtida a partir de ensaios com impulsos de baixa tensão conhecidos pela sigla LVI (*Low Voltage Impulse*). Neste, é verificada a transferência de tensão do sinal entre os terminais de baixa e alta tensão, com a variação da frequência, por meio da transformada de Fourier (VAESSEN; HANIQUE, 1992).

### 1.3.2 Análise de descargas parciais

A análise de descargas parciais é um ensaio normatizado pela IEC-60270. Esta norma define por descarga parcial “uma descarga elétrica localizada, a qual atravessa parcialmente o isolamento entre condutores e que pode ou não ocorrer próxima ao condutor” (LEMKE et al., 2008). A presença de descargas parciais na operação do transformador é danosa tanto para o isolamento sólido como para o isolamento líquido. A análise do problema se dá pelo método de emissão acústica e-ou pelo método eletromagnético. O ensaio por emissão acústica apresenta resultados mais confiáveis por não sofrer interferência eletromagnética, sendo utilizado principalmente quando é necessária a avaliação do ativo em campo.

### 1.3.3 Ensaios de tensão de retorno

O ensaio de tensão de retorno comumente associado a sigla de identificação RVM (*Recovery Voltage Measurements*) constitui um espectro de polarização do transformador. Esse objetiva estimar o envelhecimento no papel isolante e a quantidade de umidade presente no isolamento (BOLHUIS et al., 1999). O espectro de polarização para um transformador saudável deve possuir um máximo e por consequência uma constante de tempo associada a esta polarização máxima. A magnitude da constante de tempo principal, pode ser influenciada pela umidade no isolamento, envelhecimento do papel isolante, temperatura e geometria do isolamento.

### 1.3.4 Ensaio de corrente de polarização e despolarização

Técnicas de medição de resposta dielétrica, como o ensaio de corrente de polarização e despolarização identificado pela sigla PDC (*Polarization and Depolarization Current*) visam fornecer informações importantes quanto a condição do isolamento em um transformador. O princípio de medida do ensaio PDC baseia-se na aplicação de uma tensão com corrente contínua em um objeto de teste por um longo tempo, onde realiza-se a medição de corrente até a polarização do objeto. Diferentes constantes de tempo irão corresponder a diferentes tipos de materiais isolantes. Após a medição da corrente de polarização, a tensão é removida e o objeto de teste curto circuitado, realizando a medição da corrente de despolarização (SAHA; PURKAIT, 2004). Assim, as correntes de polarização e despolarização são influenciadas pelas propriedades dos materiais isolantes, contaminantes, danos, bem como, pela estrutura geométrica do sistema isolante (KÜCHLER; BEDEL, 2001).

## 1.4 Considerações Finais

Neste capítulo foram abordados os principais métodos de avaliação de transformadores de potência, utilizando algumas destas características para composição do *Health Index* nesta dissertação. No próximo capítulo, os principais trabalhos relacionados ao problema de priorização de ativos serão introduzidos.

## Capítulo 2

# TRABALHOS RELACIONADOS

**E**STE capítulo apresenta os principais trabalhos relacionados ao problema de priorização de ativos. Os métodos apresentados concatenam mecanismos de priorização, compondo ensaios de caracterização colaborativamente para inferir um diagnóstico. Na Seção 2.1 são apresentados os métodos analíticos para obtenção de um índice de saúde. Na Seção 2.2 são abordados os principais métodos inteligentes para determinação do estado dos ativos. Por fim, na Seção 2.3 são realizadas as considerações finais do capítulo.

### 2.1 Métodos Analíticos

Nesta seção são abordados métodos analíticos encontrados na literatura para determinação da condição dos equipamentos. Os métodos analíticos se subdividem em modelos baseados em técnicas determinísticas e probabilísticas.

#### 2.1.1 Técnicas determinísticas

Em (RONCERO-CLEMENTE; ROANES-LOZANO, 2017) é desenvolvido um pacote na linguagem Maple para detecção e diagnóstico de falhas em transformadores de potência. Este pacote faz a entrada de dados oriundos de diversos ensaios, como: análise de gases dissolvidos em óleo isolante, impedância de curto circuito, análise de resposta em frequência, fator de potência, resistência de enrolamento, relação de transformação e termografia. Todas as técnicas determinísticas consagradas para avaliação dos dados obtidos nos ensaios são realizadas. Uma estrutura de saída com os diagnósticos advindos de cada técnica é validada. Essa estrutura verifica possíveis contradições entre as técnicas implementadas, indicando ao usuário se houve conflito entre os diagnósticos ou não.

A abordagem é baseada em técnicas determinísticas tradicionais e sistemas especialistas. Os ensaios e avaliações não são conclusivos para um diagnóstico autônomo. O pacote não é capaz de lidar com as contradições entre as técnicas, mas apenas indicá-las.

A comparação de transformadores constituintes de um mesmo sistema pelo nível de criticidade com ordenação dos ativos não é suportada. O sistema faz apenas uma sumarização dos diagnósticos e avaliações tradicionais em um ambiente computacional.

Em (LEI et al., 2017) é proposto uma técnica de avaliação determinística, utilizando séries de Volterra para monitoramento em tempo real de transformadores. Este método faz a utilização de dois transdutores que transmitem os sinais de tensão na entrada e saída do transformador para uma placa de aquisição de dados. As informações aquisitadas são transferidas para o computador, ocorrendo o processamento matemático da série. O desligamento do ativo não é necessário para a realização do monitoramento. Nesta técnica a própria tensão de linha serve como fonte de excitação, podendo o ensaio ser realizado na calibração do equipamento ou mesmo na sua primeira instalação. Os sinais de entrada são capturados, prevendo a saída de acordo com a precisão do equipamento. Com a tensão de saída prevista e o sinal de saída real, calcula-se o vetor de erro total, TVE (*Total Vector Error*). Desta forma, uma falha é provavelmente detectada quando o valor TVE, não é compatível com o a precisão do modelo.

A abordagem modela a ocorrência de uma falha ou erro pela condição operacional normal do ativo. Todavia, o método não consegue apresentar um diagnóstico conclusivo por tratar apenas um aspecto e não um conjunto de características de avaliação do transformador. O método não é efetivo para comparação e ordenação dos ativos, mostrando-se eficiente para detecção de anomalias.

Em (FERNÁNDEZ et al., 2017) é apresentado um método de determinação do *Health Index* para transformadores, considerando pontos de elevada temperatura (pontos quentes) e o índice de carregamento do ativo. A primeira etapa do método realiza a determinação de um índice de saúde base, utilizando quatro subíndices. Os subíndices avaliavam o papel isolante, a concentração de gases dissolvidos, a qualidade do óleo isolante e o envelhecimento do transformador. Ao índice base é introduzida uma melhoria com a consideração de pontos de elevada temperatura nos enrolamentos. Este fator é levado em consideração por acelerar o processo de degradação do isolamento líquido e sólido. Os pontos quentes são calculados computacionalmente pelo método de elementos finitos. Para o cálculo é necessário definir a geometria dos enrolamentos e as características dos materiais. Um modelo termo-fluído é construído, considerando o ativo sob carga. Com o modelo criam-se variações do carregamento com diferentes níveis de corrente e

liberação de calor. Com isso, um fator de correlação entre o índice de carga e a temperatura do ponto quente é estabelecido, bem como, uma relação entre o envelhecimento do transformador e o fator de carga.

A composição com o índice de saúde em duas etapas promete uma melhora na avaliação dos ativos. Todavia, o método mostra-se complexo e de difícil acesso aos gestores. Nota-se uma necessidade neste trabalho de cálculos e modelagens sofisticados, aumentando o tempo de resposta para diagnóstico de cada transformador.

Em (ORTIZ et al., 2016) é proposto um estudo de caso, comparando dois índices de saúde determinísticos. Os índices realizam a soma ponderada de características obtidas em ensaios reais. O primeiro índice de saúde proposto é baseado ensaios para verificação da qualidade do óleo, concatenando 3 subíndices. Os subíndices verificam ensaios de rigidez dielétrica, acidez, umidade, coloração, tensão interfacial, análise de gases dissolvidos em óleo isolante e análise de 2-furfuraldeído. O segundo índice de saúde proposto consiste de quatro subíndices. Os subíndices avaliam a concentração de gases chave, a concentração de 2-furfuraldeído, a análise de acidez, a rigidez dielétrica, a concentração de umidade, perdas dielétricas, idade e carregamento. Os dois índices principais tem seu desempenho comparado utilizando dados de 52 transformadores reais. A análise de desempenho indica o segundo índice de saúde como um indicador mais confiável pela inserção das informações quanto a idade e carregamento dos ativos.

As características avaliadas em ambos índices são basicamente voltadas a análise química do óleo isolante, mudando apenas duas características no segundo índice (idade e carregamento). A não utilização de uma diversidade de técnicas acaba limitando o diagnóstico, com a avaliação de aspectos semelhantes. Ressalta-se, que os pesos de cada subíndice podem não ser os ideais, uma vez, que são definidos pelo homem.

Em (TANAKA et al., 2010) é proposto um modelo de comparação da condição de saúde de subestações através do processo hierárquico analítico ou simplesmente AHP (*Analytic Hierarchy Process*). Este é um método multi critério onde a comparação é feita em pares. O modelo visa a interligação de 3 subíndices principais, os quais tratam a confiabilidade no fornecimento de energia elétrica, a integridade do *hardware* e a regulamentação jurídica. Com os três subíndices definidos existe a concatenação de todos estes com as referidas covariáveis e critérios através de uma matriz de pesos. Esta matriz é responsável pela ponderação de cada avaliação, realizando a agregação dos múltiplos cri-

térios através do método AHP. Assim, as subestações podem ser ordenadas pela condição operacional e os índices de saúde da subestação avaliados pela repetição temporal. Uma linha de tendência é criada, sendo possível o envelhecimento da subestação ser previsto e estudado.

A ferramenta mostra-se útil para a verificação da condição de saúde da subestação como um todo. O sistema é eficiente quando o número de subestações avaliadas for de uma ordem muito grande. Todavia, o modelo proposto não consegue lidar com os ativos individualmente num processo de classificação e ordenação.

### 2.1.2 Técnicas probabilísticas

Em (JACOB et al., 2016) é proposto um método de análise da degradação do papel isolante, através de um sistema de microscopia ótica. Neste método uma análise da textura do papel isolante é realizada, com a conversão de cada imagem em uma matriz espacial de níveis de cinza identificada pela sigla SGLDM (*Spatial Gray Level Dependence Matrix*). A verificação estatística da intensidade dos níveis de cinza nos píxeis é realizada, extraindo com a aplicação dos operadores matemáticos 22 características de textura para cada amostra. Com a extração dos padrões de textura é feito um processamento estatístico, o qual correlaciona a análise de textura com o tipo de degradação sofrido, utilizando LDA (*Linear Discriminant Analysis*). O método de classificação dos vizinhos mais próximos K-NN (*K-Nearestneighbor Classifier Method*) agrupa os dados advindos da análise estatística da textura. A técnica mostra-se capaz de determinar diferentes níveis de degradação térmica no papel isolante com alto nível de precisão, podendo substituir ensaios para determinação do grau de polimerização do isolamento sólido.

O modelo mostra-se efetivo para a classificação de falhas térmicas. Entretanto, o método faz a análise apenas do isolamento sólido, não sendo possível ser utilizado para um diagnóstico, classificação, comparação e ordenação dos ativos.

Em (JÜRGENSEN; NORDSTRÖM; HILBER, 2016) é proposto um modelo de probabilidade de falha de ativos. A sua estrutura baseia-se na estatística de falhas individuais dos transformadores e medidas de avaliação da qualidade do óleo isolante. O modelo proposto gera como saída dois índices. O primeiro índice trabalha com a determinação do *Health Index* tradicional, ponderando características avaliadas de acordo com normas e padrões. O índice é composto a partir da associação de 6 características: concentração de umidade, acidez do óleo isolante, tensão de ruptura, fator de dissipação, grau de concentração de

gases dissolvidos em óleo isolante e análise de 2-furfuraldeído. O segundo índice apresenta como saída a probabilidade de falha do equipamento. Sua estrutura baseia-se na avaliação de dados históricos da taxa média de falha dos ativos em um intervalo de tempo determinado.

O trabalho indica os transformadores, que tem maior probabilidade de falha com base em dados históricos. Todavia, certos tipos de defeitos podem acelerar o processo de envelhecimento, não sendo este um modelo conclusivo.

Em (QIU et al., 2015) é proposto um modelo de taxa de falha, baseado no método de regressão não paramétrico. Este método é uma evolução do modelo de risco proporcional estratificado, utilizando uma maior quantidade de covariáveis representativas ao ciclo de vida do equipamento. Neste, a recorrência de eventos relacionados a falha e a manutenção do equipamento são avaliados. O modelo mostra-se superior aos sistemas que utilizam apenas idade e falha baseada na condição. Com este modelo a necessidade de aquisição de dados do ciclo de vida é reduzida, consolidando um sistema de gerenciamento de ativos. O sistema é capaz de descrever a tendência de falhas, considerando características individuais e coletivas.

O sistema se mostra eficiente para uma previsão da condição futura de falha do transformador. Entretanto, o modelo necessita de dados completos do conjunto de transformadores o que nem sempre é viável, ocorrendo a diminuição da confiabilidade com a ausência de dados.

Em (LIM; CHOI; LEE, 2015) um índice de saúde probabilístico é proposto para sistemas de potência, sendo identificado pela sigla PSHI (*Power System Health Index*). O índice de saúde se subdivide em dois itens principais, verificação quanto a adequação e segurança. O índice que trata a adequação verifica o nível de tensão, frequência, reserva e sobrecarga de linhas. O índice referente a segurança verifica o nível de tensão, sobrecarga em linhas, limites de transferência de energia entre áreas e sistema de proteção especial. Os dois índices são mapeados nos domínios da saúde, margem e risco por um especialista. Para composição do PSHI utiliza-se o método de média geométrica.

O trabalho apresenta o estado do sistema de potência como um conjunto. A ferramenta não mostra-se eficiente para uma avaliação individualizada, com posterior classificação e ordenação dos ativos.

## 2.2 Métodos de Inteligência Computacional

Nesta seção são abordados os principais métodos que utilizam sistemas inteligentes para priorização de transformadores de potência. Abaixo, os métodos baseados em aprendizagem, sistemas nebulosos, métodos de otimização e sistemas híbridos são apresentados.

### 2.2.1 Técnicas baseadas em aprendizagem

Em (ABU-ELANIEN; SALAMA; IBRAHIM, 2011) é descrito um método que utiliza redes neurais artificiais para a determinação do índice de saúde para transformadores de potência. Uma rede neural multi camadas perceptron é treinada, utilizando como entrada a concentração umidade no óleo isolante, acidez, tensão de ruptura, concentração de gases chave, concentração de 2-furfuraldeído, fator de perda e sólidos totais no óleo. Como saída da rede é estabelecido um índice de zero a um, representando transformadores com condição operacional boa até muito ruim. Um conjunto de dados de 88 transformadores é utilizado, sendo 59 amostras escolhidas randomicamente para treinamento e as 29 restantes para validação. O sistema alcança acurácia de 96,55% com a priorização de especialistas.

A abordagem apresenta-se eficiente, utilizando característica obtidas com análises químicas do óleo isolante. Entretanto, o modelo utilizado mostra-se complexo em uma apresentação para gestores não especialistas em inteligência computacional, já que, o modelo é uma caixa preta.

Em (TRAPPEY et al., 2015) um sistema inteligente de gerenciamento de ativos para a manutenção de transformadores de potência é desenvolvido. O sistema monitora em tempo real parâmetros chave através de modelos de predição de falhas e mineração de dados. O sistema utiliza o método PCA (*Principal Component Analysis*) para reduzir a quantidade de características a serem avaliadas por um modelo que utiliza redes neurais. Um estudo de caso com ativos disposto na Austrália e de Taiwan são utilizados para treinamento, validação e teste do modelo desenvolvido. A acurácia das predições com a utilização de PCA mostram-se superiores. O autor defende que o modelo pode ser adotado por gerentes em diferentes regiões, desenvolvendo estratégias adequadas de manutenção e prevenção de falhas.

A utilização do método PCA alcança impacto substancial na consolidação do modelo. Contudo, a utilização de redes neurais dificulta a justificativa de conclusões para gestores não especialistas, por não ter uma correspondência de causa e efeito, mas ser um modelo caixa preta.



Em (ASHKEZARI et al., 2013) é proposto um método que utiliza máquina de suporte de vetores fuzzy, do inglês FSVM (*Fuzzy Support Vector Machine*), para priorização de ativos. Um modelo estatístico com dados históricos de treinamento de 181 transformadores em serviço é desenvolvido, incluindo medidas de ensaios químicos e elétricos do óleo isolante. Emprega-se 70% dos dados para treinamento e 30% para teste, realizando a classificação em cinco condições operacionais: excelente, bom, médio, ruim e insatisfatório. Com um pré-processamento híbrido verifica-se o alcance de melhores resultados. Aplica-se neste processo uma sobre-amostragem nas classes minoritárias e subamostragem nas classes majoritárias, definido este método pela sigla SMOTE (*Synthetic Minority Over-sampling Technique*).

O trabalho apresenta resultados relevantes. Entretanto, o modelo utiliza apenas análise da qualidade do óleo isolante para caracterização, não apresentando flexibilidade para introdução de técnicas complementares. O método não é capaz de realizar a comparação de transformadores de uma mesma classe, não se mostrando efetivo para ordenação dos ativos.

Em (AHMED et al., 2015) um método de determinação do índice de saúde para transformadores de potência é proposto com a utilização de redes de Wavelet. Redes de Wavelet combinam as características das funções de Wavelet nas camadas ocultas de uma rede neural. A associação destas técnicas proporcionam um aumento da capacidade de aprendizagem, inserindo propriedades de localização de tempo-frequência. O sistema proposto utiliza 11 entradas (características químicas do óleo isolante) e 1 saída (*Health Index*). Um conjunto de 973 transformadores são utilizados, sendo 600 para a etapa de treinamento e 373 para validação. O autor afirma que o índice de saúde desenvolvido pode ser empregado para justificar um plano de capital, com a substituição de ativos em fim de vida útil.

A utilização de redes de Wavelet mostra-se promissora. Contudo, o modelo é complexo e fechado, dificultando a justificativa de decisões para gestores.

### 2.2.2 Técnicas baseadas em lógica nebulosa

Em (ABU-ELANIEN; SALAMA; IBRAHIM, 2012) utilizam-se sistemas nebulosos para a determinação do *Health Index* em transformadores imersos em óleo, com tensão nominal abaixo de 69kV. O sistema *fuzzy* baseado no máximo e mínimo de Mamdani é utilizado. Seis conjuntos *fuzzy* de entrada são utilizados para inserção do teor de água, acidez, tensão

de ruptura, fator de dissipação, gases combustíveis dissolvidos e análise de 2-furfuraldeído como características. Um conjunto *fuzzy* de saída é modelado para o *Health Index*. Normas e padrões internacionais são utilizados para definir as funções de pertinência dos conjuntos de entrada. Utilizam-se 33 regras de inferência para correlacionar os universos de discurso de entrada e saída. O conjunto de saída é dirimido em cinco variáveis linguísticas: muito bom, bom, moderado, ruim e muito ruim. O autor realiza a comparação dos resultados obtidos com especialistas, que determinam o diagnóstico para 90 transformadores, alcançando o sistema uma acurácia de 96,7%.

O sistema mostra a eficiência do tratamento linguístico de variáveis precisas, sendo especialmente eficaz para demonstração de causa e efeito para gestores. Contudo, o modelo torna-se pouco flexível, já que, para inserção de novas características todo o conjunto de regras deve ser revisto por especialistas.

Em (BAKAR; ABU-SIADA, 2016) é proposta uma abordagem com sistema de inferência *fuzzy* de forma a apoiar a tomada de decisão no gerenciamento de ativos. O sistema busca a previsão da vida operacional restante de um transformador de potência, com uso de ensaios de avaliação da qualidade de óleo isolante. Os dados de entrada são agrupados, realizando inferências parciais quanto ao tempo de vida restante do ativo, a recomendação para a manutenção do óleo isolante e o estado de condição operacional. A arquitetura do sistema de inferência utilizado é o sistema *fuzzy* Mamdani, com funções de pertinência determinadas por padrões e normas. O modelo proposto é validado com amostras de 50 transformadores, alcançando uma acurácia de 96% com resultados previamente conhecidos.

Nota-se a inserção do tempo de vida como um ponto altamente relevante na aplicação. Sobretudo, a utilização exclusiva de características advindas da análise de qualidade do óleo isolante empobrecem o trabalho. O modelo não apresenta mecanismos para flexibilizar a inserção de novas características, sendo necessário a redefinição do conjunto de regras em um processo de expansão.

### 2.2.3 Técnicas baseadas em otimização

Em (IBRAHIM et al., 2016) é proposto um método de otimização binária por bando de gatos, para otimização dos parâmetros e características de entrada de uma máquina de vetores de suporte. A eficiência no cálculo do índice de saúde e diagnóstico para transformadores de potência é estudada com o processo de otimização. Uma base de dados

com 724 transformadores é utilizada, sendo aplicado: 60% dos dados amostrais para treinamento, 20% para validação e 20% para teste. O sistema é comparado com a aplicação de algoritmo genético e otimização por enxame de partículas. Os resultados exibem uma superioridade em termos de acurácia, necessitando de mais tempo para completar a mesma quantidade de iterações. Os valores do *Health Index* são ajustados em faixas, compreendendo transformadores com condição operacional boa, moderada e ruim.

A utilização de uma técnica de otimização para escolha das melhores variáveis para utilização em uma máquina de vetores de suporte é interessante. No entanto, o modelo não é suficiente para ordenação, uma vez, que a precisão do algoritmo foi condicionada em faixas de valores, não conseguindo estabelecer níveis de criticidade dentro de uma mesma classe.

#### 2.2.4 Métodos híbridos

Em (RIGATOS; SIANO, 2016) é descrito um modelo híbrido *neuro-fuzzy*, com uma abordagem estatística local para o diagnóstico de falhas iniciais em transformadores de potência. O método consiste na modelagem térmica do transformador, associando a temperatura de ponto quente a ensaios termográficos, químicos, elétricos e de vibração. Os dados são comparados. Os resíduos da comparação entre o sistema *neuro-fuzzy* e as medições reais passam por um processamento estatístico. Assim, um determinado nível de desvio é aceito para operação do equipamento, aumentando este valor o sistema indica uma falha.

A abordagem mostra-se eficiente com a verificação estatística adotada. Entretanto, o modelo não apresenta um meio de quantização dos resultados eficaz para comparação dos transformadores, com posterior classificação e ordenação dos ativos.

Em (SUN et al., 2016) a técnica de sistema de inferência *fuzzy* é integrada ao processo analítico hierárquico. O modelo avalia 4 fatores principais (análise de gases dissolvidos, testes elétricos, análise físico-química e fatores diversos), totalizando um conjunto de 20 subíndices. O conjunto *fuzzy* é utilizado para quantificar graus de pertinência para cada índice. Em seguida, o processo analítico hierárquico modificado com lógica *fuzzy* é inserido. Este sistema é capaz de lidar com incertezas da matriz de comparação para o cálculo do peso de cada índice. Por fim, a média ponderada modificada é utilizada na composição do índice, lidando melhor com conflitos entre evidências.

A inserção de sistemas *fuzzy* ao processo analítico hierárquico com a média ponderada modificada, trás robustez ao processamento das informações que, por vezes, são

conflitantes. No entanto, o processo não é automatizado, atrasando a resposta para tomada de decisão por parte dos gestores.

Em (ZEINODDINI-MEYMAND; VAHIDI, 2016) é proposto um estudo para o cálculo do *Health Index* com parâmetros de entrada técnico e economicamente viáveis. Estes parâmetros são extraídos de ensaios rotineiros na manutenção ou operação dos ativos, levando em conta a vida útil do equipamento como variável chave. O sistema aplica redes neurais e um sistema de inferência *neuro-fuzzy* adaptativo, utilizando dados de 226 de transformadores reais. Como entradas são selecionados ensaios de tensão de ruptura, fator de dissipação a 90°, acidez, tensão interfacial, concentração de umidade no óleo a 20°, concentração umidade no papel isolante, análise de 2-furfuraldeído, concentração de gases dissolvidos no óleo isolante e o percentual econômico de vida útil do transformador. O percentual de vida útil advém da análise do custo do ciclo de vida do ativo, o qual avalia os custos de aquisição, propriedade e eliminação. Como informação de saída é apresentado o *Health Index*, variando de 0 (condição operacional muito ruim) a 1 (operação normal). Cerca de 80% dos dados amostrais são utilizados na etapa de treinamento, e 20% são utilizados para verificar a aplicabilidade e desempenho. Os resultados indicam desempenho superior com sistemas *neuro-fuzzy*, entretanto, o autor afirma como viável a implementação de um sistema com uso exclusivo de redes neurais.

A solução para o cálculo do *Health Index* mostra-se eficiente para uma diversidade de dados de entrada. O ponto crítico deste sistema está vinculado a sua complexidade, tornando a justificativa de decisões junto a gestores não especialistas difícil, uma vez, que o modelo é fechado.

Em (VELASQUEZ-CONTRERAS; SANZ-BOBI; ARELLANO, 2011) um modelo de gerenciamento completo de ativos aplicado a transformadores de potência é proposto. O sistema consiste em uma plataforma de integração de dados. Este modelo correlaciona um módulo de diagnóstico, um modelo de estimação da taxa de falhas, um modelo de análise de confiabilidade e um modelo de otimização para o planejamento da manutenção, simultaneamente. O módulo de diagnóstico utiliza redes neurais e sistemas especialistas, para modelagem e julgamento da condição operacional do ativo, por meio de análises térmicas e elétricas. O modelo de estimação de falhas utiliza dados históricos, para determinação da taxa de falhas e verificação da confiabilidade do equipamento. O modelo oculto de Markov, análise Bayesiana e um modelo de previsão de falhas baseado em dados

de inspeção dos equipamentos são utilizados para composição do modelo de estimação de falhas. No módulo de análise de confiabilidade são utilizados os conceitos tradicionais do tempo médio para falha e o tempo médio para reparo. Como saída são obtidos índices de desempenho com o tempo de paralisação no fornecimento de energia anual, o tempo de interrupção no fornecimento a um cliente específico e a média da energia não fornecida em kWh. Por fim, com o modelo de otimização para o planejamento da manutenção integra-se as informações com o menor custo e maior eficiência.

O sistema de gerenciamento é sofisticado, possuindo uma combinação de métodos diversificados. No entanto, a aquisição de dados histórico nem sempre é viável, devendo o modelo possuir um mecanismo de flexibilização e tratamento de incertezas.

## 2.3 Considerações Finais

Neste capítulo foram apresentados os principais métodos para composição de indicadores da condição operacional de transformadores de potência. No próximo capítulo serão introduzidos os principais métodos de inteligência computacional utilizados nesta dissertação.

## Capítulo 3

# TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL UTILIZADAS

**M**ÉTODOS baseados em inteligência computacional são instrumentos para solução de problemas NP-Hard (*Non Deterministic Polynomial Time-Hard*) nas mais diversas áreas do conhecimento. Os modelos de inteligência computacional têm seu desenvolvimento datado desde o início do século XX. Nesta dissertação aplicou-se otimização por enxame de partículas mono-objetivo e multi-objetivo, otimização por manada de elefantes, algoritmo genético, redes neurais Perceptron de múltiplas camadas e de Kohonen, clusterização evolucionária e lógica nebulosa.

### 3.1 Otimização por Enxame de Partículas

O algoritmo de otimização por enxame de partículas (*Particle Swarm Optimization - PSO*) é um método desenvolvido em (KENNEDY; EBERHART, 1995), usado para resolução de problemas NP-Hard, onde a solução do problema não pode ser encontrada com métodos tradicionais. Na Seção 3.1.1 realizou-se uma introdução a versão mono-objetivo do algoritmo PSO. Na Seção 3.1.2 são abordados os principais pontos da versão multi-objetivo.

#### 3.1.1 PSO mono-objetivo

No PSO mono-objetivo, ou canônico, cada partícula do enxame representa uma possível solução para o problema. A estratégia de movimentação das partículas em um espaço de busca multi-dimensional fundamenta-se no comportamento social de um bando de pássaros e cardume de peixes. A seleção da melhor solução é obtida a partir da avaliação da qualidade de cada partícula por uma função de custo. Essa função deve ser modelada para cada problema com rigoroso critério, de modo que, uma boa solução para o problema

físico receba uma boa avaliação no algoritmo. O algoritmo apresenta dois tipos de topologias principais: em anel (*local best* PSO) ou estrela (*global best* PSO). Na topologia em anel, cada partícula pode se comunicar com duas partículas vizinhas, apresentando cada partícula uma solução ótimo local. Na topologia em estrela, cada partícula se comunica com todo o enxame, apresentando uma solução ótimo global.

Algoritmo 1 apresenta as principais etapas para a versão *global best* PSO, sendo adotada nesta dissertação. Neste algoritmo as posições e velocidades das partículas são inicializadas estocasticamente em um espaço de busca multi-dimensional. As aptidões das soluções são avaliadas. Em seguida, a estratégia de movimentação é implementada iterativamente, de modo que, cada partícula tenha o vetor velocidade influenciado por um componente cognitivo, social e de inércia para composição de uma nova solução. O controle de velocidade favorece o processo de exploração limitando os passos de cada partícula. Com uma nova posição determinada para cada partícula, é realizado o processo de confinamento, ou seja, as novas soluções devem estar contidas dentro do espaço de busca de interesse. Este processo é repetido para cada partícula, realizando, ao fim, a atualização das melhores soluções locais e globais. O processo é repetido até ser alcançada uma condição de parada, apresentando a solução final alcançada.

---

**Algoritmo 1** Pseudocódigo do algoritmo PSO
 

---

```

início
  Inicializar parâmetros;
  Inicializar partículas;
  repita
    para  $i$  de 1 a  $n$  faça
      para  $j$  de 1 a  $d$  faça
         $v_{ij_{new}} := (\omega * v_{ij}) + (\varphi_1 * \text{rand}()) * (p_{ij} - x_{ij}) + (\varphi_2 * \text{rand}()) * (g_j - x_{ij});$ 
        Controlar  $v_{i_{new}}$ ;
         $x_{ij_{new}} := x_{ij} + v_{ij_{new}};$ 
        Confinar  $p_i$ ;
      fim
      Atualizar  $p_{best_i}$  e  $g_{best}$ ;
    fim
  até condição de parada;
  Retornar  $g$  e  $g_{best}$ ;
fim

```

---

No Algoritmo 1, nota-se que  $i$  representa a partícula tratada,  $n$  o número máximo de partículas utilizadas,  $j$  a dimensão considerada,  $d$  o número de dimensões,  $v_{ij}$  a velocidade de avanço,  $v_{ij_{new}}$  a nova velocidade. Observa-se ainda que  $\omega$  corresponde ao coeficiente de inércia,  $\varphi_1$  o coeficiente de aprendizado cognitivo,  $\varphi_2$  o coeficiente de aprendizado social. O componente  $x_{ij}$  representa a posição atual da partícula,  $x_{ij_{new}}$  a nova posição da partícula,  $p_{ij}$  a melhor posição da partícula  $i$  na dimensão  $j$ ,  $g_j$  a melhor

posição global na dimensão  $j$ ,  $pbest_i$  a qualidade da melhor partícula  $i$  após o processo de otimização,  $gbest$  a qualidade da melhor partícula do enxame e  $g$  a sua posição.

### 3.1.2 PSO multi-objetivo

O algoritmo de otimização multi-objetivo por enxame de partículas (*Multi-Objective Particle Swarm Optimization* - MOPSO) foi proposto em (MOORE; CHAPMAN, 1999). O algoritmo realiza a busca por um conjunto de soluções para otimização de problemas com dois ou mais objetivos conflitantes, baseando-se na versão canônica do PSO. No MOPSO, o conceito de ótimo deixa de ser uma solução simples e passa a ser representado como uma tentativa de obter bons compromissos entre os diferentes objetivos (*trade-offs*). O conjunto de soluções ótimas é contido na fronteira de Pareto. O critério de dominância de Pareto é aplicado ao algoritmo MOPSO (COELLO, 1996). Este critério estabelece, que uma solução  $x$  domina  $y$ , quando  $x$  é superior a  $y$ , ao menos, em um objetivo e em todos os demais apresenta aptidão igual. A dominância de Pareto também estabelece, que  $x$  e  $y$  são indiferentes, quando  $x$  e  $y$  possuírem melhor aptidão em objetivos distintos.

A inicialização do algoritmo se dá de forma aleatória, obtendo os valores iniciais para posição  $x_i$  e velocidade  $v_i$  de cada partícula. A Tabela  $T$ , também conhecida por repositório externo, é inicializada com as posições das partículas não dominadas. A cada iteração, é selecionada a partícula líder  $g$  entre os  $\xi$  primeiros elementos do repositório externo. Uma nova velocidade  $v_i$  e posição  $x_i$  são calculados para cada partícula. Com o operador de mutação busca-se uma diversidade de soluções, evitando convergências para ótimos locais. A atualização da melhor solução local de cada partícula  $i$ , ou simplesmente  $p_i$ , se dá pela verificação de dominância. Caso uma nova posição  $x_i$  domine  $p_i$ , está será atualizada com valor de  $x_i$ . Caso  $p_i$  domine a partícula de posição  $x_i$ ,  $p_i$  mantém sua posição atual. Caso  $p_i$  e  $x_i$  sejam indiferentes, é selecionada aleatoriamente uma das duas posições para assumirem o valor de  $p_i$  atual. A velocidade e posição de cada partícula é calculada sob a mesma estrutura da versão canônica do PSO, utilizando como guia local e global, respectivamente,  $p_i$  e  $g$ .

O repositório externo é atualizado a cada iteração, adicionando partículas não dominadas. O cálculo da distância de superlotação (DS) fornece uma estimativa da densidade de soluções em torno de cada partícula disposta na tabela  $T$ , guiando a exploração e remoção de partículas. O cálculo da DS é descrito, por meio da Equação 1:

$$DS(l) = DS(l) + \frac{f_k[T(l+1)] - f_k[T(l-1)]}{f_{k_{max}} - f_{k_{min}}}, \quad (1)$$



onde  $DS(l)$  é a distância de superlotação para uma solução  $l$  contida no repositório externo,  $f_k$  representa o valor de aptidão de uma partícula em um objetivo  $k$ . As variáveis  $f_{k_{max}}$  e  $f_{k_{min}}$  representam, respectivamente, o valor de aptidão máximo e mínimo em um objetivo  $k$ . Os índices  $T(l+1)$  e  $T(l-1)$  apontam as posições: posterior e anterior, a solução  $l$  no repositório externo.

A cada repetição do Algoritmo 2 é verificado se o repositório externo está cheio. Caso  $T$  estiver cheio, as partículas contidas em  $T$  são ordenadas de forma crescente com base em DS e mantidas as primeiras partículas. Esta medida visa o armazenamento de soluções em regiões menos lotadas, obtendo uma melhor distribuição em  $T$ . Ao final do processo de repetição converge-se para um conjunto de soluções contido no repositório externo. O Algoritmo 2 descreve processo de exploração de soluções para o MOPSO utilizado nesta dissertação.

---

**Algoritmo 2** Pseudocódigo do algoritmo MOPSO
 

---

**início**

**Inicializar** enxame de partículas com posições  $x_i$  e velocidades  $v_i$  aleatórias;

**Avaliar** aptidão das partículas em cada objetivo;

**Inicializar**  $p_i$  e  $pbest_i$ ;

**Avaliar** dominância de cada partícula inicializada;

**Inicializar** Tabela  $T$  com as posições das partículas não dominadas;

**Realizar** cálculo da distância de superlotação;

**repita**

**para**  $i$  de 1 a  $n$  **faça**

**Ordenar**  $T$  em ordem decrescente dos valores de distância de superlotação;

**Escolher** aleatoriamente, dos  $\xi$  primeiros elementos da Tabela  $T$ , uma posição;

**Definir** a posição selecionada como  $g$ , armazenando as aptidões com relação a todos objetivos em  $gbest$ ;

**Calcular** nova velocidade  $v_i$ , considerando  $p_i$  como a melhor posição da partícula e  $g$  como a melhor posição do enxame;

**Calcular** nova posição  $x_i$ ;

**Realizar** confinamento da partícula;

**Determinar** a aptidão com relação aos objetivos;

**Realizar** operação de mutação;

**Atualizar**  $pbest_i$  com verificação da dominância;

**fim**

**Verificar** dominância;

**Adicionar** ao repositório externo as partículas não dominadas;

**Atualizar** distribuição de soluções em  $T$  com cálculo da distância de superlotação;

**Ordenar**  $T$  em ordem decrescente dos valores de distância de superlotação;

**Verificar** se repositório está cheio;

**Ordenar** de forma crescente com base em DS e manter primeiras posições, caso  $T$  estiver cheio;

**até** condição de parada;

**Retornar** a população de partículas e  $T$ ;

**fm**

---

No Algoritmo 2,  $\xi$  representa uma quantidade de amostras não dominadas, onde é selecionada aleatoriamente a partícula líder  $g$ . Neste algoritmo,  $pbest_i$  representa um

vetor, contendo a qualidade em cada objetivo para a melhor solução local  $p_i$ . A variável  $g_{best}$  representa a qualidade para a posição líder  $g$ .

## 3.2 Otimização por Manada de Elefantes

O método de otimização por manada de elefantes (*Elephant Herding Optimization* - EHO) é um método recente de inteligência de enxame apresentado em (WANG; DEB; COELHO, 2015). O algoritmo propõe a busca de soluções ótimas globais em espaços de busca multidimensionais, com sua implementação inspirada no comportamento social de elefantes asiáticos e africanos.

Na natureza, os elefantes da manada se movem sob a orientação da matriarca. O elefante macho ao entrar na fase adulta abandona a manada. Para representar esse comportamento artificialmente, dois operadores principais são propostos. O primeiro é denominado operador de agregação, sendo responsável pela atualização da posição de cada elefante da manada. O segundo, é identificado como operador de separação, sendo responsável pela substituição da pior solução da manada por uma nova. Em uma manada artificial ou clã, a melhor solução em cada geração representa a matriarca e a pior solução o elefante macho na fase adulta.

No algoritmo EHO, as posições dos elefantes de cada clã são inicializadas aleatoriamente. Em um processo iterativo, cada clã tem a aptidão das suas soluções avaliadas. A melhor solução do clã é definida como a matriarca,  $x_{best,c_i}$ . O mesmo processo acontece com a pior solução do clã, sendo definido o elefante macho na fase adulta,  $x_{worst,c_i}$ . Um processo iterativo de atualização das posições dos elefantes de cada clã é realizado. Caso o elefante a ter sua posição atualizada for  $x_{worst,c_i}$ , uma nova posição entre os limites de posição  $x_{min}$  e  $x_{max}$  será gerada. Nota-se que esta nova posição poderá não se manter com o pior valor de aptidão, desta forma, o valor é atribuído a  $x_{new,c_i,j}$ . Esta estratégia visa imitar o comportamento natural, onde o elefante macho sai da manada ao entrar na fase adulta. Caso o elefante a ter sua posição atualizada for  $x_{best,c_i}$ , sua nova posição será guiada pelo centro do clã ponderado por um coeficiente  $\beta$ , contido entre 0 e 1. Ressalta-se, que a nova posição gerada não necessariamente se manterá como melhor solução do clã, por conta disso, é identificada como  $x_{new,c_i,j}$ . Para os demais elefantes do clã, a sua posição  $x_{new,c_i,j}$  é guiada pela matriarca e por sua última posição  $x_{c_i,j}$ . Ao fim do processo de repetição as matriarcas de todos os clãs tem suas aptidões avaliadas, representando

a matriarca com maior aptidão a solução ótimo global para o problema. O Algoritmo 3 descreve o processo de exploração de novas soluções com algoritmo EHO, sendo sua estrutura utilizada nesta dissertação.

---

**Algoritmo 3** Pseudocódigo algoritmo EHO
 

---

```

início
  Inicializar a população de cada clã aleatoriamente;
  repita
    para  $c_i := 1$  até  $nClan$  faça
      Avaliar a aptidão da população contida em  $c_i$ ;
      Determinar  $x_{worst,c_i}$  e  $x_{best,c_i}$  para cada clã;
      para  $j := 1$  até  $n_{c_i}$  faça
        se ( $x_{c_i,j} = x_{worst,c_i}$ ) então
           $x_{new,c_i,j} := x_{min} + (x_{max} - x_{min} + 1) \cdot r$ ;
        fim
        se ( $x_{c_i,j} = x_{best,c_i}$ ) então
          para  $d := 1$  até  $d$  faça
            
$$x_{center,c_i,d} := \frac{1}{n_{c_i}} \cdot \sum_{j=1}^{n_{c_i}} x_{c_i,j,d};$$

          fim
           $x_{new,c_i,j} := \beta \cdot (x_{center,c_i,d});$ 
        fim
        se ( $x_{c_i,j} \neq x_{best,c_i}$ ) e ( $x_{c_i,j} \neq x_{worst,c_i}$ ) então
           $x_{new,c_i,j} := x_{c_i,j} + \alpha \cdot (x_{best,c_i} - x_{c_i,j}) \cdot r$ ;
        fim
      fim
    até condição de parada;
    Verificar aptidão  $x_{best,c_i}$  de todos clãs;
    Definir  $x_{best,c_i}$  com maior valor de aptidão como solução ótimo global;
    Retornar a solução ótimo global;
  fim

```

---

No Algoritmo 3,  $c_i$  representa o número de clãs, indo até o limite superior  $nClan$ . O índice  $j$  representa o elefante do clã a ser avaliado, indo até o número total de elefantes  $n_{c_i}$ . A posição  $x_{c_i,j}$  refere-se a posição atual do elefante. A variável  $x_{center,c_i,d}$  corresponde ao centro do clã em uma dimensão  $d$  para o problema. Os problemas de otimização estudados com este algoritmo podem variar de 1 até  $d$  dimensões. O coeficiente  $\beta$  define a influência do centro do clã, no cálculo da posição de uma nova solução. O coeficiente  $\alpha$  define a influência da matriarca sobre o cálculo da posição de uma nova solução. O coeficiente  $r$  é um número aleatório utilizado no algoritmo EHO para aumentar a diversidade de soluções.

### 3.3 Redes Neurais Artificiais

Rede neural artificial é uma técnica de inteligência computacional baseada em aprendizagem. Este modelo é reconhecido pela capacidade de generalizar e extrair padrões

complexos, tendo o cérebro humano como inspiração natural. Redes de neurônios artificiais são utilizadas para extração do conhecimento, através do processo de treinamento. A utilização deste modelo traz benefícios, tais como a possibilidade de trabalhar com modelos não-lineares, mapeamento de entrada-saída, adaptabilidade, resposta a evidências e tolerância a falhas (HAYKIN, 1994).

O primeiro modelo de neurônio artificial foi proposto em (MCCULLOCH; PITTS, 1943). Este modelo é a unidade de processamento fundamental para a operação de uma rede neural. O neurônio artificial é composto por um conjunto de sinapses ou elos de conexão. Cada sinapse contém um peso  $\omega_{k_n}$ , que pondera os sinais de entrada. Os sinais ponderados seguem para o operador soma, que constitui um combinador linear. No combinador linear é somado um *Bias*  $b_k$ , que aumenta ou diminui a entrada líquida da função restritiva. A função de ativação, ou função restritiva, limita o sinal de saída do neurônio. A Figura 1 apresenta a estrutura de um neurônio artificial.

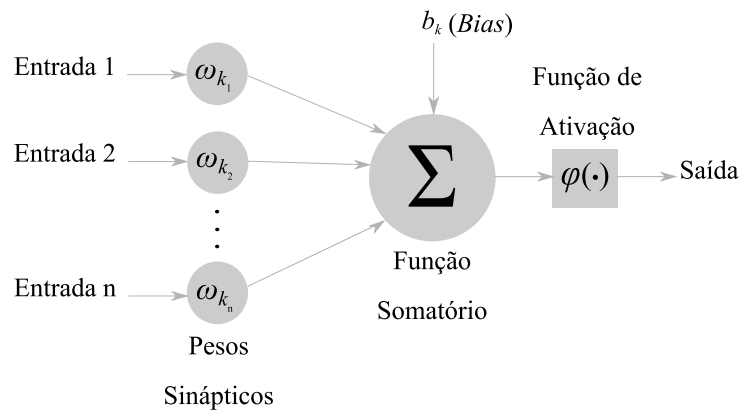


Figura 1: Modelo de neurônio artificial

Com a unidade fundamental de processamento, distintas arquiteturas de rede são compostas. Estas arquiteturas estão intimamente ligadas ao seu tipo de aprendizagem. As arquiteturas de rede se subdividem em dois grandes blocos, redes com: aprendizado supervisionado e não-supervisionado. Na Seção 3.3.1 é apresentada uma das arquiteturas mais tradicionais e difundidas para aprendizado supervisionado: Rede Neural Perceptron de Múltiplas Camadas (MLP, *Multilayer Perceptron*). Na Seção 3.3.2 é apresentada a arquitetura de aprendizado não-supervisionado: Rede Neural de Kohonen (RNK).

### 3.3.1 Rede neural Perceptron de múltiplas camadas

Rede Neural Perceptron de Múltiplas Camadas é uma generalização da Rede Neural Perceptron de Camada Única desenvolvida em (ROSENBLATT, 1958). Como em uma Perceptron

de camada única a rede MLP é uma arquitetura concebida para aprendizagem supervisionada, ou seja, necessita de um tutor com um par verdade entre entrada e saída. A rede MLP é composta por uma camada de neurônios na entrada, uma ou mais camadas ocultas e uma camada de saída. O sinal de entrada se propaga para frente através da rede, camada por camada. A Figura 2 apresenta a arquitetura de uma rede MLP.

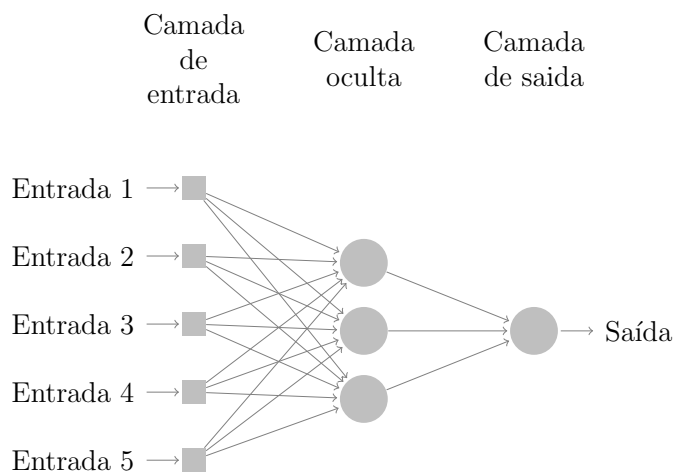


Figura 2: Arquitetura de rede neural Perceptron de múltiplas camadas

Dentro das arquiteturas de aprendizagem supervisionada existem redes: de camada única, múltiplas camadas e recorrentes. Como já dito, redes MLP tem treinamento supervisionado, sendo o algoritmo de retropropagação de erro (*error back-propagation*) um dos mais difundidos. Este algoritmo é baseado na regra de aprendizagem por correção de erro. Neste, a aprendizagem consiste de dois passos: propagação e retropropagação. Com a propagação é aplicado um vetor de entrada, propagando seu efeito para frente, camada por camada, produzindo uma saída. Na retropropagação a resposta real da rede é subtraída da desejada, produzindo um sinal de erro. Este sinal de erro é propagado para trás, ajustando os pesos sinápticos, para a resposta real se aproximar do valor desejado.

Algoritmos adaptativos e evolucionários, também, tem sido aplicados no treinamento e otimização de redes neurais MLP. A aplicação de técnicas como o algoritmo PSO no treinamento de redes MLP (GRIMALDI et al., 2004) mostra-se promissora, guiando o ajuste de pesos sem cair em ótimos locais. Nesta dissertação aplicou-se na etapa de treinamento supervisionado a utilização do algoritmo PSO. Nesta aplicação, os possíveis pesos ótimos para a rede MLP representam a posição de cada partícula. As possíveis soluções têm sua qualidade verificada na função de custo. Como aptidão para cada partícula é retornada a aproximação alcançada com relação ao especialista.

### 3.3.2 Rede neural de Kohonen

Redes Neurais de Kohonen, também conhecida por SOM (*Self Organizing Map*) ou Mapa Auto-organizável, é uma arquitetura de redes neurais concebida para aprendizagem não supervisionada. O modelo neural tem inspiração no comportamento do cérebro humano, que possui áreas diferentes do córtex topologicamente ordenadas. Dessa forma, estímulos sensoriais como tátil, visual e acústico ativam partes específicas do córtex cerebral (KOHONEN, 1982).

RNK tratam problemas com padrões de entrada de dimensão arbitrária, extraindo similaridades e correlações entre os dados. Os padrões de entrada de alta dimensionalidade são agrupados em um mapa discreto de uma ou duas dimensões, constituído por neurônios artificiais. O mapa auto-organizável ou grade neural, é comumente constituído por uma única camada de neurônios, sendo ativado aquele neurônio cujo vetor de pesos está mais próximo do vetor de entrada. Dessa forma, após o processo de ajuste no treinamento, entradas com características semelhantes tendem a ativar os mesmos neurônios, formando agrupamentos (*clusters*), os quais, por sua vez, indicarão classes formadas.

O processo de adaptação dos pesos tem sua inicialização de forma estocástica. Posteriormente o processo de treinamento pode ser sumarizado em três processos essenciais: Competição, Cooperação e Adaptação. No processo de competição, a distância Euclidiana entre os padrões de entrada e os pesos sinápticos são calculadas. Cada padrão de entrada excita um neurônio. O neurônio ativado é definido com a verificação do valor mínimo para distância euclidiana, entre o padrão de entrada e os neurônios da grade, sendo calculado por meio da Equação 2:

$$I(x) = \underset{j}{\operatorname{argmin}} \|x - w_j\|, \quad (2)$$

onde  $I(x)$  representa a menor distância euclidiana e por consequência o neurônio ativado,  $x$  representa o padrão de entrada e  $w_j$  o conjunto de pesos dos  $j$  neurônios pertencentes a grade. Assim, o neurônio excitado é definido como neurônio vencedor.

No processo de cooperação, o neurônio vencedor indica o centro da vizinhança topológica de neurônios cooperativos. A vizinhança topológica é definida pela função  $h_{j,I(x)}$ . A função de vizinhança define a influência no processo de adaptação dos pesos sobre os neurônios ao redor do neurônio vencedor, quanto mais próximo maior a influência. Uma escolha típica para  $h_{j,I(x)}$  é a função gaussiana, definida pela Equação 3:

$$h_{j,I(x)}(n) = \exp\left(-\frac{d_{j,I(x)}^2}{2\sigma^2(n)}\right), \quad (3)$$

onde  $h_{j,I(x)}$  é a função de vizinhança a cada época  $n$  do treinamento não supervisionado,  $d_{j,I(x)}$  a distância lateral da função e  $\sigma$  a largura da função de vizinhança. A largura  $\sigma$  passa por um decaimento exponencial, descrito, por meio da Equação 4:

$$\sigma(n) = \sigma_0 \exp\left(-\frac{n}{\tau_1}\right), \quad (4)$$

onde  $\sigma$  é a largura da função de vizinhança a cada época do treinamento  $n$ ,  $\sigma_0$  o valor inicial da largura e  $\tau_1$  uma constante de tempo. Este decaimento visa a cada geração reduzir a atuação da função de vizinhança sobre os neurônios que estão ao redor do neurônio vencedor, refinando o ajuste dos pesos.

O processo de adaptação é a última etapa do processo de aprendizagem não supervisionado. Este processo visa a modificação dos pesos sinápticos  $w_j$  de cada neurônio da grade, para torna-lá auto-organizável. Este processo é definido, através da Equação 5:

$$w_j(n+1) = w_j(n) + \eta(n)h_{j,I(x)}(n)(x - w_j(n)), \quad (5)$$

onde  $w_j(n+1)$  representa o vetor contendo os pesos sinápticos atualizados do neurônio  $j$ ,  $w_j(n)$  o vetor contendo os pesos sinápticos antecedentes,  $\eta$  a taxa de aprendizagem. A função de vizinhança é definida por  $h_{j,I(x)}$ ,  $x$  define o padrão de entrada e  $n$  a época correspondente no processo de treinamento. Neste processo a taxa de aprendizagem sofre um decaimento exponencial, por meio da Equação 6:

$$\eta(n) = \eta_0 \exp\left(-\frac{n}{\tau_2}\right), \quad (6)$$

onde  $\eta$  representa a taxa de aprendizagem em uma época  $n$ ,  $\eta_0$  o valor inicial da taxa de aprendizagem e  $\tau_2$  uma constante de tempo. Os limites para a taxa de aprendizagem devem estar dentro do limite superior  $\eta_0$  e inferior  $\eta_{min}$ , estes limites passam por um processo de otimização com o algoritmo PSO nesta dissertação. O processo de otimização também ocorre com o valor de  $\tau_2$ , e  $\tau_1$ , de forma indireta, com a otimização do parâmetro  $k_{\tau_1}$ , descrito por meio da Equação 7:

$$\tau_1 = \frac{k_{\tau_1}}{\text{Log } \sigma_0}, \quad (7)$$

onde  $\tau_1$  é uma constante de tempo,  $k_{\tau_1}$  uma constante a qual tem seu valor otimizado e  $\sigma_0$  a largura inicial da função de vizinhança.

### 3.4 Algoritmo Genético

Algoritmo Genético (AG) consiste em uma técnica de otimização, inspirada no princípio Darwiniano de seleção natural e reprodução genética apresentado em (HOLLAND, 1975).

De acordo com a teoria Darwiniana, o princípio da seleção natural privilegia os indivíduos com características hereditárias que favoreçam a sobrevivência e a reprodução. Por conta destes indivíduos tenderem a deixar mais descendentes, há a perpetuação destas características ao longo das gerações. Esses princípios são usados em AG, que realiza a busca em espaços de busca d-dimensionais pela melhor solução para problemas de otimização, através da evolução de uma população de soluções codificadas através de cromossomos artificiais.

O cromossomo artificial ou genótipo é uma estrutura de dados, que representa uma possível solução para o problema. O indivíduo é uma possível solução para o problema. A população de indivíduos é dividida em: pais e filhos. Indivíduos pais representam o conjunto de possíveis soluções, antes da passagem pelo ciclo de evolução usado em AG a cada geração. Em contrapartida, indivíduos filhos são as possíveis soluções para o problema, que, passam pelo ciclo de evolução usado em AG. Os indivíduos podem ser representados de diversos modos, comumente, utiliza-se a codificação em: binário, por permutação, em árvore, entre outras. Nesta dissertação utilizou-se a representação de valores reais codificados em binário.

Os indivíduos pais têm seu genótipo iniciado estocasticamente na primeira geração. A aptidão, ou *fitness*, é verificada para cada indivíduo pai através da função de custo. Os indivíduos pais passam por um processo de seleção, onde uma fração da população de soluções é selecionada para realizar o cruzamento, par a par. O processo contempla métodos de seleção por: roleta, torneio, estado estacionário, elitismo, entre outros. Nesta dissertação, foi utilizado o método de seleção por roleta. Na seleção por roleta, todos os cromossomos são inseridos. O lado de cada seção da roleta é proporcional ao valor de aptidão de cada indivíduo. Um número aleatório  $r$  entre 0 e 1 é gerado. O valor  $r$  corresponde a uma seção da roleta, que representa o indivíduo selecionado.

Após, o processo de seleção, os indivíduos filhos selecionados passam pelo operador genético de cruzamento, ou *crossover*. O operador cruzamento pode realiza a troca de parte dos genótipos, entre os indivíduos selecionados. O seccionamento do genótipo pode ocorrer de diferentes modos, dependendo do tipo de cruzamento. Os principais operadores de cruzamento utilizados são, cruzamento: único, em dois pontos, uniforme ou aritmético. Nesta dissertação utilizou-se o cruzamento único, onde apenas um ponto de corte é selecionado no genótipo dos indivíduos selecionados.



Em seguida, o operador genético de mutação é implementado em uma fração da população de indivíduos filhos. O operador de mutação realiza a alteração de uma característica do genótipo. Esta alteração está intimamente ligada ao tipo de codificação do genótipo. A operação de mutação pode ser realizada com: inversão de bit, mudança de ordem, mudança de operador, entre outros. Nesta dissertação como os cromossomos são codificados em binário, o operador de mutação é implementado com a inversão de bit. Ao fim, realiza-se a avaliação da aptidão dos indivíduos filhos, que substituem os indivíduos pais em uma nova geração. A Figura 3 ilustra as etapas descritas.

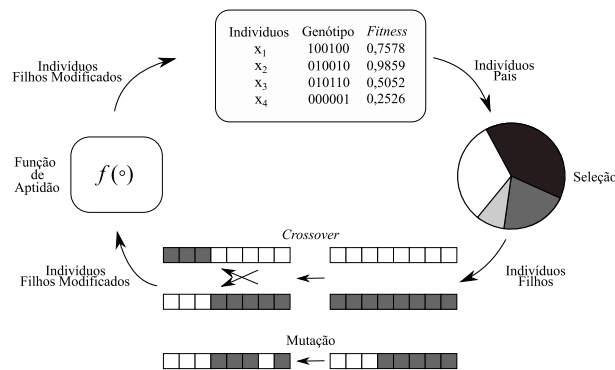


Figura 3: Ciclo de evolução usado em algoritmo genético

### 3.5 Clusterização Evolucionária

Clusterização Evolucionária (CE) é um algoritmo de clusterização automática, baseado na regra do vizinho mais próximo modelado como um problema de otimização. Para o processo de otimização podem ser utilizados: Algoritmo Genético (MAULIK; BANDYOPADHYAY, 2000), PSO (MERWE; ENGELBRECHT, 2003), Evolução Diferencial (ou, Differential Evolution - DE) (PATERLINI; KRINK, 2006), entre outros. Nesta dissertação é implementada a versão com Algoritmo Genético, com representação binária e operador de cruzamento único.

No algoritmo CE os agrupamentos, ou *clusters*, tem a posição do seu centro otimizada. A quantidade  $o_i$  centros de agrupamentos e o espaço de busca para cada devem ser declarados. O algoritmo inicializa os cromossomos artificiais, com um vetor contendo as posições dos  $o_i$  centros estocasticamente. Após o processo de inicialização o algoritmo de otimização AG é repetido até uma condição de parada. A cada geração é verificada a aptidão de cada solução. A aptidão de cada indivíduo do AG é representada pela média das distâncias entre os padrões de entrada e os centros dos *clusters*. Esta estratégia visa

criar agrupamentos, onde os padrões de entrada estejam fortemente correlacionados. A função de custo é apresentada através no Algoritmo 4.

---

**Algoritmo 4** Função de Custo para CE
 

---

```

início
  Calcular a distância euclidiana com relação aos centros dos clusters, contidos em cada cromossomo, para cada padrão de entrada  $x_k$ ;
  Atribuir o padrão  $x_k$  ao cluster, que apresentar menor distância euclidiana entre o padrão e seu centro;
  Armazenar em  $Q_{o_i x}$  quantidade de padrões de entrada  $x_k$  ao redor de cada centro  $o_i$ ;
  se  $Q_{o_i x} = 0$  então
     $l_{med} := \infty$ ;
  fim
  se  $Q_{o_i x} > 0$  então
    Atribuir ao vetor  $l_{o_i}$  a média das distâncias euclidianas entre cada centro  $o_i$  e os padrões correspondentes  $x_k$ ;
    Atribuir a  $l_{med}$  a média dos valores  $l_{o_i}$ ;
  fim
  Retornar  $l_{med}$ ;
fim

```

---

No Algoritmo 4,  $x_k$  representa os  $k$  padrões de entrada os quais deseja-se agrupar. A quantidade de padrões de entrada ao redor do centro de um cluster  $o_i$  é representada pela variável  $Q_{o_i x}$ . A média das distâncias euclidianas entre cada padrão de entrada e o centro de cada cluster é representado pelo vetor  $l_{o_i}$ . O valor médio para distância euclidiana referente a todos os *clusters* é indicado pela variável  $l_{med}$ . Ressalta-se que caso  $Q_{o_i x}$  apresente valor 0 a solução é invalidada, atribuindo valor  $\infty$  a  $l_{med}$ .

Verificada a aptidão dos indivíduos, realiza-se o processo de seleção pelo método de roleta. Os indivíduos filhos selecionados passam por um cruzamento com corte único, realizando, na sequência, a inversão de um bit com o operador de mutação. O conjunto de soluções evoluído, substituí os indivíduos pais e uma nova geração se inicia, até ser alcançada a condição de parada. Ao fim do ciclo de evolução do AG, é retornada a solução final com os centros dos *clusters* ótimos e os padrões  $x_k$  correspondentes. O Algoritmo 5 apresenta as etapas descritas.

---

**Algoritmo 5** Algoritmo principal CE, utilizando AG
 

---

```

início
  Definir a quantidade de possíveis centros  $o_i$  e definir seu espaço de busca;
  Inicializar cada cromossomo com  $o_i$  centros de agrupamentos;
  repita
    Avaliar a aptidão de cada indivíduo;
    Selecionar indivíduos pelo método de roleta;
    Realizar operação de cruzamento com corte único;
    Realizar operação de mutação, invertendo um bit;
    Atualizar conjunto de soluções, que minimizam  $l_{med}$ ;
  até condição de parada;
  Retornar a solução final com os centros dos clusters ótimos e os padrões  $x_k$  correspondentes;
fim

```

---

No Algoritmo 5 a variável  $T$  define o índice dos centros dos agrupamentos. A distância  $l_{med}$  representa a média da total das distâncias euclidianas entre os padrões de entrada  $x_k$  correspondentes e os centros dos *clusters*.

## 3.6 Lógica Nebulosa

O conceito de Lógica Nebulosa, ou Sistemas de Inferência *Fuzzy*, foi introduzido por Lotfi Zadeh em (ZADEH, 1965). Este formalizou os princípios de conjuntos com graus de pertinência estabelecidos por Jan Lukasiewicz em (LUKASIEWICZ, 1920), associando-os aos conceitos de lógica aristotélica clássica.

Sistemas de Inferência *Fuzzy*, ou FIS (*Fuzzy Inference System*), permitem a transformação de sinais de entrada precisos em conjuntos de entradas *fuzzy*, guiados por variáveis linguísticas. Este processo de transformação é definido como *fuzzificação*. Os conjuntos contendo os sinais precisos são definidos como universo de discurso. O processo de *fuzzificação* é possível pela existência de funções de pertinência. Funções de pertinência caracterizam regiões do universo de discurso, traduzindo o conjunto em um conceito linguístico. As funções de pertinência mais comuns e utilizadas são: triangular, trapezoidal e gaussiana. A cada elemento contido em uma função de pertinência é atribuído um grau de pertinência. Grau de pertinência é o nível de compatibilidade de um elemento do conjunto *fuzzy*, com o conceito linguístico do conjunto. Os graus de pertinências de cada elemento do conjunto *fuzzy* estão contidos em valores de 0 a 1.

Através de um processo de inferência, com um conjunto de regras bem definido, é estabelecida uma relação de causa e efeito entre os conjuntos *fuzzy* de entrada e saída. No processo de inferência podem ser utilizadas abordagens baseadas em: sistemas Mamdani, modelos Sugeno e modelos Tsukamoto (ROSS et al., 2004). Nesta dissertação, as soluções apresentadas são baseadas no sistemas Mamdani. Cada regra neste sistema possui termos: antecedente e conseqüente. Os termos antecedentes correlacionam as regras vinculadas aos conjuntos *fuzzy* de entrada. O termo conseqüente demonstra a ação produzida sobre o conjunto *fuzzy* de saída. Em sistemas Mamdani, os operadores lógicos relacionais, *OU* e *E*, representam os operadores matemáticos, máximo e mínimo. As relações de máximo e mínimo em cada regra, no termo antecedente, geram o valor para o termo conseqüente.

Com os termos conseqüentes de todas as regras definidos, realiza-se o processo de composição através do processo de *defuzzificação*. O processo de *defuzzificação* pode ser

realizado pelos métodos: centróide, média dos máximos, média ponderada dos máximos, critério máximo (ou mínimo). Nesta dissertação, as soluções que são apresentadas utilizam o método do centróide para *defuzzificação*. No método do centróide é calculado o centro de gravidade do conjunto *fuzzy* de saída, influenciado pelo termo consequente de todas as regras. Assim, com a composição determina-se o valor preciso para o universo de discurso de saída. A Figura 4 ilustra as etapas descritas acima, por meio, de um sistema de controle de velocidade simples.

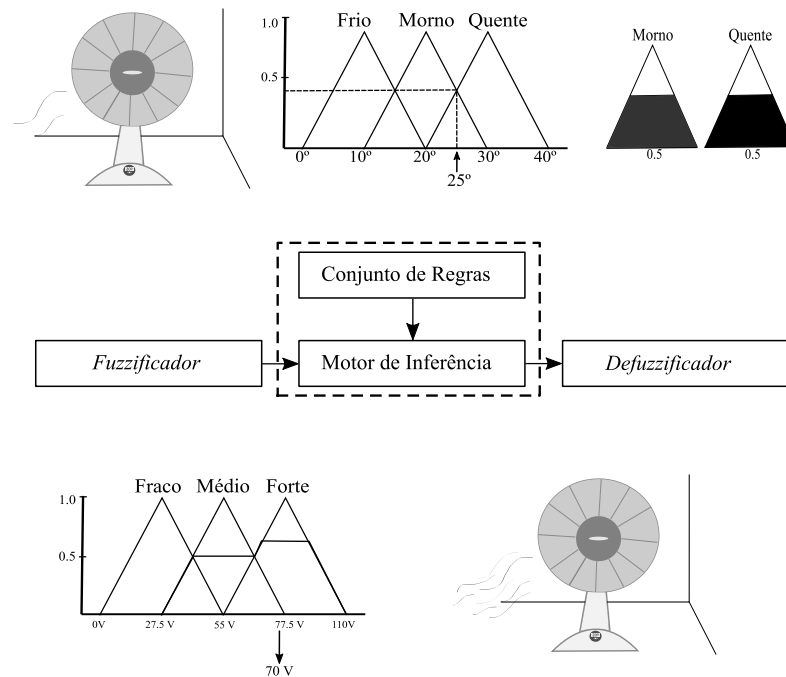


Figura 4: Exemplo de sistema de controle de velocidade, utilizando sistema *fuzzy*

### 3.7 Considerações Finais

Neste capítulo foram apresentadas as técnicas de inteligência computacional aplicadas nesta dissertação, sendo elas o algoritmo PSO mono-objetivo e multi-objetivo, algoritmo EHO, Redes Neurais MLP e Kohonen, Algoritmo Genético, Clusterização Evolucionária e Lógica Nebulosa. No próximo capítulo será abordado o método proposto para a solução do problema de priorização de ativos de alta potência.

# Capítulo 4

## MÉTODO PROPOSTO

**E**STE capítulo apresenta o método proposto nesse projeto para o problema de priorização de ativos de alta potência com a associação de inteligência computacional para a composição do *Health Index*. A Seção 4.1 apresenta abordagens introdutórias utilizadas nessa dissertação. A Seção 4.2 descreve a priorização de ativos por níveis de criticidade. A Seção 4.3 aborda o método adotado para ordenação dos ativos. Por fim, na Seção 4.4 são apresentadas as considerações finais do capítulo.

### 4.1 Análise Preliminar

Para introdução à priorização de ativos, utilizou-se um banco de dados disposto no trabalho (MARTINS et al., 2016) em que três características foram selecionadas: idade do ativo, potência e resultado da análise de cromatografia gasosa. A esse banco de dados preliminar foi adicionada, como avaliada, a característica referente à concentração de 2-furfuraldeído (MARTINS et al., 2004). Desse modo, o conjunto de dados utilizado pode ter algumas informações extraídas com base na análise dos dados na Figura 5, sendo obtidas informações como a idade mais recorrente nos ativos, os níveis de potência com o qual se está trabalhando ou mesmo os principais valores para cromatografia e 2-FAL.




Figura 5: Análise estatística para a base de dados preliminar utilizada

As técnicas de avaliação, acima mencionadas, têm seus dados apresentados na íntegra na Seção A.1 do Apêndice A. Essas foram selecionadas inicialmente pelo desafio

de ser obtida uma base de dados extensa com número vasto de características advindas de ensaios reais em transformadores de potência. Esta base inicial torna-se um caminho para introduzir os primeiros experimentos com inteligência computacional, tendo um panorama quanto aos passos a serem seguidos.

Nesta base de dados, a característica de potência foi correlacionada à importância do ativo para o sistema elétrico, estabelecendo níveis de criticidade por faixas de potência, onde: transformadores com menos de 100 MVA de potência possuem nível de criticidade 1; de 100 a 200 MVA, nível de criticidade 2; e níveis de potência acima de 200 MVA, foram considerados com nível de criticidade 3. Esta convenção foi adotada com base em discussão com especialistas, de modo que transformadores com maior nível de potência tenham uma maior carga demandada e, portanto, podendo atingir um número maior de consumidores.

De modo a observar o comportamento dos algoritmos de inteligência de enxame na otimização da ponderação das características, não foi realizada uma normalização inicial. Deixou-se o espaço de busca com faixas amplas, de modo ao algoritmo conseguir a composição do índice que mais se adaptasse à ordenação definida pelo estado operacional do equipamento, sem a interferência de métricas determinadas pelo homem, que limitassem a exploração pelos algoritmos de inteligência computacional.

Definida a base de dados e os parâmetros iniciais, a primeira técnica de inteligência computacional utilizada para a composição do *Health Index* foi o método de otimização por enxame de partículas. Com o algoritmo de otimização PSO, é realizada a busca pelo vetor com o conjunto de pesos ótimos para ponderação das quatro características. Esse vetor no algoritmo de otimização por enxame de partículas está contido em cada uma das partículas, representando as coordenadas de cada uma destas.

Para avaliar a qualidade da solução de cada uma das partículas, uma função de avaliação deve ser implementada. Nesse projeto, o conjunto de pesos contido em cada uma das partículas é utilizado no cálculo do HI na Equação 8:

$$HI = \sum_{i=1}^n S_i w_i, \quad (8)$$

onde  $i$  representa o valor numérico de características avaliadas indo de 1 até  $n$ ,  $S$  a pontuação de cada técnica e  $w$  o peso o qual a pondera. Em seguida ao cálculo do HI, é realizada a ordenação dos ativos através dos valores numéricos, avaliando o número de acertos quanto à ordenação alcançada em relação ao estado físico dos ativos.

Após à aplicação do algoritmo PSO, aplicou-se o algoritmo MOPSO buscando visualizar relações entre características que apresentassem melhoria na ordenação dos ativos, a fim de determinar o conjunto de características mais importantes para o processo de priorização. Para a utilização do algoritmo, definiram-se dois objetivos principais, criando dois conjuntos de características. O primeiro está voltado a ensaios de avaliação rotineiros, definidos como dados históricos, sendo utilizados especificamente a idade e potência do ativo. O segundo está relacionado a um conjunto de características, voltadas a dados experimentais, encontrando, dentro da base de dados utilizada inicialmente, os ensaios de análise de 2-furfuraldeído e análise de gases dissolvidos no óleo isolante.

Com esta separação em dois grupos, características históricas e experimentais, criaram-se dois objetivos quanto à otimização do ranqueamento, com base em cada um dos grupos. Isto permite a visualização de quais características eram mais significativas para o processo de otimização, para suprir a base de dados com aquelas que gerassem resultados mais significativos, vislumbrando os resultados através do conjunto de soluções disposto na fronteira de Pareto após o processamento do algoritmo.

Após a utilização do algoritmo MOPSO visualizou-se como oportunidade a implementação de uma técnica de clusterização não supervisionada. Esta implementação objetivou visualizar possíveis relações desconhecidas entre as características ou mesmo algum problema junto aos dados. A técnica de clusterização evolucionária baliza a otimização dos *clusters* formados no cálculo da distância euclidiana, entre o centro do agrupamento e seus indivíduos. Insere-se como informação o número de *clusters* máximo os quais se deseja obter, verificando a formação dos agrupamentos. Podendo representar estas formações possíveis *outliers*, quando apresentando *clusters* com um único indivíduo ou mesmo com poucos indivíduos. Ressalta-se que os centros dos *clusters* são otimizados por meio de algoritmos como PSO e Algoritmo Genético, de modo que os indivíduos de cada um dos *clusters* estejam fortemente correlacionados.

Concluído o processo de clusterização evolucionária foram verificados os transformadores contidos em cada uma das classes. Com esta etapa verifica-se se o processo separação em três classes principais (boa, mediana e ruim) é factível. O algoritmo PSO é aplicado à otimização dos índices de ordenação específicos para cada uma das classes. Dessa forma, ao serem inseridos novos dados esses terão sua classe identificada e serão ordenados com a aplicação do *Health Index* correspondente a sua criticidade.

A fim de aumentar a robustez e o número de características dos dados trabalhados, encontrou-se em (ABU-ELANIEN; SALAMA; IBRAHIM, 2012), uma base de dados com 30 transformadores. Nesta base foram selecionadas seis características experimentais, sendo elas: concentração de umidade, acidez, tensão de ruptura, fator de dissipação, grau de concentração de gases dissolvidos em óleo isolante e grau de concentração de 2-furfuraldeído.

Os dados utilizados são normalizados pelo valor máximo de cada característica, estando os valores em faixas que vão de 0 a 1. A representação do conjunto de soluções é dado em um vetor binário, alcançando uma precisão de  $1 \times 10^{-6}$ . A função de avaliação quantiza a qualidade das soluções pela minimização da distância euclidiana entre os valores do HI através da Equação 9:

$$HI = \frac{\sum_{i=1}^n w_i S_i}{\sum_{i=1}^n w_i}, \quad (9)$$

onde  $i$  representa o número de características avaliadas que vão de 1 a  $n$ ,  $S$  a pontuação obtida com os ensaios de caracterização dos transformadores e  $w$  o valor numérico de ponderação das características, que nesta formulação tem seus valores normalizados, e valores previamente conhecidos, dados por um especialista, dispostos na base de dados utilizada.

Com a implementação de Algoritmo Genético aplicou-se um conjunto de medidas visando a melhoria da ordenação dos ativos com base nos primeiros experimentos, comparando com o algoritmo PSO. Ao final do processo de otimização, o vetor de representação binária é decomposto nos seis valores reais para os pesos, de modo a serem utilizados na composição do *Health Index*.

Com o aumento quantitativo de características e transformadores, foi observado o aumento da robustez dos resultados e do desafio para realização da priorização de ativos. Desse modo, determinou-se, como fator essencial, o aumento quantitativo de dados e o estabelecimento de uma priorização efetiva em níveis de criticidade para depois retornar à ordenação dos ativos.

## 4.2 Priorização por Níveis de Criticidade

Realizada a análise inicial de possíveis soluções para o problema, partiu-se para a segunda etapa. Manteve-se a expansão alcançada quanto aos dados. Apenas ensaios experimentais foram utilizados, sendo estes: concentração de umidade, acidez, tensão de ruptura, fator



de dissipação, grau de concentração de gases combustíveis dissolvidos em óleo isolante e análise do teor de 2-furfuraldeído. Realizou-se um aumento quantitativo do número de transformadores, alcançando o total de 48 ativos vistos na Seção A.2 do Apêndice A, obtendo esses a partir da composição de bases de dados públicas disponíveis nos seguintes trabalhos (ABU-ELANIEN; SALAMA; IBRAHIM, 2012) e (CERÓN et al., 2015).

Com base nos ensaios realizados em cada transformador e nos diagnósticos, foi estabelecido um modelo para utilização de técnicas de otimização, tratado em três etapas: pré-processamento dos dados, processo de otimização e validação da solução encontrada. Os dados de entrada foram separados de forma randômica em dois grupos: dados para processo de otimização dos pesos do *Health Index* e dados para validação.

Na etapa de pré-processamento dos dados a normalização das características é realizada com base no desvio padrão dos resultados de cada ensaio. Não foram utilizados métodos de seleção de características nessa etapa. Esta estratégia visa verificar a capacidade dos algoritmos realizarem a busca do conjunto de pesos ótimos ( $w$ ) para ponderar a pontuação identificada por  $S$  (*Score*) obtida com os diagnósticos de cada característica ( $i$ ) até o seu número máximo ( $n$ ).

No processo de otimização são implementados algoritmos baseados em inteligência de enxame (PSO e EHO) e, para comparação, Algoritmo Genético. Com estas técnicas de inteligência computacional busca-se o conjunto de pesos ótimos utilizados na Equação 9 para a composição do *Health Index*. Cada possível solução apresentará um vetor de pesos para a composição do *Health Index*. Essas soluções serão aplicadas em um conjunto de ativos conhecidos. O valor do *Health Index* composto para cada ativo, o enquadra em um estado operacional. O valor de aptidão de cada solução é estimado pela aproximação com a classificação do especialista. Com a solução alcançada, o processo de validação é realizado com parte dos transformadores não utilizados no processo de otimização. Ao fim do processo de otimização e validação da solução, o conjunto de pesos ótimo é alcançado para composição do *Health Index* associado a níveis de criticidade.

A implementação de Redes Neurais de Kohonen é observada como oportunidade de comparação. São utilizados 70% dos dados para treinamento e 30% para teste dos resultados. Um processo de otimização dos parâmetros da RNK é realizado com PSO. O espaço de busca de cada partícula do algoritmo PSO é definido por um vetor com as variáveis a serem otimizadas na RNK. São otimizados seis parâmetros da RNK, sendo

estes: o número máximo de épocas, número de neurônios para um arranjo quadrado da RNK, constante de tempo da taxa de aprendizagem, constante de tempo do cálculo do raio da função de vizinhança, valor mínimo e inicial da taxa de aprendizagem.

A função de custo do PSO é determinada por um procedimento de verificação dos neurônios ativados. Este procedimento é baseado em regras que permitem quantificar os acertos na classificação dos ativos. O percentual de acerto na classificação com relação ao especialista retorna, como valor de aptidão, para cada partícula do algoritmo PSO. Na Figura 6 o processo de otimização realizado é ilustrado, objetivando este a obtenção de resultados ótimos de forma autônoma.

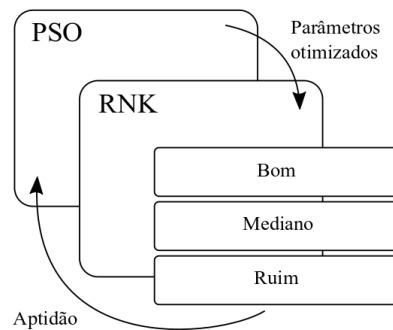


Figura 6: Processo otimização RNK com PSO

Como dito, para mensurar a qualidade das soluções alcançadas no processo de otimização da RNK, foram estabelecidas regras e, por conseguinte, um índice numérico percentual com a acertividade total na etapa de treinamento e teste. A Regra 1 estabelece que transformadores de classes distintas não podem ativar o mesmo neurônio na etapa de teste, observando através do exemplo ilustrado na Figura 7: o erro de clusterização na Figura 7(a) e o comportamento correto esperado na Figura 7(b).




Figura 7: Representação Regra 1 para RNK

A Regra 2 determina que neurônios ativados no processo de teste devem ter sido ativados previamente na etapa de treinamento do mapa. Pode-se visualizar por meio do exemplo disposto da Figura 8(a), a ocorrência de erro na etapa de treinamento, enquanto, na Figura 8(b) um acerto, uma vez que, a Figura 8(c) apresenta os neurônios ativados na etapa de teste.




Figura 8: Representação Regra 2 para RNK

Na Regra 3 foi estabelecido que, caso transformadores de classes distintas ativem os mesmos neurônios na etapa de treinamento, serão considerados como acertos aqueles que possuírem maior quantitativo de transformadores ativando o respectivo neurônio no mapa de treinamento. Ou seja, é uma classe vencedora aquela que possuir maior número de ativos em um neurônio. Além disso, para um neurônio ser vinculado a uma classe, a classe vencedora no primeiro requisito deverá possuir transformadores ativando o mesmo neurônio na etapa de teste. Ou seja, além de ter maior quantitativo no respectivo neurônio no treinamento, esse deverá ser ativado também na etapa de teste por ativos de mesma classe. Com as regras implementadas, se têm uma métrica de avaliação da qualidade das soluções apresentadas, no processo de treinamento e teste, e, desta maneira, se torna possível o cálculo dos percentuais de acerto e determinação do valor de aptidão de cada partícula do PSO.

### 4.3 Ordenação de Ativos de Alta Potência

Uma vez consolidado o método de classificação de ativos por níveis de criticidade, concentra-se os esforços na ordenação dos ativos. Com às experiências advindas dos primeiros experimentos entende-se como ponto de partida a utilização das informações de classificação, para então, realizar a ordenação de ativos identificados com condição operacional crítica. Algoritmos de otimização canônicos e associados a Redes Neurais MLP são aplicados.

Afim de analisar o comportamento dos dados de entrada, realizou-se uma análise estatística descritiva, concatenando em histogramas informações como média e desvio padrão. Verificou-se a presença de possíveis *outliers*, os quais dificultavam a separação dos dados, a fim de, com uma filtragem, fosse obtida uma base de dados linearmente separável. Na Figura 9 temos a apresentação estatística da base de dados sem filtragem.

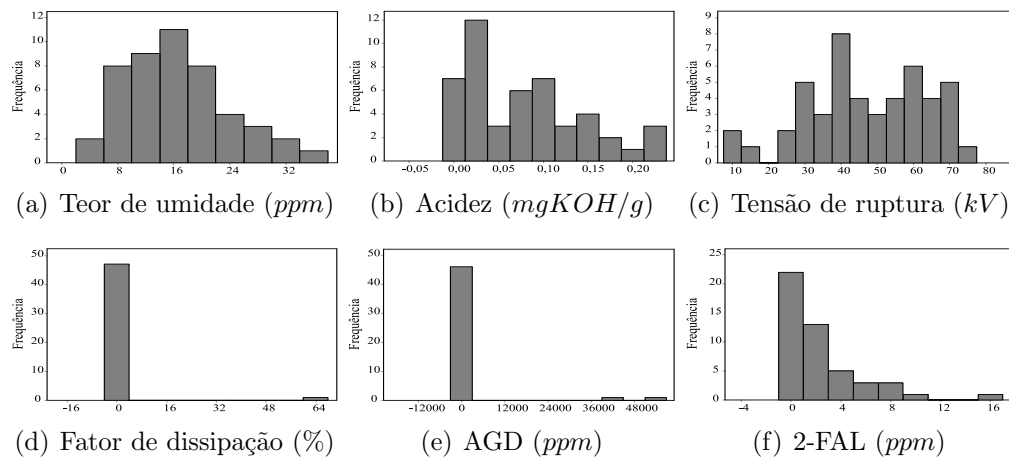


Figura 9: Análise estatística realizada para a base de dados sem tratamento

Notaram-se alguns problemas na distribuição dos dados para algumas das características avaliadas. Os dados apresentavam uma distribuição estatística inadequada em duas características avaliadas, Fator de Dissipação e AGD. Constatou-se que a distribuição estatística incorreta ocorria devido a 3 transformadores com medidas discrepantes, sendo considerados *outliers*, por conta, das medidas não terem sido realizadas nesta dissertação. Com os *outliers* removidos, refez-se a análise, podendo essa ser vista através dos histogramas para cada característica na Figura 10.

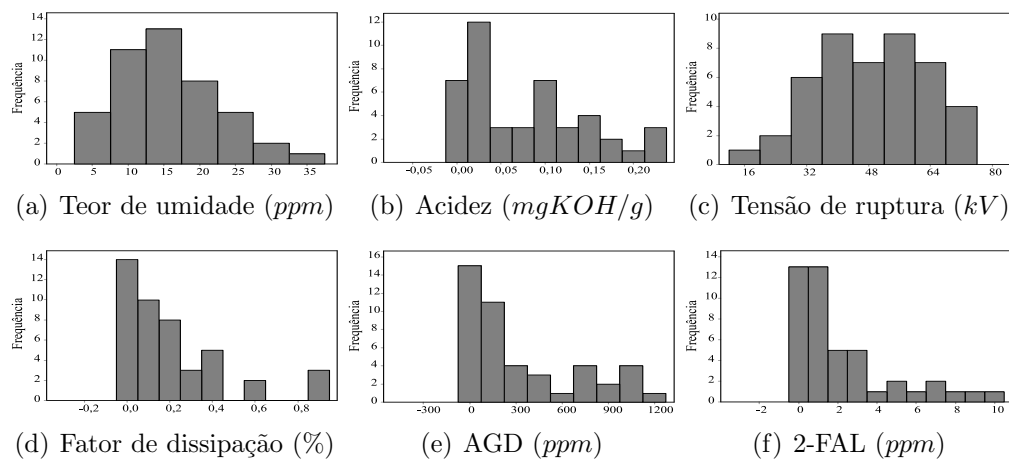


Figura 10: Análise estatística realizada para a base de dados filtrada

Realizada a análise, verificou-se que a distribuição estatística do fator de dissipação apresentava dois pontos de descontinuidade da distribuição. Aplicou-se então, um tratamento estatístico através da normalização dos dados ( $x_n$ ), por meio da Equação 10:

$$x_n = \frac{x - \bar{x}}{\sigma}, \quad (10)$$

onde  $x$  representa o valor numérico a se normalizar,  $\bar{x}$  a média e  $\sigma$  o desvio padrão. Com a filtragem do banco de dados, normalização e análise estatística disposta na Figura 11, aplicou-se o método de clusterização não supervisionado, utilizando RNK.

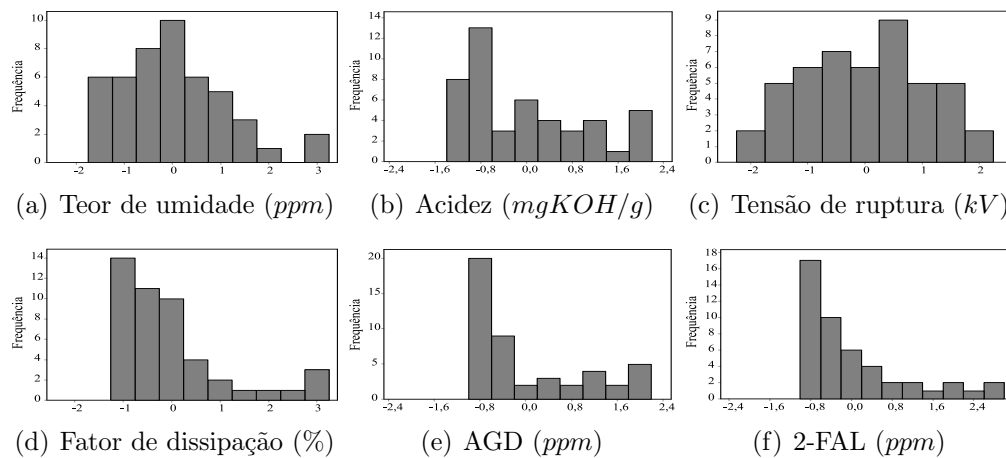


Figura 11: Análise estatística realizada para a base de dados filtrada e normalizada

Realizado o tratamento dos dados e verificada a condição operacional de cada ativo, aplicou-se o algoritmo PSO nos ativos identificados com condição operacional crítica. Cada partícula carrega um vetor com os pesos para ponderação das características de avaliação dos ativos classificados como ruins. O índice numérico é composto com base na Equação 9. A composição dos valores do HI para o conjunto de transformadores classificados como ruim é ordenada, representando 1 e 0, respectivamente, condição operacional ruim e boa. O percentual de acertos na ordenação dos ativos com relação ao especialista é definido como o valor de aptidão de cada partícula. Dessa forma, o processo de otimização dos pesos com base na ordenação dentro da classe é estabelecido, sendo possível a priorização de recursos com a ordenação dos ativos.

Em seguida, desenvolveu-se uma estratégia nomeada Valoração Não Linear (VNL), associando sua aplicação ao PSO. Esta estratégia explora resultados subótimos adequados a aplicação. A função de custo do PSO é alterada, de modo, que amostras críticas não podem ter erros na sua ordenação. Todavia, ativos em condição operacional menos crítica podem assumir erros de no máximo uma posição com perda de 50% de sua pontuação na

composição do valor de aptidão da partícula. Assim, estabeleceu-se que 60% dos ativos mais críticos devem direcionar a otimização dos pesos do HI, ou seja, aqueles que tem maior importância e estão em pior estado de operação não podem ter sua priorização equivocada.

Com o objetivo de aumentar a capacidade de extração de informações e a complexidade, de forma gradual, realizou-se um novo experimento com a inserção de uma função de ativação nos valores do HI. Na Figura 12(b) pode-se ver a inserção da função de ativação, assemelhando-se a estrutura com o cálculo do HI tradicional, visto na Figura 12(a).

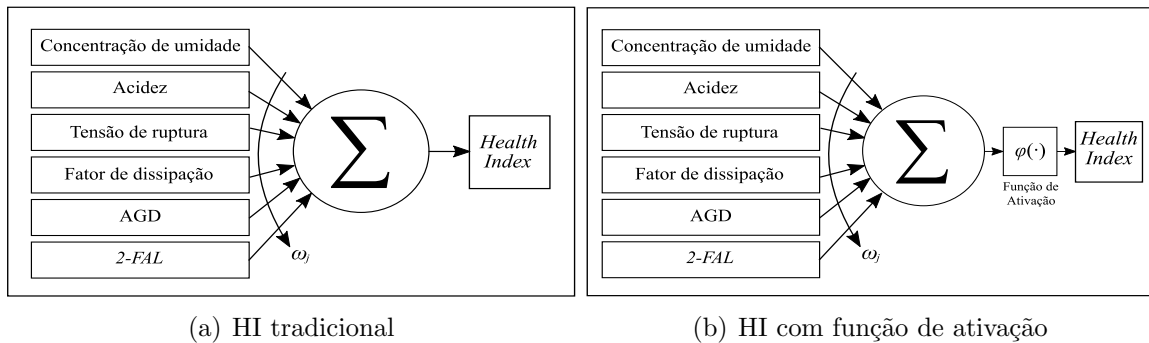


Figura 12: Metodologia de aproximação com priorização do especialista

No procedimento de composição convencional do *Health Index* ilustrado na Figura 12(a) ou mesmo no processo realizando o uso de função de ativação na Figura 12(b), temos a ponderação por pesos normalizados  $w_j$ . O cálculo dos pesos  $w_j$  são descritos matematicamente através da Equação 11:

$$w_j = \frac{w_i}{\sum_{i=1}^n w_i}, \quad (11)$$

onde  $i$  representa o número de características de avaliação dos ativos utilizados indo de 1 a  $n$ , e  $w_i$  o vetor de pesos não normalizado. A inserção da função de ativação limita o valor de saída, inserindo um intervalo de interesse no *Health Index* calculado. Experimentou-se funções de ativação linear (*Purelin*), sigmóide (*Logsig*) e tangente hiperbólica (*Tansig*).

Com a inserção da função de ativação e verificação dos resultados completa-se o modelo, compondo uma rede neural MLP. Dessa forma, ao modelo é inserido um *bias*. A sintonização de todos os pesos da rede MLP é realizada com a aplicação o algoritmo PSO, sendo utilizado como algoritmo de treinamento. Cada partícula do PSO contém o conjunto de pesos otimizados para a rede MLP, retornando como aptidão o número

de acertos percentual com VNL. Como estrutura inicial utiliza-se apenas um neurônio artificial, consolidando uma estrutura mínima, como segue na Figura 13.

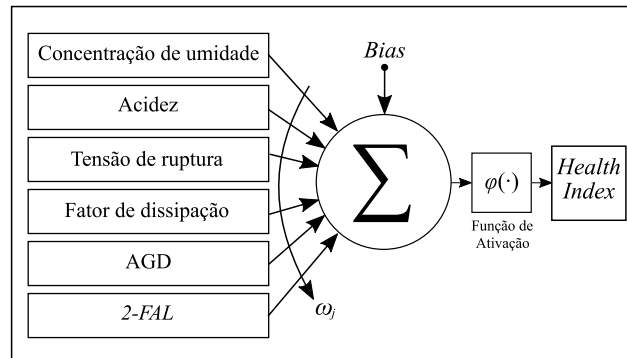


Figura 13: Modelo de neurônio artificial

O desempenho atingido com a utilização de uma estrutura mínima é verificado. O número de neurônios artificiais na camada escondida no decorrer do experimento foi aumentado gradualmente, de modo, a crescer o poder de extração de padrões do modelo. Na camada de saída utilizou-se em toda experimentação apenas um neurônio, consolidando o valor numérico do *Health Index*.

Realizaram-se experimentos alterando a quantidade de: neurônios da rede, número de camadas, número de épocas, número de partículas utilizadas no PSO e a função de ativação. Com diferentes configurações estudou-se os impactos alcançados na ordenação dos ativos em termos de acurácia.

A utilização do algoritmo PSO canônico no processo de ordenação foi revisitada com a alteração da função de custo. A modificação visou a composição dos pesos do HI, de forma, que os valores de saída calculados se aproximassem de valores conhecidos, como em uma rede neural, porém, com uma complexidade inferior. Para isso, a função de custo foi alterada avaliando a aptidão de cada partícula pelo cálculo e minimização de uma composição de erros.

A composição disposta na função de avaliação da aptidão das partículas foi alterada. Nesta função foi inserido a média ponderada entre o MSE (*Mean Square Error*) máximo, MSE médio e o erro de posicionamento ( $E$ ). Essa tentativa buscou a otimização de pontos críticos, sendo eles: a minimização do MSE médio do conjunto de ativos como um todo, a redução de erros pontuais onde se tem alta distância entre o valor calculado e conhecido para o *Health Index*, e a minimização de  $E$ . Em um segundo momento é aplicada a utilização apenas do cálculo do MSE como estimador, entre os valores conhecidos e calculados. Nesta abordagem é verificado se com índice único e específico o desempe-

nho na ordenação dos ativos é elevado. Esse conjunto de medidas visou a possibilidade de melhoria das soluções obtidas com o PSO, representando esse algoritmo as técnicas de inteligência de enxame, sendo um fator limitante para implementação de novos algoritmos para o processo de ordenação o tempo.

## 4.4 Considerações Finais

Nesse capítulo foi apresentado o método para composição do *Health Index* com a aplicação de técnicas de inteligência computacional para classificação e ordenação de ativos de alta potência. No próximo capítulo serão abordados e discutidos os principais resultados experimentais alcançados com a aplicação das estratégias apresentadas neste.



# Capítulo 5

## EXPERIMENTOS E RESULTADOS

**E**STE capítulo apresenta os resultados obtidos neste projeto para o problema de priorização de ativos de alta potência com a associação de inteligência computacional para a composição do *Health Index*. Os resultados alcançados, bem como as configurações e parâmetros dos algoritmos utilizados no desenvolvimento desta dissertação são apresentados e discutidos. Na Seção 5.1 são apresentados os resultados alcançados para os experimentos preliminares. Na Seção 5.2 são apresentados os resultados alcançados para o processo de priorização de ativos por níveis de criticidade. Na Seção 5.3 são apresentados os resultados alcançados para o processo de ordenação de ativos. Por fim, na Seção 5.4 são apresentadas as considerações finais.

### 5.1 Resultado Preliminar

As primeiras implementações focaram na exploração de algoritmos de otimização baseados em enxame, sendo o primeiro o PSO. Esse algoritmo foi aplicado sob uma base de dados não consolidada à qual se dispunha inicialmente. Como configuração foram utilizados: população de 100 indivíduos; número máximo de 300 iterações; coeficiente de inércia igual a 1; coeficiente cognitivo igual a 2; coeficiente de aprendizado social igual a 2; velocidade máxima de avanço de 1,5, 8, 20 e 15, respectivamente para, idade, importância no sistema, cromatografia e 2-FAL. Para posição máxima e mínima das partículas no sistema utilizou-se: 0 a 20 unidades, para idade e importância no sistema; 0 a 50 unidades, para cromatografia e 2-FAL. Os parâmetros base são empregados ao longo das implementações, inclusive para os parâmetros comuns ao algoritmo MOPSO.

Os primeiros experimentos focaram na otimização dos pesos do HI sem nenhum tipo de filtragem da base de dados, até porque a quantidade de dados era restrita, não sendo desejado perder nenhum tipo de informação que pudesse trazer bons resultados.

Observou-se também a capacidade do algoritmo PSO minimizar os pesos de características menos significativas, as quais não trouxessem benefícios para a composição e ordenação dos ativos.

Os resultados médios em termos de acurácia podem ser observados abaixo para a base de dados sem qualquer processo de filtragem ou tratamento. Nesta os experimentos foram repetidos 100 vezes, variando o número de iterações e o número de indivíduos (NI) do algoritmo, como pode ser observado na Figura 14.

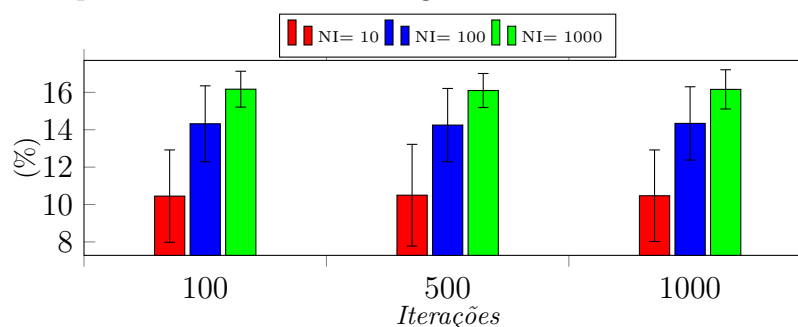


Figura 14: Acurácia média (%) utilizando PSO com base de dados sem filtragem

Em termos de acurácia média para a base de dados sem tratamento observaram-se valores insatisfatórios tanto na reprodução dos experimentos como nos melhores resultados alcançados. A filtragem de alguns elementos que foram considerados *outliers* dentro da base de dados tornou-se necessária. Uma melhora na priorização alcançada ocorreu, repetindo os experimentos com algoritmo PSO 100 vezes, buscando resultados médios. Ressalta-se, que a filtragem dos dados tornou-se evidente, após a aplicação da técnica de clusterização evolucionária. Para melhor entendimento e comparação, os resultados podem ser vistos abaixo na Figura 15.

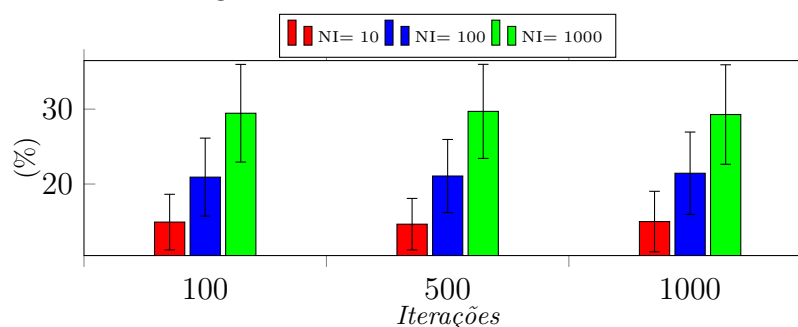


Figura 15: Acurácia média (%) utilizando PSO com base de dados filtrada

Com os resultados médios alcançados observa-se uma dificuldade na reprodutibilidade de bons resultados, ocorrendo este pela dificuldade do algoritmo convergir sucessivas vezes para soluções adequadas. Entretanto, dentro destas repetições, nos melhores resultados, com o processo de filtragem e utilização do algoritmo PSO, foi alcançada uma

acurácia de 73,08% com relação à ordenação do especialista, utilizando número máximo de 1000 iterações. Esse resultado pode ser observado através da Figura 16.

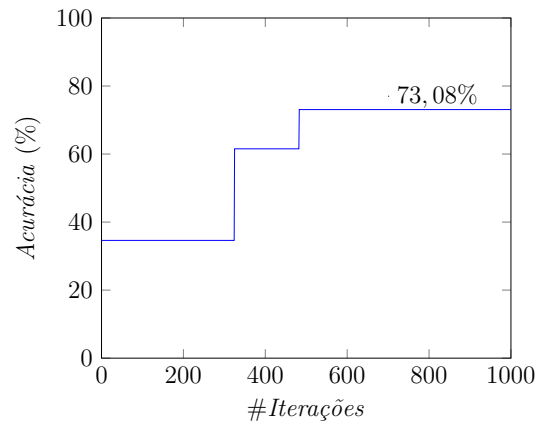


Figura 16: Acurácia com base de dados filtrada utilizando algoritmo PSO

Com PSO observa-se que a dificuldade de estabelecer uma priorização, advém das características utilizadas não serem suficientes para representação de cada um dos transformadores utilizados. Deste modo, verifica-se com o algoritmo MOPSO a sensibilidade às características utilizadas no processo de otimização. As características são separadas em dois conjuntos: características de avaliação dos transformadores baseadas em informações históricas (idade e potência) e características experimentais fruto de medições (análise da concentração de 2-furfuraldeído e análise de cromatografia gasosa). Dessa forma, com o processo de otimização multi-objetivo visualizou-se com qual grupo de característica uma melhora na ordenação era alcançada. O tamanho do repositório é definido como 50, o coeficiente  $\xi$  é definido igual a 10, e os demais parâmetros comuns ao PSO canônico são mantidos. Na Figura 17, nota-se o conjunto de soluções dispostas na fronteira de Pareto após a execução do MOPSO.




Figura 17: Fronteira de Pareto obtida com a aplicação do algoritmo MOPSO

Com a fronteira de Pareto nota-se que os melhores valores em acurácia são alcançados com a utilização de características experimentais. Afim de observar relações entre as

classes desconhecidas, experimenta-se o algoritmo de clusterização evolucionária. Como parâmetro inicial para o algoritmo determinou-se número de *clusters* máximo igual a 7, verificando o agrupamento formado na Figura 18.




Figura 18: Aplicação de clusterização evolucionária em base de dados sem filtragem

Notou-se na Figura 18 a formação de dois *clusters*. Com isso, verificou-se a necessidade de realizar uma filtragem dos dados, eliminando da base de dados as informações dos transformadores: SPT1843, SPT4907, SPT4912, SPT4910 e SPT4906. Com a filtragem repetiu-se o experimento, reduzindo o número máximo de *clusters* para 5, alcançando o agrupamento dos dados dispostos na Figura 19.




Figura 19: Divisão de classes com clusterização evolucionária após filtragem dos dados

Com os *clusters* formados, verificou-se a possibilidade de sumarização em três classes, como foi ilustrado na Figura 19, sendo elas: classe B, ativos com condição operacional ruim; classe M, ativos com condição operacional mediana e classe G, ativos com condição operacional boa. Essas classes foram definidas a partir da validação dos ativos agrupados, observando que a separação estava alinhada à classificação dos especialistas. Em seguida, o algoritmo PSO é aplicado na otimização dos pesos usados na fórmula de cálculo do

HI em cada classe. Assim, um conjunto de pesos específico para cada classe de ativos é estabelecido, otimizando sua ordenação.

Com a filtragem e clusterização dos dados, o grau de acurácia na ordenação dos ativos em cada uma das classes teve um aumento. Obteve-se acurácia máxima de 100% para o grupo de ativos classificados como ruins (grupo B), 80% para ativos classificados como medianos (grupo M) e 100% para o grupo de ativos classificados como bons (grupo G), ressaltando a redução do número de características avaliadas nessa implementação para duas: análise de 2-furfuraldeído e análise de gases dissolvidos em óleo isolante.

Com a redução do número de características e filtragem consegue-se obter uma melhora significativa na priorização. Todavia, observa-se que pela dimensão da base de dados ser mínima e pouco diversificada podem ocorrer problemas em uma expansão. Desse modo, um aumento da base de dados foi realizado, visando observar o comportamento de um algoritmo de otimização. Neste aumento alcançou-se 30 ativos com 6 características distintas (ABU-ELANIEN; SALAMA; IBRAHIM, 2012).

Aplicou-se Algoritmo Genético ao processo de otimização, alterando a função de custo com a aproximação de valores do HI fornecidos por especialistas. Aos dados executou-se o processo de normalização pelo valor máximo de cada característica, estando os valores fixos de 0 a 1. O conjunto de soluções real foi representado de forma binária com um vetor de 162 bits, sendo 27 bits para cada característica. Uma precisão de  $1 \times 10^{-6}$  foi alcançada, estando os valores dos pesos entre 1 e 100 por determinação de especialistas envolvidos. A taxa de cruzamento foi estimada em 80%, a taxa de mutação em 10% e o número máximo de gerações igual a 1000. Os experimentos foram repetidos 100 vezes alcançando valores médios para os valores estimados para cada ativo na aproximação do HI.

No processo de otimização foi alcançado uma acurácia média de 77,57% após 100 repetições. Os valores estimados para o HI podem ser comparados com os valores apresentados por especialistas na Tabela 1. Nota-se que existe elevada distância em ativos com condição operacional ruim (valores próximos a 1) entre valores estimados e apresentados por especialistas. Entretanto, a solução apresenta boa reprodutibilidade de resultados e erro significativamente mais baixo entre aproximadamente 2/3 dos ativos menos críticos.

Tabela 1: Valores médios estimados para HI, utilizando AG

Ativo	Especialista		Estimado		Ativo	Especialista		Estimado	
	HI	$\sigma$	HI	$\sigma$		HI	$\sigma$	HI	$\sigma$
1	0,072	0	0,1477	0,0047	17	0,368	0	0,0841	0,0053
2	0,102	0	0,1188	0,0057	18	0,371	0	0,3761	0,0048
4	0,225	0	0,2256	0,0034	19	0,377	0	0,2688	0,0078
5	0,226	0	0,2106	0,0065	21	0,414	0	0,2299	0,0080
6	0,241	0	0,0981	0,0048	22	0,45	0	0,3107	0,0089
7	0,241	0	0,2230	0,0031	23	0,45	0	0,3521	0,0044
8	0,274	0	0,2415	0,0046	24	0,45	0	0,5882	0,0101
9	0,29	0	0,1862	0,0054	34	0,7	0	0,5670	0,0045
10	0,29	0	0,2555	0,0038	36	0,732	0	0,4967	0,0060
11	0,291	0	0,3121	0,0076	43	0,916	0	0,5214	0,0046
12	0,316	0	0,3447	0,0034	44	0,931	0	0,4864	0,0031
13	0,316	0	0,3885	0,0096	45	0,953	0	0,5930	0,0047
14	0,334	0	0,3774	0,0079	46	1	0	0,5594	0,0047
15	0,347	0	0,2488	0,0060	47	1	0	0,5297	0,0026
16	0,354	0	0,3370	0,0069	48	1	0	0,7973	0,0056

Na Figura 20 os valores apresentados na Tabela 1 são apresentados por gráfico de barras. Os ativos utilizados no processo podem ter suas características avaliadas por meio da sua identificação na Seção A.2 do Apêndice A.

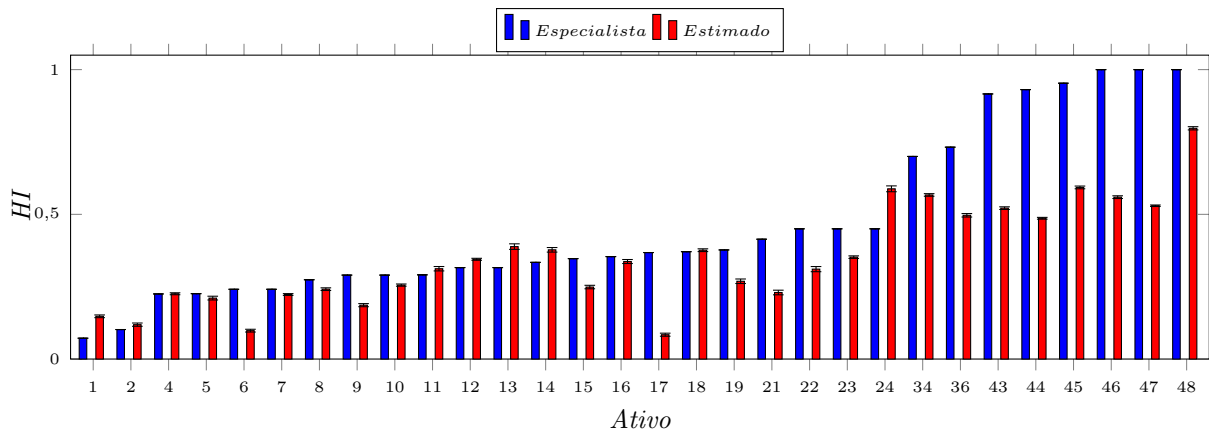


Figura 20: Aproximação alcançada para HI com a aplicação de AG

## 5.2 Resultado da Classificação de Ativos

Nesta seção serão apresentados os resultados para priorização de ativos por níveis de criticidade. Os modelos para classificação de ativos propostos nesta seção são comparados com técnicas tradicionais, como algoritmo genético, redes neurais MLP (ABU-ELANIEN; SALAMA; IBRAHIM, 2011) e sistema de inferência *fuzzy* (ABU-ELANIEN; SALAMA; IBRAHIM, 2012).

Os ativos utilizados na base de dados foram previamente classificados por níveis de criticidade (bom, mediano e ruim). Os valores numéricos após a composição do *Health Index* se dão sob: 0,75 à 1, condição operacional ruim; 0,45 à 0,75, condição operacional mediana; 0 à 0,45, condição operacional boa (SANTOS et al., 2018a). Os primeiros resultados descritos abaixo são fruto da divisão do banco de dados com 54,2% dos transformadores para otimização e 45,8% para validação (SANTOS et al., 2018b). Apresentam-se diferentes configurações quanto ao número de indivíduos e número máximo de iterações, com limite de 100 iterações (Caso 1 -  $C_1$ ) e 1000 iterações (Caso 2 -  $C_2$ ). Foram implementados e comparados os resultados de três algoritmos de otimização: PSO, EHO e GA. Notam-se, na Tabela 2, os valores numéricos alcançados em termos de acurácia média, após 500 repetições, sob diferentes parâmetros para os algoritmos de otimização utilizados.

Tabela 2: Acurácia média (%)

NI	PSO		EHO		GA	
	$C_1$	$C_2$	$C_1$	$C_2$	$C_1$	$C_2$
10	89,87	91,61	99,19	100	74,11	86,21
20	92,58	93,44	99,82	100	78,23	93,19
50	92,78	93,43	99,98	100	82,81	94,55
100	93,45	93,15	99,95	100	86,31	94,79

Os resultados em termos de acurácia evidenciam o algoritmo EHO com resultados promissores apresentando nos melhores resultados uma acurácia de 100% com relação a classificação do especialista. Os piores resultados são obtidos com a aplicação de Algoritmo Genético alcançando nos piores resultados uma acurácia de 74,11%. O algoritmo PSO apresenta valores intermediários em termos de acurácia na classificação de ativos. Com a Tabela 3 são apresentados os desvios padrões correspondentes às repetições dos experimentos em cada um dos algoritmos com suas diferentes configurações apresentando todos os valores em termos percentuais.

Tabela 3: Desvio padrão ( $\sigma$ ) dos valores encontrados para acurácia média (%)

NI	PSO		EHO		GA	
	$C_1$	$C_2$	$C_1$	$C_2$	$C_1$	$C_2$
10	8,79	7,44	3,03	0,00	10,49	11,47
20	6,66	4,97	1,37	0,00	10,08	6,44
50	5,01	4,21	0,29	0,00	10,18	4,04
100	4,30	4,17	0,45	0,00	10,37	3,60

Nota-se que o algoritmo EHO apresenta alto grau de reprodutibilidade dos resultados, observando uma maior variabilidade com a aplicação de Algoritmo Genético. De modo a facilitar a visualização dos resultados obtidos para os experimentos, utilizando 54,2% dos transformadores para otimização e 45,8% para validação, observa-se na Figura 21 a apresentação gráfica para os valores das Tabelas 2 e 3.

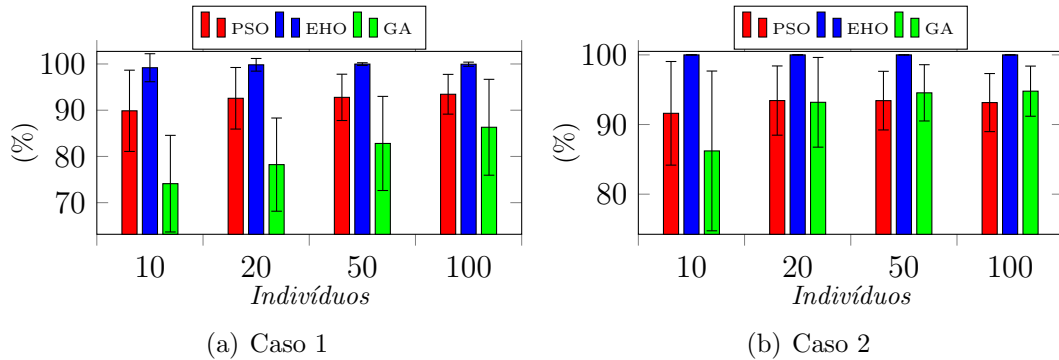


Figura 21: Acurácia média (%) alcançada para classificação de ativos

Com os resultados alcançados destaca-se o algoritmo EHO, sendo um grande trunfo a sua simplicidade construtiva. Os resultados com a aplicação de AG mostram baixo desempenho, acreditando ser um dos motivos a sofisticação e maior número de parâmetros para sintonização. Afim de realizar uma comparação em termos de eficiência, verificou-se o tempo de convergência médio obtido, sendo visto na Tabela 4.

Tabela 4: Tempo de convergência médio ( $s$ )

NI	PSO		EHO		GA	
	$C_1$	$C_2$	$C_1$	$C_2$	$C_1$	$C_2$
10	1,21	13,11	0,68	0,59	2,12	13,24
20	2,48	24,65	1,64	0,92	3,96	21,92
50	5,94	59,50	3,68	1,97	6,91	98,99
100	11,78	187,69	3,81	4,84	16,59	176,10

Com o tempo de convergência médio a simplicidade de execução do algoritmo EHO é notada. Os piores resultados em tempo de execução ocorreram com a utilização do algoritmo PSO. A Tabela 5 complementa as informações com o desvio padrão.

Tabela 5: Desvio padrão ( $\sigma$ ) do tempo de convergência médio ( $s$ )

NI	PSO		EHO		GA	
	$C_1$	$C_2$	$C_1$	$C_2$	$C_1$	$C_2$
10	0,27	4,87	0,42	0,58	0,17	3,93
20	0,84	9,24	0,86	0,67	0,24	12,85
50	1,73	26,41	1,79	0,92	0,79	26,96
100	4,54	65,13	1,81	2,29	2,20	82,99



Com os resultados de desvio padrão para o tempo de convergência médio observa-se que a variabilidade permanece maior para AG. Assim, ressalta-se que algoritmo PSO possui uma melhor reprodutibilidade comparado a Algoritmo Genético, mesmo tendo um tempo de convergência médio mais elevado. Na Figura 22 os valores médios e de desvio padrão são apresentados de forma gráfica, facilitando a interpretação dos dados.

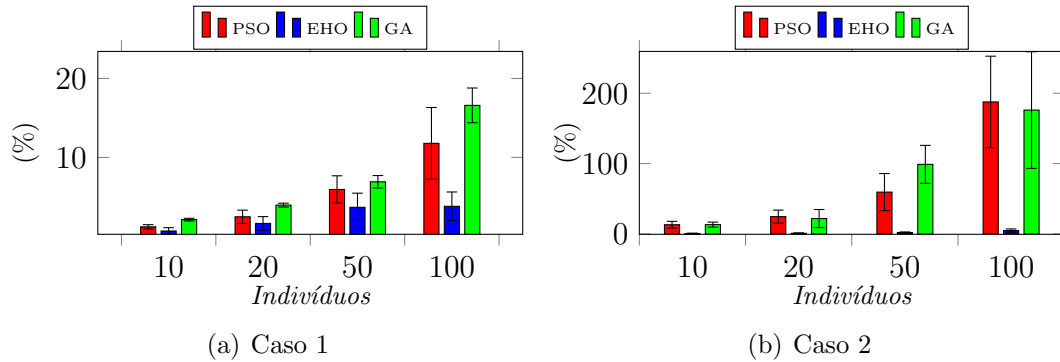


Figura 22: Tempo de convergência médio (s) alcançado na etapa de classificação de ativos

A segunda sequência de experimentos apresenta os resultados obtidos com a mudança na distribuição dos dados. São utilizados 62,5% dos transformadores disponíveis na base de dados para o processo de otimização e 37,5% para validação. Na Tabela 6, são apresentados os valores numéricos médios percentuais para a acurácia alcançada com relação a uma classificação conhecida dos ativos. Na Tabela 7, são apresentados os respectivos valores de desvio padrão complementando as informações.

Tabela 6: Acurácia média (%)

NI	PSO		EHO		GA	
	$C_1$	$C_2$	$C_1$	$C_2$	$C_1$	$C_2$
10	89,72	92,08	98,74	100,00	70,67	85,67
20	92,74	94,71	99,28	100,00	76,32	93,72
50	93,94	94,34	99,98	100,00	82,37	96,37
100	94,78	94,84	99,97	100,00	84,59	96,80

Tabela 7: Desvio padrão ( $\sigma$ ) da acurácia média (%)

NI	PSO		EHO		GA	
	$C_1$	$C_2$	$C_1$	$C_2$	$C_1$	$C_2$
10	11,07	9,55	4,08	0,00	10,68	12,82
20	8,17	6,10	3,17	0,00	11,48	8,61
50	7,32	6,13	0,35	0,00	11,66	4,11
100	6,12	4,90	0,43	0,00	11,85	3,93

Com a alteração da relação de dados percebe-se uma piora nos resultados com Algoritmo Genético, acreditando esta ocorrer por o algoritmo não conseguir realizar o

reconhecimento de novos padrões de forma adequada. Em contrapartida o algoritmo EHO mostra-se eficaz aumentando a acurácia uma vez que consegue otimizar o HI com a adaptação a novos padrões de entrada. A Figura 23 apresenta os resultados médios obtidos com os respectivos desvios padrões, para cada uma das configurações dos algoritmos de otimização implementados em termos de acurácia.

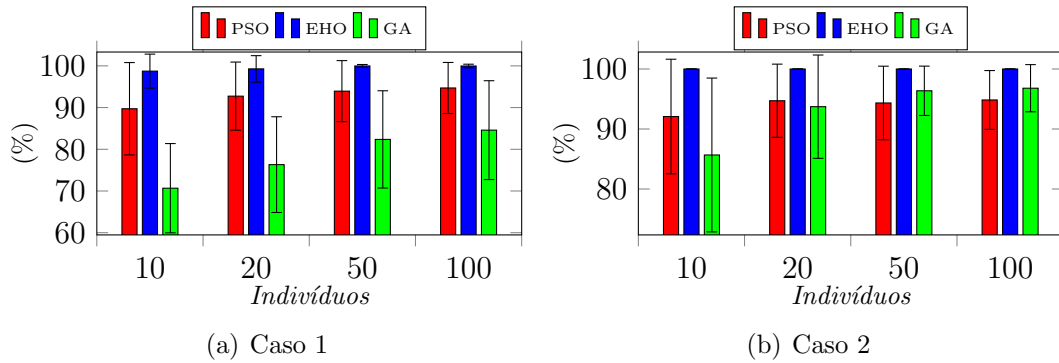


Figura 23: Acurácia média (%) alcançada com aumento de dados

A influência do aumento da capacidade de extração de informações pertinentes à composição dos pesos do *Health Index* é verificada, com o aumento da relação de dados no processo de otimização. Realiza-se o registro dos tempos de convergência médio de cada algoritmo na Tabela 8.

Tabela 8: Tempo de convergência médio (s)

NI	PSO		EHO		GA	
	$C_1$	$C_2$	$C_1$	$C_2$	$C_1$	$C_2$
10	1,20	9,61	1,09	1,12	1,55	13,11
20	3,01	16,81	1,04	1,83	2,88	31,15
50	4,78	41,78	2,01	3,90	6,88	38,93
100	14,24	86,21	7,26	4,15	13,45	69,38

Nota-se um aumento no tempo necessário para convergência uma vez que os padrões de entrada são aumentados no processo de otimização. A Tabela 9 apresenta os respectivos valores de desvio padrão. Dessa forma, pode-se analisar os algoritmos que convergem numa maior velocidade e conseguem repetir esses valores.

Tabela 9: Desvio padrão ( $\sigma$ ) do tempo de convergência médio (s)

NI	PSO		EHO		GA	
	$C_1$	$C_2$	$C_1$	$C_2$	$C_1$	$C_2$
10	0,45	5,92	0,71	1,39	0,15	5,01
20	1,31	11,76	0,65	2,41	0,40	18,04
50	2,48	28,55	1,04	2,45	1,05	28,05
100	8,54	56,24	3,67	5,01	2,09	57,66

Com os resultados observa-se que o algoritmo EHO consegue convergir com um menor tempo médio e ainda alcançar valores em acurácia elevados como visto na Tabela 6. Na Figura 24 são apresentados de forma gráfica os resultados para o tempo de convergência médio com os respectivos desvios, sintetizando os valores observados nas Tabelas 8 e 9.

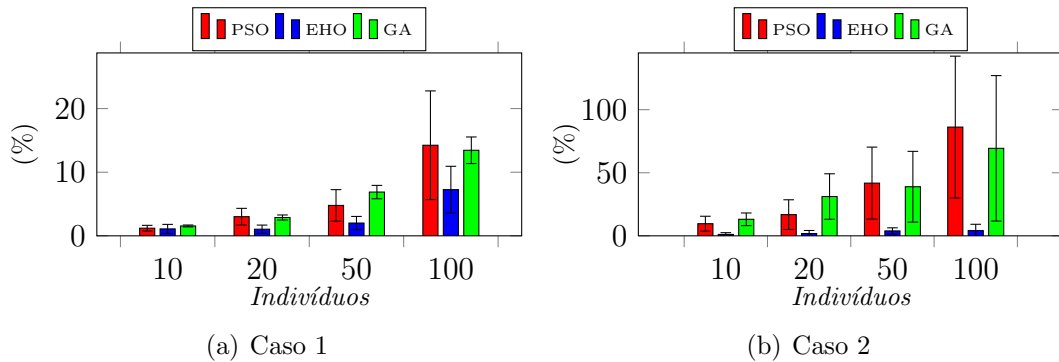


Figura 24: Tempo de convergência médio (s) alcançado na classificação de ativos

Para alcançar os resultados apresentados, nas implementações, que utilizaram algoritmo AG e PSO, foram mantidos os parâmetros comuns utilizados na Seção 5.1, alterando apenas o NI e o número máximo de iterações. Para as implementações que utilizaram o algoritmo EHO definiu-se o número de clãs como 1, para ter igualdade na comparação com os demais algoritmos. O coeficiente  $\beta$  foi definido empiricamente como 0,8 e o coeficiente  $\alpha$  como 0,2. Os parâmetros comuns aos demais algoritmos, como número de elefantes e número máximo de gerações, foram apresentados a cada experimentação.

Com as técnicas de inteligência coletiva aplicadas realizou-se a implementação de RNK com a otimização de seus parâmetros com o algoritmo PSO. Essa aplicação visou complementar o estudo de classificação de transformadores de potência. A utilização do PSO visou a otimização da RNK para separação de padrões em classes, reunindo as melhores características da RNK para solução do problema.

No processo de otimização da RNK com PSO, cada partícula compõe um vetor com um conjunto de configurações ótimas para RNK. A aptidão de cada partícula no algoritmo PSO é obtida com a acurácia total alcançada no processo de treinamento e teste da RNK. A acurácia total é quantizada por meio regras descritas no capítulo anterior, as quais, automatizam o processo de verificação de resultados da RNK. Como parâmetros para o algoritmo PSO são definidos:

- Peso de inércia igual a 1;
- Peso de aprendizado cognitivo igual a 1,5;

- Peso de aprendizado social igual a 2;
- Número de partículas igual a 10;
- Número máximo de iterações igual a 100;
- Velocidade de avanço-recuo igual a 50% do *span* de cada parâmetro otimizado.

O processo de otimização de uma RNK é justificado uma vez que as possíveis combinações entre os parâmetros chegam a  $1,12 \times 10^{11}$  possibilidades. Desta forma, o algoritmo PSO é aplicado visando a obtenção de parâmetros adequados em um prazo viável. As variáveis e os limites de posição a serem otimizados na RNK, foram:

- Número máximo de épocas variando de 1 a 20;
- Número total de neurônios para uma grade quadrada variando de 4 a 225;
- Constante de tempo  $\tau_2$  variando de 1 a 1000;
- Constante de tempo  $k_{\tau_1}$  variando de 1 a 1000;
- Valor mínimo da taxa de aprendizagem variando de 0,001 a 0,1;
- Valor inicial da taxa de aprendizagem variando de 0,1 a 0,5.

Os resultados em termos de acurácia média percentual no processo de treinamento e teste da RNK são quantizados a partir de 100 repetições. No processo de otimização foi alcançada uma acurácia média de 94,22%. No processo de teste foi alcançada uma acurácia média de 84,08%. Dessa forma, entre acertos no processo de otimização e teste, é alcançada 91,29% de acurácia na classificação de ativos.

Como parâmetros ótimos para RNK são encontrados com PSO: número máximo de épocas igual a 5, 144 neurônios, constante de tempo  $\tau_2$  igual a 601,1271, constante de tempo  $k_{\tau_1}$  igual a 781,4849, valor mínimo para taxa de aprendizagem igual a 0,0307 e valor inicial da taxa de aprendizagem de 0,2238. Na melhor execução são alcançados resultados com acurácia no processo de treinamento de 96,88% e teste 92,31%. Esses valores compõem uma acurácia total na melhor execução da RNK otimizada com PSO de 95,56%.

Com o processo de otimização, o percentual de acerto nas classes boa e ruim, no treinamento e teste, alcançou de 100% em acurácia. Pequenos problemas ocorreram apenas sob a classe mediana, nesta, alcançou-se em acurácia: 87,5% e 66,67%, respectivamente, no treinamento e teste. Observa-se a ativação dos neurônios por cada uma das classes de ativos, na Figura 28 para ativos de treinamento, e na Figura 26 com os ativos de teste.

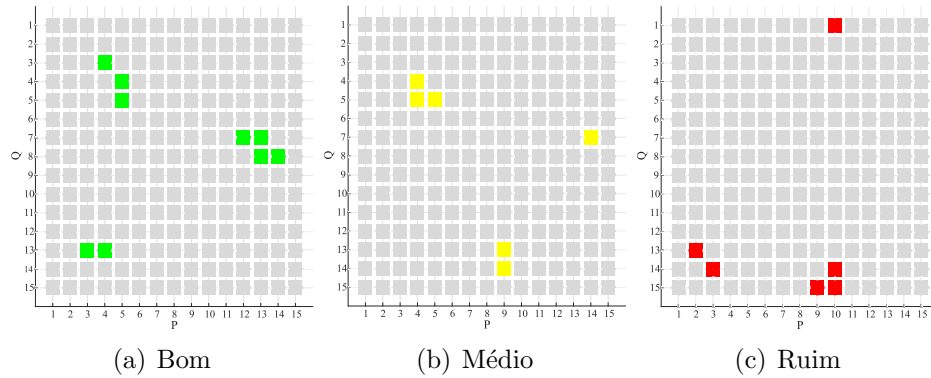


Figura 25: Ativação dos neurônios por cada classe de ativos no treinamento

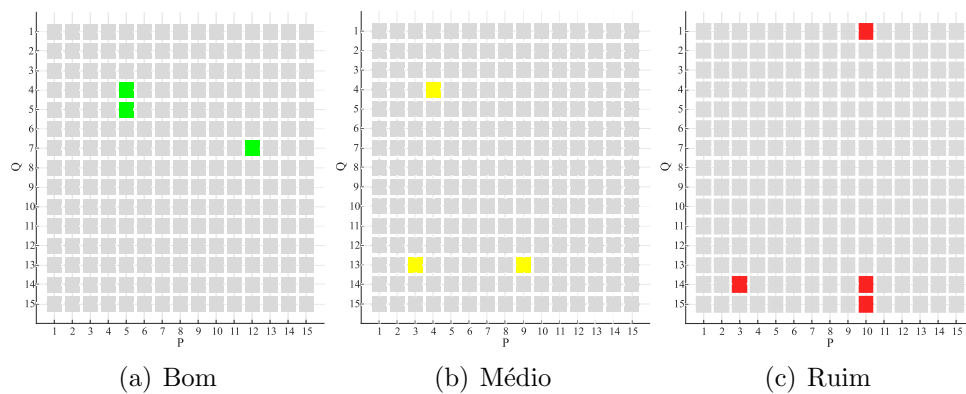


Figura 26: Ativação dos neurônios por cada classe de ativos no teste

Acredita-se que a relação de acerto entre treinamento e teste, não tenha sido ainda mais expressiva, devido à baixa quantidade de amostras para a extração de padrões, fato este que contribui para uma geometria não tradicional dos *clusters*. Todavia, nota-se que a extração de padrões se tornou extremamente adequada, não ocorrendo o processo de *overfitting*.

Estes resultados tornaram-se viáveis com a aplicação do PSO na otimização da RNK, sendo essencial para o aumento da acurácia da classificação dos ativos. A utilização de RNK torna-se interessante uma vez que, os dados não são classificados por faixas do HI, mas sim pela similaridade com os pesos de entrada da rede. Evidencia-se, que o problema na classificação de ativos medianos não é um ponto extremamente grave, porque tanto a etapa de classificação como ordenação de ativos visam evidenciar os piores ativos de uma subestação.

Concluída as implementações a análise dos resultados é complementada com técnicas consagradas implementadas em trabalhos semelhantes. A aplicação de redes neurais MLP na classificação de ativos é notada na literatura, atingindo uma acurácia de 96,55%

na priorização de um grupo de ativos conhecidos (ABU-ELANIEN; SALAMA; IBRAHIM, 2011). Todavia, não há registro do tempo necessário para treinamento nem disponibilização dos dados necessários à sua reprodução, apenas sua estrutura. Esta rede utiliza 4 neurônios na primeira camada escondida com função de ativação linear, 2 neurônios na segunda camada escondida com função tangencial hiperbólica e um neurônio na camada de saída com função de ativação sigmóide. O segundo ponto de referência é notado com um modelo que utiliza sistema de inferência *fuzzy*. Este trabalho é estruturado sob o máximo-mínimo de Mamdani, com um conjunto de 33 regras e única saída, atingindo uma acurácia de 96,7% (ABU-ELANIEN; SALAMA; IBRAHIM, 2012).

### 5.3 Resultados de Ordenação de Ativos

Realizou-se, na sequência, a ordenação de ativos de alta potência com o algoritmo PSO. Buscou-se uma validação da estrutura de tratamento dos dados realizada na Seção 5.1, onde experimentou-se a estrutura de classificação e, em seguida, ordenação. O fluxo de tratamento dos dados pode ser observado na Figura 27, notando que o foco na ordenação estará nos ativos com condição operacional ruim.




Figura 27: Fluxo de tratamento de dados para ordenação de ativos críticos

Os resultados alcançados na Seção 5.2 se mostraram promissores e consolidaram uma ferramenta de classificação de ativos, tratando nesta seção dos resultados para etapa de priorização com a sua ordenação. Obtém-se, desta forma, com o método proposto nesta seção uma priorização dentro de grupos de ativos pertencentes à mesma classe.

O primeiro experimento busca o conjunto de pesos ótimos para composição do HI com PSO. Neste algoritmo as características de entrada são ponderadas pelos pesos normalizados, alcançando o valor do HI. Com o valor do HI de cada ativo determinado na função de custo realiza-se o processo de ordenação. Após o processo de ordenação verifica-se as posições estimada e fornecida por especialista. A cada acerto alcançado é atribuído peso 1. Ao final é somado todos os valores de acerto e dividido pelo número total de ativos, alcançando o valor de aptidão de cada partícula. Paralelamente é imple-

mentado em um segundo experimento uma estratégia similar, porém privilegiando acertos do posicionamento em 60% dos ativos críticos. Esta estratégia definida VNL é implementada com a alteração da pontuação na função de custo dos erros. Desta forma, partículas com conjunto de pesos que privilegiem acertos no posicionamento de ativos críticos terão maior valor de aptidão.

Os experimentos são repetidos 100 vezes para obtenção de dados estatísticos. Os experimentos são divididos em duas etapas principais, a primeira com a base de dados com ativos de classes mistas, e a segunda com dados exclusivamente classificados como ruins. Os dados são divididos em 70% para otimização e 30% para teste. Na Figura 28(a), apresenta-se a curva de comportamento da acurácia ao longo do processo de otimização dos melhores resultados utilizando PSO e PSO com estratégia VNL, para ativos classificados como mistos. Na Figura 28(b), apresentam-se as mesmas curvas porém sobre o grupo de ativos previamente identificados como ruins. Nota-se melhora em termos de acurácia para o processo de otimização, utilizando informações mistas. Entretanto, no processo de otimização apenas de ativos previamente identificados como ruins não observa-se melhoras em valores absolutos da acurácia, priorizando, entretanto, os acertos de posicionamento em ativos críticos. Verificou-se que, apenas duas posições eram invertidas acertando todas as demais após o processo de composição e ordenação com base no HI estimado. Ressalta-se que com a aplicação de VNL os erros de posicionamento encontravam-se em 40% dos ativos menos críticos.




Figura 28: Melhor resultado para ordenação de transformadores

Comparativamente, verifica-se, que o processo de classificação e posterior ordenação de classes específicas de ativos trazem melhores resultados na ordenação com base nos valores absolutos em acurácia. Nota-se na Figura 29, os valores médios em acurácia com os respectivos desvios após 100 repetições com PSO canônico e com a aplicação da estratégia VNL. Observa-se que o resultado é expressivo, ocorrendo apenas um erro na ordenação entre os ativos 36 e 39 com a inversão de posições com base no valor do HI, utilizando PSO com VNL apenas nos ativos identificados como ruins.




Figura 29: Acurácia utilizando algoritmo PSO canônico e com VNL

Com os resultados alcançados com a estratégia VNL complementou-se a estratégia com a inserção de uma função de aptidão nos valores estimados do HI. Esta experimentação visava estabelecer uma distribuição dos valores do HI de acordo com um padrão, sendo aplicadas empiricamente algumas funções de ativação para identificar, se ocorria melhora nos resultados. O fluxo da aplicação pode ser observado na Figura 30.

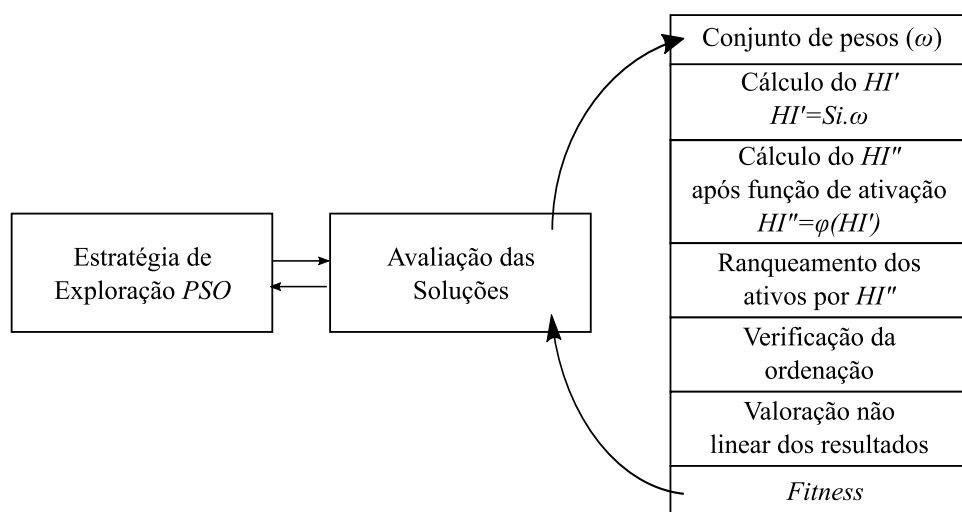


Figura 30: Estratégia para composição do *Health Index* com valoração não linear



Realizaram-se experimentos com funções linear (*Purelin*), sigmóide (*Logsig*) e tangencial hiperbólica (*Tansig*), como apresentadas na Figura 31. Com os resultados expressivos alcançados, nota-se que os melhores valores em acurácia ocorreram com a aplicação das funções de ativação sigmóide e tangencial hiperbólica.




Figura 31: Acurácia alcançada utilizando o algoritmo PSO com função de ativação

Com os valores em acurácia expressivos com a aplicação de funções sigmóide e tangencial hiperbólica realizou-se uma investigação, notando a ocorrência de um erro após a aplicação das funções não lineares. Com a aplicação destas os valores do *Health Index* eram transportados para os limites inferior ou superior das funções. Assim, os valores de HI permaneciam em sua maioria iguais e o algoritmo não conseguia realizar a ordenação. Acredita-se que estes erros tenham sido causados por conta do modelo não ter um *bias*, que aumentaria ou diminuiria a entrada líquida da função de ativação.

Assim, a experimentação de uma rede MLP tornou-se necessária. Experimentos com variações das funções de ativação (FAt) e quantidade de neurônios ( $\#N$ ) são realizados, buscando a maior simplicidade possível. O aumento da complexidade da rede foi realizado de forma progressiva até que fosse alcançado um resultado satisfatório para ordenação com base no HI. O processo contou com a otimização dos pesos da rede MLP com o algoritmo PSO. O limite de posição de cada partícula do algoritmo PSO foi parametrizado em  $-1$  e  $1$ . O limite de velocidade foi parametrizado em  $-0,5$  e  $0,5$ . Na função de custo foi implementada a estrutura de uma rede neural com os pesos otimizados pelo PSO, retornando a acurácia com relação a ordenação do especialista. Os demais parâmetros do algoritmo PSO foram permanecidos como o padrão utilizado nesta dissertação. Os experimentos foram repetidos 100 vezes para cada configuração. Com as execuções foram armazenados os valores percentuais médios para acurácia (Amed), o desvio padrão ( $\sigma$ ) e o melhor resultado (MR). Na Tabela 10, os resultados alcançados podem ser observados,

verificando empiricamente o impacto do aumento do número de neurônios ( $\#N$ ), número de épocas ( $\#E$ ), quantidade de indivíduos ( $\#I$ ) e função de ativação utilizada.

Tabela 10: Parâmetros utilizados e resultados alcançados com rede neural MLP

$\#N$	$\#E$	$\#I$	FAt	Amed (%)	$\sigma$ (%)	MR(%)
1	100	10000	purelin	80,77	7,14	84,62
1	100	10000	tansig	80,94	6,01	84,62
1	100	10000	logsig	80,22	6,55	84,62
3	10	1000000	purelin/purelin	73,00	7,46	84,62
3	100	10000	tansig/purelin	67,08	7,34	84,62
3	100	100000	purelin/purelin	74,77	7,09	84,62
3	100	100000	tansig/purelin	78,85	8,19	100,00
3	100	100000	tansig/tansig	78,21	10,23	100,00
3	100	100000	tansig/logsig	77,62	7,09	100,00
3	10000	1000	tansig/purelin	61,00	7,83	84,62
3	100000	10	tansig/purelin	40,85	8,59	76,92

Com a associação de redes neurais artificiais e PSO, obtiveram-se resultados promissores e adequados à aplicação. Essa associação mostrou ser a melhor estratégia para a ordenação de ativos de alta potência, uma vez aliada à alta acurácia com uma maior simplicidade com a otimização da rede.

A possibilidade de aplicação exclusiva do algoritmo PSO foi verificada, após os resultados com redes neurais MLP. A função de custo do algoritmo PSO foi alterada. Nessa alteração, o valor aptidão de cada partícula é dado por uma composição de erros no primeiro experimento, e ao cálculo do MSE, entre o *Health Index* estimado e dado por especialista no segundo experimento.

A composição de erros do primeiro experimento é descrita pela média ponderada entre o MSE, o erro de posicionamento dos ativos e o MSE máximo. Julgou-se adequada a determinação dos respectivos pesos para ponderação de cada um dos erros supramencionados: 0,17, 0,66 e 0,17. O número máximo de iterações do algoritmo PSO é alterado, especificando 1000 iterações no Caso 3 (C3) e 10000 no Caso 4 (C4). A velocidade máxima de avanço e recuo de cada partícula do PSO é parametrizada em 0,1 e -0,1.

Na Figura 32, pode-se visualizar os valores estimados médios do HI após 100 execuções para os casos C3 E C4. Os valores estimados são comparados ao valor dado pelo especialista. Na Seção A.2 do Apêndice A é possível verificar as características avaliadas dos transformadores identificados na Figura 32. Os resultados mostraram-se não satisfatórios por conta do erro não ter sido suficientemente baixo. Desta forma, os

valores do HI apresentam acentuada distância entre o estimado e fornecido por especialista, mesmo com o aumento do número máximo de iterações.




Figura 32: Aproximação HI com composição de erros, utilizando PSO

No segundo experimento utilizou-se apenas o MSE como métrica de avaliação da aproximação na função de custo do algoritmo PSO. Na Figura 33, pode-se visualizar a aproximação alcançada. Nota-se, uma melhora na reprodutibilidade dos resultados com a redução dos valores de desvio padrão e uma melhora na aproximação. Entretanto, a ocorrência de erros pontuais de elevada distância euclidiana entre os valores do HI estimado e fornecido, desencadeiam erros na ordenação com base no valor do HI. Desta forma, conclui-se que a aplicação exclusiva do algoritmo PSO não se mostrou plenamente eficiente. Ressalta-se que melhores resultados para a ordenação foram alcançados por meio da combinação de redes neurais MLP com PSO.




Figura 33: Aproximação do HI com MSE, utilizando PSO

## 5.4 Considerações Finais

Neste capítulo, foram apresentados os resultados experimentais para o método proposto nesta dissertação, destacando-se as aplicações com sistemas híbridos utilizando inteligência de enxame. No próximo capítulo, serão apresentadas as principais conclusões alcançadas com a consecução desta dissertação, bem como as propostas para trabalhos futuros.

## Capítulo 6

# CONCLUSÕES E TRABALHOS FUTUROS

**N**ESTE capítulo, são apresentados as principais conclusões a cerca das metodologias utilizadas nesta dissertação. Os resultados mais relevantes para priorização de ativos de alta potência com *Health Index* são discutidos. Adicionalmente, são apresentados possíveis pontos de melhoria e propostas para novas experimentações nos trabalhos futuros.

### 6.1 Conclusões

Esta dissertação abordou o problema de priorização de ativos de alta potência, estudando a aplicação de técnicas de inteligência computacional para a composição do *Health Index*. A aplicação de técnicas baseadas em inteligência coletiva explorou um novo viés. Esta exploração trouxe um novo horizonte, uma vez que não se dispunha de informações quanto à aplicação de técnicas como PSO e EHO para priorização de ativos na literatura.

Com a utilização de técnicas de otimização na composição do *Health Index*, buscou-se alcançar uma solução com maior simplicidade. O usuário trabalha apenas com um conjunto de pesos de simples manipulação, extraídos com base na condição operacional do ativo. Deste modo, a determinação dos pesos do HI depende menos do fator humano, não necessitando majoritariamente de conhecimentos profundos sobre todos os tipos de ensaios. Com o método proposto, é possível captar o conhecimento tácito dos responsáveis técnicos por uma subestação, com base nos dados de referência fornecidos para realizar o processo de otimização do HI.

A base de dados utilizada nesta dissertação passou por uma processo de normalização, análise e filtragem dos dados. A priorização de ativos por níveis de criticidade introduz a verificação por possíveis transformadores com condição operacional ruim. Esta

análise visa identificar o(s) ativo(s) que podem fornecer maior risco para a equipe de operação da subestação, aos equipamentos instalados e aos clientes. A identificação dos ativos com condição operacional ruim guia uma análise mais detalhada. O foco desta análise é a identificação de ativos em condição operacional crítica, por conta dos recursos investidos serem escassos. Os ativos com condição operacional mediana e boa também são identificados, podendo guiar manutenções preventivas, quando os recursos não se apresentam limitados.

Nestes experimentos, as técnicas baseadas em inteligência coletiva, como PSO e EHO, destacaram-se, sendo empregadas tanto em sua versão canônica, como combinadas com redes neurais de Kohonen. Os resultados foram comparados com outras técnicas como redes neurais MLP, sistemas baseados em lógica nebulosa e algoritmo genético. A partir da experimentação verificou-se que técnicas baseadas em inteligência coletiva apresentavam alta acurácia e tempo de convergência baixo. A aplicação com EHO mostrou-se a solução mais eficiente para priorização por níveis de criticidade. Este modelo destacou-se por otimizar um modelo aberto, de simples manipulação e por ser possível a expansão dos padrões de entrada sem necessitar de grandes alterações.

Com a identificação dos ativos críticos um processo de refino ocorre com a ordenação. Na etapa de ordenação, a técnica de inteligência coletiva PSO foi aplicada à composição do HI para os ativos críticos. Com os valores de HI, uma ordenação é estabelecida. Com a ordenação, são identificados os ativos que necessitam de prioridade no processo de intervenção. Diferentes metodologias para composição do HI com PSO foram utilizadas, apresentando melhor resultado a estratégia VNL. Esta estratégia obteve 84,62% em acurácia para priorização nos melhores resultados. O ponto chave desta estratégia ocorre com o deslocamento dos erros de ordenação para regiões menos críticas. Assim, 60% dos piores ativos obtinham ordenação fiel à relação fornecida por especialistas.

Com o objetivo de alcançar uma ordenação fiel ao especialista, aumentou-se a complexidade do modelo com a aplicação de redes neurais MLP associada ao algoritmo PSO. O objetivo foi alcançado com uma rede utilizando apenas 3 neurônios, com função tangencial hiperbólica na primeira camada e linear na segunda. Por fim, a fim de verificar a aplicação exclusiva do algoritmo PSO sobre um novo viés, realizou-se a aproximação de valores do HI fornecidos pelo especialista. Entretanto, os resultados mostraram-se insatisfatórios, não alcançando correlação total com a ordenação do especialista.

A melhor solução para ordenação de ativos manteve-se a partir de um sistema híbrido. Observa-se que os resultados com sistema híbrido obtiveram melhoria, por conta da sua maior complexidade e capacidade de extração de informações. Entretanto, em problemas que admitam uma menor precisão pode-se aplicar a solução proposta com PSO para ordenação, por conta de sua maior simplicidade. Evidencia-se que um ponto de impacto dos resultados está na quantidade de amostras e quantidade de ensaios, contidos na base de dados. Com a base de dados mais extensa e com mais característica, novas relações entre os dados podem surgir, favorecendo aplicações com inteligência coletiva.

Contudo, pode-se aplicar os dois métodos propostos para ordenação de ativos. Em uma primeira etapa pode-se aplicar a solução com inteligência coletiva, que é um método aberto apenas com a manipulação dos pesos ótimos. Por fim, pode-se realizar um refino nos resultados com a aplicação do método baseado em sistemas híbridos, confrontando os resultados.

## 6.2 Trabalhos Futuros

Nesta seção, sugerem-se algumas formas de continuar o estudo do tema abordado. Com o intuito de aumentar a robustez do trabalho, sugere-se, como fator essencial, o aumento da base de dados. O aumento no número de amostras pode trazer significativa melhoria, visto que as técnicas de inteligência computacional são sensíveis à quantidade e qualidade das informações.

Outro ponto que pode ser explorado é a aplicação de um número maior de técnicas utilizando inteligência coletiva, as quais não foram implementadas pela restrição de tempo. Sugere-se a implementação de algoritmos baseados em inteligência coletiva, como: ACO (*Ant Colony Optimization*), FA (*Firefly Algorithm*), BCO (*Bee Colony Optimization*), BFO (*Bacterial Foraging Optimization*), entre outros. Estes algoritmos talvez possam se adaptar melhor ao problema e obter melhores resultados.

O trabalho ainda pode evoluir no sentido de se desenvolver um sistema adaptativo. Nesta abordagem, pode-se dispor de um ambiente com uma diversidade de índices, que sejam aplicados de acordo com as características fornecidas pelo usuário. Com este sistema, seria possível atender subestações que possuíssem vasto e diverso histórico de ensaios para cada ativo e, em contrapartida, atender subestações que possuíssem apenas informações de ensaios periódicos.

# REFERÊNCIAS

- ABU-ELANIEN, A. E.; SALAMA, M. Asset management techniques for transformers. *Electric power systems research*, Elsevier, v. 80, n. 4, p. 456–464, 2010.
- ABU-ELANIEN, A. E.; SALAMA, M.; IBRAHIM, M. Determination of transformer health condition using artificial neural networks. In: IEEE. *Innovations in Intelligent Systems and Applications (INISTA), 2011 International Symposium on*. Istanbul, Turkey, 2011. p. 1–5.
- ABU-ELANIEN, A. E.; SALAMA, M.; IBRAHIM, M. Calculation of a health index for oil-immersed transformers rated under 69 kv using fuzzy logic. *IEEE Transactions on Power Delivery*, IEEE, v. 27, n. 4, p. 2029–2036, 2012.
- AHMED, M. et al. Transformer health index estimation using orthogonal wavelet network. In: IEEE. *Electrical Power and Energy Conference (EPEC), 2015 IEEE*. London, ON, Canada, 2015. p. 120–124.
- ANTOSZ, S. et al. Ieee standard test code for liquid-immersed distribution, power, and regulating transformers corrigendum 1:editorial and technical corrections. *IEEE Std C57.12.90-2015/Cor 1-2017 (Corrigendum to IEEE Std C57.12.90-2015)*, p. 1–13, 2017.
- ASHKEZARI, A. D. et al. Application of fuzzy support vector machine for determining the health index of the insulation system of in-service power transformers. *IEEE Transactions on Dielectrics and Electrical Insulation*, IEEE, v. 20, n. 3, p. 965–973, 2013.
- BAKAR, N. A.; ABU-SIADA, A. Fuzzy logic approach for transformer remnant life prediction and asset management decision. *IEEE Transactions on Dielectrics and Electrical Insulation*, IEEE, v. 23, n. 5, p. 3199–3208, 2016.

- BOLHUIS, J. P. V. et al. Interpretation of recovery voltage measurements on power transformers. In: *1999 Eleventh International Symposium on High Voltage Engineering*. London, UK: IET, 1999. v. 1, p. 90–93 vol.1.
- BOLHUIS, J. V.; GULSKI, E.; SMIT, J. Monitoring and diagnostic of transformer solid insulation. *IEEE Transactions on Power Delivery*, IEEE, v. 17, n. 2, p. 528–536, 2002.
- CERÓN, A. F. et al. Índice de salud para transformadores de potencia inmersos en aceite mineral con voltajes entre 69kv y 230kv usando lógica difusa. *Información tecnológica*, SciELO Chile, v. 26, n. 2, p. 107–116, 2015.
- COELLO, C. A. C. *An Empirical Study of Evolutionary Techniques for Multiobjective Optimization in Engineering Design*. Tese (Doutorado), New Orleans, LA, USA, 1996.
- DICK, E.; ERVEN, C. Transformer diagnostic testing by frequency response analysis. *IEEE Transactions on Power Apparatus and Systems*, IEEE, n. 6, p. 2144–2153, 1978.
- ERDMAN, H. G. *Electrical insulating oils*. Philadelphia, PA, USA: ASTM International, 1988.
- FENWICK, S. et al. *Standard Test Method for Acid and Base Number by Color indicator Titration*. West Conshohocken, PA: ASTM International, 2012.
- FERNÁNDEZ, F. O. et al. Transformer health indices calculation considering hot-spot temperature and load index. *IEEE Electrical Insulation Magazine*, IEEE, v. 33, n. 2, p. 35–43, 2017.
- GRIMALDI, E. A. et al. Pso as an effective learning algorithm for neural network applications. In: *Proceedings. ICCEA 2004. 2004 3rd International Conference on Computational Electromagnetics and Its Applications, 2004*. Beijing, China: [s.n.], 2004.
- HAYKIN, S. *Neural networks: a comprehensive foundation*. Hamilton, Canada: Prentice Hall, 1994.
- HIRST, J. et al. Mineral insulating oils in electrical equipment—supervision and maintenance guidance. BSI, Geneva, Switzerland, v. 60422, 2013.



- HOLLAND, J. *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. London, England: MIT Press, 1975.
- IBRAHIM, K. et al. Selection criteria for oil transformer measurements to calculate the health index. *IEEE Transactions on Dielectrics and Electrical Insulation*, IEEE, v. 23, n. 6, p. 3397–3404, 2016.
- JACOB, N. D. et al. Classification of degradation in oil-impregnated cellulose insulation using texture analysis of optical microscopy images. *Electric Power Systems Research*, Elsevier, v. 133, p. 104–112, 2016.
- JAHROMI, A. et al. An approach to power transformer asset management using health index. *IEEE Electrical Insulation Magazine*, IEEE, v. 25, n. 2, p. 20–34, 2009.
- JÜRGENSEN, J. H.; NORDSTRÖM, L.; HILBER, P. Individual failure rates for transformers within a population based on diagnostic measures. *Electric power systems research*, Elsevier, v. 141, p. 354–362, 2016.
- KACHLER, A. J.; HOHLEIN, I. Aging of cellulose at transformer service temperatures. part 1: Influence of type of oil and air on the degree of polymerization of pressboard, dissolved gases, and furanic compounds in oil. *IEEE Electrical Insulation Magazine*, IEEE, v. 21, n. 2, p. 15–21, 2005.
- KÜCHLER, A.; BEDEL, T. Research note: Dielectric diagnosis of water content in transformer insulation systems. *European Transactions on Electrical Power*, Wiley Subscription Services, Inc., A Wiley Company, v. 11, n. 1, p. 65–68, 2001.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: *Neural Networks, 1995. Proceedings., IEEE International Conference on*. Perth, WA, Australia: IEEE, 1995. v. 4, p. 1942–1948 vol.4.
- KOHONEN, T. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, v. 43, n. 1, p. 59–69, 1982.
- LEI, T. et al. On-line fault detection technique for voltage transformers. *Measurement*, Elsevier, 2017.

- LEMKE, E. et al. Guide for electrical partial discharge measurements in compliance to iec 60270. *Electra*, v. 241, p. 60–68, 2008.
- LEWAND, L. Understanding water in transformer systems. *Neta World*, p. 1–4, 2002.
- LIM, J.; CHOI, J.; LEE, K. Y. Expert criteria based power system health index model and visualization considering differential value. *IFAC-PapersOnLine*, Elsevier, v. 48, n. 30, p. 239–244, 2015.
- LUKASIEWICZ, J. On the history of the logic of propositions. *Polish logic*, v. 1939, n. 1967, 1920.
- MARTINS, H. J. A. et al. Índice de avaliação da condição de transformadores de potência (health index) - estado da arte e aplicações. In: CIGRÉ-BRASIL. *International Workshop on Power Transformers, Equipment, Substations and Materials*. Recife, Brazil, 2016.
- MARTINS, H. Jailson de A. et al. *Relatório Técnico DIE nº 28676/2004*. Rio de Janeiro, Brazil, 2004.
- MAULIK, U.; BANDYOPADHYAY, S. Genetic algorithm-based clustering technique. *Pattern Recognition*, v. 33, n. 9, p. 1455 – 1465, 2000.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943.
- MERWE, D. W. van der; ENGELBRECHT, A. P. Data clustering using particle swarm optimization. In: *Evolutionary Computation, 2003. CEC '03. The 2003 Congress on*. Canberra, Australia: IEEE, 2003. v. 1, p. 215–220 Vol.1.
- MOORE, J.; CHAPMAN, R. Application of particle swarm to multiobjective. *Department of Computer Science and Software Engineering*, Auburn University, 1999.
- ONS. *Indicadores de Desempenho do SIN*. 2017. [Http://ons.org.br/](http://ons.org.br/). Acessado em 28-11-2017.
- ORTIZ, F. et al. Health indexes for power transformers: a case study. *IEEE Electrical Insulation Magazine*, IEEE, v. 32, n. 5, p. 7–17, 2016.

- PATERLINI, S.; KRINK, T. Differential evolution and particle swarm optimisation in partitional clustering. *Computational Statistics and Data Analysis*, v. 50, n. 5, p. 1220 – 1247, 2006.
- PRADHAN, M.; RAMU, T. Criteria for estimation of end of life of power and station transformers in service. In: IEEE. *Electrical Insulation and Dielectric Phenomena, 2004. CEIDP'04. 2004 Annual Report Conference on*. Boulder, CO, USA: IEEE, 2004. p. 220–223.
- QIU, J. et al. Nonparametric regression-based failure rate model for electric power equipment using lifecycle data. *IEEE Transactions on Smart Grid*, IEEE, v. 6, n. 2, p. 955–964, 2015.
- RIGATOS, G.; SIANO, P. Power transformers' condition monitoring using neural modeling and the local statistical approach to fault diagnosis. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 80, p. 150–159, 2016.
- RONCERO-CLEMENTE, C.; ROANES-LOZANO, E. A multi-criteria computer package for power transformer fault detection and diagnosis. *Applied Mathematics and Computation*, Elsevier, 2017.
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, p. 65–386, 1958.
- ROSS, T. J. et al. *Fuzzy logic with engineering applications*. New Mexico, USA: Wiley Online Library, 2004.
- SAHA, T. K.; PURKAIT, P. Investigation of polarization and depolarization current measurements for the assessment of oil-paper insulation of aged transformers. *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 11, n. 1, p. 144–154, 2004.
- SANTOS, R. et al. Health index para transformadores de potência usando inteligência de enxame. *XXII Congresso Brasileiro de Automática*, Anais do CBA 2018, João Pessoa, Brasil, 2018.
- SANTOS, R. et al. Transformer's health index using computational intelligence. *7th International Conference on Metaheuristics and Nature Inspired Computing*, Proceeding of META 2018, Marrakech, Morocco, v. 1, p. 165–174, 2018.

- SUN, L. et al. Research on multi-attribute decision-making in condition evaluation for power transformer using fuzzy ahp and modified weighted averaging combination. *IET Generation, Transmission & Distribution*, IET, v. 10, n. 15, p. 3855–3864, 2016.
- TANAKA, H. et al. Multiple criteria assessment of substation conditions by pair-wise comparison of analytic hierarchy process. *IEEE Transactions on power delivery*, IEEE, v. 25, n. 4, p. 3017–3023, 2010.
- TRAIN, D. et al. Ieee guide for diagnostic field testing of electric power apparatus - part 1: Oil filled power transformers, regulators, and reactors. *IEEE Std 62-1995*, p. 1–68, 1995.
- TRAPPEY, A. J. et al. Intelligent engineering asset management system for power transformer maintenance decision supports under various operating conditions. *Computers & Industrial Engineering*, Elsevier, v. 84, p. 3–11, 2015.
- VAESSEN, P.; HANIQUE, E. A new frequency response analysis method for power transformers. *IEEE Transactions on Power Delivery*, IEEE, v. 7, n. 1, p. 384–391, 1992.
- VELASQUEZ-CONTRERAS, J. L.; SANZ-BOBI, M. A.; ARELLANO, S. G. General asset management model in the context of an electric utility: application to power transformers. *Electric Power Systems Research*, Elsevier, v. 81, n. 11, p. 2015–2037, 2011.
- WAHAB, M. A. et al. Novel modeling for the prediction of aged transformer oil characteristics. *Electric Power Systems Research*, Elsevier, v. 51, n. 1, p. 61–70, 1999.
- WANG, G. G.; DEB, S.; COELHO, L. d. S. Elephant herding optimization. In: *2015 3rd International Symposium on Computational and Business Intelligence (ISCBI)*. Bali, Indonesia: IEEE, 2015. p. 1–5.
- WANG, M.; VANDERMAAR, A.; SRIVASTAVA, K. D. Review of condition assessment of power transformers in service. *IEEE Electrical Insulation Magazine*, IEEE, v. 18, n. 6, p. 12–25, 2002.
- ZADEH, L. Fuzzy sets. *Information and Control*, v. 8, n. 3, p. 338 – 353, 1965.
- ZEINODDINI-MEYMAND, H.; VAHIDI, B. Health index calculation for power transformers using technical and economical parameters. *IET Science, Measurement & Technology*, IET, v. 10, n. 7, p. 823–830, 2016.

---

ZHANG, X.; GOCKENBACH, E. Asset-management of transformers based on condition monitoring and standard diagnosis. *IEEE Electrical Insulation Magazine*, v. 24, n. 4, p. 26–40, 2008.

# APÊNDICE A - BASE DE DADOS

Este apêndice apresenta os dados utilizados nesta dissertação. Os dados foram sintetizados com base em trabalhos envolvendo priorização de ativos de alta potência. As informações utilizadas estão disponíveis em artigos, advindos de periódicos e conferências.

## A.1 Conjunto Preliminar

Nº de série	Idade (anos)	Potência (MVA)	Cromatografia (%)	2-FAL (ppm)
SPT4903	35	63	78,78	0,280
SPT1843	35	75	75,00	0,070
575800	7	75	71,58	0,001
47829	31	50	65,73	0,035
39695	35	250	64,72	0,044
24195	35	250	63,89	0,068
SPT4907	35	63	61,15	0,930
SPT4909	35	63	61,15	0,034
32114	13	300	57,55	0,008
20653	11	50	57,19	0,001
12015	35	100	53,96	0,028
12014	25	100	53,96	0,046
12016	25	100	53,96	0,029
24196	35	250	50,00	0,123
37793	35	250	50,00	0,056
47827	31	50	50,00	0,049
24194	35	250	50,00	0,083
100356/5	14	100	50,00	0,023
100365/6	14	100	50,00	0,117
100365/4	14	100	50,00	0,023
SPT4908	35	65	47,87	0,166
111097/U	7	75	45,37	0,013
20654	11	50	45,41	0,001
SPT4912	35	63	45,37	2,347
SPT4910	35	65	40,40	0,629
32112	13	300	35,35	0,010
24193	35	250	27,78	0,031
12013	14	100	27,80	0,001
20652	11	50	27,78	0,001
32115	13	300	27,78	0,019
SPT4906	35	65	27,78	0,658

## A.2 Conjunto Consolidado

#Ativo	Concentração umidade (ppm)	Acidez (mg-KOH/g)	Tensão de ruptura (kV)	Fator de dissipação (%)	AGD (ppm)	2-FAL (ppm)	Estado	Especialista
1	11,1	0,032	67,2	0,089	119,0	0,040	Muito bom	0,072
2	10,0	0,010	75,0	0,111	126,0	0,060	Muito bom	0,102
3	11,9	0,009	57,6	0,025	157,0	0,165	Muito bom	0,140
4	7,50	0,160	70,1	0,448	10,00	0,060	Bom	0,225
5	17,0	0,035	62,7	0,113	9,000	0,210	Muito bom	0,226
6	8,10	0,010	66,9	0,042	71,00	0,050	Muito bom	0,241
7	13,0	0,091	51,6	0,369	8,000	0,320	Bom	0,241
8	15,5	0,075	71,0	0,143	38,00	0,530	Bom	0,274
9	14,5	0,033	58,0	0,140	78,00	0,260	Bom	0,290
10	15,0	0,092	67,8	0,211	28,00	0,690	Bom	0,290
11	23,6	0,070	39,2	0,203	22,00	0,500	Bom	0,291
12	16,8	0,167	70,1	0,255	149,0	0,780	Bom	0,316
13	30,0	0,088	37,6	0,353	197,0	0,310	Bom	0,316
14	26,9	0,098	40,5	0,894	254,0	0,650	Bom	0,334
15	18,4	0,063	64,5	0,243	69,00	0,150	Bom	0,347
16	23,5	0,106	45,8	0,207	30,00	0,240	Bom	0,354
17	6,00	0,010	67,6	0,126	427,0	0,080	Bom	0,368
18	21,5	0,147	60,8	0,938	168,0	0,920	Médio	0,371
19	21,7	0,024	32,5	0,075	483,0	0,860	Bom	0,377
20	6,00	0,035	58,0	0,006	12,00	0,813	Bom	0,395
21	21,1	0,019	28,4	0,025	144,0	0,020	Muito bom	0,414
22	24,8	0,012	29,9	0,068	504,0	1,680	Médio	0,450
23	18,4	0,152	37,2	0,299	81,00	1,140	Médio	0,450
24	35,7	0,229	41,4	0,639	24,00	1,070	Médio	0,450
25	6,70	0,005	57,5	0,000	674,0	1,499	Médio	0,525
26	8,60	0,019	46,3	0,000	233,0	2,502	Médio	0,539
27	14,1	0,020	44,5	0,000	788,0	2,446	Médio	0,549
28	19,8	0,110	29,0	0,870	287,0	2,466	Médio	0,563
29	26,8	0,074	10,7	0,369	54859	0,802	Médio	0,620
30	3,90	0,129	15,9	0,555	975,0	1,714	Médio	0,637
31	13,4	0,009	56,2	0,014	1094	1,185	Médio	0,650
32	24,9	0,131	40,1	0,351	1067	2,020	Médio	0,663
33	15,5	0,062	34,3	0,026	1161	1,113	Médio	0,665
34	21,2	0,226	48,7	0,424	215,0	5,530	Ruim	0,700
35	8,60	0,019	46,3	0,000	711,0	2,989	Ruim	0,702
36	27,6	0,089	30,4	0,128	336,0	5,120	Ruim	0,732
37	6,70	0,038	49,4	0,010	871,0	3,051	Ruim	0,758
38	4,90	0,083	11,1	0,426	40426	1,276	Ruim	0,769
39	11,0	0,024	57,0	0,000	792,0	3,304	Ruim	0,789
40	10,8	0,020	41,5	0,000	819,0	3,351	Ruim	0,794
41	10,0	0,020	59,0	0,000	830,0	4,571	Ruim	0,796
42	11,5	0,058	56,7	0,101	1113	3,995	Muito ruim	0,876
43	15,0	0,210	57,2	0,220	53,00	6,690	Ruim	0,916
44	15,0	0,155	37,5	0,182	53,00	7,290	Muito ruim	0,931
45	19,6	0,216	41,1	0,264	48,00	7,540	Muito ruim	0,953
46	16,2	0,181	25,5	0,201	35,00	8,760	Muito ruim	1,000
47	16,8	0,115	25,6	0,174	78,00	9,600	Muito ruim	1,000
48	30,5	0,073	28,7	67,00	30,00	15,70	Muito ruim	1,000